



UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO

PROGRAMA DE MAESTRIA Y DOCTORADO EN
INGENIERIA

FACULTAD DE INGENIERIA

**COMPUTO APROXIMADO EN LA
SOLUCION DE PROBLEMAS GEOSISMICOS**

T E S I S

QUE PARA OPTAR POR EL GRADO DE:

DOCTOR EN INGENIERIA

INGENIERIA CIVIL – ANALISIS Y DISEÑO DE CIMENTACIONES

P R E S E N T A :

SILVIA RAQUEL GARCIA BENITEZ

TUTOR:
DR. MIGUEL PEDRO ROMO ORGANISTA

2009



JURADO ASIGNADO

Presidente: Dr. Daniel Reséndiz Núñez
Secretario: Dr. Luis Esteva Maraboto
1^{er} Vocal: Dr. Miguel Pedro Romo Organista
2^{do} Vocal: Dr. Roberto Meli Piralla
3^{er} Vocal: Dr. Francisco Sánchez Sesma
1^{er} Suplente: Dr. Efraín Ovando Shelley
2^{do} Suplente: Dr. Jesús Figueroa Nazuno

Lugar o lugares donde se realizó la tesis:

MEXICO, D.F.

TUTOR DE TESIS:

DR. MIGUEL PEDRO ROMO ORGANISTA

FIRMA

Agradecimientos

Al Dr. Miguel P. Romo por la profunda, extensa y crítica revisión de este documento. Sobre otras experiencias, gracias por enseñarme a buscar, entender y confiar.



UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO

PROGRAMA DE MAESTRIA Y DOCTORADO EN
INGENIERIA

FACULTAD DE INGENIERIA

**COMPUTO APROXIMADO EN LA
SOLUCION DE PROBLEMAS GEOSISMICOS**

T E S I S

QUE PARA OPTAR POR EL GRADO DE:

DOCTOR EN INGENIERIA

INGENIERIA CIVIL—ANALISIS Y DISEÑO DE CIMENTACIONES

P R E S E N T A :

SILVIA RAQUEL GARCIA BENITEZ

TUTOR:

DR. MIGUEL PEDRO ROMO ORGANISTA

2009



JURADO ASIGNADO

Presidente: Dr. Daniel Reséndiz Núñez
Secretario: Dr. Luis Esteva Maraboto
1^{er} Vocal: Dr. Miguel Pedro Romo Organista
2^{do} Vocal: Dr. Roberto Meli Piralla
3^{er} Vocal: Dr. Francisco Sánchez Sesma
1^{er} Suplente: Dr. Efraín Ovando Shelley
2^{do} Suplente: Dr. Jesús Figueroa Nazuno

Lugar o lugares donde se realizó la tesis:

MEXICO, D.F.

TUTOR DE TESIS:

DR. MIGUEL PEDRO ROMO ORGANISTA

FIRMA

Agradecimientos

Al Dr. Miguel P. Romo por la profunda, extensa y crítica revisión de este documento. Sobre otras experiencias, gracias por enseñarme a buscar, entender y confiar.

Índice

	Página		Página
1. Introducción	1	5. Modelos aproximados: aplicaciones geosísmicas	62
2. Problemática Geosísmica	3	5.1 Estimación de la velocidad de ondas de corte V_s a partir de la resistencia a la penetración del cono q_c	62
2.1 Variabilidad e Incertidumbre	3	Estimación de propiedades dinámicas (G, λ)	116
2.2 Propiedades Dinámicas de los Suelos	4	5.2 Estimación de movimientos de terreno en la Ciudad de México	136
2.3 Respuesta de Sitio	8	6. Conclusiones	284
3. Cómputo Aproximado	11	7. Apéndices	291
3.1 Redes Neuronales	15	7.1 Apéndice 2.1.A	291
3.2 Lógica Difusa	29	7.2 Apéndice 3.1.A	293
4. Técnicas de Análisis de Series de Tiempo	45	7.3 Apéndice 3.1.B	300
4.1 Mapas de Recurrencia	49	7.4 Apéndice 4.1.A	306
4.2 Eigenfaces	55	8. Referencias	308

máximas capacidades siendo cada día más evidente el desequilibrio entre la complejidad de los comportamientos observados y las técnicas usadas para modelarlos. En la búsqueda de nuevas hipótesis, códigos y metodologías de estudio, deben tomarse en cuenta aspectos centrales en este tipo de sistemas: i) la presencia de una amplia gama de comportamientos, en su mayoría no lineales, ii) la imposibilidad para medir algunas variables de estado o peor aún, el desconocimiento de las *verdaderas* variables de estado y iii) la condición simultánea de abundancia y escasez de datos: megabytes de información registrada sobre un parámetro y la dificultad para medir otros igualmente importantes en la representación de los hechos.

Por lo general, si el sistema bajo estudio es lineal, los datos producto de la observación de los comportamientos pueden ser caracterizados usando estadística (media, desviación estándar, etc.), ajustando curvas a ellos (aproximación de funciones) y generando gráficas para visualizar su comportamiento. La experiencia en el modelado de fenómenos geosísmicos ha demostrado que estas operaciones de procesamiento resultan poco eficaces cuando lo que se necesita es *aprender* (abstraer y comprender) y no sólo *imitar*. La integración a la ingeniería geosísmica de herramientas de procesamiento numérico y lógico, dominio del cómputo aproximado CA - Redes Neuronales RNs y Lógica Difusa LD-, figura como una alternativa *natural* para el análisis de fenómenos relacionados con los suelos y los sismos.

Sabiendo que las RNs permiten el estudio y manejo de sistemas cuya definición es parcial, difíciles de modelar, con espacios de solución a gran escala y en donde la información relevante disponible se representa por medio de datos entrada→salida y que la LD, por su parte, es el marco teórico formal para aproximaciones graduadas de lo difuso y desarrollos que modelan la deducción natural humana; en este trabajo de investigación se describe y respalda el uso de estas técnicas para desarrollar algoritmos, verificar teorías y establecer modelos geosísmicos eficientes.

A través de los resultados y conclusiones de: a) la evaluación de las velocidades de ondas de corte a partir de los resultados de una prueba de penetración de cono y b) el análisis de la respuesta sísmica del Valle de México, se demuestra la conveniencia de utilizar RNs y sistemas de LD en la construcción de modelos *aproximados* (opuestos a los *precisos* obtenidos con métodos numéricos clásicos). Como subproducto de esta disertación se presenta una alternativa en el análisis de bases de datos masivas (series de tiempo o vectores unidimensionales) que parte de conceptos básicos de la Teoría del Caos -Mapas de Recurrencia, MR- y de técnicas de reconocimiento de imágenes -Eigenfaces, EF-. Esta original herramienta (MR-EF) facilita y optimiza la construcción y el desempeño de estructuras de CA, llamadas también estructuras conexionistas.

La intención de esta tesis doctoral es el desarrollo y la disseminación de tecnologías complementarias para su establecimiento, a través de guías prácticas, como piezas estándar en procesos y procedimientos en el ámbito de la ingeniería geosísmica sin que esto signifique reemplazar los análisis convencionales ni el juicio ingenieril.

1. Introducción

En la incorporación de la dimensión ambiental a la planificación y desarrollo de comunidades, la condicionante sísmica es un importante factor de riesgo cuando se procuran asentamientos humanos menos vulnerables. Es imposible evitar su ocurrencia, pero las consecuencias económicas, sociales y ambientales de las grandes sacudidas pueden disminuir a través de los avances en la ciencia apoyada en la práctica de la ingeniería.

El principal objetivo de la Ingeniería Geosísmica es mitigar el riesgo sísmico desde el punto de vista geotécnico. Esta rama de la ingeniería ha evolucionado desde la dinámica de suelos hacia los modelos que permiten anticipar el comportamiento del suelo o de la roca a través del juicio de expertos y de las aproximaciones teórico-empíricas.

Para el análisis de sistemas geotécnicos complejos (naturales y construidos por el hombre) se cuenta con herramientas analíticas que permiten establecer relaciones causa→efecto con fines de estimación y predicción. Sin embargo, muchos de estos procedimientos están cerca de alcanzar sus

El proceso empírico de creación de modelos

De acuerdo con el proceso empírico de creación de modelos una condición necesaria para que M sea un buen modelo del proceso P , para un conjunto preestablecido de secuencias de entrada S , es que:

$$M(u) \cong P(u), \forall u \in S \quad 1.1$$

$M(u)$ y $P(u)$ representan las respuestas del modelo y del proceso ante una determinada secuencia de entrada, u . Esta condición se compone de varios elementos que la hacen altamente flexible: i) la interpretación del símbolo \cong , ii) el conjunto de entradas S y iii) la clase de modelos C , entre la que se busca el mejor de ellos (M).

Es fundamental, en primer lugar, aclarar el significado que se adopta del símbolo \cong . ¿Qué quiere decir que un modelo *aproxima* correctamente la salida de un sistema? Esta pregunta nos lleva a cuantificar, de alguna manera, la diferencia entre las respuestas del modelo y las del proceso, es decir, a medir el *error*. Existen diversos criterios para establecer estas diferencias y cada uno de ellos puede tener justificación en un ámbito científico particular. Las medidas usuales en ingeniería son la suma cuadrática y la suma absoluta de errores. Resulta particularmente interesante, aunque es un aspecto no tratado en esta tesis, que ahora es obligación del científico relacionar esta capacidad aproximativa con la complejidad computacional (número de parámetros y costo tiempo-recursos-máquina de las operaciones), la competencia en transmisión de conocimiento, y la eficiencia interpretativa de los modelos para calificar el desempeño de sus proyectos.

En este trabajo se presentarán los modelos que fueron marcados como exitosos y no se aborda el proceso de competencia que condujo a ellos. Es suficiente tener en cuenta que en ambos incisos de análisis el error se mide con dos tipos de criterios, en resultados experimentales se utilizan las medidas estándar para determinar la distancia entre lo que se calcula y lo que se plantea como *cierto*; esto permite acotar y penalizar el error máximo de una aproximación y, por otro lado, se comparan modelos con similares niveles de error y se jerarquizan de acuerdo con su i) complejidad, ii) operabilidad (aplicables, prácticos) y iii) vinculación con los conocimientos naturales.

La aplicación del criterio de error puede, en general, realizarse *a priori* sobre cualquier patrón o entrada al modelo, pero resulta más comprometido seleccionar el conjunto de zonas de trabajo o señales de entrada S para los que el modelo M (desconocido) será válido en su operación normal. Los sistemas no lineales (como los estudiados en este trabajo) se comportan de modo cualitativamente diferente según el régimen de operación en que se encuentren. No existe una forma sistemática de saber cuántos de estos regímenes de operación hay y, sobre todo, cómo llegar a ellos (qué entradas llevarán el proceso a tales estados).

Debido a esta ambigüedad, aquí se utiliza el conjunto de señales de entrada formado por todas las secuencias originales (refiriéndose a los datos

medidos, obtenidos o calculados directamente de algún ensayo geotécnico o sísmico) y se consideran como los patrones que llevan al sistema a gran parte de sus estados alcanzables. Para minimizar esta incertidumbre sobre lo que se presenta como ejemplos de estados, se divide el conjunto total en tres subconjuntos: señales de entrenamiento o identificación, de prueba y de validación (modo directo), respectivamente, de forma que la evaluación de las capacidades de los modelos se realizarán únicamente con las señales de validación, entradas no utilizadas en el proceso de creación del modelo y consideradas más oportunas.

Finalmente, la clase de modelos C en que se basa este trabajo se refiere al cómputo aproximado y algunas otras herramientas avanzadas de análisis de señales. La caracterización y justificación del uso de estas teorías y metodologías se ofrece en los capítulos donde se presentan los resultados de cada inciso de análisis.

Organización del escrito

Esta tesis está ordenada en unidades de información. Para el lector familiarizado con la geotecnia y la sismología se ofrecen los módulos de **Cómputo Aproximado** y de **Técnicas de Análisis de Series de Tiempo** como una breve introducción a las herramientas de modelado, mientras que los expertos en cómputo y matemáticas avanzadas pueden recurrir a la sección **Problemática Geosísmica** para conocer los aspectos medulares de los fenómenos estudiados.

El núcleo del documento es el capítulo de **Resultados** el cual pretende i) dar una visión particular de las metodologías computacionales y ii) establecer la filosofía, el criterio de aplicación y la certidumbre en los modelos.

Prefacio

Esta tesis intenta ser una amplia introducción al cómputo aproximado para los ingenieros involucrados en la solución de problemas geotécnicos y sísmicos. Se pretende resaltar especialmente los principios que dirigen el modelado con redes neuronales, lógica difusa y teoría del caos y establecer las condiciones en que pueden aplicarse para estudiar fenómenos relacionados con los suelos. Se relega a un segundo término el panorama histórico y el tratamiento matemático formal de cada técnica.

Una de las características de este trabajo es el énfasis en las aplicaciones. Cada solución es desarrollada sistemáticamente comenzando con el planteamiento de la física del problema seguido de su interpretación desde un enfoque "aproximado" (construcción del ambiente de cálculo) y culminando con la interpretación de los resultados. Sobre los ejemplos se discuten los métodos y su integración con la intuición y juicio ingenieril.

Sin aspirar a ser un libro de texto, este documento se conduce como una guía para el desarrollo de análisis alternativos que clarifiquen y/o corrijan nuestro ejercicio teórico y práctico.

2.1. Variabilidad e Incertidumbre

La variabilidad aleatoria VA y la incertidumbre epistémica IE son de tomarse en cuenta cuando se jerarquiza y selecciona un método de análisis. VA es la aleatoriedad natural del proceso estudiado, mientras que IE es la incertidumbre propia del modelo debida a datos y conocimiento limitados.

La interpretación de la VA y la IE concierne a los límites futuros del conocimiento. Existe una escuela de pensamiento donde no se contempla VA en los procesos sísmicos. En un principio los sismos son respuestas a esfuerzos y deformaciones en la corteza terrestre que se transmiten hacia capas más superficiales. Eventualmente, transcurrido el tiempo, se habrán recopilado suficientes datos para desarrollar modelos detallados del proceso sísmico con los que se pronosticarán localizaciones, intensidades y respuestas a futuros terremotos. Si el proceso sísmico es en teoría *comprendible* (puede llegar a conocerse en su totalidad) contiene sólo IE y ésta debería reducirse con el paso del tiempo.

La idea de distinguir entre VA e IE suena simple pero en la práctica esta separación puede volverse confusa. Como un ejemplo considérese una falla con un punto de segmentación postulado. Un modelo consideraría que el punto de segmentación es una barrera impenetrable y un modelo alternativo podría considerar que el punto de segmentación no existe. En este caso, la existencia del punto de segmentación es IE. Otro modelo de segmentación de la falla podría considerar que el punto de segmentación existe pero que sólo detiene un poco la ruptura, aceptando VA en el modo en que rompe pues algunas veces la ruptura es detenida en el punto de segmentación y otras rompe a través de él.

Tomemos ahora el ejemplo de las leyes de atenuación de movimientos de terreno. La estructura detallada 3D de la corteza es potencialmente explicable, con lo que sería posible desarrollar un modelo de propagación de ondas para cada fuente y sitio específicos. Se puede argumentar entonces, que la variabilidad entre las relaciones de atenuación de movimientos de terreno se debe a la falta de conocimiento para explicar el complejo proceso de propagación de ondas (hablamos de IE) y ésta pudiera ser eliminada (teóricamente) una vez que estén disponibles datos adicionales sobre este tipo de fenómenos.

Relacionando estos conceptos con el análisis de la respuesta de sitio y la caracterización dinámica de los suelos, se deben distinguir como restricciones de modelado: i) la incertidumbre relacionada con la forma del modelo -función matemática y parámetros físicos asociados- y ii) la variabilidad en las observaciones de entrada. Advirtiendo que ambos aspectos limitan la flexibilidad y la robustez de los esquemas de estudio, en esta investigación, a través de los postulados conexionistas, se ofrece una vertiente que significa la simplificación de los estándares geosísmicos y la construcción de buenos modelos científicos: menor número de variables básicas para predecir las variables derivadas con suficiente aproximación y confiabilidad.

2. Problemática Geosísmica

Desde los primeros intentos por desarrollar marcos de referencia para catalogar la observación y la experiencia en el comportamiento de suelos y rocas a través de conceptos básicos de la mecánica (origen en el trabajo de Terzaghi, 1925), la difícil empresa de tratar con materiales cuyas características son producto de acciones de la naturaleza marcó el lento avance -si se compara con otros campos de la ingeniería- en el establecimiento de métodos geotécnicos racionales.

A diferencia de la ingeniería estructural y mecánica cuyas incertidumbres son deductivas (a partir de condiciones razonablemente bien conocidas se emplean modelos para deducir el comportamiento de un universo específico), la ingeniería geotécnica trata con incertidumbres puramente inductivas (con base en observaciones limitadas, conocimiento geológico parcial y razonamiento estadístico ambiguo, se infiere el comportamiento de un universo pobremente definido). Debido a lo anterior, es importante tener en cuenta el riesgo de manejar el razonamiento puro en geotecnia (aproximaciones deductivas a condiciones inciertas del mundo geológico) y aplicar literalmente los resultados cualitativos y cuantitativos producto de este tipo de análisis.

Por otro lado, las técnicas de análisis deductivo abarcan campos del conocimiento cuyas características -y limitaciones- se reflejan en los modelos obtenidos a través de ellas. Los métodos prácticos de evaluación y diseño carecen en cierta medida de rigor científico y análisis directo. Por ejemplo, la respuesta de un sistema suelo-estructura ante eventos sísmicos severos se espera que, en la mayoría de los casos, sea no lineal (particularmente en terrenos blandos), sin embargo, la evaluación del comportamiento se representa por medio de mapas y cuantificadores simples procurando, sistemáticamente, involucrar un mínimo de variables. Los cálculos, desarrollados con funcionales lineales, son sensibles a factores de ajuste que se establecen con base en la experiencia, las observaciones (casi siempre muy reducidas) y las restricciones que impone el conocimiento sobre los materiales involucrados.

Estas aproximaciones empíricas e indirectas a menudo arrojan importantes discrepancias entre los comportamientos registrados y los que los modelos pronostican, como lo han demostrado sismos recientes. Un modelo geosísmico que intente mejorar esta tendencia debería usar i) el conocimiento empírico y ii) los recursos que ofrecen la sismología, la geotecnia, la geología, la mecánica aplicada, las matemáticas y la computación para interpretar, caracterizar y predecir más efectivamente los fenómenos analizados.

2.2. Propiedades Dinámicas de los Suelos

Los suelos son materiales 4D (x, y, z, t) extremadamente complejos en su comportamiento constitutivo y cuyos elementos mineralógicos y geológicos, presencia de los tres estados de la materia y distribuciones logarítmicas del tamaño de sus partículas, los hacen elementos naturales únicos (Terzaghi, 1943). Además, el estado inicial de esfuerzos, la rigidez no lineal, la resistencia, la anisotropía, la permeabilidad, las características de drenaje, y el comportamiento reológico hacen de la investigación de los suelos con fines de caracterización (in situ y/o laboratorio) una formidable tarea.

Contemplar la diversidad de partículas, mineralogías, agentes cementantes, y arreglos estructurales en un modelo numérico global sería difícil e ineficiente (Prévost y Popescu, 1996). La articulación de un modelo del suelo está contaminada de la incertidumbre inherente a la determinación de cualquier propiedad y ella no podrá ser eliminada sin importar cuántas pruebas sean dirigidas para conocer las condiciones de los materiales (Bendat y Piersol, 1986; Popescu y Prévost, 1995). La mejor práctica de estudio para emitir conclusiones útiles en el diseño geotécnico es la combinación de la exploración (perforación, muestreo, pruebas de campo y laboratorio), juicios calificados y teorías básicas bien fundamentadas.

Propagación de ondas, vibración de maquinaria, respuesta sísmica e índices de licuación, son algunos ejemplos de las aplicaciones donde es indispensable el conocimiento de las propiedades mecánicas del suelo asociadas con la carga dinámica: velocidad de ondas de corte V_s , módulo de rigidez al corte G , relación de amortiguamiento λ y relación de Poisson μ . Las metodologías y programas de computadora en Ingeniería Geosísmica orientados a estimar la respuesta dinámica de los depósitos (método lineal equivalente, método característico y método de elementos finitos, entre otros) dependen de la adecuada determinación del módulo de rigidez al corte para bajas deformaciones G_{max} y la atenuación del módulo G y el incremento de la relación de amortiguamiento λ respecto a la deformación angular $\gamma\%$ (G versus $\gamma\%$; λ versus $\gamma\%$) para caracterizar el comportamiento dinámico de los materiales (Martin y Seed, 1982) y generar evaluaciones de movimientos particulares (Fig. 2.1).

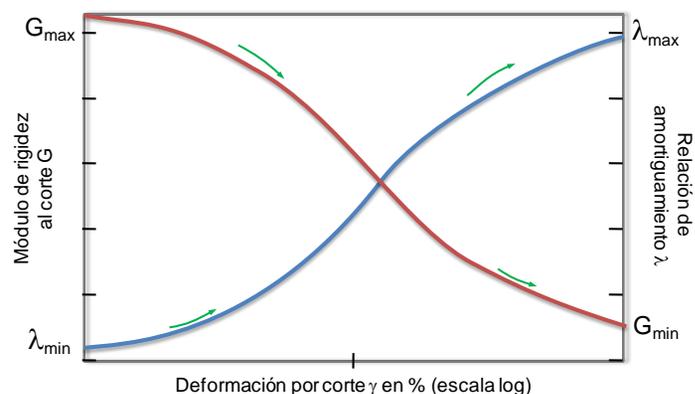


Figura 2.1 Propiedades dinámicas en función de la deformación por corte

Estimación de propiedades

Las acciones de exploración en el suelo pueden dividirse en tres categorías generales: pruebas in situ, pruebas de laboratorio y clasificación de materiales. Las pruebas in situ esencialmente evalúan las propiedades ingenieriles geotécnicas en su ambiente natural. Algunas de las ventajas de usar mediciones de campo sobre las obtenidas de pruebas de laboratorio son: i) las alteraciones sobre el material se minimizan, ii) los efectos de la estructura y de la edad se preservan y, iii) el suelo es ensayado en su estado natural (in situ) de esfuerzos (Campanella, 1994). Además, en la extrapolación de propiedades medidas en un punto (probeta de laboratorio) hacia características atribuibles a capas de suelo, los tan comúnmente llamados estratos "homogéneos" son en realidad sólo "estocásticamente homogéneos", es decir, existen importantes variaciones espaciales en las propiedades, identificables sólo a través de pruebas de campo.

La obtención directa de la resistencia y deformabilidad de los suelos así como datos suplementarios (estratigrafía, distribución granular, propiedades de amortiguamiento, etc.) a partir de pruebas de campo y un mínimo de ensayos de laboratorio, elimina algunas fuentes de incertidumbre y economiza los análisis preliminares a estudios formales de peligro sísmico (Harder y von Bloh (1988), Jefferies y Davies (1993) Stewart y Campanella (1993), Campanella et al (1994), Campanella y Kokan (1993)).

Prueba de Penetración del Cono

La prueba de penetración del cono CPT (por sus siglas en inglés Cone Penetration Test) consiste en empujar una punta cónica para hacer una perforación cilíndrica en el terreno a una velocidad muy lenta (FUGRO, 1996). La prueba es instrumentada para medir la fuerza resistente al avance de la punta (q_c) y la fricción sobre la superficie del dispositivo, generando lecturas que constituyen un registro casi continuo de las características del subsuelo (Fig. 2.2). El hecho de que esta prueba sea de avance lento (carga cuasi-estática) hace que sus estimaciones se prefieran sobre las obtenidas de una prueba de penetración estándar SPT (por sus siglas en inglés Standar Penetration Test) que se realiza con carga dinámica y las fuerzas de amortiguamiento (desconocidas) podrían influenciar los resultados en suelos de baja permeabilidad (Jefferies y Davies, 1993).

Adicionalmente, pueden hacerse mediciones geofísicas en el mismo pozo para medir la velocidad de onda de corte (V_s) del suelo a varias profundidades (Fig. 2.2). Esta información es muy efectiva en la evaluación del potencial de daño en eventos sísmicos y su uso, a través de correlaciones entre V_s y la rigidez del suelo, es rutinario cuando se evalúa la respuesta de sitio.

CPT: correlaciones empíricas.

Además del valor de resistencia no drenada (para suelos cohesivos) y la construcción de cartas para identificación de suelos (Douglas y Olsen, 1981) el valor de q_c puede asociarse al valor de G_{max} relacionando las bases de datos de la prueba CPT y los resultados de la prueba realizada en ese mismo sitio para obtener V_s .

V_s puede ser usada para determinar el módulo G del suelo a través de

$$G = \rho \cdot V_s^2 \quad 2.1$$

donde $\rho = \gamma_t / g_a$, ρ = densidad de masa, γ_t = peso volumétrico total, y g_a = aceleración de la gravedad, 9.8 m/s². Para ondas planas, la deformación por corte, γ_s ($\gamma\%$), se define como la relación entre la velocidad máxima de partícula, \dot{u} , y la velocidad de onda de corte:

$$\gamma_s = \frac{\dot{u}}{V_s} \quad 2.2$$

A pequeñas deformaciones, el movimiento de partícula resultante de la propagación de las ondas de corte es no destructivo. Conforme γ_s se incrementa más allá del límite de deformación elástica $\gamma_{iésimo}^e$, el módulo cortante decrece a partir de su máximo valor G_{max} . (Dobry et al., 1982).

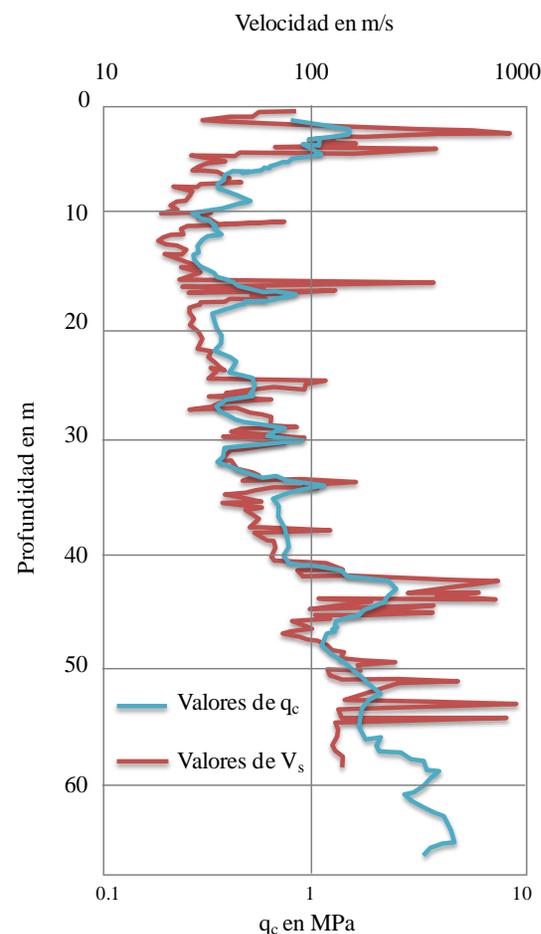


Figura 2.2 Ejemplos de perfiles de velocidad de onda de corte y resistencia a la penetración de la punta (modificado de Ovando y Romo, 1991)

Las pruebas in situ se asumen comúnmente como representativas de pequeñas deformaciones ($\gamma_s > \gamma_{s\text{ íesimo}}^{\circ}$), y la medida de la velocidad de ondas de corte puede relacionarse directamente al valor máximo del módulo G .

Existen diferentes tipos de funciones matemáticas que intentan relacionar los valores de q_c y V_s a través de hipótesis particulares a cada material y evitan el costoso y especializado ensaye geofísico para determinar el perfil de caracterización dinámica. Lamentablemente, la mayoría de estas aproximaciones centran su eficiencia en el ambiente definido por la base de datos estudiada y carecen de capacidad de generalización (Na et al., 2005; Hegazy y Mayne, 1995).

En el caso de las arcillas de la Ciudad de México, existen las correlaciones semi-empíricas propuestas por Ovando y Romo (1991) y Jaime y Romo (1988) para estimar V_s a partir de q_c . En la primera aproximación se usa la teoría de expansión de cavidades acoplada con un modelo hiperbólico para definir el comportamiento esfuerzo-deformación de la arcilla, mientras que en la segunda se trata con un análisis de aproximación con mínimos cuadrados (Tabla 2.1). Debido a su sustento matemático, la primera es más confiable y consecuentemente es la que se usa en la práctica profesional.

Tabla 2.1 Correlaciones semi-empíricas para las arcillas de la Ciudad de México

Ovando y Romo , 1991	Jaime y Romo , 1988
HIPERBÓLICO	MÍNIMOS CUADRADOS
$V_s = \eta \sqrt{\frac{q_c}{N_{kh} \gamma_s}}$ <p>γ_s: Peso volumétrico del suelo, t/m³</p> <p>N_{kh}: para las arcillas del lago de Texcoco preconsolidado y virgen su valor medio es de 9.5 y para las del lago de Xochimilco-Chalco es de 9.9</p> <p>η: Es una constante que depende del tipo de suelo, $\eta = \sqrt{\frac{g}{\gamma_r}}$</p> <p>$g$: Aceleración de la gravedad, m/s²</p> <p>γ_r: Deformación de referencia, para las arcillas del lago de Texcoco preconsolidado se considera 1.5%, mientras que 1.17% para las arcillas del lago Xochimilco-Chalco</p>	$V_s = 10.03 + 0.0789q_c \rightarrow \text{a)}$ $V_s = 6 + 0.1211q_c \rightarrow \text{b)}$ <p>a) Lago de Texcoco precargado</p> <p>b) Lago de Texcoco virgen</p>
q_c en kPa y V_s m/s.	

Comportamiento de los parámetros dinámicos G y λ

En general, la relación esfuerzo-deformación de un suelo se torna no lineal e histerética para excitaciones de gran amplitud. Esta no linealidad e histerisidad corresponde a una reducción de la resistencia del suelo, incremento del amortiguamiento, y deformación de ondas si se comparan con la forma de las ondas a bajas deformaciones (Hardin y Drnevich 1972a, b; Erdik 1987; Vucetic y Dobry 1991; Silva et al. 1999, entre otros).

El valor del módulo de rigidez depende fuertemente del nivel de deformación cíclica inducida. Las aproximaciones para modelar las curvas G/G_{max} versus $\gamma\%$ y λ versus $\gamma\%$ precisan del módulo de rigidez máximo y algunos otros parámetros para incluir las diferencias por tipo de suelo (Zen et al., 1978; Kokusho et al., 1982). En el caso de materiales cohesivos, un gran número de estudios experimentales (Kokusho et al., 1982; Dobry y Vucetic, 1987; Sun et al., 1988; Romo, 1990; entre otros) han demostrado que el índice de plasticidad I_p tiene un efecto significativo sobre la forma de las curvas de degradación, mientras que el nivel de esfuerzos efectivos (incluido en el peso volumétrico, γ_t) está relacionado directamente con el rango de G_{max} (Dobry y Vucetic, 1987; Sun et al. 1988).

Para las arcillas de la Ciudad de México, Romo (1990) desarrolló relaciones hiperbólicas esfuerzo-deformación con las cuales los aspectos más relevantes del comportamiento (incluso a grandes deformaciones) de las arcillas pueden ser modelados con cierta eficiencia:

$$G = G_{max} (1 - H(\gamma\%)), \quad H(\gamma) = \left[\frac{(\gamma\% / \gamma_r)^{2B}}{1 + (\gamma\% / \gamma_r)^{2B}} \right]^A \quad 2.3$$

donde γ_r es una deformación de referencia (en por ciento), A depende del índice de plasticidad I_p y B es otra función experimental derivada de A . El modelo se construyó con base en resultados de pruebas triaxiales y de columna resonante desarrolladas para obtener el valor de G dependiente de la deformación por corte. Hardin y Drnevich (1972) mostraron que el amortiguamiento λ de materiales viscoelásticos (materiales que obedecen las reglas Masing durante la carga cíclica) puede relacionarse con el módulo G a través de una simple expresión ($\lambda = \lambda_{max} (1 - G/G_{max})$) y junto con la ecuación anterior se usa para construir la dupla de curvas G y λ dependientes de $\gamma\%$.

En cualquier análisis que haga uso de propiedades dinámicas del suelo debe reconocerse i) la inevitable incertidumbre en la determinación de las variables básicas (en este caso q_c y la caracterización puntual del material por medio del I_p y el peso volumétrico) y su efecto sobre las dependientes (V_s y las curvas G versus $\gamma\%$ y λ versus $\gamma\%$), ii) la restricción adherida a las hipótesis y teorías empleadas (que no necesariamente simulan el comportamiento del suelo bajo condiciones "reales") y iii) el significado *no físico* de los parámetros asociados con el fin de mejorar la identificación de los comportamientos modelados.

2.3. Respuesta de sitio: aspectos básicos

Este apartado no contiene metodologías ni abunda sobre los conocidos pasos para determinar la respuesta de un sitio ante un evento sísmico. Se recomienda al lector interesado la revisión del Apéndice: 2.3.A. El objetivo de esta sección es analizar los puntos débiles de los planteamientos convencionales que sirven como base en la estructuración de los modelos conexionistas (cómputo aproximado) propuestos en secciones posteriores.

La atención en los últimos años sobre los análisis de riesgo sísmico ha generado una gran cantidad de modelos para describir fuentes sísmicas, evaluar la recurrencia de los eventos y establecer el efecto que sobre los movimientos tiene la estratigrafía de sitios específicos. Los ingenieros que trabajan en este tema algunas veces consideran negativas las consecuencias del rápido crecimiento en este campo de investigación, pues los enfrenta al problema de comprender distintas metodologías numéricas, manipular apropiadamente los datos para la selección de parámetros asociados a cada modelo y relacionar e interpretar los resultados de acuerdo con su experiencia en estos fenómenos.

Ya que no todos los profesionales involucrados con este tipo de estudios cuentan con los recursos para desarrollar análisis de riesgo sísmico de una manera consistente (en particular la respuesta de sitio RS), una herramienta simple y auto-documentada a este respecto sería muy útil en la comprensión y el razonamiento correctos de los resultados.

Para decidir sobre la aplicación de cierto modelo bajo condiciones específicas in situ y/o la validez de las respuestas calculadas, es fundamental aclarar las limitantes y desventajas de cada herramienta de análisis, lo que al mismo tiempo representa la dirección que deben seguir las mejoras en futuros desarrollos.

Validación de las Estimaciones

La confianza puesta en cualquier estimación sobre movimientos de terreno es proporcional al realismo físico del modelo y el soporte que éste tenga en observaciones del fenómeno. El nivel de la investigación sobre la dinámica de la ruptura en fallas tectónicas, propagación de ondas, y respuesta no lineal de los suelos sugiere que nuestro conocimiento sobre la física asociada con estos procesos es incompleto (O'Connell y Ake, 2000).

La IE en la evaluación de la RS se refiere al entendimiento parcial sobre procesos sísmicos (generación, propagación y respuesta) mientras que la VA se relaciona con los aspectos inherentemente impredecibles de los sismos, por ejemplo, el patrón de esfuerzos específico que desarrollará un evento futuro (Toro et al., 1997).

La identificación de las incertidumbres en la estimación de movimientos de terreno en términos epistémicos y aleatorios es útil, pero la experiencia reciente sugiere que es probable que existan IE que ni siquiera han sido descubiertas. En principio, datos adicionales y mejoras en el conocimiento

podrían reducir la IE pero, en general, existe una fusión entre IE y VA que hace muy difícil determinar qué beneficio reportan sobre nuestro conocimiento los modernos y voluminosos bancos de datos y/o las inclusiones multiparamétricas a las que tienden las mejoras hechas a modelos convencionales.

Además, el hecho de que muchas fuentes sísmicas, factores de propagación de ondas y comportamientos de materiales naturales quizá nunca sean conocidos (no totalmente) caracteriza a los modelos de RS como *sistemas abiertos*, es decir, cualquier modelo de movimientos de terreno es necesariamente no-único (Oreskes, et al., 1994) y por esto, las cuantificaciones precisas de movimientos para sitios específicos, no son posibles.

Debido a que los modelos sísmicos se construyen para que confirmen experiencias pasadas, su habilidad para predecir comportamientos futuros es necesariamente limitada, pero al mismo tiempo estos estudios son el único medio para establecer la susceptibilidad de un sitio a ciertos sesgos en intensidades y duraciones máximas relativas a la historia de movimientos. Si la validación de la simulación de movimientos de terreno se refiere exclusivamente a los resultados y a su consistencia cuando se comparan con las observaciones, esta imposición es una condición explícita de que la información de movimientos a la fecha contiene todos los comportamientos físicos posibles.

Las comparaciones no son validaciones, se trata de simples confirmaciones de la capacidad del modelo para reproducir la experiencia y dan una idea de que tan correcto, desde el punto de vista físico, es el planteamiento (Oreskes et al., 1994) y por ello no deben tomarse como único recurso para establecer la capacidad de las herramientas o métodos de análisis. Cuando se jerarquizan los modelos la mayoría juegan el papel de esquemas de interpolación de experiencia, descuidando el aspecto crítico de descubrir comportamientos potencialmente significativos más allá de los límites de nuestra experiencia actual (Anderson, 2001). Los modelos que tienden a usar exclusivamente información empírica para evaluar sus capacidades, son propuestas que restringen sus propios límites de operación o representan una espectacular aseveración de que en el futuro no caben las sorpresas. ¿Qué se requiere para ponderar el uso de alguna aproximación sobre las conocidas hasta la fecha?. Bajo la perspectiva expuesta en este capítulo, sólo las bases físicas que eliminen hipótesis contradictorias (premisas ajenas al comportamiento *natural* o registrado) y mejoren el conocimiento (llevando a conclusiones simples e *inteligentes*) elevará el nivel de confianza en las estimaciones hechas sobre comportamientos futuros.

Marco de desarrollo para estimar RS

Las simulaciones de movimientos de terreno se sustentan en simplificaciones y descripciones estadísticas de los procesos de propagación de ondas y las fuentes generadoras en lugar de tratar de modelar la física de la ruptura o la propagación de las ondas elásticas.

Esta representación ha sido necesaria porque el conocimiento para formular (apropiadamente) ecuaciones diferenciales es vago, las observaciones de movimientos severos de terreno son escasas, el conocimiento 3D de la estructura y velocidad de propagación de las ondas en la corteza es limitado, y la demanda computacional para construir un esquema que incluya todos estos aspectos sería extrema. Las investigaciones que intentan cubrir cada ángulo de esta compleja perspectiva han sido catalogadas como *raras*, *exóticas*, y *caras* (computacionalmente) dejando a las aproximaciones estadísticas simplificadas como *buenas* y la mayoría de las veces únicas alternativas de análisis.

El proceso en la estimación de movimientos fuertes de terreno debe mejorarse a través del reemplazo (con conocimiento y monitoreo adecuado) de los parámetros estadísticos y puramente matemáticos por parámetros físicos basados en datos y experiencia disponible, y la exclusión de la actividad, bien conocida y poco fundamentada, de especificar *a priori* las relaciones entradas→salidas de los sistemas. Desde el enfoque Bayesiano, un progreso significativo en la estimación de movimientos de terreno será representado por una evolución de las hipótesis *a priori* a declaraciones *a posteriori*.

Son los avances recientes en tecnología computacional (microprocesadores rápidos y económicos, memorias eficientes y procesamiento paralelo) los que hacen posible los cálculos complejos y las opciones de modelado avanzadas, aunque hay que reconocer que desafortunadamente la geosismología es escasa respecto a datos y conocimiento si se compara con las modernas capacidades computacionales. Es tarea del investigador equilibrar el uso de las emergentes herramientas computacionales con los progresos en la caracterización de la fuente, dinámica de la ruptura, propagación de ondas y respuestas no lineales del suelo, sin esperar a que nuestras deficiencias de análisis y cálculo sean evidenciadas conforme la naturaleza nos demuestra su poder.

Algunos de los aspectos en RS que requieren mayor profundidad en su interpretación y modelado para lograr un avance en el conocimiento y hacer de las nuevas propuestas *verdaderas* alternativas, son (O'Connell y Ake, 2000):

Tema 1: Caracterización de la fuente

Modelación de la tectónica, cinemática, distribución de esfuerzos, y localización de deformaciones para cuantificar las propiedades de las fallas. Comprensión física de los factores que promueven e inhiben la ruptura a lo largo de los segmentos de falla y las interacciones dinámicas entre ellos para estimar magnitudes sísmicas y comportamientos recurrentes (Harris y Day, 1993,1999; Magistrale y Day, 1999). Una necesidad muy poco abordada es mejorar los métodos para detectar fallas *ocultas*.

Tema 2: Restricciones dinámicas en la ruptura

Ya que las correlaciones espaciales entre los factores de fuente son *pobrementemente* comprendidas es necesario reestructurar las metodologías que asumen relaciones paramétricas donde no necesariamente existen. Investigaciones teóricas de ruptura para examinar influencias dinámicas de las velocidades, heterogeneidades en esfuerzos, y geometrías de segmentación asociadas con fallas son necesarias para reducir errores y sesgos potencialmente peligrosos en la estimación de movimientos de terreno (Harris y Day, 1983; Magistrale y Day, 1999).

Tema 3: Propagación de ondas

Un importante tema de investigación es la determinación de la influencia de la estructura 3D en respuestas de movimientos de terreno (Davis et al., 2000). Esto requiere incorporar esquemas realistas de atenuación (Day, 1998) y manejar la influencia de las topografías y anisotropías en movimientos severos, así como generar mayor conocimiento sobre ondas atrapadas en cuencas-cuña y efectos espaciales en regiones densamente pobladas.

Tema 4: Respuestas de sitio no lineales

Es importante i) determinar los límites de aplicación de los métodos lineales equivalentes con parámetros de suelo lineales independientes del tiempo; en particular, el efecto de la intensidad y tiempo de duración para alcanzar degradación significativa del módulo de rigidez; ii) definir *directividad* y su repercusión en la producción de máximas amplitudes en los estados iniciales de la sacudida antes de que una degradación significativa del módulo G ocurra; y iii) conceder la importancia debida a la no linealidad del suelo, respaldo más científico en la determinación de los parámetros que expresan este aspecto.

Tema 5: Monitoreo

Perfeccionamiento de las técnicas geológicas, geodésicas, geotécnicas y geofísicas de observación, exploración y prueba (in situ y/o laboratorio).

La solución a los 5 planteamientos anteriores mejorará la habilidad de los profesionales en la conducción de investigaciones de movimientos en sitios específicos y podrá convertirse en la motivación de inversión en monitoreo sísmico, investigaciones regionales geológicas y geofísicas, así como en el desarrollo de modernas y mejor constituidas aplicaciones geosísmicas.

3. Cómputo Aproximado

En el horizonte de los descubrimientos relacionados con la informática surgen no sólo ideas nuevas para mejorar las técnicas existentes, sino también paradigmas radicalmente diferentes de los actuales procedimientos. Uno de ellos, actualmente aplicado en casi todas las ramas de la ciencia, es el Cómputo Aproximado CA (Soft Computing en su idioma nativo). Su objetivo es bien concreto: aumentar el "coeficiente intelectual" de las máquinas a través de la *flexibilidad, adaptación e inteligencia*. En palabras de Lotfi Zadeh (1994), reconocido experto mundial en la materia, "el CA es la antítesis de la computación actual (asociada con la rigidez, la fragilidad y la simpleza) la cual no es suficientemente capaz de desarrollar y ejecutar sistemas *inteligentes*" (Fig. 3.1).

En lugar de sostenerse únicamente en las habilidades del modelador, un programa de CA aprende de su experiencia por generalización y abstracción, adquiriendo la facultad de razonamiento y aprendizaje en un ambiente incompleto, incierto, impreciso y con verdad parcial, aspectos propios de la realidad. El CA, capaz de modelar y controlar una gran variedad de sistemas, se constituye como una herramienta efectiva en problemas de toma de decisiones, control, clasificación y comprensión, reconocimiento y predicción.

En el CA se combinan diferentes técnicas de la Inteligencia Artificial IA como Lógica Difusa LD, Redes Neuronales RNs, Algoritmos Genéticos AGs y Razonamiento Probabilístico; esta última comprende Algoritmos Evolutivos, Sistemas Caóticos, Redes de Opinión y, parcialmente, Teoría del Aprendizaje (Zadeh, 1997, Bonissone, 1997). Conviene aclarar que el CA no es una mezcla de ingredientes sino una disciplina en la que cada componente contribuye con una metodología específica para manejar problemas en su dominio de aplicación que, de otra forma, se tornarían irresolubles.

La LD, en su más popular concepción, se liga a los cálculos numéricos basados en reglas difusas que tienen el propósito de modelar una función numérica para describir sistemas de ingeniería (Mendel, 1995). Sin embargo, en la literatura orientada hacia las matemáticas modernas, se le califica como una lógica multi-valuada cuyo propósito es modelar valores de verdad parcial e incertidumbres (Novak, 1996; Hajek, 1995). El desarrollo de la LD está ligado con la investigación en IA pero sobre todo con los análisis de sistemas de ingeniería por lo que las aplicaciones a problemas reales tratan en las primeras etapas de su desarrollo con la representación del conocimiento y una vez terminadas se convierten en una interfaz numérica/simbólica.



Figura 3.1 Cómputo Aproximado (soft) y Preciso (hard)

Las RNs se originaron en un intento por construir modelos matemáticos de unidades de procesamiento elementales anidadas en un *cerebro* que permitieran el flujo de señales a través de ellas. Después de un periodo de estancamiento, los modelos formales de RNs incrementaron su popularidad con el descubrimiento de eficientes algoritmos capaces de ajustarse a complicadas y masivas bases de datos. Las aplicaciones neuronales más exitosas se concentran en la construcción de arquitecturas computarizadas capaces de aproximar funciones no lineales con un gran número de variables y clasificar objetos inmersos en espacios multidimensionales. Básicamente, una red neuronal es una sofisticada función no lineal, tipo caja negra, que puede ser entrenada con datos numéricos para satisfacer tareas objetivo.

Los AGs son procedimientos de aproximación combinatoria estocástica desarrollados con base en la analogía biológica de la mutación y el intercambio de cromosomas en Genética (Holland, 1975). Pertenecen a los procesos meta-heurísticos que se usan para evitar mínimos locales en búsquedas siendo una sobresaliente particularidad su capacidad para mejorar -en paralelo- soluciones propuestas a un problema a través de saltos y fusiones aleatorias.

A la luz de las definiciones anteriores, es claro que la LD, las RNs y los AGs pertenecen a diferentes campos de investigación y el obvio punto en común es su inspiración en los seres vivos: la imprecisión del lenguaje humano y su eficiencia en la expresión y transmisión de información en el caso de la LD, la insuperable perfección de la arquitectura cerebral para las RNs y la reproducción y adaptación exitosa de los seres vivos en los AGs. De una forma complementaria y sinérgica -en lugar de competitiva- su estudio como herramientas de análisis conduce generalmente a lo que se denomina sistemas inteligentes híbridos, siendo los más destacados los neuro-difusos, los difuso-genéticos, los neuro-genéticos y los neuro-difuso-genéticos (Fig. 3.2).

El problema del sentido común

La computadora convencional "razona" utilizando una lógica estricta. El hombre no analiza las situaciones minuciosamente y basa mayormente sus reacciones en la experiencia. El cerebro trata de relacionar partes de su problema actual con algo ya solucionado en el pasado y aprovecha su amplio conocimiento acerca del modo en que funciona el mundo para razonar por aproximación antes de hacer uso de acciones precisas y rigurosas.

En ese sentido, Marvin Minsky, uno de los fundadores de la Inteligencia Artificial, postuló que, para avanzar en el campo de las máquinas inteligentes, es necesario dotarlas de sentido común. Pero, ¿qué se entiende por sentido común? Muchos lo definen como el caudal de conocimientos tácitos o de trasfondo, estrechamente interrelacionados, que facilita nuestra comprensión inmediata del entorno en el que nos desenvolvemos. El CA se perfila como una buena plataforma para dotar a las máquinas de sentido común, aunque debe aclararse que esta capacidad se ve restringida por la tarea (fenómeno) y la experiencia específicas (registro o monitoreo de los hechos estudiados).

Modelar contra Explicar

Formalizar la conexión entre datos y conocimiento es sin duda una de las más desafiantes actividades en la era de la computación. La producción de conocimiento a partir de datos se puede plantear desde dos antagónicos puntos de vista:

- **Modelación.** Se construye una función que imite los datos con suficiente precisión y que se comporte adecuadamente cuando se aplique a nuevos conjuntos de datos.
- **Abstracción:** Se construye un sistema que produzca conocimiento articulado, posiblemente en lenguaje natural, a partir de datos.

En el primer punto, el esfuerzo se concentra en desarrollar la habilidad para reproducir lo que se ha observado. Las RNs se adaptan bien a este problema. En el caso de la abstracción se busca desarrollar la destreza para comprender y explicar datos numéricos tal que se obtengan conclusiones útiles en el desarrollo del conocimiento humano. La LD ofrece los elementos teóricos para lograrlo.

Imprecisión e Incertidumbre constituyen la Indeterminación

El CA se presenta como un paradigma computacional para resolver problemas que se estudian bajo cierto grado de imprecisión e incertidumbre, características comunes en los fenómenos con los que reconocemos el mundo a nuestro alrededor. Estos fenómenos pueden dividirse en dos grandes grupos: *objetos* y *propiedades*. Un *objeto* es un fenómeno que puede ser separado del mundo, es decir, un fenómeno al que se le puede conceder individualidad (Vopenka, 1989). Los *objetos* se acompañan usualmente por lo que llamamos *propiedades*. Una misma *propiedad* puede ser aplicada a más de un *objeto*.

La *imprecisión* básicamente concierne a grupos de objetos, por ejemplo, nosotros agrupamos objetos que comparten alguna propiedad $f(x)$:

$$X = \{x \mid f(x)\} \quad 3.1$$

Donde x es la variable que declara *objetos*. Si $f(x)$ es demasiado compleja (y en la realidad así sucede en la mayoría de los casos) no es posible caracterizar el grupo X de manera precisa pues sus límites no están definidos.

Técnicas de Razonamiento Aproximado

Técnicas Optimización / Búsqueda

Mecanismo: **Condicionante**

Mecanismo: **Modus Ponens**

Búsqueda local: **gránulo fino**

Búsqueda global: **gránulo grande**

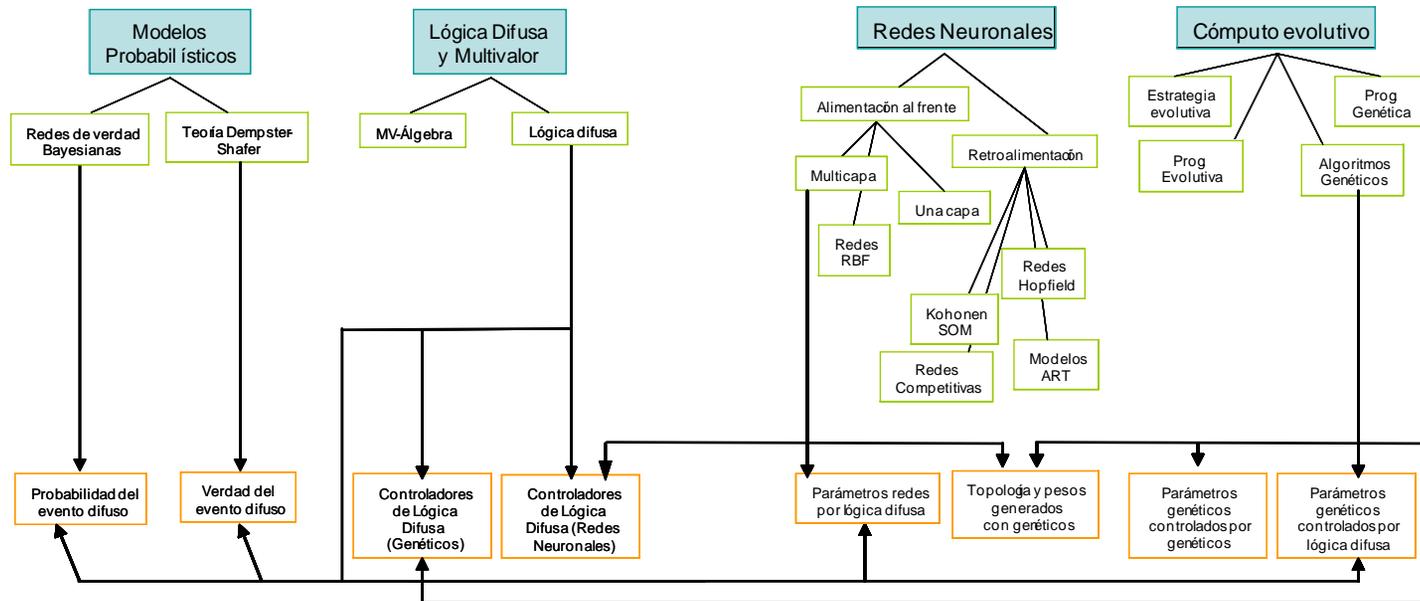


Figura 3.2 Técnicas SC

La incertidumbre, por otro lado, se caracteriza por la falta de información acerca de la ocurrencia de algún fenómeno. La palabra “ocurrencia” contiene la variable tiempo, el fenómeno de incertidumbre está siempre conectado con la posibilidad de monitorear el fenómeno en un lapso de tiempo (si éste llega a ocurrir). En la caracterización imprecisa de los grupos, el tiempo no siempre interviene; por ejemplo, en el fenómeno “árbol pequeño” sólo se busca el significado de “pequeño” ligado al elemento “árbol” sin considerar si se puede observar o no dicho objeto. La incertidumbre responde al cuestionamiento de ocurrencia mientras que la *imprecisión* se relaciona con la pregunta de qué es lo que ha ocurrido (Vopenka 1979, 1989).

Reconociendo las características básicas de los incisos planteados en esta investigación, se elige a la LD (Zadeh,1965) para la traducción numérica del conocimiento ingenieril cualitativo por medio de sus robustos mecanismos de razonamiento por interpolación; y a las RNs (Rosenbaltt,1959; Widrow y Hoff, 1960), para la determinación y aprendizaje de las relaciones numéricas entradas→salidas producto del monitoreo y ensaye geosísmicos. A continuación se presenta una breve descripción de los aspectos teóricos más relevantes de estas dos herramientas para justificar su aplicación en este trabajo de tesis.

3.1.Redes Neuronales

Una de las primeras líneas de búsqueda en la aspiración humana de diseñar y construir máquinas capaces de desarrollar procesos inteligentes de tratamiento de información fueron los autómatas. Estos artefactos mecánicos son los antecesores de las actuales computadoras que, de acuerdo con la filosofía de funcionamiento Von Neumann, se apoyan en descripciones secuenciales para llevar a cabo todos sus procesos.

A pesar del elevado nivel y competitividad de las computadoras modernas, el reto en su crecimiento sigue siendo el desarrollo de máquinas tecnológicamente avanzadas a partir de las condiciones que establece la inteligencia del silicio (artificial) frente al conocimiento que tenemos de la inteligencia del carbono (natural).

En este sentido, una de las ramas de mayor crecimiento en la inteligencia artificial es la de las redes de autoproceso. Estas redes están formadas por nodos procesadores de información de cuyas interacciones locales depende el comportamiento del sistema y pueden operar bajo el esquema de: i) procesamiento numérico y/o ii) procesamiento simbólico (Fig. 3.3). En el primero se recibe directamente la señal de entrada desde el mundo exterior y se trabaja sobre ella, mientras que en el segundo se establecen “conceptos” en los nodos y las reglas sintácticas constituyen los lazos de interconexión.

El procesamiento numérico trabaja con sistemas constituidos por nodos interconectados entre sí formando una red en el sistema intuitivo clásico, por lo que también suelen llamarse conectivistas (o conexionismo). Las raíces cognitivas (biológicas) de los sistemas conexionistas y su asociación con las ideas modernas computacionales se detallan en el Apéndice 3.1.A.

La conexión entre los nodos puede hacerse de forma global indiscriminada (aunque existen ciertas reglas de composición) o agrupada en subredes. En el primer caso estamos ante sistemas distribuidos, mientras que en el segundo

se trata de “redes de redes” o sistemas asociativos. Dentro de los sistemas distribuidos existen sub-clasificaciones: si existen agrupaciones locales de nodos que manejan “conceptos” se trata de las denominadas redes sub-simbólicas, mientras que si admitimos que todos los elementos del sistema funcionan corporativamente, se habla de una red neuronal o neurocomputador.

Los neurocomputadores, perspectiva renovada por el crecimiento de la microelectrónica, tienen su punto de partida en la constitución y ordenamiento del sistema nervioso SN de los animales y en particular de los seres humanos. Dejando aparte cualquier disquisición de tipo biológico, desde los trabajos originales de Cajal (1904) se reconocen en el SN dos aspectos fundamentales:

- Las redes nerviosas cerebrales se componen de neuronas densamente interconectadas organizadas en capas. La información circula de atrás hacia delante (camino directo), de adelante hacia atrás (realimentación entre capas) y dentro de la propia capa (interacciones laterales) (Fig. 3.4).
- Las neuronas poseen numerosas entradas y generan una única salida. Las entradas se reciben en los contactos (sinapsis) de su árbol dendrítico, mientras que la salida aparece en el axón desde donde se distribuye a otras neuronas (Fig. 3.5).

La organización indicada en el primer punto ha sugerido otro nombre para estos dispositivos: redes neuronales artificiales RNAs o por reducción, redes neuronales RNs. Es evidente que muchos aspectos puramente biológicos no son utilizados en estos modelos y del mismo modo es cierto que, por razones eminentemente prácticas, ha debido renunciarse *a priori* a muchos otros planteamientos de inteligencia aún a riesgo de perder buena parte de capacidad informática, ya que el punto básico en la aplicación de estas tecnologías en problemas del mundo *real* es conseguir, no la mejor solución, sino la más eficiente, factible y simple.

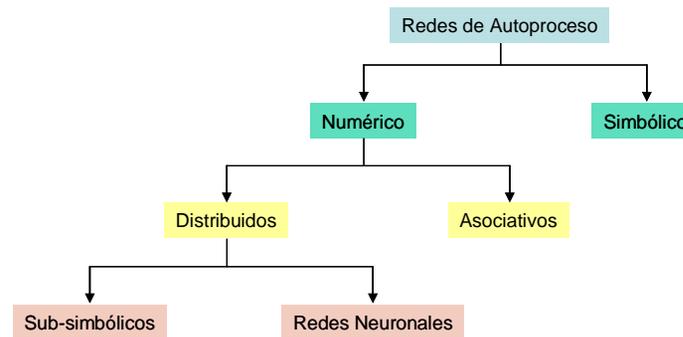


Figura 3.3 Esquema operativo de las redes de autoproceso

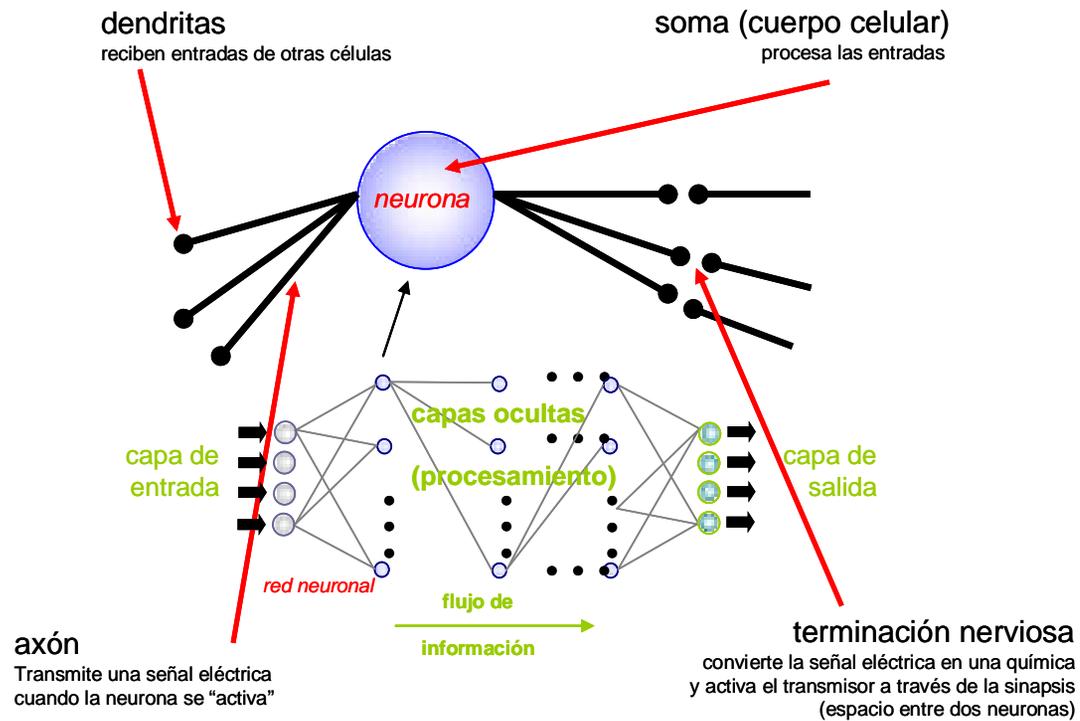


Figura 3.4 Sistema nervioso artificial

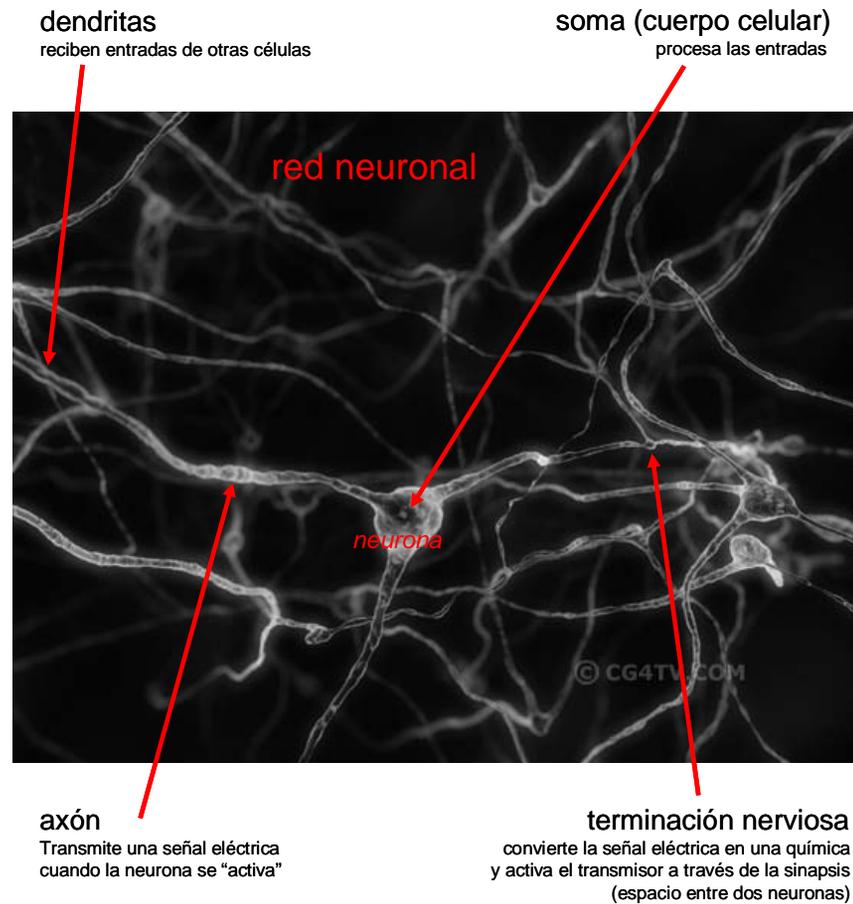


Figura 3.5 Sistema nervioso biológico

Objetivos de los Neurocomputadores

Las RNs no deben ser empleadas para realizar las tareas que las computadoras convencionales ya desarrollan a la perfección (o casi). El objetivo de un neurocomputador debe dirigirse hacia el tratamiento de estrategias de aprendizaje. Partiendo de una versión simplificada de una red biológica, la forma natural en que se *aprende* es por medio de la experiencia. Salvando las distancias, se *enseña* a la red mediante la presentación repetitiva y sistemática de una serie de entradas típicas con las que se definen, por asociación, los conceptos que deberán ser asimilados para interpretar futuras entradas.

Para lograr que este esquema funcione se requiere de: a) una riqueza másica semejante o superior a la de las entradas; un número reducido de neuronas sólo podrá aprender de un número reducido de entradas y b) de algún mecanismo que le permita a las neuronas adaptarse a los objetivos que se esperan de ellas; un elevado número de neuronas absolutamente rígidas, funcionalmente hablando, sería absolutamente incapaz de aprender nada; y si las neuronas no están densamente interconectadas, se trabaja con un conjunto numeroso de nodos muy flexibles pero desconectados unos de otros, con lo que la información apenas será procesada.

Entonces, los ejes fundamentales en las redes neuronales son: el *número de nodos*, que depende directamente de los avances tecnológicos (estructura y capacidad computacional) y las *interconexiones*, cuya complejidad reside en las características de los lenguajes de simulación y la capacidad de autoadaptación (relacionada con la flexibilidad de los algoritmos de síntesis).

Modelos Básicos

El primer modelo de neurona se debe al trabajo de McCulloch y Pitts (1943). No se trata de un modelo fisiológico de una célula nerviosa real sino de la representación lógica de los puntos más significativos del funcionamiento de ésta a través de 5 suposiciones fundamentales. Estos puntos constituyen un cuerpo de doctrina profundo y matemáticamente riguroso y a partir de él parten la gran mayoría de los modelos neuronales actuales (Fig. 3.6):

- La actividad de la neurona es un proceso “todo o nada”
- Para provocar la excitación de la neurona deben excitarse previamente (durante el tiempo de integración) un número mínimo de sinapsis (entradas) siendo este número independiente de la actividad anterior o de la posición de la neurona
- El retraso sináptico es el único significativo
- Las sinapsis inhibitoras impiden el disparo de la neurona
- La estructura de la red no cambia a lo largo del tiempo.

Básicamente para *disparar* a una neurona (hacer que genere un nivel “alto” de actividad en la salida) es preciso que:

- Ninguna entrada inhibitora, I , esté activa, y
- El número de entradas excitadoras activas iguale o supere el umbral U ,

$$\sum E_i \geq U \quad 3.2$$

$$I_j = 0 \quad 3.3$$

Una interesante propiedad de estas neuronas (llamadas *formales*) es la posibilidad de sintetizar circuitos lógicos mediante la adaptación de los umbrales. Como ejemplo, la Fig.3.7 muestra la síntesis de una función AND (Y) y de una OR (O). Este modelo inicial admite i) asignar un peso -1 a las entradas inhibitoras de forma que la condición de disparo ahora se convierte en $\sum(E_i - I_j) \geq U$ y ii) incorporar el retardo propio de las neuronas reales. De esta forma se establecen verdaderos elementos de memoria (Fig. 3.8).

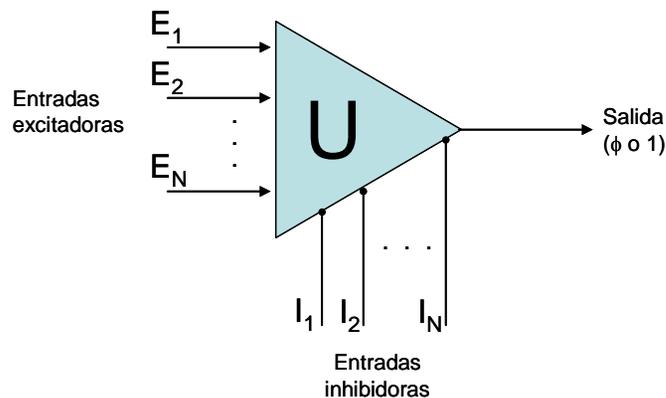


Figura 3.6 Modelo neuronal básico

Estas neuronas fueron modificadas posteriormente por M. Blum (1962) permitiendo la síntesis de funciones no separables linealmente. El punto clave en su propuesta consistió en la postulación de la inhibición presináptica: cuando una entrada está activa evita que otra, a la que inhibe antes de tocar la sinapsis, llegue hasta esta neurona (Fig. 3.9 inciso a). Un sencillo esquema (Fig. 3.9 inciso b) mediante el cual queda sintetizada la función paridad ("O exclusivo") de las variables X_1 y X_2 es:

$$Y(X_1, X_2) = \bar{X}_1 X_2 + X_1 \bar{X}_2 \quad 3.4$$

aplicable a la síntesis de funciones de cualquier número de variables. La extensión natural de este modelo consistió en la alteración del valor de las entradas de forma que la ecuación que describe el comportamiento de la neurona sería:

$$f(X) = 1 \quad \text{si} \quad \sum_{i=1}^N m_i x_i \geq U \quad 3.5$$

$$f(X) = 0 \quad \text{si} \quad \sum_{i=1}^N m_i x_i < U \quad 3.6$$

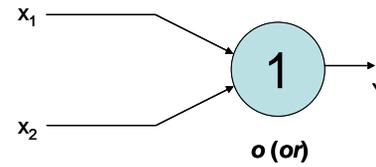
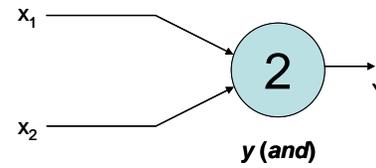


Figura 3.7 Neurona formal: funciones Y/O

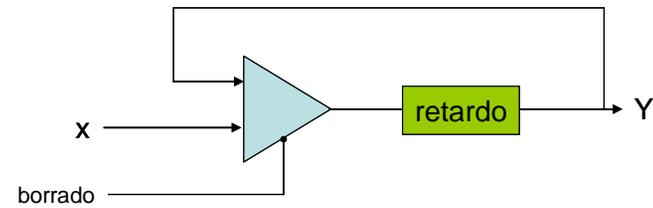


Figura 3.8 Esquema de memoria

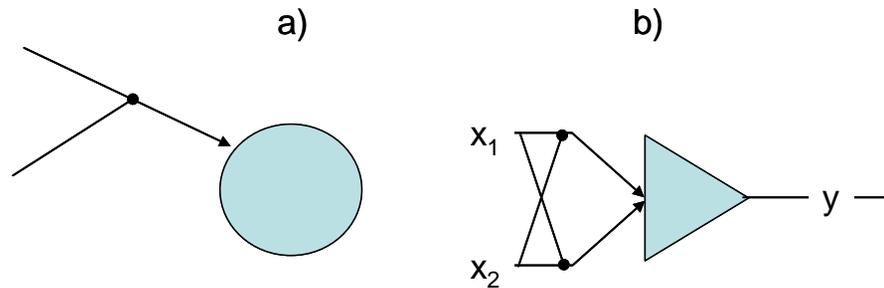


Figura 3.9 Propuesta de inhibición presináptica

donde X representa el conjunto de todas las entradas, mientras que los valores m_i son los pesos asociados a cada una de ellas (Fig.3.10). Si partimos de (X) como el conjunto de todas las entradas, X_i es la configuración correspondiente a un patrón que hay que asociar a una clase de entre dos posibles categorías. Suponiendo que, por construcción, una de las entradas está definida (rígidamente) con valor "1", la función $g(X)$ se define como:

$$g(X) = \sum_{i=1}^N m_i x \quad 3.7$$

entonces la función que realiza la neurona es:

$$f(X) = 1 \quad \text{si } g(X) \geq U \quad 3.8$$

$$f(X) = 0 \quad \text{si } g(X) < U \quad 3.9$$

Con lo que $g(X)$ no es más que la ecuación de un plano en el espacio de las coordenadas X_i que se denomina "hiperespacio". En este punto puede tomarse cada entrada como una variable binaria independiente o en otras palabras, podría construirse un generador de funciones lógicas combinatorias o con lógica de umbral.

Por otro lado, una visión diferente, con resultados más interesantes desde el punto de vista ingenieril, es considerar las entradas del elemento de umbral como las componentes de un patrón presentado al sistema. Cambiando adecuadamente los valores de los pesos, incluido el del término independiente, se puede modificar la "hipersuperficie" que separa el conjunto de los patrones para los que $f(X)$ toma el valor 1 de los que corresponden al valor 0. De esta forma, si se conecta la salida del circuito de umbral a un elemento de decisión, éste indicará qué patrones de entrada pertenecen a la clase o categoría A ($f(X) = 1$) y cuáles a la clase B ($f(X) = 0$), lo que representa un primer dispositivo de reconocimiento y clasificación de caracteres, llamado "función discriminante lineal" ($f(X)$ en este caso es lineal).

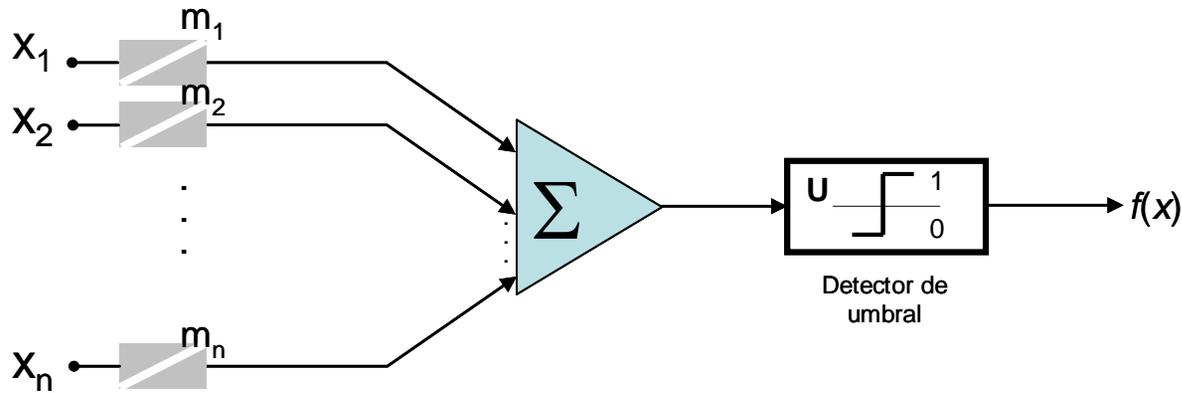


Figura 3.10 Esquema con entradas, pesos y función de activación

Este caso puede extenderse para clasificar un número superior de clases eliminando la parte de umbral y reduciendo la función a $g(X)$. Para establecer N categorías entre los caracteres se recurre a la disposición esquematizada en la Fig.3.11 En ella se establecen M discriminadores lineales

$g_k(X)$ cada uno de ellos ofreciendo el máximo valor de su salida para aquellas entradas que correspondan a la clase k . Todas las salidas son enviadas a un circuito selector de máximos que, en última instancia, decide la clase definitiva a la que pertenece la entrada concreta. Este dispositivo recibe el nombre de “máquina lineal de clasificación”.

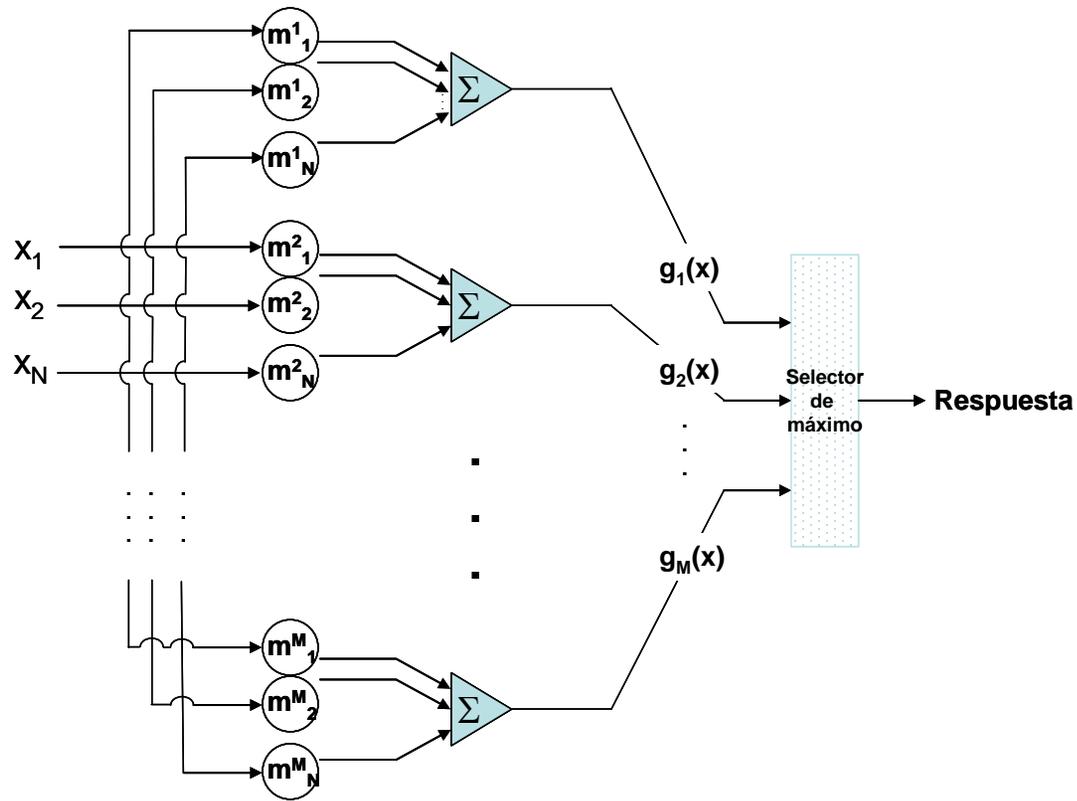


Figura 3.11 Esquema neuronal para clasificación

Mediante este tipo de dispositivos se pueden establecer asignaciones a distintas clases de pertenencia entre entradas definidas por prototipos a través de un esquema de decisión de distancias mínimas. Reuniendo R máquinas lineales es posible establecer discriminaciones no lineales establecidas en otras tantas superficies (Fig. 3.12).

Tras este modelo aparecieron, casi simultáneamente, dos aproximaciones muy semejantes enfocadas a la síntesis de elementos clasificadores lineales: la Adaline (Widrow, 1962) y el Perceptrón (Rosenblatt, 1962).

Adaline (Widrow, 1962) está constituido por dos elementos (Fig.3.13), un dispositivo de combinación lineal adaptativa (*adaptive linear combiner* ALC) donde se realiza la suma ponderada de los componentes del vector entrada para generar la salida. Esta salida Y se confronta con la correcta (esperada) a través de un elemento *comparador*. La diferencia "Δ" es realimentada a un bloque de corrección de pesos de forma que se disminuya su magnitud hasta anularse a lo largo de las sucesivas aproximaciones. La otra parte lo conforma un clasificador lineal conectado a un disparador de umbral. La función que describe el circuito completo es:

$$f(X) = -1 \quad \text{si} \quad \sum_{i=1}^N m_i x_i < 0 \quad 3.10$$

$$f(X) = +1 \quad \text{si} \quad \sum_{i=1}^N m_i x_i > 0 \quad 3.11$$

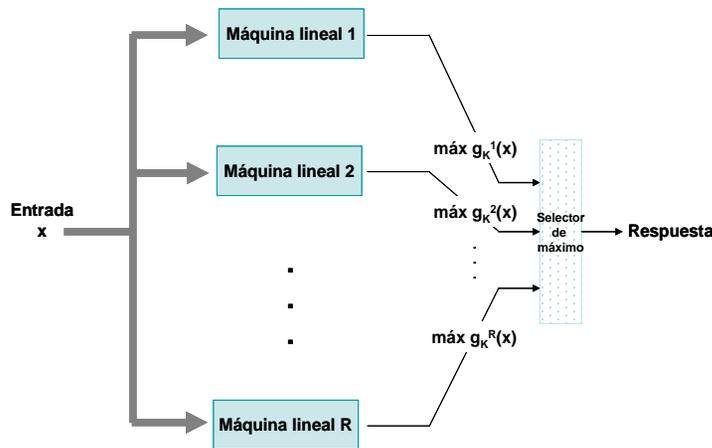


Figura 3.12 Máquinas lineales discriminantes

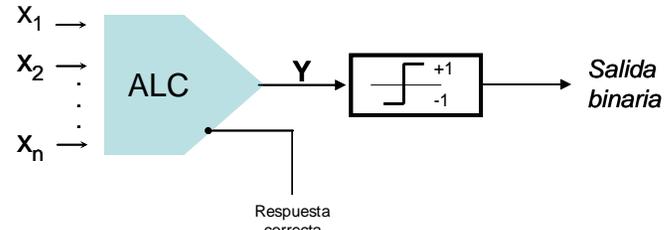


Figura 3.13 Dispositivo de combinación lineal adaptativa (ALC)

El resultado final constituye lo que el propio Widrow denominó Adaline (*adaptive threshold element*). Evidentemente también puede incluirse un umbral en el circuito de salida, además de que la combinación de varias adalinas permite la generación de superficies dicotomizantes de diversas formas (hiperplanos discriminantes).

Un aspecto muy interesante de las adalinas lo constituye la regla adaptativa, que es la ecuación que define la manera en que cambian los pesos asociados a las distintas entradas en dos instantes sucesivos cualesquiera (indicado por t y t+1):

$$m_i(t+1) = m_i(t) + x_i(t) \Delta(t) \quad 3.12$$

A la vez que Widrow presentó sus *adalinas*, Rosenblatt hizo lo propio con los *Perceptrones*, descritos posteriormente -con más detalle- por Minsky y Papert (1969). El principio de funcionamiento, muy similar al de las *adalinas*, se muestra en la Fig.3.14.

Un perceptrón está formado por tres tipos distintos de elementos constitutivos: los sensores "S", los asociativos "A" y los de respuesta "R". Los primeros constituyen la capa receptora/transformadora de los estímulos externos en señales. Las salidas de éstos se dirigen a las entradas de la siguiente capa formada exclusivamente por elementos de asociación en los que se realiza la combinación de las señales de entrada; por ejemplo, si se trata de señales digitales, los elementos de asociación podrán estar configurados como simples funciones booleanas. En principio, todos los elementos de asociación reciben señales desde todos los elementos sensores, pero pueden diseñarse distribuciones más restrictivas (en conexión y complejidad).

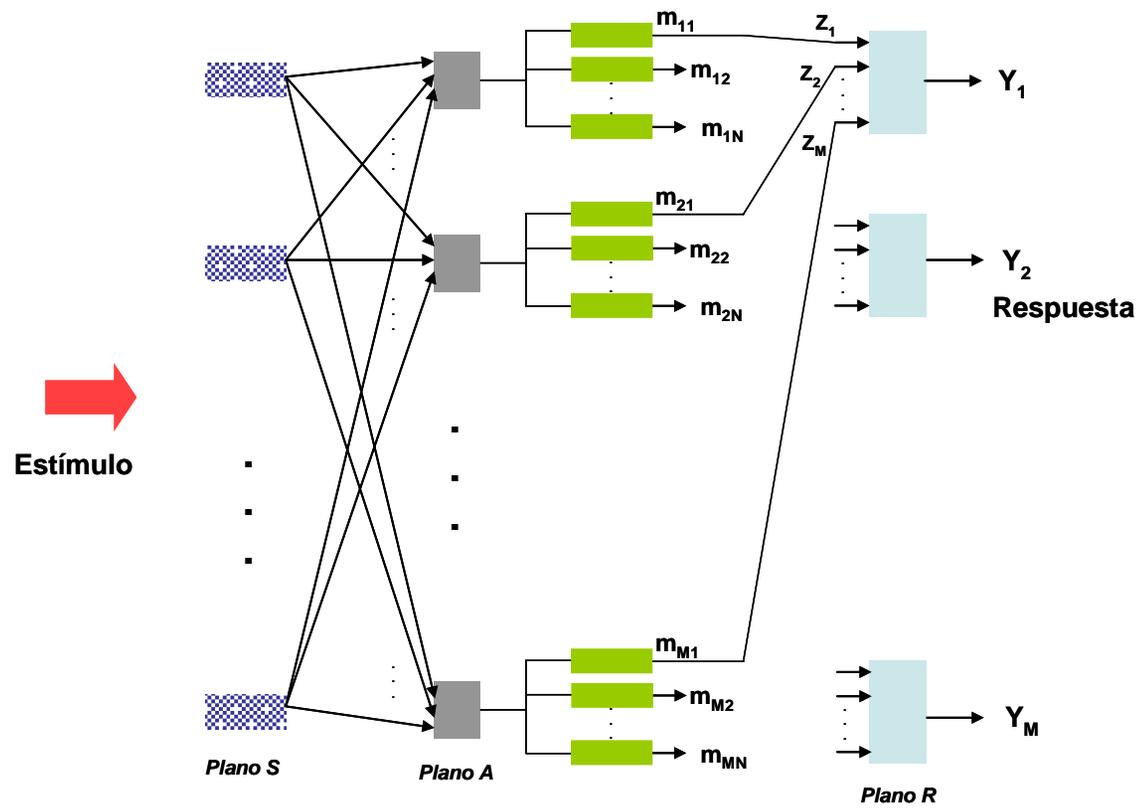


Figura 3.14 Perceptrón multicapa

El último nivel está integrado por las auténticas neuronas del sistema (elementos de respuesta) donde se ejecutan las funciones elementales:

$$y_k = 0 \quad \text{si} \quad \sum_{i=1}^N m_{ik} z_i < \text{Umbral} \quad 3.13$$

$$y_k = 1 \quad \text{si} \quad \sum_{i=1}^N m_{ik} z_i \geq \text{Umbral} \quad 3.14$$

El proceso de aprendizaje o de ajuste de los pesos m_{ik} está referido siempre a la adecuación ente la respuesta dada y la deseada, lo que se denomina *aprendizaje supervisado* y cuya forma genérica se describe en dos puntos:

- si la entrada z_i es un "1" y la salida del elemento no coincide con la deseada, entonces se aumenta el valor del peso asociado a dicha entrada si la salida es cero y debía ser 1, y se disminuye en caso contrario

- si la entrada z_i es un 0 o la salida coincide con la deseada no se altera el valor de m_{ik} .

Esta estructura, originalmente construida con elementos electromecánicos, presentaba un problema fundamental: no siempre existe una superficie discriminadora sintetizable mediante un *perceptrón*, y en caso de que exista, no siempre puede asegurarse que la aplicación reiterada del algoritmo de aprendizaje lleve a una solución estable, pudiendo caer en lazos interminables de valores oscilantes alrededor del correcto.

Otro sistema capaz de implantar ciertas propiedades inteligentes fue la llamada *matriz adaptativa* (learning matrix) propuesta por Steinbuch (1963). En su forma original se trataba de un método para simular los procesos de condicionamiento clásico (tipo Pavlov) (Figura 3.15).

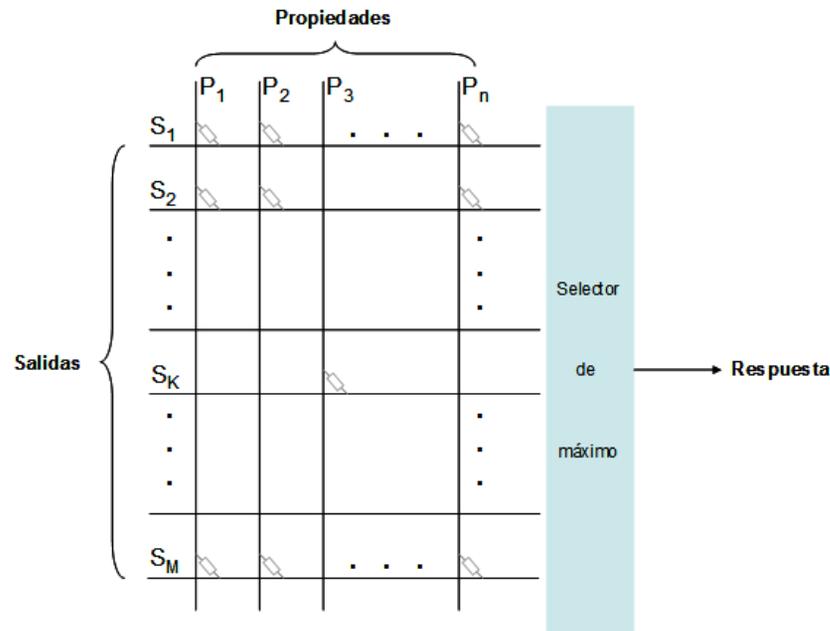


Figura 3.15 Matriz adaptativa

Las columnas constituyen las entradas al sistema y a éstas se conectan las propiedades p_1, p_2, \dots, p_n que definen el vector (P) del elemento a reconocer o asociar. Las filas representan las posibles salidas conectadas a un detector de máximos. En la fase de aprendizaje se escoge una determinada entrada $\{P_i\}$ correspondiente a un evento en particular y una fila de salida cualquiera S_k . Suponiendo que las entradas son binarias, mediante un esquema de refuerzo convencional del tipo

$$\Delta m_{hk} = +x, \quad \text{si } p_h = 1 \quad 3.15$$

$$\Delta m_{hk} = -x, \quad \text{si } p_h = 0 \quad 3.16$$

donde m_{hk} es el peso asociado a la conexión de la línea de entrada p_h con la salida s_k , al cabo de un cierto número de repeticiones, cada vez que se repita la entrada anterior sobre las líneas p, en la salida k se obtendrá

$$y_k = \sum_{h=1}^N m_{hk} p_k \quad 3.17$$

Este proceso debe repetirse para todas las líneas de salida (filas de la matriz) de forma que cada vez que haya una entrada presente, cada fila responderá con un determinado valor de salida. En ese momento se habrá terminado la fase de aprendizaje y se pasa a la de funcionamiento normal. La conexión de todas las salidas a un selector de máximos permite escoger aquella característica $\{p_i\}$ que más se parezca (su salida sea mayor) a la entrada que se presenta.

Además de los descritos anteriormente, existe una serie de modelos neuronales primigenios donde resultan especialmente interesantes los estudios teóricos de Minsky, Kleene, von Neumann, Ashby o Uttley. El lector interesado puede encontrar una revisión completa de éstos en la recopilación de Shannon y Mc Carthy (1956) y en la de Wiener y Schadé (1969).

Modelos Actuales

A partir de los fundamentos antes expuestos Fukushima (1975) desarrolló el cognitrón, una versión de la adalina aplicada a procesos de reconocimiento de formas. Este sistema evolucionó hacia las estrategias de aprendizaje sin supervisión en lo que se conoce como neocognitrón y cuyas características principales son (Figura 3.16):

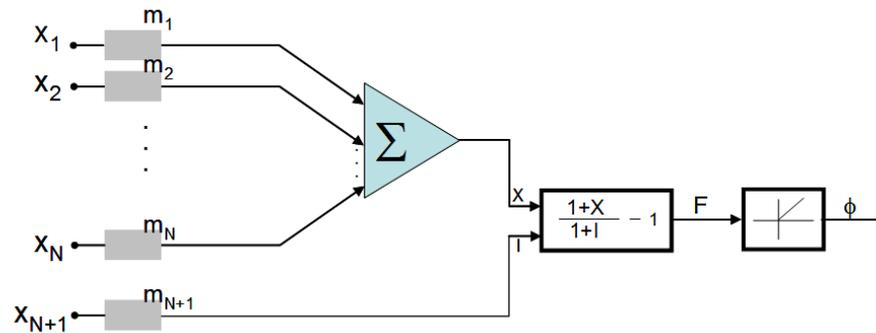


Figura 3.16 Neocognitrón

1. Sólo hay una entrada inhibidora

2. A diferencia de la neurona formal, el efecto de la entrada inhibidora no es absoluto, sino que se define por la función:

$$F(X, I) = \frac{1 + X}{1 + I} - 1 \quad 3.18$$

donde X e I corresponden al valor total de excitación e inhibición respectivamente:

$$X = \sum_{k=1}^N m_k x_k \quad 3.19$$

$$I = m_{N+1} z \quad 3.20$$

siendo z evidentemente el valor de la entrada inhibidora. $F(X, I)$ contiene un elemento no lineal cuya salida (la definitiva del modelo) es cero si la inhibición supera la excitación, o $F(X, I)$ en caso contrario, es decir:

$$\Phi(F) = F(X, I) \quad \text{si} \quad F(X, I) \geq 0 \quad 3.21$$

$$\Phi(F) = 0 \quad \text{si} \quad F(X, I) < 0 \quad 3.22$$

Estos elementos, dispuestos en capas de procesamiento, pueden eliminar las deformaciones geométricas (tamaño, giros, etc.) o físicas (ruido principalmente) que presenten los patrones de entrada una vez finalizado el proceso adaptativo. El esquema de aprendizaje sin supervisión significa que dada una entrada correspondiente a un prototipo, la excitación continua de las líneas x_j correspondientes al valor lógico 1 (suponiendo entradas binarias) hará que se incrementen los pesos asociados a ellas a la vez que se disminuyen los demás.

Volviendo a la estructuración en capas, estas células (como las llama Fukushima) se disponen en planos superpuestos de manera que cada capa recibe sus entradas desde las salidas de la anterior a la vez que envía sus propias salidas a las entradas de la siguiente (posible en ambos sentidos).

La limitante computacional en los 60 permitió sólo avances en niveles teóricos que no pudieron ser concretados en realizaciones prácticas significativas, pero que constituyen la base conceptual de los más modernos y avanzados modelos neuronales. El surgimiento de modelos tan exitosos como el trabajo de Hopfield (1986, 1988), la propuesta evolutiva de Linsker (1988), la llamada teoría de *resonancia adaptativa* (ART) de Carpenter y Grossberg (1988) y la formulación analítica de T. Kohonen (1988) representan el inicio de la etapa moderna de esta clase de estructuras inteligentes.

Redes de alimentación al frente RAF y algoritmo estándar de Retropropagación RP

El modelo neuronal más prominente y ampliamente empleado (presente en cerca del 80% de las aplicaciones prácticas) es el de red multicapa RNM con aprendizaje por retropropagación RP (Rumelhart et al., 1986). La importancia del algoritmo RP, el cual permitió generalizar a los perceptrones hacia arquitecturas con estratos ocultos, en el progreso del neurocómputo se describe detalladamente en Sarkar (1995) y Riedmiller y Braun (1993).

No es intención de este apartado revisar a fondo las ideas del conexionismo (cómputo neuronal) o del aprendizaje por RP, sino describir de forma general el proceso de aprendizaje-máquina y se da por hecho que el lector está familiarizado con los principios básicos sobre sistemas conexionistas. Lecturas recomendadas a este respecto son: Fahlman y Hinton (1987) y Rumelhart et al. (1986) además del Apéndice 3.1.A, contenido en este trabajo de tesis.

Una RNM (llamada en lo sucesivo RN) es una red neuronal de alimentación al frente en la cual un vector de entrada arbitrario es propagado hacia el frente a través de la red, originando un vector de activación que será la producción del estrato de salida (Haykin, 1994). La red se comporta como una función (aproximador universal) que mapea el vector de entrada hacia el vector de salida y esta función es determinada por la estructura (nodos) y las conexiones (pesos) de red. El objetivo de la RP es modificar los pesos de la red de tal forma que ésta consiga mapear la(s) entrada(s)-salida(s) de manera eficiente. Una interesante interpretación sobre la justificación como aproximador universal de las estructuras neuronales se detalla en el Apéndice 3.1.B.

RP estándar

Permita a u_i^l ser la i ésima neurona en el l ésimo estrato (el estrato de entrada es el o ésimo estrato y el estrato de salida es el k ésimo estrato) y a n_l ser el número de neuronas en el estrato l ésimo.

El peso de la conexión entre la neurona u_i^l y la neurona u_i^{l+1} se denota por w_{ij}^l . Ahora $\{x_1, x_2, \dots, x_m\}$, es el conjunto de patrones de entrada que la red debe aprender y $\{t_1, t_2, \dots, t_m\}$ es el conjunto de patrones objetivo (de salida) correspondiente a las entradas específicas. Los pares (x_p, t_p) $p = 1, \dots, m$ son llamados patrones de entrenamiento. Cada x_p es un vector n_0 -dimensional con componentes x_{ip} . Cada t_p es un vector n_k -dimensional con componentes t_{ip} .

La salida o_{ip}^0 de una neurona u_i^0 en el estrato de entrada, cuando el patrón x_p es presentado a la red, coincide con su entrada neta net_{ip}^0 , es decir, con el i ésimo elemento de x_p, x_{ip} . Para los otros estratos, la entrada neta net_{ip}^l de la neurona u_i^{l+1} (cuando el patrón de entrada x_p es presentado a la red) se calcula como sigue:

$$net_{ip}^{l+1} = \sum_{j=1}^{n_l} w_{ij}^l o_{jp}^l - \theta_i^{l+1}, \quad 3.23$$

donde o_{jp}^l es la entrada de la neurona u_j^l (usualmente $o_{jp}^l = f(net_{jp}^l)$ con f siendo una función de activación no lineal) y θ_i^{l+1} es el sesgo de la neurona u_i^{l+1} . Para mantener una representación homogénea, en lo sucesivo, los sesgos serán interpretados como los pesos de una conexión a una "unidad de sesgo" con un valor constante de salida de 1.

El error ε_{ip}^k de la neurona u_i^k del estrato de salida para el par de entrenamiento (x_p, t_p) se calcula con:

$$\varepsilon_{ip}^k = t_{ip} - o_{ip}^k \quad 3.24$$

Para los estratos ocultos el error ε_{ip}^l es calculado de manera recursiva a partir de los errores en otros estratos. La regla estándar de RP usa estos errores para ajustar los pesos (establecido aleatoriamente en el inicio) de tal forma que los errores gradualmente se reducen.

El comportamiento de la red puede ser ajustado usando la suma total de los errores al cuadrado (STEC):

$$E = \frac{1}{2} \sum_{p=1}^m \sum_{i=1}^{n_k} (\varepsilon_{ip}^k)^2 \quad 3.25$$

El proceso de entrenamiento se detiene cuando el error E se reduce a un nivel aceptable, o cuando no se obtienen mejoras posteriores.

En esta investigación se usa la variante del algoritmo estándar de RP donde la actualización de w_{ij}^l en el paso de aprendizaje s ésimo (llamado "época") se realiza de acuerdo con las siguientes ecuaciones:

$$w_{ij+\Delta w_{ij}^l(s)}^l(s+1) = w_{ij}^l(s) \quad 3.26$$

$$\Delta w_{ij}^l(s) = \eta \frac{\partial E}{\partial w_{ij}^l(s)} = \eta \delta_{ip}^{l+1}(s) o_{jp}^l(s) \quad 3.27$$

con $\delta_{ip}^{l+1}(s)$ refiriéndose a la señal de error de la neurona i en el estrato $l+1$ para el patrón p en la época S , la cual es el producto de la primera derivada de la función de activación y el error $\varepsilon_{ip}^{l+1}(s)$, y η es un parámetro llamado tasa de aprendizaje.

Mejoras al algoritmo estándar de RP

Varios métodos han sido explorados para mejorar el comportamiento en generalización y el tiempo de convergencia de la RP. La investigación en este campo se concentra principalmente en: i) el establecimiento óptimo de las tasas de aprendizaje y momento (Momentum y Rprop) (Chen, 1997; Eaton y Oliver, 1992; Jacobs, 1989; Riedmiller, 1994; Silva y Almeida, 1990; Tollenaere, 1990; Vogl et al., 1988; Weir, 1991); ii) el establecimiento óptimo de los pesos iniciales (Cherkassky y Shepherd, 1998; Denooux y Lengelle, 1993; Wessels y Barnard, 1992); iii) la mejora en la representación de contrastes en los patrones de entrada (Kruschke y Movellan, 1991; Anand et al., 1993; Kwon y Cheng, 1996; Vital et al., 1995; Zhang, 1994); iv) modificaciones a la función de error (Ahmad y Salam, 1992; Holt y Semnani, 1990; Ooyen y Nienhuis, 1992; Joost y Schiffmann, 1998; Solla et al., 1988); y v) técnicas para encontrar las arquitecturas óptimas ("podado") (Schittenkopf et al., 1997; Hirose et al., 1991). En este trabajo de tesis se hace uso de las modificaciones indicadas en el inciso i.

Momentum. En el método Momentum se implementa un coeficiente variable de tasa de aprendizaje al adicionar una fracción del último cambio de pesos al ajuste de los pesos de la siguiente iteración, de acuerdo con:

$$\Delta w_{ij}^l(s) = \eta \frac{\partial E(s)}{\partial w_{ij}^l(s)} + \mu \frac{dE(s-1)}{dw_{ij}^l(s-1)} \quad 3.28$$

donde μ es el parámetro momentum. Con este método decrece la oscilación de búsqueda (que ocurre comúnmente con tasas de aprendizaje muy altas) y acelera la convergencia. Para una discusión más detallada ver (Eaton y Oliver, 1992; Jacobs, 1989; Tollenaere, 1990).

Rprop (retropropagación resistente). Es una de las variaciones más veloces del algoritmo RP (Riedmiller, 1994; Schiffmann et al., 1993). Es un esquema adaptativo de aprendizaje local (aprendizaje supervisado) cuyo principio básico es eliminar la influencia negativa de la magnitud de la derivada parcial $\partial E / \partial w_{ij}^l$ sobre el cambio en los pesos. El signo de la derivada se usa para indicar la dirección de la actualización mientras que la magnitud del cambio en descensos se determina exclusivamente por medio de un valor de actualización específico para pesos $\Delta_{ij}^l(S)$ como sigue:

$$\Delta w_{ij}^l(s) = \begin{cases} -\Delta_{ij}^l(s) & \text{si } \frac{\partial E(s)}{\partial w_{ij}^l(s)} > 0, \\ +\Delta_{ij}^l(s) & \text{si } \frac{\partial E(s)}{\partial w_{ij}^l(s)} < 0, \\ 0 & \text{cualquier otro caso} \end{cases}$$

3.29

La actualización de valores $\Delta_{ij}^l(s)$ se modifica de acuerdo con la siguiente ecuación:

$$\Delta_{ij}^l(s) = \begin{cases} \eta^+ \Delta_{ij}^l(s-1) & \text{si } \frac{\partial E(s-1)}{\partial w_{ij}^l(s-1)} \bullet \frac{\partial E(s)}{\partial w_{ij}^l(s)} > 0, \\ \eta^- \Delta_{ij}^l(s-1) & \text{si } \frac{\partial E(s-1)}{\partial w_{ij}^l(s-1)} \bullet \frac{\partial E(s)}{\partial w_{ij}^l(s)} < 0, \\ \Delta_{ij}^l(s-1) & \text{cualquier otro caso} \end{cases}$$

3.30

donde η^+ y η^- son constantes que cumplen con $0 < \eta^- < 1 < \eta^+$.

En Rprop se definen a priori tres parámetros de ejecución: el valor de actualización inicial $\Delta_{ij}^l(0)$, el cual directamente determina el tamaño del primer paso de pesos (comúnmente establecido como $\Delta_{ij}^l(0) = 0.1$), y los límites para la actualización de valores Δ_{max} y Δ_{min} , las cuales previenen a los pesos de hacerse demasiado grandes o demasiado pequeños. Típicamente $\Delta_{max} = 50.0$ y $\Delta_{min} = 0.0000001$ para bases de datos normalizadas a la unidad, la convergencia es poco sensible a la diferencia numérica de estos parámetros. En algunos problemas prácticos puede ser ventajoso permitir sólo pasos muy cautelosos (pequeños) para prevenir que el algoritmo se atasque rápidamente en un mínimo local. Para un análisis detallado de los criterios de selección y su efecto sobre el desarrollo de la red ver (Riedmiller, 1994; Schiffmann et al., 1993).

A pesar de que la adición de estas dos mejoras (Momentum y Rprop) hace que el RP estándar sea considerablemente más rápido, todavía se sufre de algunos problemas operacionales durante la evolución de las redes. Se recomienda al lector interesado en este tema la revisión de (Gori y Tesi, 1992; Riedmiller, 1994).

3.2.Lógica Difusa

Las ideas básicas que subyacen a la Lógica Difusa LD y la Teoría de Conjuntos Difusos (Zadeh, 1965) fueron bien acogidas por algunos teóricos (especialmente los matemáticos) pero de forma mayoritaria la comunidad científica mostró escepticismo e incluso una hostilidad manifiesta. La tradición Cartesiana que promueve el respeto a lo cuantitativo y preciso y el desdén por lo cualitativo e impreciso está arraigada tan profundamente en nuestro pensamiento que es difícil desprenderse de ella sin presentar resistencia. Lord Kelvin –uno de los intelectos más excepcionales del siglo XIX– dictó en 1883 el dogma básico: “En la Física, un paso esencial hacia el aprendizaje de cualquier tema es encontrar principios y métodos para calcular y medir cualidades conectadas con él. Cuando se puede medir aquello sobre lo que se habla y es posible expresarlo mediante números se dice que se le conoce, en caso contrario el conocimiento es pobre e insatisfactorio, incluso nulo”.

Actualmente, la controversia que rodea a la LD continúa aunque no en el mismo grado. El éxito de numerosas aplicaciones es demasiado visible como para ignorarlas y varias ramas de la ciencia y la ingeniería se han visto obligadas a explorar esta metodología y han aprovechado los beneficios de adoptar una visión aproximada del mundo.

La representación difusa del conocimiento

En lenguaje natural se describe a los objetos o situaciones en términos imprecisos: grande, joven, tímido, etc. El razonamiento basado en estos términos no puede ser exacto pues normalmente representan impresiones subjetivas, quizá probables pero no exactas. La Teoría de Conjuntos Difusos resulta adecuada para representar el conocimiento humano y dotar a los fenómenos y observaciones de más de dos estados lógicos. En la construcción de Conjuntos Difusos para su implementación en Sistemas Inteligentes son necesarias técnicas específicas de Adquisición de Conocimiento que permitan manipular la información de manera eficiente.

La representación habitual del conocimiento en términos difusos se realiza por medio de reglas, del tipo:

$$\text{Si } x_1 \text{ es } A_{1,1}$$

$$\text{y/o } x_2 \text{ es } A_{2,1}$$

$$\text{y/o } x_n \text{ es } A_{1,n}$$

$$\text{Entonces } y \text{ es } B_1$$

Cada variable que interviene como hipótesis en una regla tiene asociado un dominio que puede estar dividido en tantos Conjuntos Difusos como el experto considere oportuno y a cada una de estas particiones se le asocia una etiqueta lingüística.

Un conjunto de términos (como el ejemplo de la Fig. 3.17) es un conjunto finito comúnmente con 7 ± 2 elementos que son restricciones de una variable lingüística difusa. El número de elementos debe ser tal que describa cualquier situación relativa al contexto en el que se sitúa el problema.

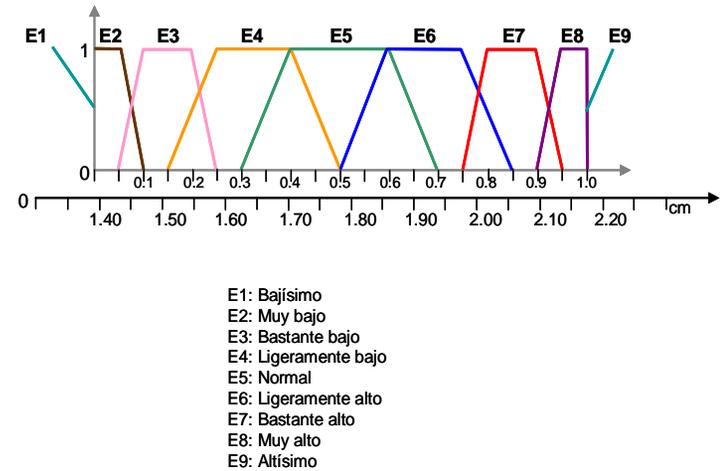


Figura 3.17. Tabla de términos para la variable lingüística “altura” (referida a personas)

El Razonamiento Aproximado

Zadeh introdujo la teoría del razonamiento aproximado (Zadeh, 1987) y a partir de sus trabajos diversas contribuciones en este campo han sido reportadas en todo el mundo. Aunque superficialmente pueda parecer que la teoría del razonamiento aproximado y la lógica clásica se diferencian considerablemente, la lógica clásica puede ser vista como un caso especial de la primera. En ambos sistemas, las premisas son inductoras de subconjuntos de mundos posibles que las satisfacen, aunque en el caso de la teoría del razonamiento aproximado esos conjuntos serán subconjuntos difusos. La inferencia en ambos sistemas está basada en una regla de inclusión: una hipótesis se infiere de una colección de premisas si el subconjunto de mundos posibles que satisfacen la conjunción de las premisas está contenido en el subconjunto de mundos posibles que satisfacen la hipótesis.

El fundamento del razonamiento aproximado es el uso de las variables y la representación de las proposiciones en términos lingüísticos (subconjuntos difusos) como valores de esas variables. La lógica clásica sólo usa de modo implícito la idea de *variable*, en el sentido de valor de verdad asociado a una proposición. Sin embargo, su naturaleza binaria le permite ocultar este hecho, ya que nos podemos referir a una proposición que es verdadera por su denotación, p , y a una que es falsa simplemente por su negación, $\neg p$, evitando así la introducción de una variable V_p cuyo valor sea la valoración de la proposición p .

El uso del concepto de variable en la teoría del razonamiento aproximado conduce a dominios que no están en el ámbito de aplicación de la lógica clásica, como es el caso de los problemas que tratan la toma de decisiones, el control y el reconocimiento de patrones. La teoría del razonamiento aproximado permite representar cuantificadores lingüísticos situados entre el “para todo” y el “existe” clásicos. Estos cuantificadores se usan para incorporar conocimiento por sentido común (Reiter, 1980; Yager, 1982) y resultan una extensión muy ventajosa cuando se modelan fenómenos naturales por su capacidad de tratar con el conocimiento ingenieril prototípico.

La lógica binaria puede ser vista como un caso especial de la teoría del razonamiento aproximado en el cual los conjuntos base tienen dos elementos $\{T, F\}$ y los grados de pertenencia se restringen a 1 ó 0. La lógica posibilista puede ser vista como una extensión de ésta, en tanto que, aunque se restringen los valores de los conjuntos base a dos, T y F, se permite que los grados de pertenencia sean números en el intervalo unidad.

La LD extiende la lógica binaria permitiendo su formalización en términos de la teoría del razonamiento aproximado. Así, “ p es verdadero”, se representa: V_p es $\{1/T, 0/F\}$, p es falso se representa: V_p es $\{0/T, 1/F\}$, mientras que V_p es $\{1/T, 1/F\}$ indica que el valor de verdad de la proposición es desconocido. En cualquiera de los casos, el conjunto base asociado a la variable valor de verdad de la proposición p es $\{T, F\}$.

La regla principal de inferencia en lógica clásica, modo de razonamiento ya introducido por los megáricos y estoicos en tiempos de Aristóteles, es el Modus Ponens (nombre asignado en la Edad Media), que establece: si se tiene la regla $A \rightarrow B$ y se da el hecho A se puede concluir B . En lógica difusa se puede generalizar esta regla, quedando su esquema de la siguiente forma:

Regla: Si x es A , entonces y es B .

Hecho: x es A'

Conclusión: y es B'

Por ejemplo, la regla podría ser “Si la ciudad es grande (x es A) entonces el tráfico es muy denso (y es B)”, el hecho podría ser “la ciudad no es muy grande (x es A')”, ¿Qué se podría decir del tráfico ($B'(x)$)?

Supongamos que las variables están relacionadas no necesariamente por una función, sino por cualquier relación. Supongamos que R es una relación

binaria difusa en el universo $X \times Y$ y que A' y B' son conjuntos difusos en X y Y , respectivamente. Si conocemos R y A' podríamos conocer B' mediante la denominada Regla de Composición de Inferencia:

$$B' = A'(x) \circ R(x, y) \tag{3.31}$$

$$B'(y) = \sup_{x \in X} \min[A'(x), R(x, y)] \tag{3.32}$$

donde $R(x,y) = I(A(x), B(y))$ (Función de Implicación).

Conceptos Básicos

La Teoría de Conjuntos Difusos fue introducida por Lotfi A. Zadeh a mediados de los años 60. Previamente, en 1922 Lukasiewicz cuestionaba la lógica clásica bivaluada (valores cierto y falso) y adelantaba una lógica de valores ciertos en el intervalo unidad como generalización de una lógica trivaluada. Max Black en un artículo de 1937 titulado "Vagueness: An exercise in Logical Analysis" y Karl Menger con el artículo de 1942 "Statistical Metrics" y los de los años 50 sobre relaciones difusas de no-distinción, sentaron las bases de lo que hoy se conoce como LD, inscrita en el contexto de la lógica multivaluada.

¿Qué son los conjuntos difusos?

En un conjunto clásico se asigna el valor 0 ó 1 a cada elemento para indicar la pertenencia a dicho conjunto, esta idea puede generalizarse de forma que se asignen valores a los elementos del conjunto que señalen el grado de pertenencia de dichos elementos al conjunto en cuestión. Esta función se llama función de pertenencia o membresía y el conjunto por ella definida conjunto difuso (ejemplo en la Fig. 3.18).

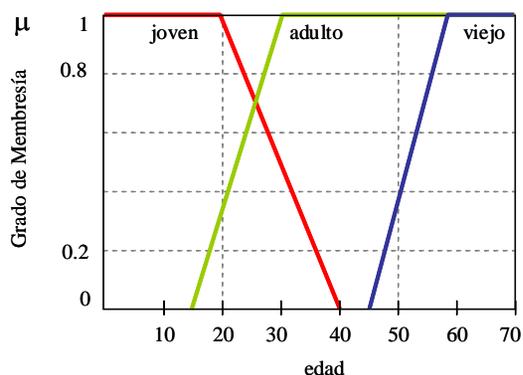


Figura 3.18. Funciones de membresía para los conceptos joven, adulto y viejo de la variable edad

La función de pertenencia μ_A con la que un conjunto difuso A se define, siendo $[0,1]$ el intervalo de números reales que incluye los extremos, tiene la forma: $\mu_A = X \rightarrow [0,1]$, es decir, mientras que en un conjunto clásico los elementos pertenecen o no pertenecen a él totalmente (por ejemplo un número puede pertenecer o no al conjunto de los pares, pero no pertenecer parcialmente) en los conjuntos difusos hay grados de pertenencia referidos a un universo local.

Definición

Siendo X un conjunto universal clásico, una función real $\mu_A: X[0,1]$ se denomina de membresía de A y define el conjunto difuso A de X. Esto es el conjunto de todos los pares $(x, \mu_A(x))$ con $x \in X$.

Por ejemplo, considerando la Fig. 3.18 en el contexto de la sociedad actual una persona de 50 años pertenecerá al conjunto difuso "viejo" con un grado supongamos de 0.4. Si en vez de usar de referencia esta sociedad aludimos a una cuya esperanza de vida fueran 40 años, este grado cambiaría radicalmente.

Operaciones con Conjunto Difusos

Unión, intersección y negación son las operaciones básicas de conjuntos clásicos. Con base en estas tres operaciones pueden ser establecidas un cierto número de identidades difusas.

Unión. La función de membresía de la unión de dos conjuntos difusos A y B con funciones de membresía μ_A y μ_B , respectivamente, se define como el valor máximo de dos funciones de membresía individuales, llamado el criterio del máximo.

$$\mu_{A \cup B} = \max(\mu_A, \mu_B) = \mu_A \vee \mu_B \quad 3.33$$

La operación unión en teoría de conjuntos difusos es el equivalente al O del álgebra booleana.

Intersección. La función de membresía de la intersección de dos conjuntos difusos A y B con funciones de membresía μ_A y μ_B , respectivamente, se define como el mínimo de dos funciones de membresía individuales, llamado el criterio del mínimo.

$$\mu_{A \cap B} = \min(\mu_A, \mu_B) = \mu_A \wedge \mu_B \quad 3.34$$

La intersección en teoría de conjuntos difusos es el equivalente al Y en álgebra booleana.

Complemento. La función de membresía del complemento de un conjunto difuso A con función de membresía μ_A es definida como la negación de la función de membresía especificada, llamado el criterio de negación.

$$\mu_{\bar{A}} = 1 - \mu_A \quad 3.35$$

La operación complemento en teoría de conjuntos difusos es el equivalente de la operación NO en álgebra booleana.

Las reglas clásicas en teoría de conjuntos (como la de Morgan, Asociativa, Conmutativa, Distributiva, etc.) también aplican a la teoría de conjuntos difusos (Jang *et al.*,1997).

En la Fig. 3.19 se muestran estas tres operaciones básicas: Fig. 3.19a se muestran dos conjuntos difusos A y B; Fig. 3.19b presenta el complemento de A; Fig. 3.19c es la unión de A y B; y la Fig. 3.19d representa la intersección de A y B.

Posteriormente se definieron clases de funciones con propiedades

axiomáticas adecuadas al uso de cada operador, principalmente las T-normas y T-conormas, que sirven como modelos de la *intersección* y la *unión* respectivamente. Las T-normas y T-conormas se desarrollaron para establecer la desigualdad triangular (en un triángulo cualquiera la suma de dos lados siempre es mayor que el tercero, Menger, 1942). El concepto de norma triangular (T-norma) surge de la necesidad de *componer* (sumar probabilísticamente) los lados de un triángulo que no *midan* un número sino una función de distribución de probabilidad y posteriormente se reveló como una herramienta adecuada para formalizar la intersección difusa.

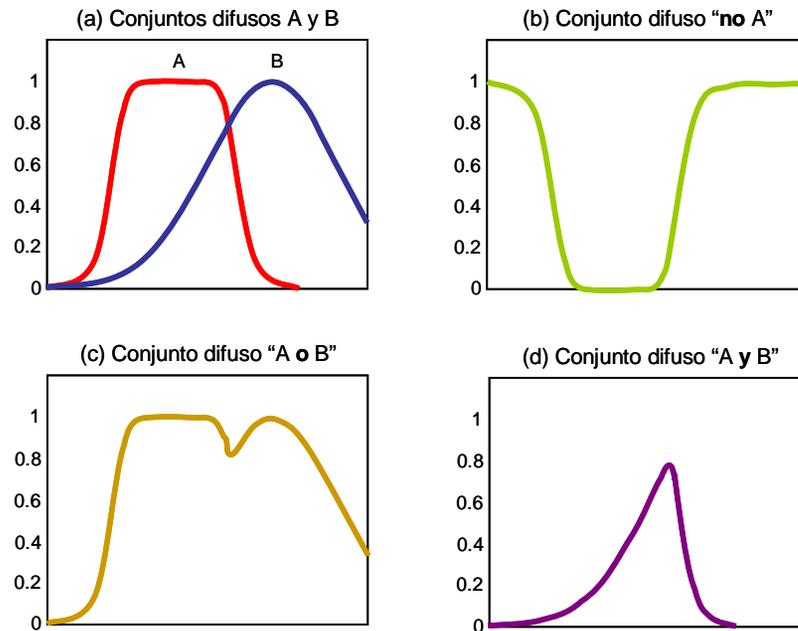


Figura 3.19. Operaciones en conjuntos difusos

Para completar un tipo de razonamiento análogo al que se realiza con lógica clásica es necesario definir el concepto de *implicación* o *inferencia*. Una implicación difusa I es, en general, una función de la forma:

$$I : [0,1] \times [0,1] \rightarrow [0,1] \quad 3.36$$

para cualesquiera dos valores ciertos a y b de proposiciones difusas p,q define el valor cierto I(a,b) de la proposición condicional “si p entonces q”, siendo una extensión de la implicación clásica $p \rightarrow q$ del dominio restringido {0,1} al dominio completo [0,1].

En lógica clásica una implicación se puede expresar de distintas formas y todas son equivalentes, sin embargo sus extensiones a lógica difusa no son directas y han dado lugar a diferentes clases de implicaciones difusas, como el llamado “Principio de Extensión” que permite la generalización de conceptos matemáticos *exactos* hacia la Teoría de Conjuntos Difusos: “cualquier función que asocie puntos x_1, x_2, \dots, x_n del conjunto *exacto* X al Y puede generalizarse de forma que asocie subconjuntos difusos de X en Y. Definiciones, terminología y operaciones teóricas entre conjuntos difusos pueden ser consultados en Jang *et al.*, (1997).

Inferencia desde Datos Imprecisos. ¿Dónde radica el éxito de las aplicaciones difusas?. El éxito radica en la simplicidad, tanto conceptual como de desarrollo. Las aplicaciones más notables se encuentran en el área del control y a estos ejercicios prácticos se deben los avances y la formalización de los métodos difusos. Los dos paradigmas clásicos del control difuso son el sistema de inferencia Mamdani (Munukata y Jani, 1994) y el Takagi-Sugeno (Takagi and Sugeno, 1985).

Las reglas de *Inferencia Difusa* tienen la misma estructura que las clásicas. Las reglas R₁ y R₂, por ejemplo, tienen la forma:

R₁ : Si X O Y Entonces Z

R₂ : Si X O Y Entonces W

La diferencia con las reglas de *inferencia* convencionales es la semántica de los operadores difusos. Estos (O,Y) son identificados con las funciones *máx* y *mín*, respectivamente. Esto es, por ejemplo, permita a los valores de X y Y ser 0.4 y 0.7, entonces

$$X (O) Y = \text{máx} (0.4, 0.7) = 0.7$$

$$X (Y) Y = \text{mín} (0.4, 0.7) = 0.4$$

El *mecanismo de inferencia difusa* (Kandel, 1992; Takagi and Sugeno, 1985; Kosko, 1992) permite a las reglas R₁ y R₂ ser aplicadas sólo parcialmente, esto es, la regla R₁ es aplicada al 70% y la regla R₂ al 40%. El resultado de la inferencia es una combinación de las proposiciones Z y W.

La estructura básica de un *sistema de inferencia difuso* consta de: a) base de reglas difusas; b) base de datos (incluye funciones de membresía) y c) un *mecanismo de razonamiento*, o procedimiento de inferencia sobre las reglas

para obtener una conclusión razonable de salida. Con entradas y salidas exactas, un *sistema de inferencia difusa* implementa un mapeo no lineal desde el espacio de entradas hacia el espacio de salida a través de un cierto número de reglas Si-Entonces que describen el comportamiento local del mapeo. El antecedente de una regla (oraciones antes de la conclusión Entonces) define una región difusa en el espacio de entrada mientras que la consecuencia (oración después de Entonces) es la salida en la región difusa.

Los sistemas básicos de *inferencia difusa* pueden emplear entradas exactas o difusas, pero las salidas son siempre difusas. Cuando, por la aplicación, se requiere una salida exacta (por ejemplo en un controlador) es necesario un método *inverso difuso* para extraer los valores exactos adecuados. Un sistema de inferencia difuso con salida exacta se describe en la Fig. 3.20.

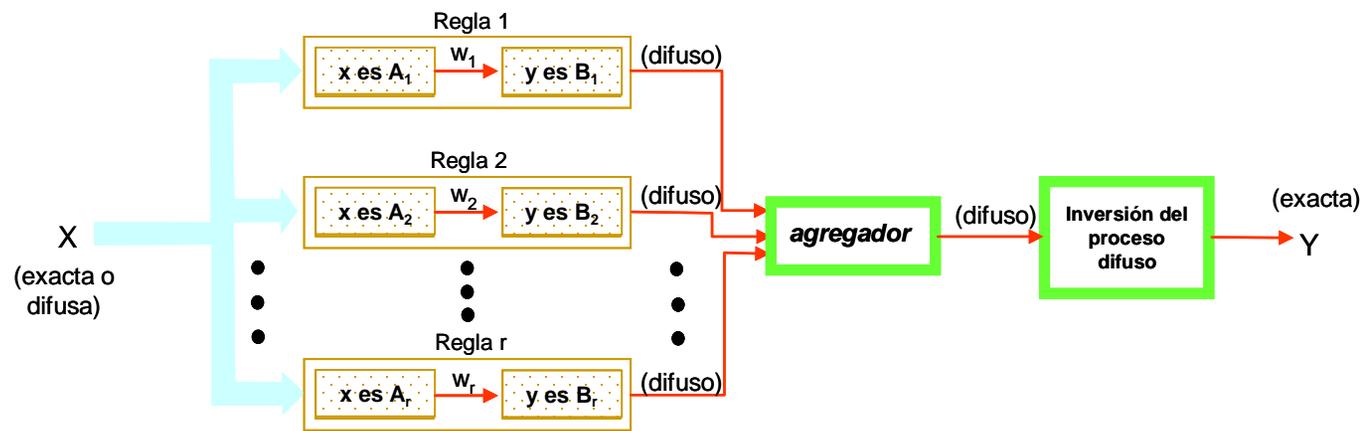


Figura 3.20 Diagrama de bloques para un sistema de inferencia difusa

Existen varios métodos para invertir el proceso difuso de un conjunto difuso A en un universo de discurso Z (Fig. 3.21):

1) Centroide

$$Z_{COA} = \frac{\int \mu_A(z)zdz}{\int \mu_A(z)dz} \quad 3.37$$

donde $\mu_A(Z)$ es la *función de membresía* de salida agregada. Éste es el método más ampliamente adoptado como estrategia *inversa difusa* y es similar al cálculo de valores esperados en distribuciones de probabilidad.

2) Bisector de área z_{BOA} , la cual satisface

$$\int_{\alpha}^{z_{BOA}} \mu_A(z)dz = \int_{z_{BOA}}^{\beta} \mu_A(z)dz \quad 3.38$$

donde $\alpha = \min\{z|z \in Z\}$ y $\beta = \max\{z|z \in Z\}$. Esto es, la línea vertical $z = z_{BOA}$ parte la región entre $z = \alpha$, $z = \beta$, $y = 0$ y $y = \mu_A(z)$ en regiones con la misma área.

3) Promedio de máximos z_{MOM} .

$$z_{MOM} = \frac{\int z dz}{\int dz} \quad 3.39$$

donde $Z' = \{z|\mu_A(z) = \mu^*\}$. En particular, si $\mu_A(z)$ tiene un máximo único en $\mu = \mu^*$, entonces $Z_{MOM} = z^*$. Si $\mu_A(z)$ alcanza su máximo en cualquier $z \in [z_{izq}, z_{der}]$ (como en la Fig. 3.21) entonces $z_{MOM} = (z_{izq} + z_{der})/2$.

4) El más pequeño de los máximos z_{SOM} . Es el mínimo (en términos de magnitud) de la maximización de z .

5) El más grande máximo z_{LOM} . Es el máximo (en términos de magnitud) de maximizar z .

Por sus obvios sesgos, z_{SOM} y z_{LOM} son raramente usados.

Es importante mencionar que estas operaciones *difusas inversas* no pueden ser fácilmente analizadas con rigor matemático y la mayoría de los estudios están basados en resultados experimentales (Yager y Filev, 1993).

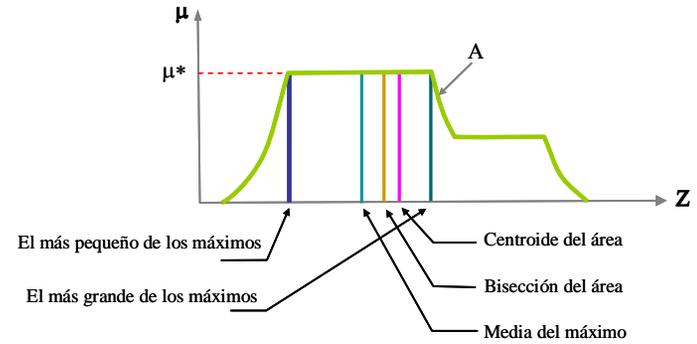


Figura 3.21 Esquemas de procesos inversos difusos

Sistema de Inferencia Mamdani

En el enfoque Mamdani un experto especifica su conocimiento en forma de reglas gramaticales y define las etiquetas lingüísticas que describen los estados de las variables. Para cada entrada (X_1, X_2, \dots, X_n) se especifica la correspondiente etiqueta lingüística que define la salida Y. Cada una de las n variables de entrada y la de salida se reparten en conjuntos difusos específicos. Así se definen P_1 conjuntos difusos distintos en la variable X_1 . Lo mismo se puede hacer con el resto de las variables y la salida. Cada conjunto difuso P_i lleva asociado una etiqueta lingüística.

En la Base de Conocimiento las reglas tienen la forma clásica:

Si h_1 es $A^{(1)}$ y h_2 es $A^{(2)}$, ..., y h_n es $A^{(n)}$ entonces η es B

$A^{(1)}$, ..., $A^{(n)}$ y B son etiquetas lingüísticas que corresponden a los conjuntos difusos μ_1, \dots, μ_n y μ , de acuerdo a las particiones de los conjuntos X_1, X_2, \dots, X_n y Y. La base (o bloque) de reglas constará de K reglas de control. En la lógica de control se comprueba separadamente cada regla de la base de reglas y se determina el grado de cumplimiento de cada hipótesis de la regla de acuerdo a la variable medida.

Si h_1 es $A^{(1)}$ y ... h_n es $A^{(n)}$ Entonces η es B. Para cada regla se observa el grado de compatibilidad de las variables medidas x_1, x_2, \dots, x_n con las etiquetas lingüísticas $A^{(1)}$, ..., $A^{(n)}$ y después se hace la conjunción de grados de cumplimiento. Para cada regla R_r de las K de control se calcula: $\alpha_r = \min\{\mu_{1r}, \dots, \mu_{nr}\}$. La salida de R_r es un conjunto difuso de valores de salida obtenidos cortando el conjunto difuso μ_{ir} asociado con la conclusión de la regla R_r en el nivel de cumplimiento α_r .

Supongamos, por ejemplo, una base de reglas como la siguiente:

R_1 : Si ángulo A es positivo pequeño y ángulo B es aproximadamente cero

Entonces ángulo de salida es positivo pequeño

R_2 : Si ángulo A es positivo medio y es ángulo B aproximadamente cero

Entonces ángulo de salida es positivo medio

Las variables de entrada (ángulo A y ángulo B) y la de salida (ángulo de salida) tienen cada una asignada un conjunto de términos. Supongamos que

los datos reales medidos son los siguientes: ángulo A = 36° y ángulo B = -2.25° . ¿Cuál debe ser la salida (orden) que debe dar el controlador difuso?. La evaluación de la regla R_1 se presenta en la Fig. 3.22a Y la evaluación de la regla R_2 se muestra en la Fig. 3.22b Tras la evaluación de cada regla, se combinan todos los conjuntos difusos obtenidos de la salida de las reglas mediante la operación máxima (unión), como se indica esquemáticamente en la Fig. 3.23.

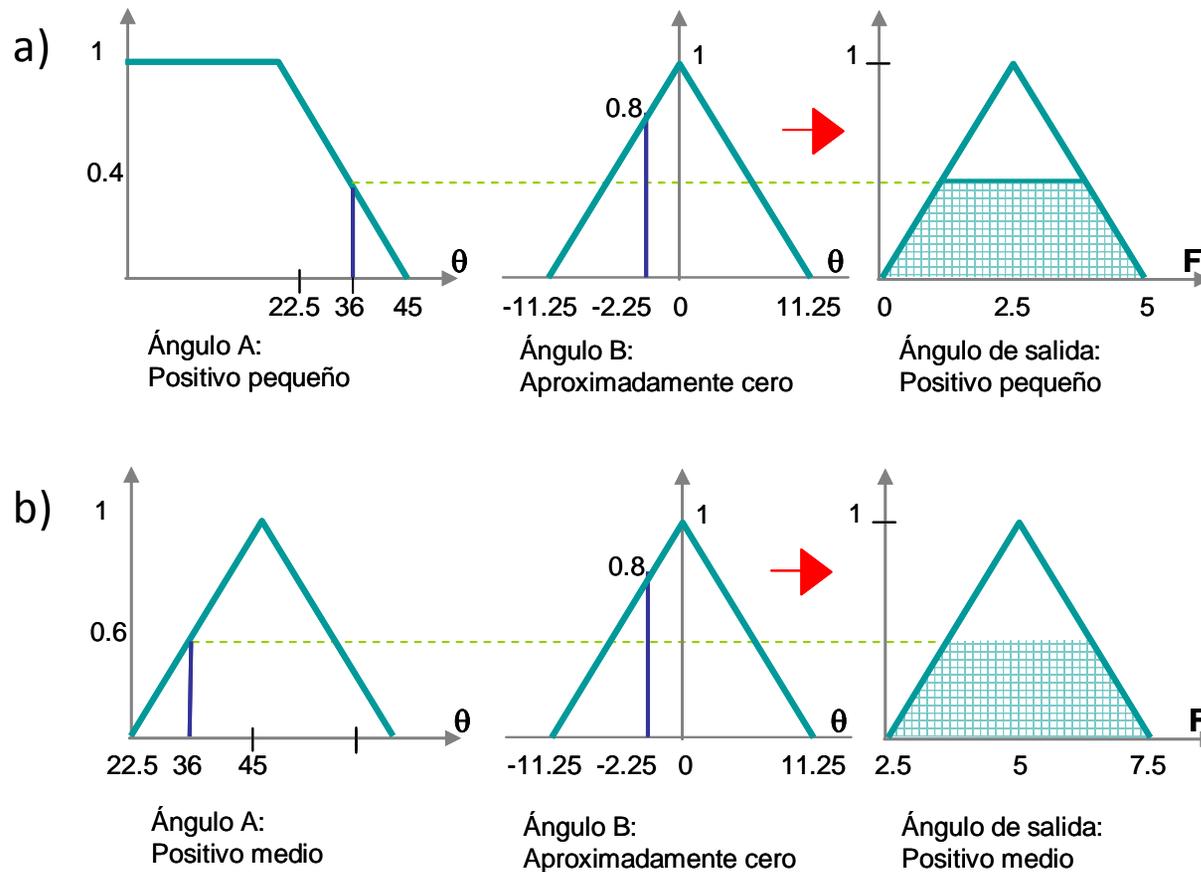


Figura 3.22 Evaluación de la Regla R_2

La salida es la asociación de cada dupla de entradas medidas $(x_1, \dots, x_n) \in X_1 \times \dots \times X_n$ con un conjunto difuso de salida para Y . Pero el sistema a controlar no entendería un conjunto difuso como orden, necesita un valor concreto para actuar, en nuestro ejemplo un ángulo de salida. Por ello es necesaria una interfaz de *proceso difuso inverso* que puede seguir varias estrategias: i) usar algún valor máximo del conjunto de salida (en el ejemplo cualquier valor en $[4^\circ, 6^\circ]$), ii) usar la media de los máximos (con este criterio en el ejemplo el valor de salida sería 5°) o iii) calcular la proyección sobre el eje X del centro de gravedad del conjunto difuso de salida (en el ejemplo el valor de salida con este método es 3.9°). Cada estrategia tiene ventajas e inconvenientes que deben ser revisados por el modelador para decidir sobre su aplicación en problemas particulares.

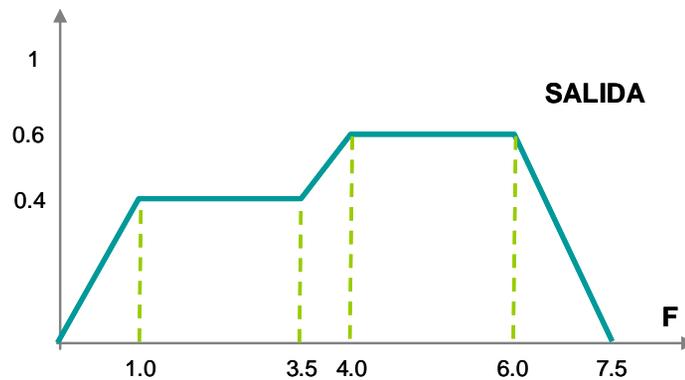


Figura 3.23 Combinación de conjuntos difusos

Sistema de Inferencia Takagi-Sugeno

Este modelo de inferencia fue propuesto por Takagi-Sugeno (1985) en un intento por desarrollar una aproximación sistemática para generar *reglas difusas* a partir de un conjunto de datos entrada-salida de la forma:

$$\text{Si } x \text{ es } A \text{ y } Y \text{ es } B, \text{ Entonces } z = f(x, y)$$

donde A y B son *conjuntos difusos* en el antecedente y $z = f(x, y)$ es una función exacta en la consecuencia. Comúnmente $f(x, y)$ es un polinomio sobre x y y pero puede ser cualquier función tal que sea capaz de describir la salida del modelo en la región difusa especificada por el antecedente de la regla. Si $f(x, y)$ es de primer orden el *sistema difuso* resultante es llamado TS-1, cuando $f(\cdot)$ es una constante resulta un TS de orden cero.

El procedimiento de razonamiento difuso para un TS-1er orden se ejemplifica en la Fig. 3.24 las reglas difusas tienen dos antecedentes y las salidas de cada regla son una combinación lineal de variables de entrada (p_1, q_1, p_2, q_2 , parámetros de la consecuencia) más un término constante del modelo lineal (r_1 y r_2). La salida final es el promedio pesado de cada salida parcial:

$$z = \frac{w_1 z_1 + w_2 z_2}{(w_1 + w_2)} \quad 3.40$$

Los pesos pueden ser calculados como

$$w_1 = A_1 x_1 + B_1 y_1 \quad 3.41$$

$$w_2 = A_2 x_1 + B_2 y_1 \quad 3.42$$

cuya forma general se escribe como

$$z = \frac{\sum_i^n w_i z_i}{\sum_i^n z_i} \quad 3.43$$

donde n es el número de implicaciones difusas, z_i es calculada para la entrada por la ecuación consecuente de la implicación i -ésima y el peso w_i implica el valor de verdad de la premisa de la implicación i -ésima para la entrada que se calcula

$$w_i = \prod_j A_j^i x_i \quad 3.44$$

Donde A_j^i es el grado de membresía de un conjunto difuso A , y x_i es el vector de variables de entrada.

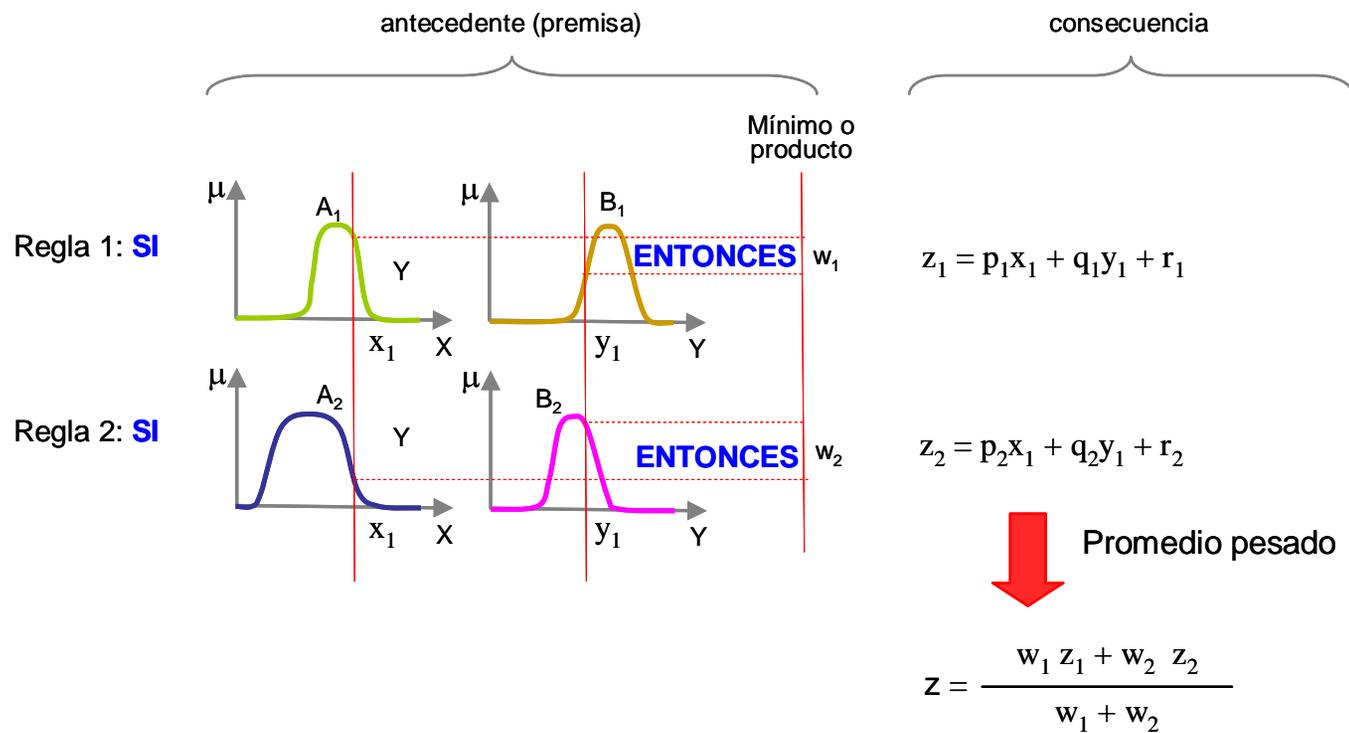


Figura 3.24 El modelo difuso Takagi-Sugeno

Reducción por métodos Difusos

El análisis de reducción es una técnica para agrupar datos y encontrar patrones en ellos para ser ordenados en grupos y clases. El pre-procesamiento remueve datos redundantes y resuelve conflictos entre patrones. La remoción de información superflua permite reducir el tamaño de la base de datos y un patrón característico (*típico*) puede sustituir a los miembros de los *grupos* formados. El resultado del análisis de reducción es un conjunto de *típicos* donde cada uno contiene las características de los patrones cercanos (vecinos próximos en el espacio de entradas y salidas).

Resolver conflictos entre datos implica identificar puntos de información incongruente en el conjunto de entrenamiento con lo que las reglas deducidas a partir de estos ejemplos son claras y simples (Bezdek, 1981; Höppner et al. (1999).

En la *reducción difusa* se calcula la similitud entre puntos de datos considerando condiciones diferentes para cada variable de acuerdo con el rango dinámico de los parámetros. La *reducción difusa* asocia a cada variable una función de membresía que establece la similitud entre dos puntos dependiendo de la diferencia entre sus valores referidos a la base asignada a cada parámetro. La distancia d_{xy} entre los dos puntos es calculada como el mínimo negativo de las similitudes:

$$d_{xy} = -\min v\{\mu_{xy}\} \quad 3.45$$

Los dos puntos que tienen la d_{xy} menor son considerados los más cercanos (Fig.3.25). El parámetro ε es la diferencia más grande entre dos puntos para que se consideren completamente similares y δ es la diferencia más pequeña para que dos puntos se estudien como totalmente no similares.

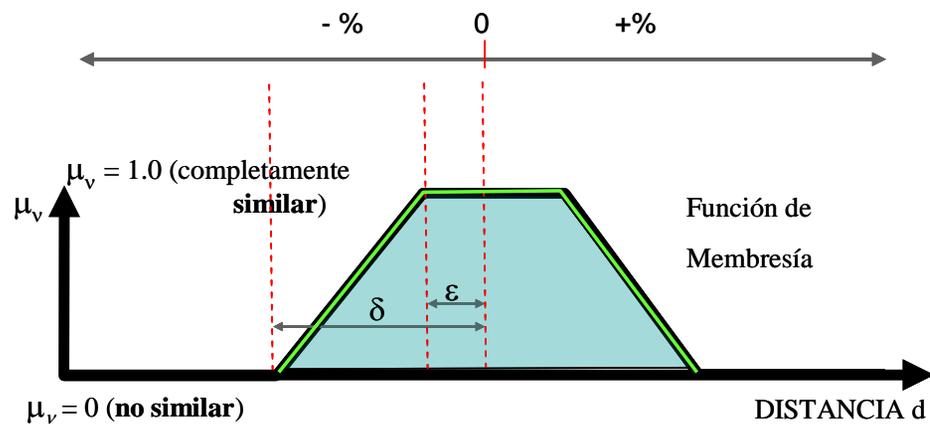


Figura 3.25 Distancias difusas

Sistemas Neurodifusos

La fusión entre RNs y Sistemas de Inferencia Difusa SID han atraído el interés de los investigadores en varias áreas de la ciencia y la ingeniería debido a la creciente necesidad de sistemas inteligentes adaptativos para resolver problemas *reales*. Las RNs aprenden, a partir de resultados, por medio del ajuste de las interconexiones entre estratos. Un SID es un marco computacional basado en conceptos de conjuntos difusos, reglas difusas Si-Entonces y razonamiento difuso. Las ventajas de la combinación de RNs y SID son obvias. Existen un gran número de aproximaciones que integran RNs y SID y la elección de la más adecuada depende totalmente de la aplicación. De manera muy general, la integración de estas dos herramientas arroja tres categorías: modelos concurrentes (Fig. 3.26), modelos cooperativos (Fig. 3.27), y modelos fusionados totalmente (Nauck y Kruse, 1996a, 1996b).

La mayoría de las aplicaciones difusas se encuentran en sistemas de control aunque en la última década el híbrido RNs-SID ha sido usado para resolver exitosamente problemas en ingeniería civil (Romo, 1999; Romo y García, 2003; Romo y García, 2004; Agrawal *et al.*, 1997; Ghaboussi *et al.*, 1991; García *et al.*, 2004, entre otros).

El cómputo neurodifuso es una estructura computacional capaz de resolver problemas complejos. Si tenemos conocimiento expresado en forma de reglas lingüísticas se puede construir un SID, si se tienen datos o se puede aprender a partir de una simulación (entrenamiento) entonces se pueden usar RNs. Para construir un SID se tienen que especificar los conjuntos difusos, los operadores difusos y la base de conocimiento. Similarmente, para construir una RN para una población el usuario necesita definir la arquitectura y un algoritmo de aprendizaje. Las desventajas de cada una de estas aproximaciones parecen complementarias y por lo tanto es natural considerar construir un sistema integrado que combine los conceptos. Mientras que la capacidad de aprendizaje es una ventaja desde la perspectiva de un SID, la formación de una base de reglas lingüísticas será ventajosa cuando se trata de RNs.

Las Figs. 3.26 y 3.27 muestran las arquitecturas neurodifusas más comunes: i) el *sistema neurodifuso cooperativo*, considerado un pre-procesador donde el mecanismo de aprendizaje neuronal determina el sistema de inferencia difuso (SID), funciones de membresía o reglas difusas a partir de datos de entrenamiento; y ii) el *sistema difuso concurrente*, donde una red neuronal y un sistema difuso trabajan juntos en algunas tareas, sin constituirse como un solo elemento de análisis.

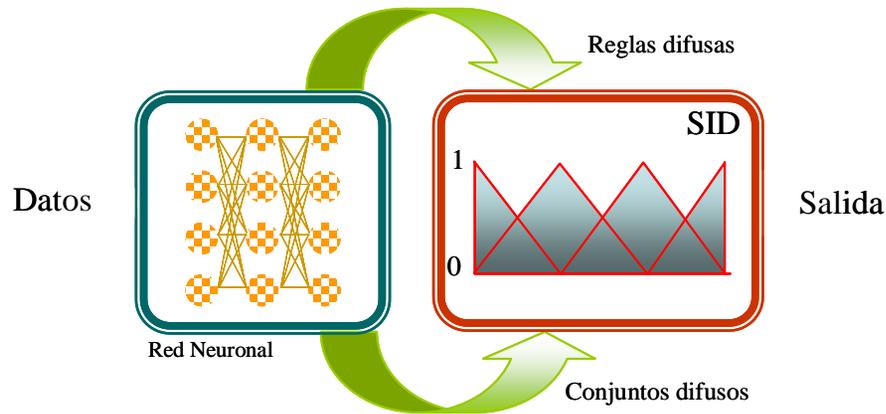


Figura 3.26. Modelo cooperativo (modificado de Abraham, 2001)

En el *sistema neurodifuso cooperativo*, una vez que los parámetros del SID son determinados (*fase de aprendizaje*) el sistema trabaja sin un esquema neuronal. La base de reglas, se obtiene generalmente por medio de una aproximación de agrupamiento que genera patrones *típicos* (*clustering* o algoritmos de *clusters*, Abraham, 2001). Las funciones de membresía iniciales se definen con base en el criterio de un grupo de expertos y son modificadas a través de un procedimiento iterativo neuronal sobre el conjunto de típicos que resulta del pre-procesamiento de los datos raíz. Esto se detiene una vez que la optimización de la solución (minimización de la función de error) alcanza un límite preestablecido.

Los *sistemas neurodifusos concurrentes* son aproximaciones en las cuales una red neuronal es usada como pre-procesamiento o como pos-procesamiento de un sistema difuso. Tales combinaciones no optimizan un *sistema difuso*, sólo tienden a mejorar el desarrollo de un sistema combinado. El *aprendizaje* toma lugar en la red neuronal y el *sistema difuso* permanece sin cambios. Este tipo de sistemas es especialmente útil si en las variables de entrada existen algunas que no puedan ser medidas directamente y resulten de una combinación entre otras variables.

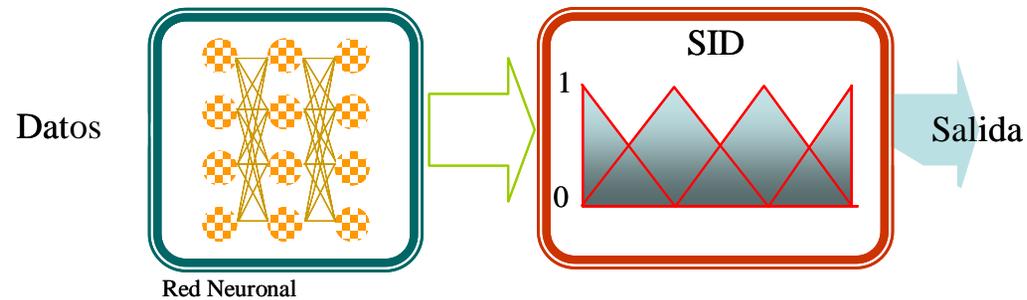


Figura 3.27 Modelo concurrente (modificado de Abraham, 2001)

Sistemas ND fusionados

En una arquitectura ND fusionada, los algoritmos de aprendizaje son usados para determinar los parámetros del SID. Los sistemas ND fusionados comparten estructuras de datos y representaciones de conocimiento.

Una manera común de aplicar un algoritmo de aprendizaje a un sistema difuso es representarlo en una arquitectura especial similar a la de RNs. Sin embargo, los algoritmos de aprendizaje convencionales de las RNs (gradiente descendiente, por ejemplo) no pueden ser aplicados directamente a tales sistemas porque las funciones usadas en los procesos de inferencia son comúnmente no diferenciables.

Este problema puede ser atacado usando funciones diferenciables en el sistema de inferencia o no usando el algoritmo estándar neuronal. Algunos de los trabajos en esta área son (siglas en su idioma nativo): GARIC (Bherenji y Khedkar, 1992), FALCON (Lin y Lee, 1991), ANFIS (Jang, 1992), NEFCON (Nauck y Kruse, 1997), FUN (Sulzberger et al., 1993), SONFIN (Juang et al., 1998), FINEST (Tano et al., 1996), EFuNN (Kasabov, 1999), dmEFuNN (Bherenji y Khedkar, 1992; Abraham y Khedkar, 2000), y muchos otros. A continuación se describe brevemente el sistema ANFIS, que será utilizado en la solución de la estimación de la velocidad de ondas de corte a partir del valor de la resistencia a la penetración del cono eléctrico.

Sistema de Inferencia Adaptativo Neurodifuso SIAN (Adaptive Neuro Fuzzy Inference System ANFIS)

SIAN es un SID Takagi-Sugeno y tiene una arquitectura de cinco estratos como se muestra en la Fig. 3.28. El primer estrato oculto se destina al proceso difuso de las variables de entrada y los operadores T-norma son desarrollados en el segundo estrato para calcular la parte del antecedente de la regla. El tercer estrato normaliza los pesos de las reglas seguido por el cuarto estrato donde se determinan los parámetros de la consecuencia de la regla.

El estrato de salida calcula la entrada total como la suma de todas las señales que llegan. SIAN usa el aprendizaje por retropropagación para determinar los parámetros de las premisas (para aprender los parámetros relacionados con las funciones de membresía) y el algoritmo de máxima pendiente para determinar los parámetros de la consecuencia. Uno de los pasos en el procedimiento de aprendizaje se divide en dos partes: i) la primera parte propaga los patrones de entrada y los parámetros óptimos de la consecuencia son estimados a través de iteraciones del proceso de máxima pendiente, mientras que los parámetros de las premisas se asumen fijos para el ciclo que ocurre a través del conjunto de entrenamiento; ii) en la segunda parte los patrones son propagados otra vez, y en esta época (o ciclo) la retropropagación se usa para modificar los parámetros de las premisas, mientras que los parámetros de las consecuencias permanecen fijos. Este procedimiento se repite hasta alcanzar un criterio de convergencia predeterminado.

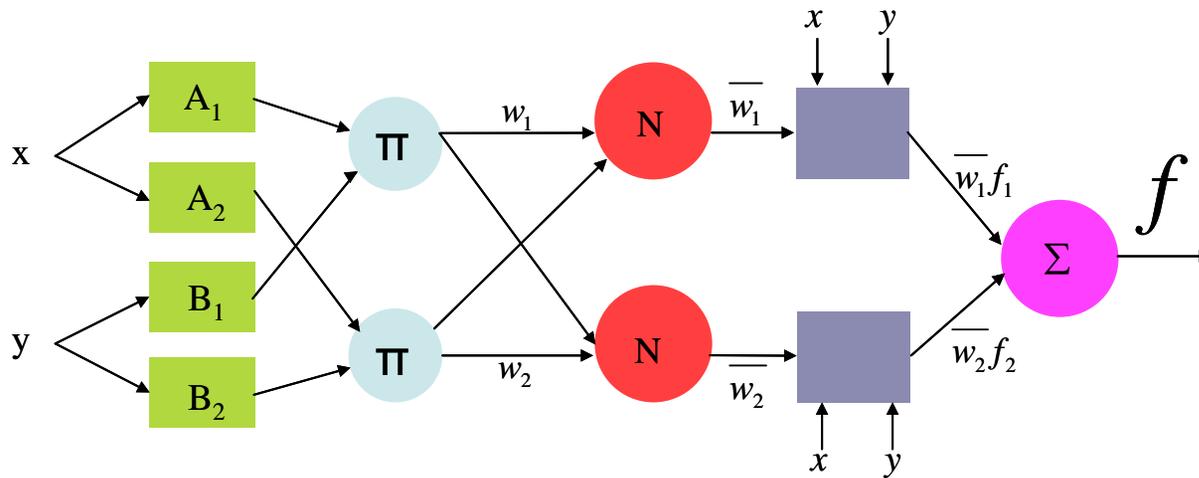


Figura 3.28 SIAN, modelo fusionado totalmente

Algoritmo SIAN

Un sistema difuso puede considerarse como un mapa no lineal parametrizado, llamado f . La expresión explícita de f es

$$f(x) = \frac{\sum_{l=1}^m y^l \left(\prod_{i=1}^n \mu_{A_i^l}(x_i) \right)}{\sum_{l=1}^m \left(\prod_{i=1}^n \mu_{A_i^l}(x_i) \right)} \tag{3.46}$$

donde y^l es un lugar de la salida en el razonamiento Mamdani o es una constante si se aplica el razonamiento Sugeno. La función de membresía $\mu_{A_i^l}(x_i)$ corresponde a la entrada $x = [x_1, \dots, x_n]$ de la regla l .

El “y” (and) conectivo de la premisa es manejada por medio de un producto y proceso difuso inverso (método del centro de gravedad).

Esto puede entonces escribirse como

$$f(x) = \sum_{i=1}^m w_i b_i(x) \tag{3.47}$$

Donde $w_i = y^i$ y

$$b_j(x) = \frac{\prod_{i=1}^n \mu_{A_i^j}(x_i)}{\sum_{l=1}^m \left(\prod_{i=1}^n \mu_{A_i^l}(x_i) \right)} \tag{3.48}$$

Si F es un continuo, un mapa no lineal sobre un conjunto compacto, entonces f puede aproximar F a cualquier exactitud deseada, es decir $F \approx f_{FS}$. Teoremas bien conocidos para aproximación a la teoría de polinomios pueden ser extendidos a los conjuntos difusos (Wang, 1997).

Teorema 1

Permita a F ser una función con límites en $[a,b]$ y $E = \{x_1, \dots, x_k\}$ un conjunto de puntos en $[a,b]$. Entonces existe un polinomio de mínimos cuadrados de grado $\leq n$, p_n^k , que minimiza

$$\sum_{i=1}^k |F(x_i) - p(x_i)|^2 \tag{3.49}$$

sobre todos los polinomios de grado $\leq n$.

Teorema 2

Si $F \in C[a, b]$, entonces para cualquier $n \geq 0$, existe el mejor polinomio aproximador π_n de grado $\leq n$ tal que

$$\|F - \pi_n\|_{\infty} \leq \|F - p\|_{\infty} \tag{3.50}$$

sobre los polinomios p de grado $\leq n$.

Se puede considerar también que el problema más simple de aproximar hacia varios puntos de forma finita.

Teorema 3

Si F es una función con límites en $[a,b]$ y $E = \{x_1, \dots, x_k\}$ un conjunto de puntos en $[a,b]$, entonces existe el mejor polinomio aproximador π_n^k de grado $\leq n$, p_n^k el cual minimiza

$$\max_{0 \leq i \leq k} |F(x_i) - p(x_i)| \tag{3.51}$$

sobre todos los polinomios de grado $\leq n$.

El mensaje de los Teoremas puede resumirse diciendo que los polinomios son densos en el espacio de las funciones continuas. Lo mismo puede decirse se las funciones trigonométricas.

Estructura SIAN

Considere un tipo de sistema difuso del tipo Sugeno teniendo la base de reglas

1. Si x es A_1 y y es B_1 , entonces $f_1 = p_1x + q_1y + r_1$
2. Si x es A_2 y y es B_2 , entonces $f_2 = p_2x + q_2y + r_2$

Permita a las funciones de membresía de los conjuntos difusos $A_i, B_i, i= 1,2$, ser μ_{A_i}, μ_{B_i} .

En la evaluación de las reglas, escoja el *producto* para la T-norma (unión lógica y).

1. Evaluar los resultados de las premisas de las reglas en

$$w_i = \mu_{A_i}(x) \mu_{B_i}(y), i = 1,2. \tag{3.52}$$

2. Evaluar la implicación y las consecuencias de las reglas genera

$$f(x, y) = \frac{w_1(x, y)f_1(x, y) + w_2(x, y)f_2(x, y)}{w_1(x, y) + w_2(x, y)} \quad 3.53$$

o dejando los argumentos fuera

$$f = \frac{w_1 f_1 + w_2 f_2}{w_1 + w_2} \quad 3.54$$

Esto puede ser separado en fases por medio de la definición de

$$\bar{w}_1 = \frac{w_1}{w_1 + w_2} \quad 3.55$$

Entonces f puede ser escrita como

$$f = \bar{w}_1 f_1 + \bar{w}_2 f_2 \quad 3.56$$

4. Técnicas de Análisis de Series de Tiempo

El análisis inteligente de sistemas (extracción de conclusiones valiosas acerca de su comportamiento) requiere del uso de series de tiempo de datos medidos con sensores. Si el sistema es lineal, una gran cantidad de técnicas bien establecidas están a disposición del analista. En el caso de los fenómenos no lineales, el análisis resulta más complejo e involucra otros campos del conocimiento. El problema se complica aún más debido a la condición simultánea de abundancia y escasez de datos: megabytes de información que describen un parámetro y la imposibilidad de medir otras variables importantes en la descripción e interpretación del fenómeno.

Para aclarar lo anterior, revisemos el ejemplo de la Fig. 4.1 que muestra un sistema mecánico masa-resorte y dos conjuntos de series de tiempo obtenidos de sensores que miden la posición y la velocidad de la masa. Un sistema como este puede considerarse lineal: responde en proporción a los cambios. Pero cuando se trata del movimiento pendular, el sistema reacciona de manera no lineal: si la masa es jalada un *poco*, el movimiento forzado tendrá un *pequeño* efecto sobre la posición de la masa, pero si es excitada de tal forma que se balancee hasta una posición invertida (referencia el punto de reposo), *mínimas desviaciones* en las condiciones iniciales (ángulo de aplicación de la fuerza, por ejemplo) tendrán *grandes efectos* en su respuesta.

Esta distinción es de suma importancia en la ciencia en general y en el análisis de datos en particular. Si el sistema bajo estudio es lineal, uno puede caracterizar los datos usando estadística (media, desviación estándar, etc.), ajustar curvas a ellos (aproximación de funciones) y realizar gráficas que permitan entender su comportamiento. Si se requiere un análisis más detallado, el comportamiento del sistema lineal puede ser representado por medio de un esquema *entrada + función de transferencia* \rightarrow *salida* usando algún modelo que trabaje en el dominio del tiempo o en el de la frecuencia.

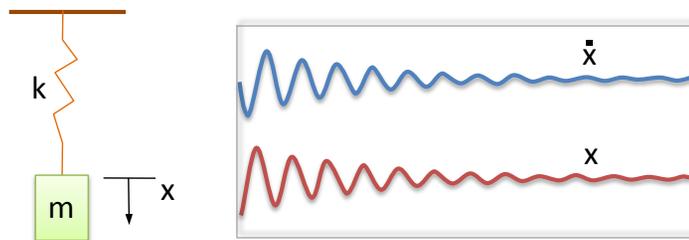


Figura 4.1 Sistema masa-resorte (desplazamiento y velocidad de la masa)

Los sistemas no lineales, por su parte, presentan tan diversos comportamientos que las operaciones de procesamiento tradicionales resultan inútiles. Esta clase de fenómenos no se pueden descomponer de la manera estándar (*entrada + función de transferencia* \rightarrow *salida*) ni se puede simplemente pasar un filtro para limpiar la señal de ruido y manipularla como proveniente de un sistema de comportamiento más simple. Además, el concepto de conjunto discreto de componentes espectrales no tiene sentido en muchos problemas no lineales por lo que usar transformadas para llevarlos del dominio del tiempo al dominio de la frecuencia es inoperante.

Otra complicación en el análisis no lineal es el acceso a suficiente información para describir completamente el sistema. En la mayoría de esta clase de sistemas en la naturaleza, las variables de estado son inaccesibles físicamente, no existen sensores adecuados para medirlas, o peor aún, las *verdaderas* variables de estado no se conocen. La identificación de comportamientos en el caso de sistemas *controlados* (aquellos donde se cuenta con datos *acción* \rightarrow *reacción*) es directa pero en la mayoría de los sistemas naturales (o algunos construidos por el hombre con materiales naturales) la información disponible para su análisis es parcial. Lo único con lo que se cuenta son mediciones de respuestas a eventos dudosamente definidos (el control de las entradas no es posible y prácticamente son desconocidas) por lo que el cuestionamiento de si se puede llegar a identificar un sistema de este tipo (establecer la estructuración matemática, los parámetros funcionales, la categorización de comportamientos, etc) es una pregunta abierta.

Resulta evidente que, bajo estas condiciones, solamente será posible alcanzar un cierto conocimiento general del proceso que subyace en las conexiones expuestas por los datos disponibles (Bendat 1990; Priestly 1988; Tong 1990; Kantz y Schreiber 1997). El manejo eficiente de este argumento resulta clave en cualquier estudio empírico cuya finalidad sea *modelar* (predecir, validar teorías, describir fenómenos, sugerir nuevas hipótesis y delimitar el aprendizaje). Conforme las computadoras abren la puerta a diversas aproximaciones, nuevos conjuntos de hipótesis deben ser probados, nuevos códigos deben ser generados, mejores metodologías deberían ser desarrolladas y la relación entre la complejidad de los datos y las técnicas usadas para modelarlos debe guardar un mejor equilibrio dentro de los modelos científicos.

Los sistemas geosísmicos, raramente pasivos, tienen entradas (parcialmente definidas) y salidas (contienen un alto grado de ruido, esto es, una componente estocástica muy grande) y las relaciones establecidas entre ellas resultan mayormente de aproximaciones empíricas. A partir de lo anteriormente expuesto, el análisis de estos sistemas, usando series de tiempo, debe ser estudiado teniendo en cuenta: i) que no es posible mostrar explícitamente el proceso detrás de los datos y ii) que a través de las teorías lineales es ineficiente inferir información de los datos.

En nuestro empeño de generar modelos con series de tiempo sísmicas que sean suficientemente buenos para ser usados en predicción, los métodos de caracterización y análisis provenientes de la teoría dinámica no lineal resultan muy atractivos en la caracterización de las series y en la inferencia de comportamientos futuros basados en los registros de aceleraciones.

El objetivo del siguiente apartado es presentar las bases conceptuales de los análisis clásicos y avanzados de series de tiempo. La importancia de esta revisión radica en que el mundo matemático es un concepto muy abstracto y muchas veces no es del todo claro cómo una idea o teorema nos acerca al mundo, siendo la tendencia sobrevalorar la aplicación de las matemáticas donde no existe una conexión real. Además se incluye una breve explicación sobre una teoría matemática (Teoría del Caos) que ofrece al analista (cualquiera que sea su rama de estudio) medios para el manejo más eficiente de información y la posibilidad de modificar su visión matemática de los fenómenos que le conciernen, de manera que la observación y el análisis le resulten más provechosos.

El viejo paradigma

En el desarrollo de las ciencias clásicas y las matemáticas varios son los axiomas que han afectado nuestro pensamiento y se han convertido en parte del paradigma científico que prevalece hasta nuestros días:

Determinismo- el conocimiento completo del estado actual de un sistema genera una completa capacidad para enunciar comportamientos pasados y predecir futuros

Linealidad- los modelos estándar lineales son suficientes para definir el ambiente que nos rodea

Reduccionismo- un sistema complejo puede ser analizado eficientemente en términos de sus partes constitutivas

Complejidad- problemas complejos deben tener soluciones complejas

Aleatoriedad- fenómenos que tengan apariencia aleatoria no tiene patrones naturales distinguibles.

Desde muchos puntos de vista, la ciencia clásica puede ser vista como la búsqueda de la certidumbre. El paradigma Cartesiano-Newtoniano establece que el mundo físico está hecho de entidades básicas con distintas propiedades que las distinguen unas de otras, separando y reduciendo el mundo físico a sus entidades básicas puede obtenerse un universo completamente predecible y por lo tanto controlable.

“Este universo es gobernado por leyes inmutables y sus patrones de comportamiento son semejantes a los de una enorme máquina” (De Jong, 1990). Los límites en este enfoque de estudio resultan obvios así que la ciencia moderna ha virado la tendencia hacia herramientas menos restrictivas como la Teoría del Caos, la cual puede ser vista como el siguiente paso en la búsqueda científica por la certeza.

¿Qué es el Caos?

El Caos (en un sentido teórico matemático) es muy difícil de definir. No existe ninguna definición de Caos matemáticamente aceptada y numerosas discusiones, en términos filosóficos, se han establecido sobre el hecho de si pudiera existir alguna (Davis, 1994). Para los propósitos de esta investigación lo que se requiere es sólo aclarar los conceptos *sistema dinámico* y *sensibilidad a condiciones iniciales*.

Para un científico un *sistema* es una colección de objetos que están interrelacionados. Ejemplos de sistemas son: la población de conejos, el sistema solar, los sismos en una región. Un *sistema matemático* es aquel en que sus características sobresalientes pueden ser cuantificadas matemáticamente en términos de variables. Un conjunto particular de valores para las variables de este tipo de sistemas es llamado un *estado* del sistema. Un *sistema dinámico* cambia en el tiempo y se define comúnmente por medio de un *estado inicial* y las *reglas* (conjunto de ecuaciones) para cambiar de *estado* en algún tiempo (futuro o pasado).

Un ejemplo de sistema dinámico (May y Ester, 1976) es la población de algunas especies de pescados que se define con una sola regla: la ecuación logística $x_{t+1} = r(x_t - x_t^2)$, una ecuación no lineal debido al término x_t^2 . Siendo x la fracción de la población máxima posible de peces y x_t la fracción de la población en el tiempo t . Aquí el tiempo puede sólo ser discreto en cantidades como 0, 1,2, por lo que ésta es una ecuación de diferencia del sistema dinámico. Un valor inicial, x_0 , es elegido y sustituido dentro de la regla para calcular x_1 . El proceso se repite y los valores x_2, x_3, \dots son calculados.

El símbolo r es un parámetro que determina algún tipo de crecimiento o factor de ajuste (supervivencia). Para una población particular de peces el valor del parámetro r permanece constante pero para diferentes poblaciones de peces debería tener diferentes valores. En contraste, la variable x_t cambia en el tiempo para cada población. Un objetivo de la teoría del caos es estudiar cómo el valor de r afecta el comportamiento de la dinámica de la población en el tiempo.

El lector interesado puede desarrollar los cálculos con esta ecuación logística (o verificar en la literatura sobre Caos los exhaustivos análisis de la ecuación de Mandelbrot $x_{t+1} = x_t^2 + c$, la cual presenta exactamente la misma dinámica) y descubrir qué tan complicado este simple sistema puede llegar a ser. Aquí sólo se apuntarán algunos detalles que se consideran útiles para el alcanzar el objetivo de esta sección.

Por ejemplo, si el parámetro r es 2.1, entonces la población pronto decrecerá hacia un valor estable de población de aproximadamente 0.52, no importa el valor de la población de arranque (tanto como sea estrictamente entre 0 y 1). Si el parámetro cae por debajo del 1 la población se dirige. Dentro de este rango la población final alcanza un valor fijo. Todo parece estar progresando de manera predecible hasta que el parámetro rebasa el 3. Repentinamente la población final no decae hacia un valor único sino que oscila entre dos valores durante todo un año. Como el parámetro se incrementa cada dos años, el ciclo continúa pero los valores bajos y altos se mueven alejándose. Un incremento mayor del parámetro hace que repentinamente la población se mueva de un ciclo de 2 hacia uno de 4. Estas divisiones desde un valor único a un ciclo de 2 y después a uno de 4 son llamadas *bifurcaciones*. Conforme el parámetro se incrementa, estas bifurcaciones se dirigen más rápidamente hacia los ciclos 4,8,16, ..., etc. En un cierto punto toda la periodicidad parece desaparecer y la población comienza a fluctuar de manera muy complicada y aparentemente aleatoria, que ha sido llamada caótica. Sin embargo, conforme el parámetro se incrementa y atraviesa esta región caótica, la población comienza otra vez a regularse y baja hacia un periodo impar (alrededor del 5to ciclo).

Sensibilidad a condiciones iniciales

Existen varios aspectos del caos que están bellamente ilustrados por la ecuación logística. Para ciertos valores del parámetro r la población tiende a un comportamiento periódico. Para otros valores la población nunca se aproxima a un comportamiento periódico. Los valores de r que no llevan a poblaciones periódicas son llamados la región caótica y se dice que el sistema exhibe caos (en el sentido matemático) sólo en esta región.

La región caótica de la ecuación logística se compone de sub-regiones no caóticas llamadas ventanas periódicas. Si uno observa muy cercanamente dentro de estas ventanas periódicas existen bifurcaciones dobles periódicas que producen una sub-región caótica más pequeña. Esta sub-región más pequeña tiene todavía ventanas de periodicidad aún más pequeñas. Cuando alguna porción de esta sub-región es magnificada, la región pequeña presenta comportamiento muy similar al de la región total. Esta propiedad de sub-regiones entre regiones sucede en cada posible magnificación. La propiedad de similitud en cada nivel de escala es un sello en los sistemas caóticos. Un sistema caótico no puede ser estudiado descomponiéndolo en pequeñas piezas ya que cada pieza será tan complicada en su detalle como lo es el sistema completo. Por esta razón la teoría del caos es inherentemente anti-reduccionista y por lo tanto es reconocida como una teoría holística.

Dentro de la región caótica de la ecuación logística la población fluctúa de manera impredecible. Sin embargo, si la población se grafica para muchas generaciones el patrón emerge. Los puntos de población se agruparán en algunas zonas y podrían desaparecer completamente en otras (llamados *atractores extraños* y son ejemplos de objetos geométricos conocidos como *fractales*).

En la región periódica de la ecuación logística la población decrece hacia el mismo valor independientemente del valor de inicio. En la región caótica la situación es muy diferente: dos valores de arranque diferentes pueden llevar a resultados completamente distintos (incluso para longitud de tiempo infinita) aún con inicios extraordinariamente cercanos. Esto es lo que se conoce como *sensibilidad a condiciones iniciales*.

El Caos contra una visión lineal del mundo

El método Cartesiano-Newtoniano propone, como primer método de estudio, reducir un sistema físico a un sistema de ecuaciones y después resolverlas para determinar comportamientos. La antigua revolución en el pensamiento científico culminó en el legado de Newton de la visión del universo como un gigantesco mecanismo donde bajo condiciones de ambiente idénticas se apreciarán comportamientos de respuesta idénticos. Un ingeniero que conoce las especificaciones de la máquina o de los materiales con los que trabaja y el estado que éstos guardan en cualquier momento puede, en principio, manejarlo precisamente en cualquier instante de tiempo (Stewart, 1989).

Ciertamente esta ha sido una aproximación muy productiva para la ciencia en los últimos 300 años. En un universo *máquina* parece no haber lugar para el caos y la dependencia en condiciones iniciales, ¿por qué entonces esta aproximación Newtoniana ha sido tan efectiva por tanto tiempo? Y ¿por qué tomó tanto tiempo descubrir el caos?

La respuesta es, por supuesto, compleja pero una gran parte de ella es que hasta la mitad del siglo XX los matemáticos y los físicos se concentraron en estudiar sólo sistemas dinámicos lineales. Los científicos apoyados en matemáticas clásicas se concentran en ajustar el mundo a comportamientos lineales por una razón pragmática: no pueden resolver nada más con este tipo de planteamientos.

Caos y Determinismo

Incluso los sistemas lineales bajo la perspectiva Cartesiana-Newtoniana han sido siempre ambiciosos matemáticamente -las ecuaciones son usualmente muy difíciles de resolver. El *sueño* de completa predictabilidad para cualquier sistema complejo ha sido siempre más un *ideal* que una *realidad* práctica. Ahora comprendemos, a partir de la teoría del caos, que la predicción total ha sido siempre una falsa meta. Los sistemas no lineales tienen una limitación inherente a partir de que, en la región caótica, la exactitud absoluta es necesaria para predicciones útiles. Algunos sistemas podrían manifestar una mezcla de comportamientos predecibles y no predecibles (Kellert, 1993).

Una de las pruebas para la *buena* investigación científica es la *repetibilidad*. En el paradigma Cartesiano-Newtoniano decir que se puede *explicar* un evento comúnmente significa que podemos predecirlo. Si las únicas alternativas en el determinismo para concluir sobre fenómenos muy complejos es la aleatoriedad, entonces este determinismo es atractivo como una verdad *a priori* o una pregunta científica de metodología imperativa (Earman, 1986).

El caos ha dado otra opinión a esta dicotomía. Kellert (1993) apunta que el término determinismo puede ser visto en por lo menos cuatro formas y las enlista en el siguiente orden, desde la más simple y menos restrictiva hasta la más robusta y completa:

Ecuaciones diferenciales o de diferencias a partir de un modelo correcto del sistema.

Evolución única, es decir, la evolución del sistema se fija una vez que nosotros especificamos el estado del sistema en cualquier momento.

La determinación de valores (como atributo).

Predictibilidad total (lo que sea que esto signifique, se recomienda la discusión sobre el significado de *predicción* en Davis, 1994).

El caos nos ha obligado a reconsiderar tres de los cuatro significados de Kellert para decidir sobre el determinismo dentro de un sistema. La visión más simple, que es la de los modelos con ecuaciones de diferencia o con ecuaciones diferenciales, es la más usada pero debe tenerse en cuenta cuando se usa y construyen modelos de sistemas dinámicos a partir de estas ecuaciones que: i) el comportamiento del sistema no puede ser estudiado por reducción en partes, ii) los resultados no son pruebas descriptivas y iii) los sistemas no pueden ser estudiados si las descripciones son instantáneas.

Una opinión personal...

Es justo preguntarse si la teoría del *caos* es una moda, camina en dirección de una teoría matemática de la catástrofe o se convierte más en una religión/creencia que en una teoría formal. ¿El *caos* revolucionará la ciencia?. Las respuestas a estos cuestionamientos las dará el tiempo, pero de lo que sí estoy convencida es de que matemáticamente la teoría del caos es válida, importante, está presente y significativamente cambiará la manera en la que se estudia la naturaleza.

El *caos* no elimina la predicción, el *caos* se concentra en el hecho de qué clase de predicción es posible y cuáles son los límites de nuestras predicciones. El *caos* nos ayuda a enfocarnos en aspectos básicos importantes y notables que han sido despreciados por nuestra limitación teórico-práctica. En este trabajo de tesis se postula a la teoría del caos como la herramienta que nos ayuda en la búsqueda del orden, de la armonía, en la búsqueda que nos conduce a *conceptos generales* más que a leyes.

"... son los modelos, no las leyes, los que forman el corazón de la ciencia..."

(Kellert, 1993).

4.1. Mapas de Recurrencia

Dentro de la sismología existen dos aspectos que han sido motivo de exhaustivas investigaciones y aún se consideran problemas que deben ser resueltos. Uno de ellos involucra el uso de ciertas hipótesis (por lo general restrictivas) acerca de la naturaleza de la fuente de vibración. El segundo se refiere a la selección de los métodos apropiados para estudiar las señales que expresan movimientos de terreno (procesos no-estacionarios). La sugerencia de algunos investigadores sobre la no linealidad involucrada en la generación sísmica y la respuesta del suelo (García et al., 2003; Huang y Turcotte, 1990a, 1990b, entre otros) alerta sobre una reconsideración de los métodos y técnicas involucradas en su análisis. En esta investigación se propone el uso de los Mapas de Recurrencia MR como herramienta alternativa para evitar las *suposiciones* y para enmarcar a los estudios sísmicos en un contexto *no estacionario*.

La dinámica de sistemas *reales* se caracteriza por un cierto número de *estados* coexistiendo y por la presencia de *fluctuaciones*. La evolución a largo plazo de estos sistemas está dominada por las transiciones entre estos diferentes estados (Luchinsky et al., 1998; Feudal y Gregobi, 1997). Sistemas de este tipo son imposibles de resolver analíticamente y simplificarlos hacia sistemas lineales para hacerlos objeto de estudio de herramientas como transformaciones de Laplace o argumentos de superposición (análisis de Fourier) es obviar las partes del sistema que interfieren, cooperan, compiten o interactúan de maneras muy complejas.

El propósito de esta sección es presentar las condiciones básicas que permitan la aplicación de la Teoría de Sistemas Dinámicos en el estudio de la respuesta sísmica de depósitos de suelo blando. Esta breve discusión no se concentra en las ideas "puras" sobre el caos sino en la descripción de técnicas de análisis geométrico (topológico), en particular los MR (Eckman et al., 1987), para determinar patrones de comportamiento en los movimientos registrados en la ciudad de México. Sin el uso de hipótesis drásticas ni desechando aspectos *naturales*, los MR permiten extraer información relevante a partir de un análisis inverso: dada una respuesta monitoreada se dibujan sus *trayectorias* en *espacios* convenientes y a partir de ellas se encuentran las soluciones geométricas sin resolver las ecuaciones que gobiernan al propio sistema.

Cartas de comportamiento de procesos

La teoría del caos se concentra en la caracterización de los fenómenos complejos. Por ejemplo, el balanceo de un péndulo está gobernado por la ecuación

$$\ddot{x} + \frac{g}{L} \sin x = 0$$

4.1

donde x es el ángulo que forma el péndulo con la vertical, g es la aceleración debida a la gravedad y L es la longitud del péndulo. La no linealidad hace que la ecuación del péndulo sea muy difícil de resolver analíticamente. Comúnmente para ángulos pequeños se invoca la aproximación $\sin x \approx x$ para $x \ll 1$. Esto transforma el problema en uno lineal y puede ser resuelto fácilmente. Pero restringiendo el valor de x a valores muy pequeños se están despreciando los movimientos donde el péndulo puede girar incluso sobre su punto de sujeción. Una manera de extraer información usando mediciones del comportamiento del sistema es a través de métodos geométricos.

Suponga una solución al sistema del péndulo para una condición inicial particular $x_1(t)$ y $x_2(t)$ (posición y velocidad). Si se construye un espacio abstracto con coordenadas (x_1, x_2) , entonces la solución $(x_1(t), x_2(t))$ corresponde a un punto moviéndose a lo largo de una curva llamada *trayectoria* y el espacio se conoce como *espacio de fase* del sistema (Fig. 4.1). Este tipo de cartas son una descripción empírica de la posibilidad de predicción en una serie de tiempo y el hecho de no imponer un cierto modelo a los datos expuestos hace que no se vean afectadas por el paradigma usado en la explicación de las observaciones.

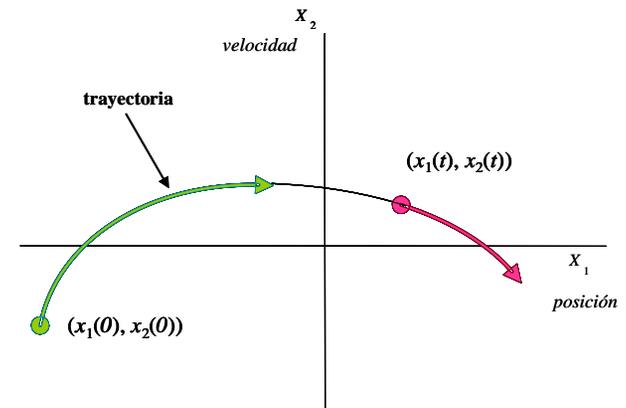


Figura 4.1 Espacio de fase

Representación del Espacio de Fase

Los sistemas dinámicos se describen a través de su evolución (lo que involucra al *tiempo*) en algún *espacio de fase* $\Gamma \subset \mathbb{R}^d$. Pueden ser expresados, por ejemplo, con ecuaciones diferenciales ordinarias

$$\dot{x}(t) = F(x(t)), \quad 4.2$$

o en tiempo discreto $t = n\Delta t$ por medio de mapas de la forma

$$x_{n+1} = f(x_n) \quad 4.3$$

Una serie de tiempo puede ser vista como una secuencia de observaciones $\{\delta_n = \delta(x_n)\}$ realizadas a través de una función de medición $\delta(\cdot)$. Ya que la secuencia $\{\delta_n\}$ (usualmente escalar) no representa adecuadamente el *espacio de fase* (multidimensional) del sistema dinámico, deben ser empleadas algunas técnicas para descubrir la estructura multidimensional usando sólo los datos disponibles. La técnica de reconstrucción más empleada es el *método del retraso*.

Los vectores en un nuevo espacio, el *espacio embebido*, se forman a partir de los valores retrasados en el tiempo de las mediciones escalares originales $\delta_n = (\delta_{n-(m-1)\tau}, \delta_{n-(m-2)\tau}, \dots, \delta_n)$. El número m se llama *dimensión embebida*. El tiempo τ es generalmente referido como el *retraso*. Los conocidos teoremas de Takens (1981) y Sauer (Sauer et al., 1991) establecen que si la secuencia $\{\delta_n\}$ son mediciones escalares del *estado* de un sistema dinámico, entonces -bajo ciertas hipótesis- el retraso genera una imagen uno-a-uno del conjunto original $\{x\}$, siempre y cuando m sea suficientemente grande. La implementación es directa y no requiere mayor explicación. Si N mediciones escalares están disponibles, el número de vectores embebidos es $N - (m - 1)d$.

Existen diversos trabajos acerca de la elección de m y d , una conclusión general es que la elección de los valores óptimos depende solamente del tipo de aplicación. En esta investigación se usa el método de información recíproca (*mutual information*; Fraser y Swinney, 1986; Palus, 1995) e inspecciones visuales de representaciones con varios valores de retraso para concluir sobre el tiempo de retraso ideal para esta aplicación. Por otro lado, después de varios análisis empíricos se determinó que el método estadístico de los *falsos vecinos* (*false neighbors*; Kennel et al., 1992) es una buena guía para elegir el valor de la dimensión embebida. Para los lectores interesados en este tema se sugiere Hegger et al., (1999).

Definiciones básicas

Los Mapas de Recurrencia MR son una herramienta para la interpretación cualitativa de series de tiempo que permiten detectar gráficamente patrones ocultos y cambios estructurales en los datos (Eckmann, et al., 1987).

Un MR es una representación bi-dimensional de una trayectoria individual que conserva la dependencia temporal y espacial de la serie de tiempo original. Las series de tiempo se expanden hacia las ordenadas y las abscisas y cada punto (i,j) en el plano es coloreado de acuerdo a la distancia entre dos puntos de trayectoria y_i y y_j . Existen MR "sin frontera" donde el píxel en la posición (i,j) se codifica a color de acuerdo con un valor de distancia, mientras que en un MR "con frontera" el píxel (i,j) es negro si la separación está dentro de una franja de valores específica y es blanco cuando la distancia tiene cualquier otro valor. Por ejemplo, para un MR "sin frontera", si el punto 117 en una trayectoria está a 14 unidades de distancia del punto 9435, el píxel en la posición $(117, 9435)$ tendrá el color que corresponda al valor de espaciamiento igual a 14. El punto $(9435,117)$ se colorea de manera similar aunque los MR no son necesariamente simétricos (Eckmann, et al., 1987).

La Fig.4.2 muestra tres MR sin frontera (en lo sucesivo las siglas MR se refieren sólo a mapas de este tipo) generados a partir de diferentes conjuntos de datos: una serie de tiempo derivada del muestreo de la función $sen(t)$, una serie de tiempo del sistema Lorenz y la representación del ruido. El color en estos gráficos va desde amarillos-blanco para espaciamientos muy pequeños hasta azules-negro para distancias muy grandes, como se muestra en las barras de calibración de la Fig. 4.2.

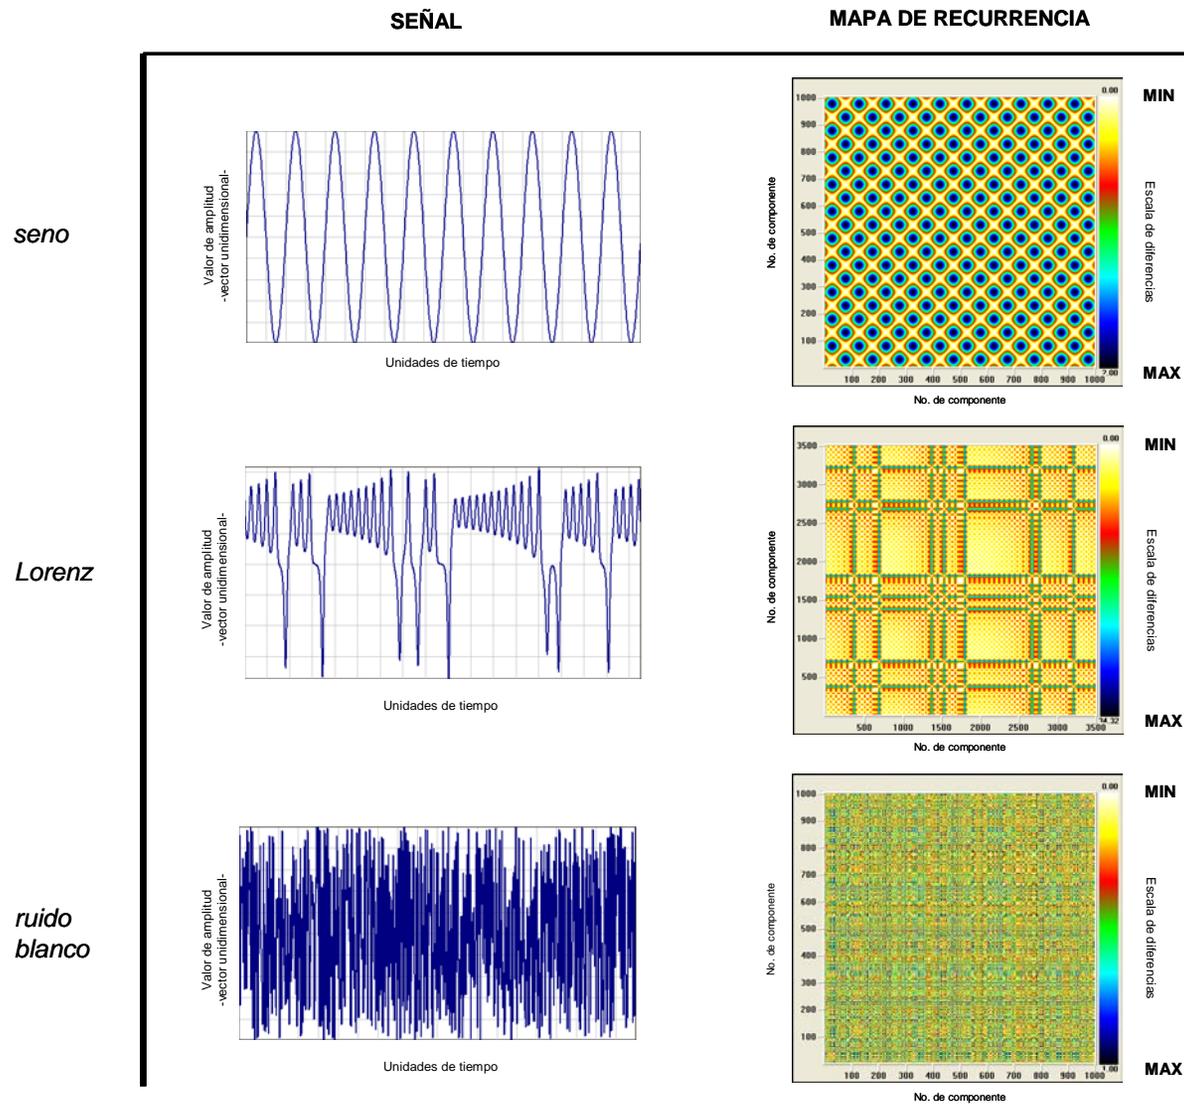


Figura 4.2. Ejemplos de mapas de recurrencia para sistemas deterministas, caóticos y aleatorios.

El MR de la onda seno es relativamente fácil de comprender; cada uno de los bloques de color representa la mitad del periodo de la señal (el sombreado del punto (w,v) en este gráfico refleja la distancia entre $sen w$ y $sen v$; si $w - v = \pi/2$, por ejemplo, la distancia es grande). El MR de Lorenz, que representa un conjunto de datos caóticos, es más complicado a pesar de tener una apariencia estructurada (bloques semejantes a los de la señal periódica). Esta señal, se sabe, no es periódica, por lo que los elementos estructurales repetidos deben ser explicados y clasificados comparándolos con las geometrías correspondientes al ruido blanco, señal que representa el comportamiento aleatorio y el extremo en estructuración nula.

Con estos sencillos ejemplos se observa que los MR son visualmente llamativos, favorables en la búsqueda de correlaciones ocultas en datos altamente complicados, no demandan la estacionalidad en las series de tiempo y son particularmente útiles en el análisis de sistemas cuya dinámica podría estar cambiando. La aplicación de MR en esta investigación responde a la necesidad de encontrar un significado a las aparentes relaciones expuestas en los registros de movimientos de terreno (por lo menos en su expresión en el dominio de la frecuencia). Con el uso de los MR y sus estructuras dependientes de tipos de comportamiento, se intenta responder a los cuestionamientos sobre la mecánica del fenómeno sísmico sin involucrar el uso de funcionales prohibitivos.

Los trabajos previos a este respecto están orientados hacia aplicaciones muy concretas y los resultados cuantitativos están sesgados. En esta propuesta metodológica se pretende extender, formalizar y sistematizar el manejo de MR con el propósito de encontrar propiedades cualitativas y cuantitativas útiles en la práctica ingenieril.

Construyendo un MR

En esta sección se apuntan brevemente algunos aspectos básicos de los MR y se describe cómo se genera un MR a partir de un conjunto de datos experimentales. El primer paso en el procedimiento estándar es reconstruir la dinámica por medio de embeber la serie de tiempo uni-dimensional en el espacio de reconstrucción d_E -dimensional usando el método del retraso de coordenadas.

Dado un sistema cuya dimensión topológica sea d , el muestreo de una variable de estado individual es equivalente a proyectar la dinámica del espacio de fase d -dimensional hacia uno de los ejes. *Embeber* es similar a describir esas dinámicas pero en diferentes ejes. El Teorema de Takens garantiza que la dinámica reconstruida, si está propiamente embebida, es equivalente a la dinámica del verdadero sistema detrás de los datos, en el sentido que los invariantes dinámicos (dimensiones generalizadas y el espectro de Lyapunov (explicar brevemente esto), por ejemplo) son idénticos (Packard et al., 1980; Takens, 1981).

El proceso correcto para *embeber* es sujeto de numerosos trabajos en la literatura lo que ha generado gran cantidad de argumentos y algoritmos heurísticos para su determinación (Abardanel, 1995). Dentro de este proceso el problema básico es la elección de dos parámetros (el retraso y la

dimensión del espacio de reconstrucción) que garanticen el correcto embebimiento de los datos. Ésta es una tarea difícil porque en general no se tiene conocimiento *a priori* del valor óptimo de d ; se cuenta únicamente con una serie de tiempo uni-dimensional y a partir de ella se pretende aprender lo más posible acerca del sistema que generó los datos.

Embebimiento de Coordenadas Retrasadas

Para reconstruir una dinámica se debe contar con los datos experimentales en forma de serie:

$$\{x_1, x_2, \dots, x_N\} \quad 4.4$$

La reconstrucción de las coordenadas retrasadas del posible *espacio de fase* dinámico multidimensional a partir de la variable única observable x está gobernada por dos parámetros, dimensión de embebimiento d_E (llamada m en algunos textos técnicos) y tiempo de retraso τ . La trayectoria resultante en R^{d_E} es:

$$\{y_1, y_2, \dots, y_M\} \quad 4.5$$

donde $m = N - (d_E - 1)\tau$ y $y_k = (x_k, x_{k+\tau}, x_{k+2\tau}, \dots, x_{k+(d_E-1)\tau})$ para $k=1,2,\dots,m$. Note que usando $d_E = 1$ se regresa a la serie original; embebimiento uni-dimensión es equivalente a no embeber. Una elección adecuada de d_E y τ es crítica en este tipo de reconstrucción y debe realizarse con inteligencia; sólo valores "correctos" de estos dos parámetros generan embebimientos que garantizan ser topológicamente equivalentes a la dinámica del *espacio de fase* original (no observado) (Packard et al., 1980; Takens, 1981; Sauer et al., 1991).

Asumiendo que el embebimiento de coordenadas retrasadas es correcto, se asume que un MR de una trayectoria reconstruida presenta gran similitud con el MR de su verdadera dinámica. Más aún, se espera que cualquier propiedad de la trayectoria reconstruida inferida a partir de este MR sea propia del *verdadero* sistema. Debido a esta cualidad de los MR, distintos sistemas han sido estudiados bajo la misma perspectiva de análisis, lo que ha originado que muchas áreas del conocimiento se vean beneficiadas de esta simple y efectiva metodología (Fig. 4.3).

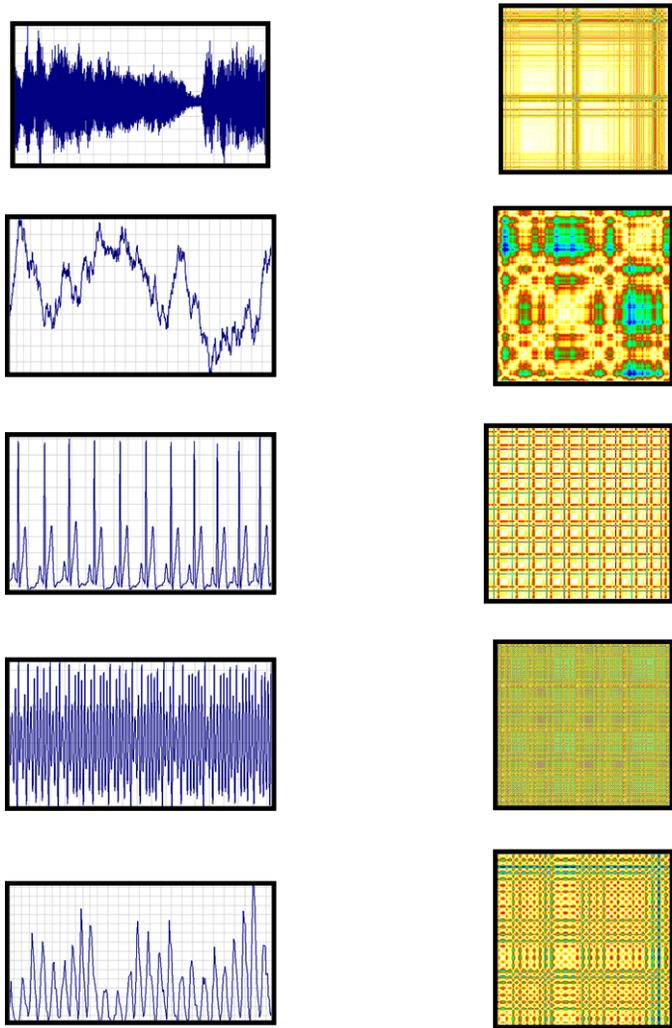


Figura 4.3. Aplicaciones en diferentes campos del conocimiento

Cálculo de las distancias

Los MR están basados en las distancias entre puntos en una trayectoria por lo que un paso muy importante en su construcción es la elección de la norma D . En este trabajo de investigación se usa la máxima norma (en uni-dimensión la máxima norma es equivalente a la p-norma euclidiana) por dos razones: i) su fácil implementación y ii) el hecho de que la máxima distancia que se alcanza en los cálculos de recurrencia (la diferencia entre la medición más grande y la más pequeña en la serie de tiempo) es independiente de la dimensión embebida d_E para esta norma en particular. Esto significa que podemos hacer comparaciones directas entre los MRs generados usando diferentes valores de d_E sin re-escalar los mapas.

Proceso de Construcción: Ejemplo numérico

Para expandir la señal 1D a un espacio de fase de M dimensiones, se sustituye cada observación de la señal original $X(t)$ con el vector $y_i = (x_i, x_{i+d}, x_{i+2d}, \dots, x_{i+(m-1)d})$ donde i es el índice del tiempo, m es la dimensión a la que se embebe y d es el tiempo de retraso. Como resultado se tiene una serie de vectores $Y = y_1, y_2, y_3, \dots, y_{N(m-1)d}$ donde N es la longitud de la serie original. La idea de la reconstrucción es capturar los estados del sistema original en cada una de las salidas observadas. Cada estado desconocido $S(t)$ en el tiempo, t , se aproxima con un vector de coordenadas retrasadas $Y(t) = \{x_i, x_{i-d}, x_{i-2d}, \dots, x_{i-(m-1)d}\}$.

Ahora, analicemos la serie de tiempo de los precios al cierre de una semana típica en el índice Dow Jones:

9/25/98 8029
 10/2/98 7785
 10/9/98 7900
 10/16/98 8417
 10/23/98 8452
 10/30/98 8592
 11/6/98 8975

...

Si $d=1$ y $m=3$, los vectores reconstruidos se definen como:

$Y(10/9/98) = \{7900, 7785, 8029\}$

$Y(10/16/98) = \{8417, 7900, 7785\}$

$Y(10/23/98) = \{8452, 8417, 7900\}$

...

La distancia Euclidiana entre los vectores $Y(10/9/98)$ y $Y(10/16/98)$ es

$$D(Y(10/9/98), Y(10/16/98)) = [(7900-8417)^2 + (7785-7900)^2 + (8029-7785)^2]^{1/2} = 583$$

Usando un código de color dependiente de la distancia máxima entre vectores, el mapa resultante se presenta en la Fig. 4.4

Este breve resumen intenta sólo cubrir los aspectos básicos de la metodología de construcción de MR, se recomienda al lector interesado en la cuantificación, calificación y determinación de elementos gráficos en caracterización de MR y demás herramientas topológicas para analizar señales, la consulta del Apéndice 4.1.A.

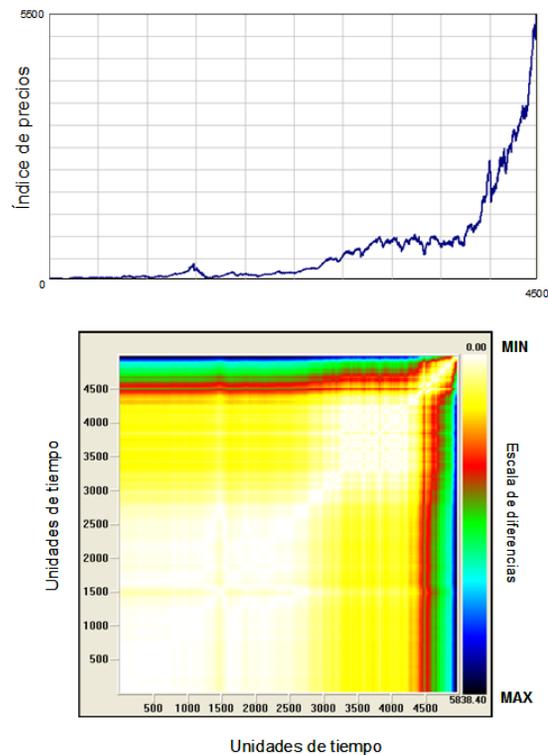


Figura 4.4. Ejemplo de aplicación

4.2. Eigenfaces

Sin duda la habilidad humana para reconocer miles de caras e identificarlas a primera vista, aún con cambios en condiciones de peso, expresión, envejecimiento y distracciones como lentes, barbas, o peinados, es una facultad impresionante. Un modelo computacional que trabaje con estímulos multidimensionales y codifique y/o agrupe imágenes de manera tan eficiente como el cerebro humano es una tarea extremadamente difícil.

Es entonces el reconocimiento de patrones automático uno de los mayores retos en el diseño moderno de sistemas de información. Existen dos tendencias de análisis a este respecto. El primer método está basado en conceptos de la teoría de información, particularmente en el método de análisis de componentes principales. Basados en la expansión de Karhunen-Loeve, siendo M. Kirby y L. Sirovich (Kirby y Sirovich, 1990; Sirovich y Kirby, 1987) los que demostraron que cualquier cara puede ser representada en términos de un sistema de coordenadas eficiente. Poco tiempo después, M. Turk y A. Pentland modifican esta propuesta y establecen el método de reconocimiento de caras *eigenfaces EF* (Turk y Pentland, 1991) considerado como la primera tecnología práctica en el reconocimiento automático de rostros (Velasco, 1998).

Un segundo método propone la extracción de aspectos particulares a partir de partes básicas de la cara: ojos, nariz, boca, y barba. En este método, con la ayuda de plantillas deformables y matemáticas exhaustivas se genera información numérica relevante que conforma un arreglo monumental de vectores característicos (Yuille et al., 1989).

Eigenfaces para reconocimiento

El sistema de reconocimiento EF trabaja con imágenes organizadas en una base de datos. Por medio de la comparación de aspectos comunes y diferencias entre las imágenes individuales, el sistema EF genera un conjunto multi-dimensional de *eigenfaces* organizado bajo un patrón particular.

En lenguaje de teoría de información, EF plantea la extracción de la información relevante en una cara, su codificación de una manera eficiente y la comparación con modelos codificados de manera similar para su identificación. En términos matemáticos, en EF se deben encontrar los componentes principales de las imágenes o *eigenvectores* de la matriz de covarianza de un conjunto de caras, siendo estos *eigenvectores* la representación numérica de las características que describen la variación entre imágenes.

Cada imagen en el archivo de entrenamiento (conjunto de imágenes seleccionadas como representativas) puede ser descrita exactamente en términos de una combinación lineal de *eigenfaces*. El número de *eigenfaces* es igual al número de imágenes en el archivo de entrenamiento. Sin embargo, las caras pueden ser aproximadas usando sólo los mejores *eigenfaces* (aquellos

que tienen los *eigenvalores* más altos) y que participan en mayor medida en la varianza del conjunto de imágenes.

La ventaja más atractiva de EF es su velocidad y eficiencia. Las aplicaciones más exitosas han demostrado que EF reduce 1/1000 veces la cantidad de datos necesaria para identificar a un individuo comparada con el tamaño de la imagen completa (Lau Technologies, 1999).

Conceptos básicos en reconocimiento de patrones

Un *patrón* es la descripción de un *objeto*. De acuerdo con la naturaleza de los patrones a ser reconocidos, la tarea del *reconocimiento* puede ser dividida en dos grandes tipos (González y Tou, 1974):

a) Reconocimiento de aspectos concretos. Se refiere al reconocimiento sensorial e incluye reconocimiento de patrones aural y visual. Es considerado un problema psico-fisiológico que involucra la relación entre la persona y un estímulo físico. Este proceso involucra la identificación y clasificación de patrones temporales y espaciales. Ejemplos de patrones espaciales son los caracteres, huellas digitales, objetos físicos e imágenes. Los patrones temporales incluyen el habla, las series de tiempo, los electrocardiogramas y las firmas.

b) Reconocimiento de aspectos abstractos. Trata con la identificación conceptual donde viejos argumentos o soluciones a problemas resueltos en el pasado pueden ser reconocidos y actualizados.

Clases y Patrones. El reconocimiento de patrones puede ser definido como la categorización de los datos en clases identificables a través de aspectos significantes (derivados de la identificación de detalles irrelevantes).

Una *clase* es una categoría determinada por algunas características o aspectos comunes entre los elementos que la constituyen. Las singularidades de clase son comunes en todos los patrones que agrupa y son referidos como aspectos intra-conjunto. Las características que representan las diferencias entre clases pueden ser referidas como aspectos inter-conjunto.

Un *patrón* es la descripción de cualquier miembro de una clase. Por conveniencia, los patrones se representan con vectores:

$$X = \begin{bmatrix} x_1 \\ x_2 \\ \dots \\ \dots \\ x_n \end{bmatrix}$$

4.6

donde cada elemento x_j representa una característica de ese patrón (X se convierte en un punto en un espacio euclidiano n -dimensional).

El diseño de un sistema automático de reconocimiento de patrones involucra:

1. La representación de los objetos a ser reconocidos a través de las mediciones (problema de detección). Cada cantidad medida describe una característica de un patrón u objeto y forma parte del vector de información. El conjunto de patrones que pertenecen a una misma clase corresponde a un ensamble de puntos cercanos en una región del espacio de características. Un ejemplo simple se muestra en la Figura 4.3 para dos clases de patrones denotados por w_1 y w_2 .
2. La extracción de aspectos o atributos característicos a partir de datos y la reducción de la dimensionalidad de los vectores (problema de pre-procesamiento). Los aspectos intra-conjunto no agregan información discriminativa y pueden ser ignorados. Si el conjunto completo de aspectos discriminatorios para cada clase puede ser determinado con las mediciones disponibles, el reconocimiento y la clasificación de patrones podría ser reducido a un proceso simple de ajuste (o tabla de apariencias). Sin embargo, en la mayoría de los problemas de reconocimiento prácticos, la determinación de un conjunto completo de aspectos discriminatorios es extremadamente difícil o imposible de conseguir.
3. Los procedimientos de decisión durante la identificación y la clasificación. Después de que los datos han sido expresados en forma de puntos en el espacio de patrones, se requiere que la computadora decida sobre M diferentes clases, en el espacio constituido por M regiones. El problema de reconocimiento se concentra en la generación de las fronteras de decisión que separan las M clases sobre la base de los vectores observados.

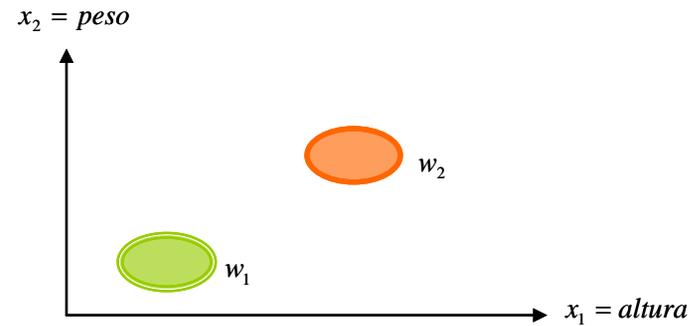


Figura 4.3 Dos clases de patrones. Cada patrón es caracterizado por dos mediciones: altura y peso. El vector del patrón tiene la forma $x = \{x_1, x_2\}^T$

Calculando las eigenfaces

Permita a una imagen $I(x,y)$ ser un arreglo bi-dimensional de $N \times N$ con valores de intensidad de 8-bits. Esta imagen puede ser considerada como un vector de dimensión N^2 por lo que una imagen típica de tamaño 256×256 se convierte en un vector de dimensión 65536, o un punto en un espacio 65536-dimensional.

Las imágenes faciales no se distribuyen aleatoriamente en este enorme espacio (todos los rostros humanos tienen una configuración similar) y por lo tanto pueden ser descritas con un sub-espacio de menor dimensión. La idea básica en el análisis de componentes principales (o la expansión de Karhunen-Loeve) es encontrar los vectores de mayor participación en la distribución de las imágenes dentro del espacio entero.

Estos vectores definen el subespacio de las imágenes faciales, el cual se llama en EF *espacio de caras*. Cada vector es de longitud N^2 (describe una imagen de $N \times N$) y es una combinación lineal de las imágenes faciales originales. Porque estos vectores son los eigenvectores de la matriz de covarianza de las imágenes originales, y porque ellos tienen apariencia de caras, nos referimos a ellos como *eigenfaces*.

Definiciones:

A continuación se detallan aspectos de lenguaje y terminología que serán empleados durante la descripción del algoritmo de evaluación de las eigenfaces.

Una matriz A de $N \times N$ se dice que tiene un eigenvector X y eigenvalor correspondiente λ si

$$AX = \lambda X \quad 4.7$$

Evidentemente, la ec. 4.7 puede sostenerse sólo si

$$\det|A - \lambda I| = 0 \quad 4.8$$

si la ec. 4.7 es expandida, se obtiene un polinomio de grado N -ésimo cuyas raíces son los eigenvalores. Esto prueba que existen siempre N eigenvalores (no necesariamente distintos). Eigenvalores iguales que provienen de las raíces múltiples son llamados "degenerados".

Una matriz es llamada simétrica si es igual a su transpuesta,

$$A = A^T \quad \text{o} \quad a_{ij} = a_{ji} \quad 4.9$$

es llamada ortogonal si su transpuesta es igual a su inversa,

$$A^T A = AA^T = I \quad 4.10$$

y finalmente, es llamada normal si ella conmuta con su transpuesta,

$$AA^T = A^T A \quad 4.12$$

Teorema. Los eigenvalores de una matriz simétrica real son todos reales. Por el contrario, los eigenvalores de una matriz real no-simétrica pueden incluir valores reales, pero podrían incluir pares de valores conjugados complejos. Los eigenvalores de una matriz normal (con eigenvalores no degenerados) son completos y ortogonales, extendiendo el espacio de vectores N -dimensional.

Proceso:

Permita al conjunto de entrenamiento de imágenes de caras ser $\Gamma_1, \Gamma_2, \dots, \Gamma_M$ entonces el promedio del conjunto está definido por

$$\Psi = \frac{1}{M} \sum_{n=1}^M \Gamma_n \quad 4.13$$

Cada cara difiere del promedio por el vector

$$\Phi_i = \Gamma_i - \Psi \quad 4.14$$

a)



b)



Figura 4.4 a) Ejemplo de archivo de entrenamiento (conjunto de caras), b) Promedio de cara del archivo de entrenamiento

Un ejemplo del conjunto de entrenamiento se muestra en la Fig. 4.4(a) y el promedio de caras en la Fig. 4.4(b).

Este conjunto de *enormes* vectores se sujeta al análisis de componentes principales para buscar el conjunto de M vectores ortonormales, u_n , que mejor describa la distribución de los datos. El k -ésimo vector, u_k , se elige de modo que

$$\lambda_k = \frac{1}{M} \sum_{n=1}^M (u_k^T \Phi_n)^2 \quad 4.15$$

sea un máximo, sujeto a

$$u_l^T u_k = \delta_{lk} = \begin{cases} 1 & \text{si } l = k \\ 0 & \text{otro caso} \end{cases} \quad 4.16$$

Los vectores u_k y escalares λ_k son los eigenvectores y eigenvalores, respectivamente de la matriz de covarianza C

$$C = \frac{1}{M} \sum_{n=1}^M \Phi_n \Phi_n^T = AA^T \quad 4.17$$

donde la matriz $A = \{\Phi_1, \Phi_2, \dots, \Phi_n\}$.

La matriz de covarianza C es una matriz simétrica real de $N^2 \times N^2$ y determinar los N^2 eigenvectores y eigenvalores es una tarea impráctica si se toman en cuenta los tamaños típicos de las imágenes. El problema entonces es idear un método computacional que permita, de manera eficiente, encontrar estos eigenvectores.

Si el número de puntos de datos en el espacio de imágenes es menor que la dimensión del espacio ($M < N^2$), entonces habrá sólo $M-1$ en lugar de N^2 eigenvectores significativos. Los eigenvectores remanentes están asociados con eigenvalores iguales a cero. Se puede trabajar para los eigenvectores N^2 -dimensionales, primero resolviendo los eigenvectores de una matriz de $M \times M$ (una matriz de 16×16 en lugar de una de $16,384 \times 16,384$) tomando combinaciones lineales de las imágenes de caras Φ_i .

Considere los eigenvectores v_i de $A^T A$ tal que

$$A^T A v_i = \mu_i v_i \quad 4.18$$

Premultiplicando ambos lados por A tenemos que

$$AA^T A v_i = \mu_i A v_i \quad 4.19$$

de lo que se puede concluir que $A v_i$ son los eigenvectores de $C = AA^T$.

Siguiendo este tipo de análisis, construimos la $M \times M$ -matriz $L = A^T A$, donde $L_{mn} = \Phi_m^T \Phi_n$, y se encuentran los M eigenvectores, v_i de L . Estos vectores determinan combinaciones lineales del M -conjunto de entrenamiento (imágenes faciales) para formar las eigenfaces u_i .

$$u_l = \sum_{k=1}^M v_{lk} \Phi_k \quad l = 1, \dots, M \quad 4.20$$

Con este análisis, los cálculos se reducen considerablemente, desde el orden del número de píxeles de la imagen (N^2) al orden del número de imágenes en el archivo de entrenamiento (M). En la práctica, el conjunto de entrenamiento de las imágenes es relativamente más pequeño ($M \ll N^2$) y los cálculos son más manejables. Los eigenvalores asociados nos permiten jerarquizar los eigenvectores de acuerdo con su utilidad en la caracterización de la variación entre las imágenes.

El éxito de este algoritmo se basa en la evaluación de los eigenvalores y eigenvectores de la matriz real simétrica L (conjunto de imágenes de entrenamiento). La búsqueda inicial en la ecuación característica (ec. 4.8) es un método computacional "pobre" para encontrar eigenvalores. Durante la fase de programación del algoritmo en este trabajo de investigación, se usó un método más eficiente en la evaluación de los eigenvalores y eigenvectores (Press, 1988). Primero, la matriz simétrica real es reducida a su forma tridiagonal con la ayuda del algoritmo "householder". Este algoritmo reduce una matriz simétrica A de $N \times N$ a su forma tridiagonal por medio de $N-2$ transformaciones ortogonales. Cada transformación anula la parte requerida de una columna completa y el correspondiente renglón completo. Después de eso, los eigenvalores y eigenvectores se obtienen con la ayuda de transformaciones QR de Gram-Schmidt. La idea básica detrás del algoritmo QR es que cualquier matriz simétrica real puede ser descompuesta en la forma $A=QR$ donde Q es ortogonal y R es triangular superior. La carga de trabajo en el algoritmo QR es $O(N^3)$ por iteración para una matriz *normal*, lo cual no es factible, sin embargo, la carga es sólo $O(N)$ por iteración para una matriz tridiagonal, haciendo de este algoritmo una alternativa extremadamente eficiente.

Usando EF para clasificar una imagen

Las imágenes eigenfaces calculadas a partir de los eigenvectores de L , forman un conjunto base con el que se describe cualquier imagen facial. Sirovich y Kirby evaluaron una versión limitada de esta metodología en un conjunto de $M=115$ imágenes de hombres caucásicos digitizados de manera controlada, y encontraron que 40 eigenfaces fueron suficientes para una muy buena descripción de todas las imágenes. Con $M'=40$ eigenfaces, los errores

cuadráticos medios (píxel por píxel) en versiones de representación de las caras fue de cerca del 2%.

En la práctica, un pequeño subconjunto de M (M') puede ser suficiente para la identificación, ya que la representación exacta de la imagen original no es el principal requerimiento técnico. Con base en esta idea, el sistema EF propuesto aquí permite al usuario especificar el número de eigenfaces (M') que va a ser usado en reconocimiento. Para máxima exactitud, el número de eigenfaces debería ser igual al número de imágenes en el archivo de entrenamiento.

En esta metodología, las eigenfaces se expanden en un sub-espacio M' -dimensional del espacio de imágenes original N^2 . Los eigenvectores significantes M' de la matriz L son aquellos con los eigenvalores asociados más grandes.

Una nueva imagen (Γ) es transformada en sus componentes eigenface (se proyecta en el espacio de caras) por medio de una simple operación,

$$w_k = u_k^T (\Gamma - \Psi) \quad 4.21$$

para $k=1, \dots, M'$. Esto describe un conjunto de multiplicaciones y sumas de imágenes punto por punto, operaciones desarrolladas, aproximadamente, a una tasa sobre el hardware de procesamiento de la imagen actual, con una complejidad computacional de $O(N^4)$.

Los pesos forman un vector característico,

$$\Omega^T = [W_1, W_2, \dots, W_{M'}] \quad 4.22$$

que describe la contribución de cada eigenface en la representación de la imagen analizada (de entrada). El vector característico se usa en el algoritmo (estándar) de reconocimiento de patrones para determinar, bajo un número predefinido de clases, la mejor descripción de la cara. Las clases faciales Ω_i pueden ser calculadas promediando los resultados de la representación eigenface sobre un pequeño número de imágenes faciales (pueden ser incluso sólo una) de cada individuo.

La clasificación se desarrolla por comparación entre los vectores característicos de los miembros catalogados y el vector característico de la imagen de entrada. Esta comparación se define con la distancia euclidiana entre los dos miembros y debe ser más pequeña que un límite predefinido ϵ_k (ec.4.23). Si la comparación está bajo el límite, entonces la cara es clasificada como "conocida", de otra manera es clasificada como "desconocida" y puede ser adicionada a la librería de caras con su vector característico para su uso posterior, acción que permite que el sistema EF se actualice y aprenda a reconocer nuevas imágenes.

$$\frac{\|\Omega - \Omega_k\|}{\|\Omega_k\|} \leq \epsilon_k \quad 4.23$$

Reconstruyendo una imagen con EF

Una imagen puede ser reconstruida usando su vector característico y las eigenfaces con

$$\Gamma' = \Psi + \Phi_f \quad 4.24$$

donde

$$\Phi_f = \sum_{i=1}^{M'} W_i u_i \quad 4.25$$

La ec. 4.24 establece que la imagen bajo consideración es reconstruida sumando al promedio del conjunto de entrenamiento la contribución W_i de cada eigenface (ec. 4.25). El grado de ajuste o "relación de error de reconstrucción" puede ser expresado por medio de la distancia euclidiana entre el original y la imagen reconstruida

Relación de error en reconstrucción

$$\frac{\|\Gamma' - \Gamma\|}{\|\Gamma\|} \quad 4.26$$

Como puede observarse, este error se incrementa conforme los miembros del conjunto de entrenamiento difieren grandemente entre ellos. Esto se debe a la adición del promedio de imágenes. Cuando los miembros difieren de cada uno (especialmente en el fondo de la imagen) el promedio de imágenes se hace más "contaminado" y esto incrementa el error.

Existen cuatro posibles estados en una imagen de entrada y su vector patrón:

- Cerca del espacio de caras y cerca de una clase de caras
- Cerca del espacio de caras pero no cerca de una clase de caras conocida
- Distante del espacio de caras y cerca de una clase de caras
- Distante del espacio de caras y no cerca de una clase de caras conocida.

En el primer caso, un individuo es reconocido e identificado. En el segundo caso, un individuo desconocido se presenta al sistema para su inclusión como clase. Los últimos dos casos indican que la imagen no es una imagen de cara. El caso tres puede ser el ejemplo de una clasificación falsa, que puede evitarse transformando la ec. 4.25 a

$$\frac{\|\Phi - \Phi_f\|}{\|\Phi_f\|} \leq \phi_k \quad 4.27$$

donde ϕ_k es un límite pre-establecido por el usuario para la definición de una imagen de entrada como perteneciente a la clase de caras k -ésima.

Resumen del procedimiento de reconocimiento EF

- Forme una librería de imágenes faciales de los individuos conocidos
- Escoja un conjunto de entrenamiento que incluya un número de imágenes (M) para cada persona con alguna variación en expresión y en iluminación
- Calcule la matriz L (de $M \times M$) y encuentre sus eigenvectores y eigenvalores, escoja los eigenvectores M' con los eigenvalores asociados más altos
- Combine el conjunto de imágenes de entrenamiento normalizado de acuerdo con la ec. 4.20 para producir las M' -eigenfaces. Almacene estos eigenfaces para su uso posterior
- Para cada miembro en la librería de caras, calcule y almacene un vector característico de acuerdo con la ec. 4.21.
- Escoja un límite ε de acuerdo con la ec. 4.23 que defina la distancia máxima permitida desde cualquier clase de caras. Opcionalmente puede escoger un límite ϕ de acuerdo con la ec. 4.26 que defina la distancia máxima permitida desde el espacio de caras
- Para identificación de una nueva imagen, calcule su vector característico de acuerdo con la ec. 4.22 y compárelo con los vectores característicos almacenados de los miembros de la librería de caras. Si la comparación satisface la condición de la ec. 4.23 por al menos un miembro, entonces clasifique esta imagen de cara como "conocida", en caso contrario una pérdida ha ocurrido y se debe clasificar como "desconocida", si se desea se puede agregar este miembro a la librería de caras con su vector característico.

5. Resultados

A continuación se presenta a) la evaluación de las velocidades de ondas de corte a partir de los resultados de una prueba de penetración de cono y b) el análisis de la respuesta sísmica del Valle de México. Estos modelos *aproximados* demuestran la conveniencia de utilizar RNs y sistemas de LD en la ingeniería geosísmica.

5.1. Estimación de la velocidad de ondas de corte V_s a partir de la resistencia a la penetración del cono q_c .

Las ecuaciones que expresan comportamientos en medios de suelo para ser consideradas (operando en conjunto) un modelo satisfactorio:

- deben ser *completas*, es decir, ser capaces de elaborar juicios o dictar sentencias sobre comportamientos para todos los estados de esfuerzos y deformaciones,
- la identificación de sus parámetros debe resultar de un número pequeño de pruebas estándar (o simples) realizadas sobre los materiales,
- y deben estar fundamentadas en interpretaciones físicas de las respuestas del material.

La primera característica es esencial cuando se diseñan modelos de aplicación práctica y la segunda solamente es *deseable*. La tercera propiedad asegura que el tiempo ocupado en el estudio se está invirtiendo en generar un modelo *útil* y no solamente un elaborado ejercicio de ajuste de curvas de rendimiento limitado (eficiente sólo sobre los datos que están siendo ajustados).

Teniendo en cuenta estas características y de acuerdo con el proceso empírico de creación de modelos se plantea el siguiente esquema de solución al problema de obtener la velocidad de ondas de corte V_s a partir de resistencias de punta en ensayos de cono q_c :

- SISTEMA: Depósitos de suelo del valle de México
- PROCESO: Propagación de ondas de corte en un medio de suelo
- ENTRADAS (datos): Resistencia a la penetración del cono, propiedades índice y caracterización espacial de la relación entrada-salida
- MODELO: sistema neurodifuso
- SALIDA (resultado): Velocidad de ondas de corte V_s

SISTEMA

La Ciudad de México es una de las metrópolis más antiguas en el hemisferio occidental. Las arcillas del subsuelo de la Ciudad tienen propiedades peculiares: su contenido de agua excede en ocasiones 400%, su índice de plasticidad supera frecuentemente 300% y el índice de compresión C_c puede alcanzar valores de 10 (en la mayoría de los suelos en el mundo es menor a 1).

Los sedimentos lacustres de origen volcánico de la Ciudad de México presentan singulares propiedades índice y mecánicas que desvían su comportamiento de la mayoría de los patrones registrados en otros suelos arcillosos. Su respuesta ante carga estática y dinámica es compleja y aún representa un desafío de interpretación. La composición de los depósitos (sedimentos heterogéneos, volcánicos, lacustres, con una proporción y variedad de microfósiles no determinada) los ubica como sujetos no propios de clasificaciones simples. Numerosos han sido los intentos de caracterizar el subsuelo de la Ciudad de México siendo el antecedente más completo el reportado por Marsal y Mazari (1959).

- Mineralogía

Los suelos lacustres se forman mediante procesos de erosión y transporte, seguidos de deposición y consolidación bajo su propio peso. El comportamiento de los suelos lacustres depende principalmente de dos factores: composición y estructura. El término composición se refiere a la naturaleza de las partículas: tamaño, forma y mineralogía mientras que la estructura se refiere a la disposición geométrica y espacial de los materiales.

La mineralogía controla el tamaño, la forma y las características de las partículas de suelo, siendo estas características y su interacción con la fase líquida quienes determinan la plasticidad, compresibilidad, resistencia y permeabilidad del material por lo que su conocimiento es fundamental en la interpretación de las propiedades de los suelos. Sin embargo, los resultados de los estudios mineralógicos realizados por diferentes investigadores a menudo varían (debido a los métodos de análisis y la preparación de las muestras, entre otros factores). En particular las experiencias en la Ciudad de México (e.g., Zeevaert, 1949; Marsal y Mazari, 1959; Lo, 1962; Mesri et al., 1975; Gómez-Looh, 1987; Peralta y Fabi, 1989; Díaz-Rodríguez, et al. 1998) llevan a concluir que el subsuelo es un material singular donde el orden de abundancia de los minerales varía erráticamente y resulta demasiado aventurado tratar de generalizar la proporción y diversidad de los componentes con alguna precisión.

- Zonificación estratigráfica de la Ciudad de México

Basados en una gran cantidad de sondeos realizados a diferentes profundidades se han definido tres zonas geotécnicas en la Ciudad de México (Fig. 5.1): la Zona del Lago, la Zona de Transición y la Zona de Lomas. A continuación se describen sólo las características estratigráficas de la Zona del Lago (zona lacustre) por ser el área de aplicación del modelo propuesto.

Estratigrafía típica de la zona lacustre

En la Fig. 5.2 se muestran perfiles típicos de los depósitos de la Zona del Lago. Estos perfiles de q_c muestran claramente que existe gran variación en los depósitos de suelo clasificados como Zona del Lago. Es evidente que identificar estos tres perfiles con el mismo calificativo llevará a interpretaciones erróneas por parte del modelo neurodifuso, por lo que se considera necesario recurrir a una zonificación geotécnica más fina que además de "Lago" incluya otro calificativo, como la propuesta por Tamez et al. (1987), la cual se detalla más adelante. Note que en la Fig 5.2 se agrega un segundo calificativo para identificar a qué área dentro de la Zona corresponde cada uno de los tres sondeos.

Con el mismo propósito, es indispensable caracterizar la variabilidad de las estratigrafías en función de la profundidad. A través de los valores de resistencia y esfuerzos efectivos, de pruebas granulométricas y de clasificaciones hechas sobre los materiales que constituyen los depósitos de este tipo se pueden identificar seis estratos característicos (en orden ascendente desde 40 m de profundidad hacia la superficie del terreno):

- Estrato 1: Arenas con grava (40-38 m).

Constituida por fragmentos de roca volcánica (las partículas mayores alcanzan un tamaño de hasta 1.5 cm), arena con grava y una matriz de limo. En comparación con el resto de la columna estratigráfica este estrato es de granulometría gruesa. El contenido de agua no supera el 25%, la resistencia q_c es del orden de 50-60 kg/cm² y la velocidad de propagación de ondas de corte V_s varía alrededor de los 110 m/s.

- Estrato 2: Arenas con grava y arenas limosas (38-36 m).

Granulométricamente la zona se caracteriza por una rápida transición de sedimentos gruesos a una textura de arenas limosas. El contenido de agua tiene un valor promedio de 100%, con un q_c de 40 kg/cm² y una V_s del orden de 100 m/s.

- Estrato 3: Limos arcillosos con arena (36-30 m).

Se compone de limos arcillosos con poca arena (excepcionalmente el contenido de arena alcanza un 50%). El valor de q_c varía de 15 a 22 kg/cm² y V_s es del orden de 75 m/s. Es la zona considerada como transición entre condiciones de depósito subaéreas y condiciones incipientes de depósito lacustre.

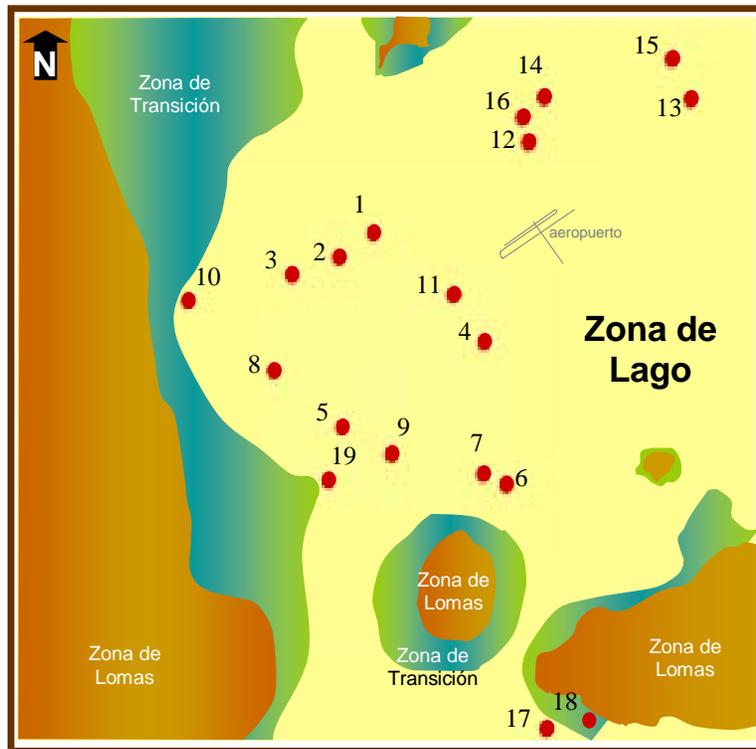


Figura 5.1 Zonas geotécnicas del valle de México

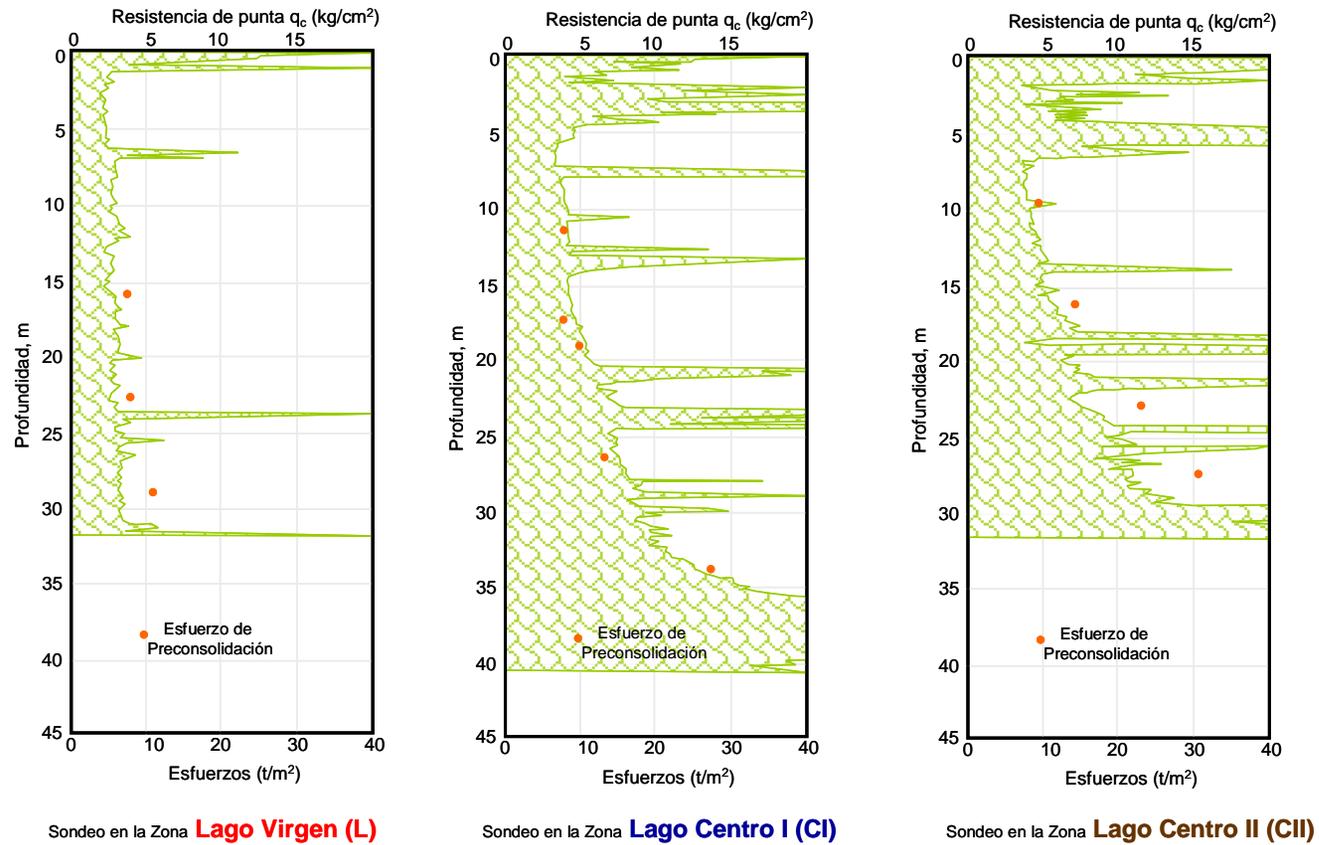


Figura 5.2 Perfiles de resistencias típicos de la zona del Lago (típicos de cada subzona geotécnica)

- Estrato 4: Limos arcillosos o arcillas limosas (30-7 m).

Esta es la capa más importante desde el punto de vista de la geotecnia, principalmente debido a su alta compresibilidad ($m_v = 0.1 \text{ kg/cm}^2$). El estrato se compone de limos arcillosos o arcillas limosas con poca arena. Se tienen varios lentes de arena interestratificados. El contenido de agua se incrementa con el decremento de la profundidad (aproximadamente 220% a 30 m y hasta 420% a 7 m). Los promedios de límite líquido, límite plástico e índice de plasticidad son 338, 80 y 308%, respectivamente. El valor de q_c es casi lineal con la profundidad y V_s es casi constante en este tramo con un promedio de 81 m/s.

- Estrato 5: Limo arcilloso con arena (7-3 m).

En la base de esta zona se encuentra un horizonte de arena que presenta el mayor contenido de arena (85%) de todo el perfil. La granulometría de esta zona corresponde a una arena con variaciones a limo arenoso y limo arcilloso. El valor de q_c es de aproximadamente 24 kg/cm² y el contenido de agua exhibe una tendencia a decrecer sin poder concretar en su valor y variación.

- Estrato 6: Relleno artificial (3-0 m).

La zona superficial es un relleno artificial producto de la actividad humana.

- Sub-Zonificación Geotécnica de la Zona del Lago

De acuerdo con la localización e historia de cargas, la Zona del Lago se ha dividido en tres sub-zonas (Fig. 5.3) atendiendo a la importancia relativa de dos factores: 1) el espesor y propiedades de la costra superficial y 2) la consolidación inducida en cada sitio. En el manual del COVITUR (Tamez et al., 1987), usado ampliamente en el diseño de cimentaciones en el valle de México, se describe cada sub-zona de la siguiente manera (cita textual):

- Lago Virgen (LV). Aunque, a consecuencia de las acciones del hombre, ya no existen arcillas tan blandas como las que existieron hace 400 años, resulta razonable identificar como arcillas en condición virgen a las más blandas de lo que ahora es el vaso del exlago de Texcoco. Sin embargo, como consecuencia del creciente desarrollo de esa zona, las sobrecargas en la superficie se han incrementado e intensificado.
- Lago Centro I (LCI). Corresponde al sector no colonial de la Ciudad el cual se desarrolló a partir de principios de este siglo y ha estado sujeto a las sobrecargas generadas por construcciones pequeñas y

medianas. Las propiedades mecánicas del subsuelo en esta zona representan una condición intermedia entre las del Lago Virgen y las del Lago Centro II. La resistencia de punta del cono eléctrico se ha incrementado por las sobrecargas.

- Lago Centro II (LCII). Esta sub-zona está limitada por la antigua traza de la Ciudad y en ella la historia de cargas aplicadas en la superficie ha sido muy variable por lo cual se presentan las siguientes condiciones extremas: 1) arcillas fuertemente consolidadas por rellenos y grandes sobrecargas de construcciones aztecas y coloniales; 2) arcillas blandas, asociadas a lugares que han alojado plazas y jardines durante largos periodos de tiempo, y 3) arcillas muy blandas en los cruces de antiguos canales. Asimismo, el intenso bombeo para surtir de agua a la Ciudad se refleja en el aumento general de la resistencia de los estratos de arcilla por efecto de la consolidación inducida, como se observa en la Fig.5.2.

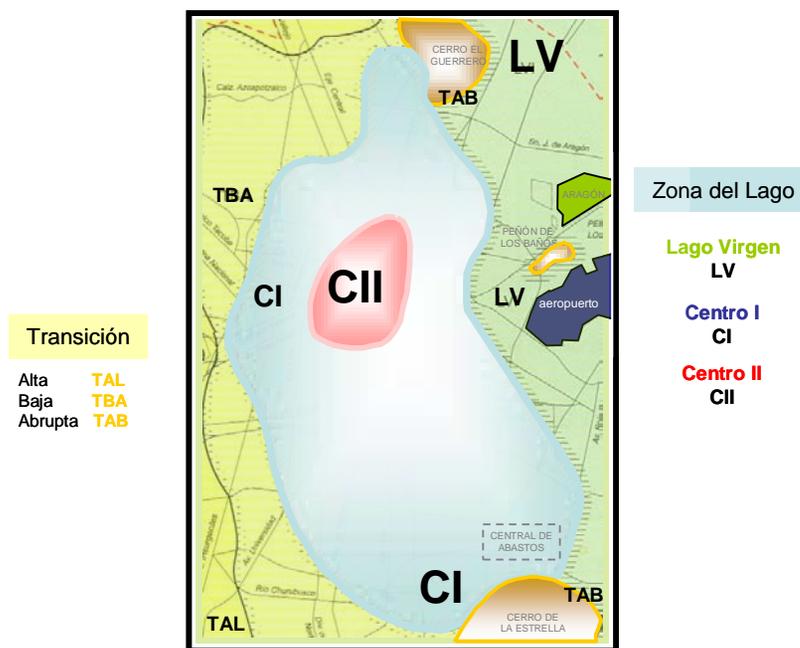


Figura 5.3 Sub-zonas geotécnicas del valle de México

PROCESO

En el Capítulo 2 de este trabajo de tesis se han expuesto los antecedentes y bases teóricas de la propagación de ondas de corte a través de un medio de suelo. Es importante señalar que el método conexionista que se propone en este trabajo no intenta modelar el fenómeno propagación ni caracterizar exhaustivamente los suelos del valle (objetivo poco funcional) sino pretende servir como confiable marco práctico de análisis y cálculo de valores de V_s a partir de las resistencias q_c de los materiales por el que se propaga el tren de ondas sísmicas.

Para el científico dedicado al estudio de los suelos ésta puede ser una herramienta numérica-lingüística que le permita: 1) estudiar formalmente las propiedades dinámicas de los suelos en un ambiente de información escasa,

incompleta y contaminada, 2) generar conclusiones *inteligentes* sobre patrones de comportamiento, y 3) incrementar el conocimiento científico a través de guías matemáticas con significado *natural*.

El **Proceso** en este estudio es la propagación de V_s , pero el esquema matemático a continuación expuesto (sistema neurodifuso) vincula el valor numérico de V_s con parámetros de suelo, por lo que la solución a este inciso es sólo un planteamiento *fenomenológico* relacionado con el *proceso*. Lo anterior significa que el sistema neurodifuso es capaz de describir las *manifestaciones* del *proceso* y eventualmente de relacionarlas con causas, pero no de explicar la estructura o el procedimiento que las genera (Fig. 5.4).

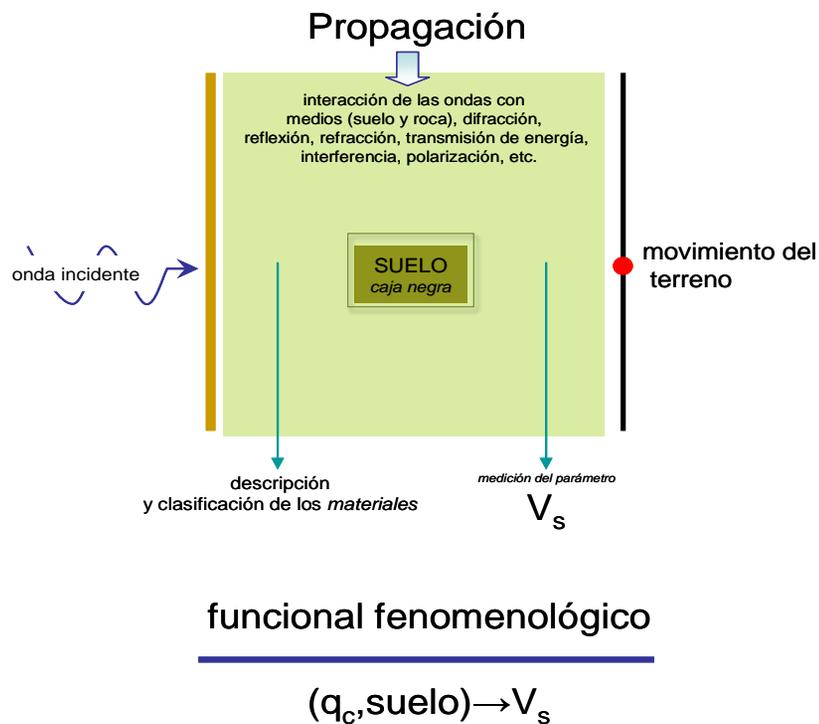


Figura 5.4 Descripción conceptual del funcional neurodifuso

Uno de los parámetros que describe la propagación de ondas de cortante es la velocidad y este valor depende, entre otros factores, de las características del medio por el que se transmite. El funcional fenomenológico que se plantea contiene sólo algunos aspectos de la propagación de ondas de corte: la variable objetivo V_s y descripciones paramétricas y/o lingüísticas del medio.

ENTRADAS

Una importante fuente de variabilidad en los resultados de ensayos geotécnicos y sísmicos es el procedimiento (aplicación de una metodología estándar) y el control de calidad en su desarrollo. Por esta razón para la alimentación del modelo neurodifuso se seleccionó información de sitios estudiados, interpretados y publicados por una misma entidad (en este caso el Instituto de Ingeniería, UNAM) de tal forma que la información mantenga este sesgo y el efecto *incierto* sobre los resultados pueda considerarse constante.

Los sitios que conforman la base de datos (círculos numerados en la Fig. 5.1) fueron elegidos de acuerdo con la disposición de perfiles de V_s y la existencia de mediciones de resistencias y propiedades índice y/o mecánicas. La subzona geotécnica y el tipo de información (uso en el desarrollo del modelo) de cada sitio se presentan en la Tabla 5.1.

La información común en los 19 sitios es el perfil de resistencias a la penetración del cono eléctrico q_c , el de velocidades de ondas de corte V_s y pesos volumétricos del suelo γ_s (se usa indistintamente en este capítulo γ_s o γ como en otros textos técnicos), esta propiedad no disponible en las

mismas profundidades en las que se determinaron los perfiles de q_c y V_s . La velocidad de onda de corte fue medida con las técnicas de sonda suspendida (sitios 1, 2, 4, 5, 6, 7, 8, 9, 17, 18 y 19) y *down hole* (sitios 3, 10, 11, 12, 13, 14, 15 y 16) y los perfiles se presentan discretizados a cada metro. En 9 sitios se conoce el contenido natural de agua w y los límites plásticos, mientras que esfuerzos efectivos, presión de poro y valores de cohesión se consiguieron en sólo 5 sitios. En la extrapolación de las propiedades medidas en un punto (probeta) hacia características atribuibles a estratos "homogéneos" debe tenerse especial cuidado en aquellas que presenten importantes variaciones espaciales ya que su inclusión como variables de modelado minimizaría e incluso eliminaría las ventajas de usar mediciones de campo para caracterizar depósitos de suelo. Los fundamentos en la selección de las variables de mayor calidad para la construcción de la estructura fenomenológica fueron confiabilidad y suficiencia. Si bien no se conoce *a priori* la relación funcional ni jerarquía entre las propiedades que conforman la base de datos, se pueden reconocer aspectos que manifiesten una dudosa representabilidad.

En un sencillo análisis paramétrico se determinó que de los 383 los patrones en la base de datos (Fig. 5.5) menos del 20% permite incluir expresiones adicionales sobre el medio (peso volumétrico γ_s , estado de esfuerzos σ , presión de poro u , índice de plasticidad I_p , contenido de agua w , cohesión c) por lo que relaciones más complejas entre las características del suelo y su capacidad de transmisión de ondas de corte resulta poco factible usando el conjunto original.

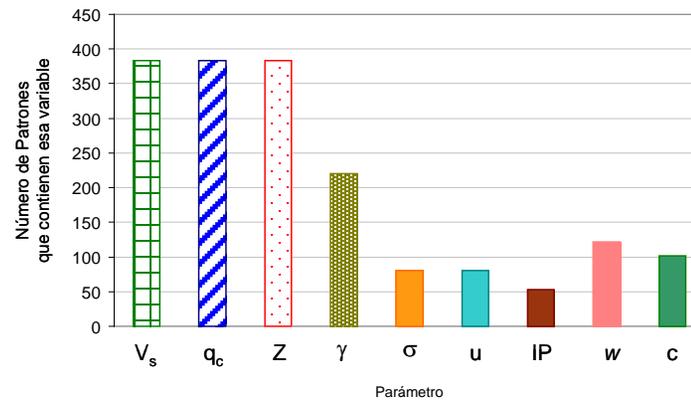


Figura 5.5 Representación de cada variable sobre el número de patrones en la base de datos

Tabla 5.1 Base de Datos

Sitio/número (Figura 1)	Sub-Zona	Geotécnica	Uso del patrón durante el desarrollo del modelo
Tlaltelolco/1	CI (Centro I)		Entrenamiento
Alameda/2	CII (Centro II)		Prueba
Plaza Córdoba/3	CII (Centro II)		Entrenamiento
Velódromo/4	CII (Centro II)		Entrenamiento
SCT/5	CI (Centro I)		Entrenamiento
CAF/6	CI (Centro I)		Entrenamiento
CAO/7	CI (Centro I)		Entrenamiento
CUPJ/8	CI (Centro I)		Prueba
Eugenia/9	CI (Centro I)		Entrenamiento
El Águila/10	CI (Centro I)		Entrenamiento
Línea B/11	L (Lago Virgen)		Entrenamiento
Av. 510/12	L (Lago Virgen)		Entrenamiento
Calle Urano/13	L (Lago Virgen)		Prueba
Nonoalco/14	CI (Centro I)		Prueba
Plaza Aragón/15	L (Lago Virgen)		Prueba
Río Remedios/16	L (Lago Virgen)		Entrenamiento
Tláhuac B/17	L (Lago Virgen)		Prueba
Tláhuac D/18	L (Lago Virgen)		Entrenamiento
5 de febrero/19	CI (Centro I)		Entrenamiento

Debe recordarse que un sistema difuso es capaz de manejar *vacíos* de información pero la *no-presencia* debe estar relacionada con el comportamiento general del funcional que se construye y de alguna manera se debe *sujetar* (declarar fronteras numéricas y condiciones de no-existencia) la "ocurrencia" de falta de datos. En esta base de datos existieron criterios prácticos (posiblemente basados en un conocimiento parcial sobre la estratigrafía) para la selección de las profundidades a las que se extraerían las muestras de acuerdo con su significado sobre la longitud de columna de suelo estudiada. Sin tener acceso a estos criterios y usando las propiedades tal como se reportan en los informes, la aplicación de los escasos valores de γ_s , σ , u , c o ω sobre los valores de campo (q_c , V_s , Z) origina incongruencias

que ningún sistema inteligente sería capaz de resolver incluso con la ayuda de un *experto* humano (vea el ejemplo con γ_s mostrado en la Fig. 5.6). ¿Por qué suceden estas contradicciones numéricas/descriptivas?. Una posible respuesta sería que las probetas no son representativas de los estratos determinados a través de pruebas de campo, o bien que los estratos así definidos no son reales, es decir, que las variaciones en valores reportados por las pruebas (de resistencia o sísmicas, por ejemplo) pueden deberse a efectos externos no relacionados con el comportamiento de la masa de suelo. Si no se pueden identificar ni la fuente de la incertidumbre ni el grado en el que afecta nuestra apreciación del medio, en esta investigación se elige utilizar parámetros con vínculos directos en la búsqueda de relaciones.

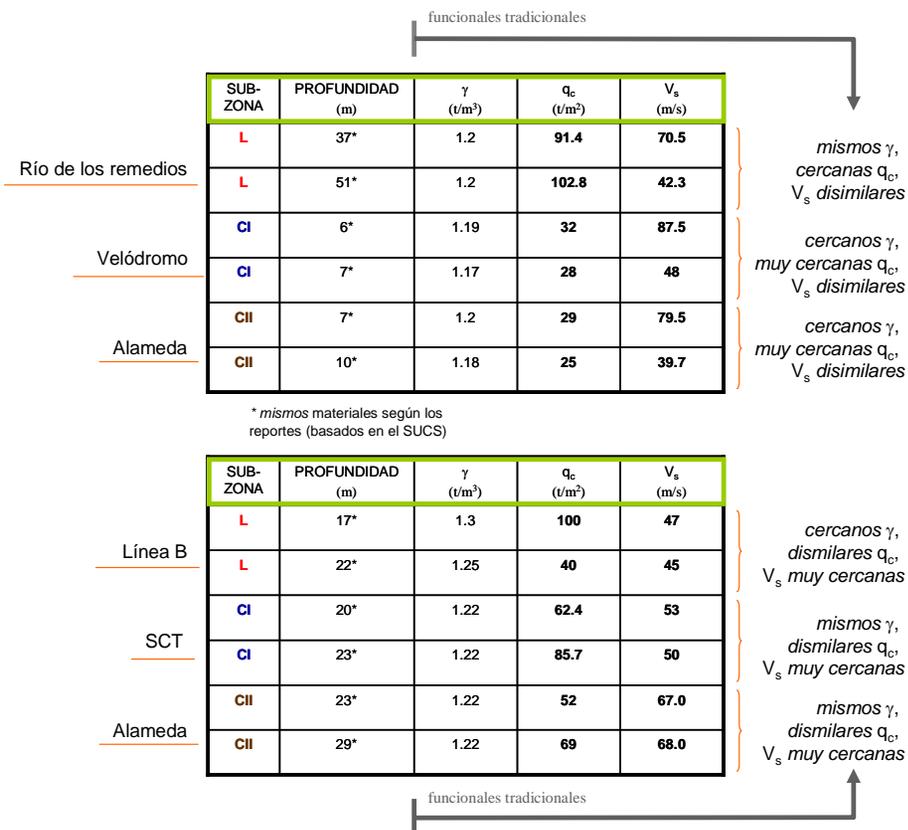


Figura 5.6 Incongruencias numérico-descriptivas en la base de datos original

De acuerdo con lo anterior, $[q_c, V_s, Z]$ es una combinación paramétrica simple y confiable. Es necesario puntualizar que si bien se están eliminando propiedades incluidas en la mayoría de los funcionales que tratan de relacionar resistencias y velocidades, éstas en realidad están implícitas en los valores reportados de q_c si se acepta que la resistencia de los materiales naturales depende de su densidad, de su plasticidad y de la condición de esfuerzos *in situ*, entre algunas de las condiciones reconocidas (motivo de otra disertación sería el análisis de las variables que no se estudian –por limitaciones teóricas y/o tecnológicas– y posiblemente tienen mayor conexión con el comportamiento mecánico y dinámico de los suelos).

Por otro lado, de acuerdo con conceptos de lo difuso, la definición de las entradas procura la selección de descripciones (numéricas y lingüísticas) cuya cercanía permita construir funciones matemáticas *naturales* y eficientes. El peso volumétrico, el contenido natural de agua, la cohesión, incluso el valor de los esfuerzos verticales efectivos no se encuentran en la vecindad del espacio (relacionadas numérica o lingüísticamente con las entradas declaradas) que ocupan las propiedades estimadas *in situ* (condiciones de ensaye *reales*).

El pre-proceso controlado (manejo y preparación de muestras, reproducción de condiciones de esfuerzos) y su interpretación en el post-proceso (relación de comportamientos complejos con funciones simplistas) colocan a estas propiedades lejos de los atributos de las pruebas de campo. Entonces, ¿por qué estos parámetros son incluidos en la mayoría de los funcionales para estimar V_s ? Porque la información de resistencias q_c resulta insuficiente si se le propone como la única dependencia de una variable tan compleja como V_s . Es decir, la naturaleza (no lineal y multidimensional, así no se conozca cabalmente la dimensión a la que pertenece) de la variable objetivo obliga a la construcción de premisas múltiples (mayor número de variables de entrada). Entonces se impone la inclusión de alguna característica numérica conectada con los materiales y/o la variable objetivo.

Aumentar la dimensión de la relación $q_c \rightarrow V_s$ con la variable *profundidad* Z , además de agregar un *contador* (nodo usado en modelos neuronales para dar idea de *secuencia*) sirve para separar los puntos con valores *muy cercanos* de resistencia que puedan tener velocidades *muy lejanas* (o viceversa). Como se explicó en la descripción del **Sistema** (depósitos de suelo del valle de México), las estratigrafías típicas de L, CI y CII comparten valores de q_c , V_s y tipos de suelo, siendo la profundidad a la que se encuentran estos materiales la que introduce la variación espacial de la velocidad. Al nodo contador Z se yuxtapone el nodo clasificador *Zona* para que, como dupla, expliquen al sistema las salidas de V_s en el rango de profundidades estudiadas a través de los perfiles de q_c , así cada relación será particular de cierta sub-zona geotécnica.

Una importante diferencia entre el planteamiento neurodifuso y los funcionales existentes es la inclusión de Z en la estimación de V_s . Z otorga la cualidad de *continuidad* a las estimaciones y hace que subconjuntos de patrones formen parte del semiespacio bajo una línea en estudio (a 90° a partir de la superficie) mientras que *Zona* ubica a estos subconjuntos

(pertenecientes a un sitio) sobre el plano del valle (sin hacer uso de coordenadas geográficas $[X,Y]$ esto es una referencia o situación geotécnica) lo que ejemplifica un mapeo tridimensional: $V_s = f(q_c, Z, Zona)$. En las funciones que no incluyen la variable Z se trata a cada punto de medición como un individuo que pertenece a una población (todos los posibles valores de resistencia y velocidad en la zona del Lago) y se asume que la variación en V_s depende únicamente de la resistencia y algunas propiedades (comúnmente la densidad del suelo) y que éstas a su vez están libres de contaminación o errores de medición (incertidumbre). Esta condición es ideal pero difícilmente se alcanza en ensayos de campo sobre materiales naturales.

Después de considerar los aspectos geotécnicos y de modelado anteriormente expuestos, se proponen como entradas del sistema:

- q_c *resistencia*
- Z *profundidad*
- Zona* *Sub – zona geotécnica*

A pesar de la inclusión de los nodos *clasificador* y *contador* existen todavía incongruencias en la base de datos que, en este trabajo de investigación, se solucionan a través de un pre-proceso difuso de agrupación (*fuzzy clustering*) que al mismo tiempo equilibra la cantidad de información dentro del espacio de entradas y salidas (elimina nubes densas de patrones a través de un *típico* que las representa). Como primer paso se define el intervalo numérico donde tienen significado las variables (Fig. 5.7).

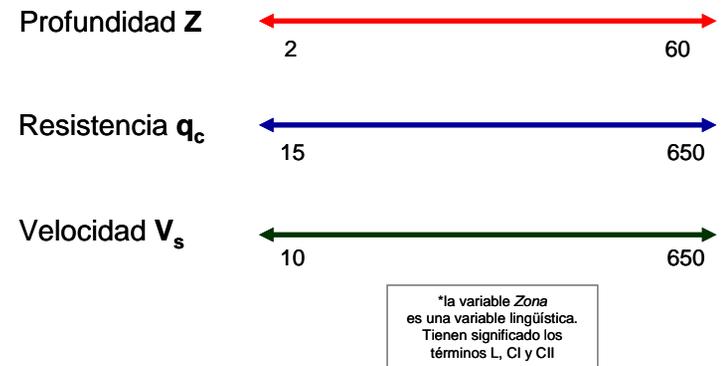


Figura 5.7 Bases numéricas de las entradas y salida

Después, de acuerdo con el conocimiento y experiencia sobre el fenómeno, la importancia o jerarquía de cada variable y la cantidad de líneas (patrones) en la base de datos se establecen las distancias sobre una función de membresía P_i (trapecio) que exponen la completa similitud ϵ o la total disimilitud δ entre patrones. Expresadas en porcentaje, estas fronteras son recomendaciones subjetivas por lo que deben probarse varias combinaciones de (ϵ, δ) para definir los conjuntos de *típicos* más representativos, es decir, cuáles bases de datos (modificadas) cubren ordenadamente el espacio paramétrico (Tabla 5.2).

En la Fig. 5.8 se muestran gráficos bidimensionales de las entradas y V_s para la base de datos original y la agrupación elegida como más eficiente (combinación C). La nueva base de datos consta de 207 patrones de entrenamiento y a partir de este momento estos *típicos* son usados como base de datos en la etapa de entrenamiento neurodifuso. Los sitios etiquetados como *Prueba* (ver Tabla 5.1) han sido apartados para la etapa de validación y no son sujetos de ningún tipo de procesamiento (representan condiciones de trabajo reales).

Tabla 5.2 Combinaciones de (ϵ, δ) para obtención de típicos

	ENTRADAS		SALIDA	REDUCCIÓN
<i>nueva</i> BASE DE DATOS	Profundidad (m)	Resistencia q_c (t/m²)	V_s (m/s)	de 259 patrones a
A	0.5-1.0%	0.15-1.0%	0.15-1.0%	246
B	1.0-2.0%	0.30-1.0%	0.30-1.0%	202
C	1.0-4.0%	0.30-2.0%	0.30-2.0%	207
D	2.0-2.0%	0.60-1.0%	0.60-1.0%	243
E	1.5-3.0%	0.45-3.0%	0.45-3.0%	147
F	2.0-3.0%	2.0-3.0%	2.0-3.0%	99
G	2.5-3.5%	2.5-3.5%	2.5-3.5%	78
H	3.0-3.0%	3.0-3.5%	3.0-3.5%	85

→ la más equilibrada

*el número de patrones original es de 259 (se excluyeron 124 para su uso en la etapa de prueba)

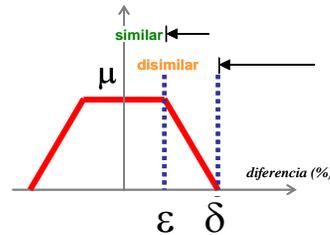


Figura 5.8 Reducción de base *original* de patrones a conjunto de *típicos*

MODELO

1. Descripción del Proyecto

VARIABLES DE ENTRADA	3
VARIABLES DE SALIDA	1
VARIABLES INTERMEDIAS	0
BLOQUES DE REGLAS	1
REGLAS	108
FUNCIONES DE MEMBRESÍA	14

2. Estructura del Sistema

La estructura del sistema permite identificar el flujo de inferencia difusa desde las variables de entrada hasta las variables de salida. Transformar las interfaces de entrada consiste en traducir entradas análogas hacia valores difusos. La inferencia difusa toma lugar en los bloques de reglas (control difuso). La salida de estos bloques son variables lingüísticas que se transforman en variables análogas por medio de un proceso inverso difuso.

En la Fig. 5.9 se muestra la estructura del sistema difuso propuesto en este trabajo de investigación, que incluye: 1) interfaces de entrada, 2) bloques de reglas y 3) interfaces de salida. Las líneas conectores simbolizan el flujo de datos.

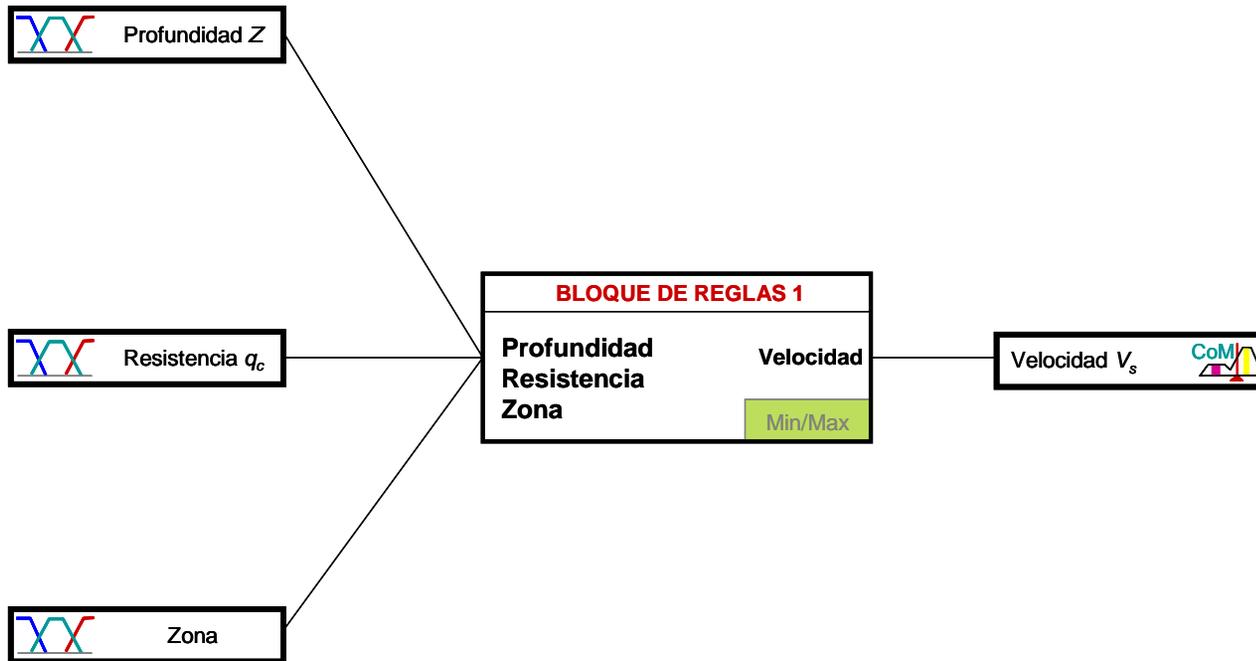


Figura 5.9 Estructura del Sistema de Lógica Difusa

- 3. Variables

A continuación se definen las variables lingüísticas y sus funciones de membresía. Estas variables sirven para traducir los valores *reales* en valores *lingüísticos*. Los posibles valores de una variable lingüística no son números sino los llamados términos lingüísticos. A cada término le corresponde una

función de membresía que se define con unos cuantos puntos sobre el espacio [*base de variable, membresía*]. A continuación se enlistan las variables, sus bases, sus términos, el método difuso y el inverso difuso aplicado en cada una de ellas.

- Entradas

#	Nombre de la Variable	Tipo	Unidad	Min	Max	Nombre de los Términos
1	Profundidad Z		m	0	70	Superficial Formación Profundo
2	Resistencia q_c		t/m ²	0	700	Blando Medio Firme Roca
3	Zona		clase	0	80*	Lago Centro I Centro II

* carece de significado físico

Métodos Difusos

	Calcula FMB*		Busca FMB**
	Variable categórica		Display
	Entrada difusa		

*se almacenan los puntos de definición de las funciones de membresía FMB

**se calculan las de las funciones de membresía FMB completas

- Salida

#	Nombre de la Variable	Tipo	Unidad	Min	Max	Nombre de los Términos
4	Velocidad V_s		m/s	0	700	Baja Media Alta Muy alta

Métodos Difusos Inversos

	Centro de Máximos (CoM)		Promedio de Máximos (MoM)
	Centro de Área (CoA)		Hiper CoM
	Salida difusa		Fuerza

* para generar el "resultado más plausible" use el Promedio de Máximos y la "mejor concesión" se obtiene con el Centro de Máximos y el Centro de Áreas.

Funciones Propuestas:

- **Profundidad Z**

De acuerdo con el modelo estratigráfico inicialmente propuesto por Marsal y Mazari, la secuencia de los suelos de la antigua zona lacustre está integrada por: 1) la costra superficial (en muchas partes cubierta con rellenos artificiales de espesor variable que pueden llegar a ser de varios metros), 2) formación arcillosa superior (arcillas blandas a muy blandas) y 3) la primera capa dura (separa la primera formación arcillosa de la segunda constituida por arcillas más consolidadas).

Esta identificación se llevó a cabo a través de pautas visuales y táctiles además de estimaciones de contenidos de agua y límites de consistencia pero incluso los más recientes sondeos de cono eléctrico no han modificado mayormente los rangos de profundidades a los que se encuentran cada tipo de suelo (clasificados según el Sistema Unificado de Clasificación de Suelos SUCS). Con base en lo anterior, a continuación se describen las tres etiquetas propuestas para la variable Profundidad (Fig. 5.10).

Superficial. Definida como función triángulo otorga el valor de pertenencia CERO a la cota 0+0.00 (superficie). El valor típico UNO se encuentra a los 10 m a partir de los cuales decrece la membresía hasta regresar a CERO a los 20 m.

Formación. Definida como función triángulo otorga el valor de pertenencia CERO al rango 0m→10m. A partir de este valor la pertenencia crece gradualmente hasta encontrar el valor típico UNO a los 30 m, desde esta profundidad decrece la membresía hasta regresar a CERO a los 50 m.

Profundo. Definida como función hombro otorga el valor de pertenencia CERO al rango 0→25m. A partir de los 25 m la membresía crece gradualmente hasta encontrar el valor típico UNO a los 50 m (profundidad aproximada donde todos los sitios presentan o han presentado valores de resistencia y velocidad propias de materiales *firμες*). Todas las profundidades más allá de este valor (hasta el límite de operación del sistema ≈70 m) serán típicas del término profundo. Si los materiales y velocidades discrepan en este rango de profundidades se propone que la diferencia la marquen los valores de resistencia (asociados con la compresibilidad de los materiales) y la zona geotécnica.

- **Resistencia q_c**

Los cambios de resistencia a la penetración que ocurren en la secuencia estratigráfica del subsuelo de la Ciudad se suceden en concordancia con las variaciones en los contenidos de agua y cargas aplicadas. Para ser congruentes con las hipótesis descritas en la elección de variables de entrada, los estratos así definidos son el punto de partida en la declaración de las etiquetas de q_c . Los valores típicos y las fronteras de la NO pertenencia están basados en las descripciones del **Sistema** (suelos del valle). Se reconocen dentro de la costra superficial la existencia de rellenos artificiales, suelos blandos y costra seca. En el caso de la formación arcillosa superior se pueden encontrar arcillas preconsolidadas (superficiales y profundas), arcillas normalmente consolidadas y lentes duros. La capa dura es un depósito heterogéneo cuya cementación es errática y su espesor es muy variable. La dificultad en su muestreo no permite definir confiablemente sus propiedades mecánicas, así que el cono eléctrico es una de las herramientas más adecuadas de exploración que permite identificar sus peculiaridades. Después y hasta el límite de operación del sistema (en términos de Profundidad) se encuentra la formación arcillosa inferior que consta de estratos de arcilla separados por lentes duros.

De acuerdo con lo anterior se eligieron cuatro etiquetas para la descripción de la resistencia que presentan los suelos que componen la estratigrafía de la zona del Lago (Fig.5.11).

Blando. Definido como función triángulo otorga el valor de pertenencia CERO a la resistencia nula. A partir de este valor la membresía crece gradualmente hasta encontrar el valor típico UNO cuando q_c alcanza las 100 t/m². La pertenencia decrece a partir de 100 y hasta 200 t/m² donde regresa a pertenencia CERO.

Medio. Definido como función triángulo otorga el valor de pertenencia CERO al rango 0→100 t/m² desde donde comienza a crecer la membresía hasta alcanzar el típico a las 200 t/m². De 200 a 300 t/m² el valor de pertenencia desciende y permanece en CERO hasta el límite de operación del sistema.

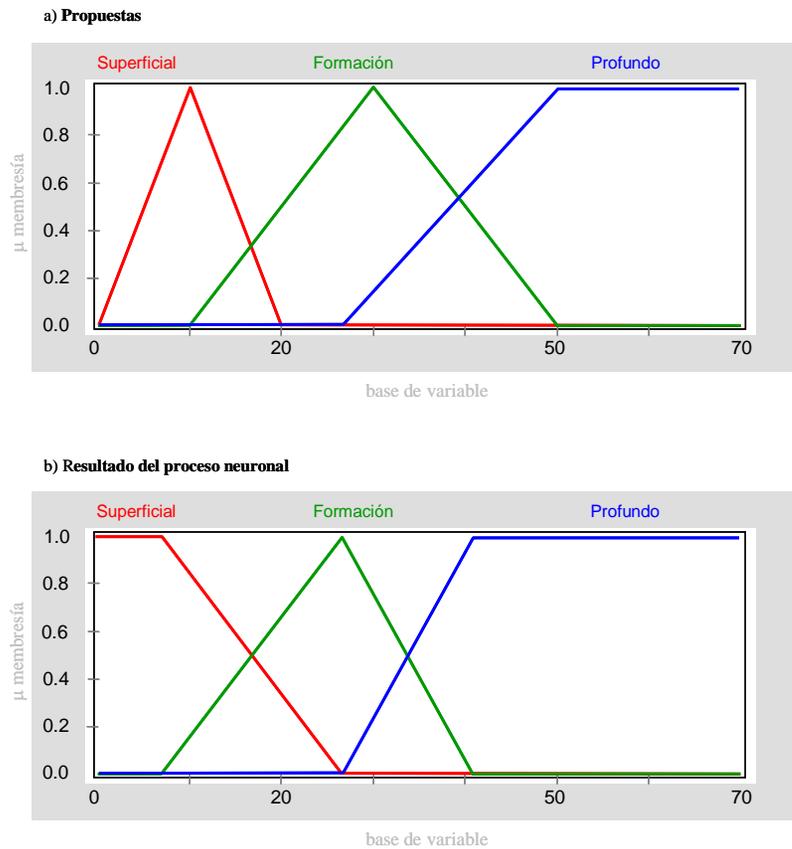
Firme. Definido como función triángulo otorga el valor de pertenencia CERO al rango 0→200 t/m² desde donde comienza a crecer la membresía hasta alcanzar el típico a las 350 t/m². De 350 a 500 t/m² el valor de pertenencia desciende y permanece en CERO hasta el límite de operación del sistema.

Roca. Definida como función hombro otorga el valor de pertenencia CERO al rango 0→ 400 t/m². A partir de este valor la membresía crece gradualmente hasta encontrar el valor típico UNO a las 500 t/m², siendo esta resistencia el valor promedio de los reportados en capa dura para los sitios de la base de datos. Todas las resistencias más allá de este valor (y hasta el límite de operación del sistema 700 t/m²) serán típicas del término *roca*.

- **Zona Geotécnica Zona**

De acuerdo con lo declarado en la descripción del **Sistema** y la elección de **Variables**, se incluye la caracterización detallada de la zona del Lago por subzonas. La base numérica de esta variable carece de significado físico. Si bien era posible incluir un nodo de clase que definiera la pertenencia *cerrada* a cada subzona, se decidió que la mejor manera de expresar esta empírica subdivisión sobre el plano de la cuenca, es a través de clases difusas. Esta variable no se abre al entrenamiento por tratarse de una categoría subjetiva y cuya liga con los valores de resistencias, profundidades y velocidades es sólo a través de apreciaciones (su fundamento numérico relacionado con mediciones *reales* ocasionaría contradicciones en muchos de los patrones de la base de datos).

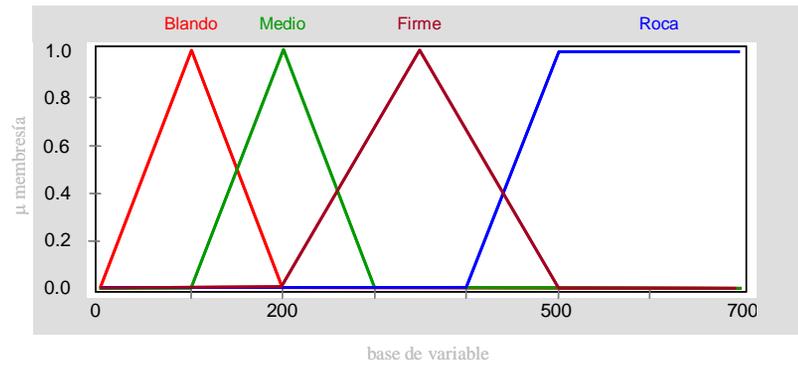
Si esta variable de clase se abiera al entrenamiento, las funciones redefinidas tendrían un sentido difícil de interpretar bajo el esquema difuso hasta ahora planteado. Para que esta modificación tuviera una repercusión en el conocimiento del fenómeno, sería necesario colocar a esta variable en la parte de las conclusiones y adicionar más términos geotécnicos y geográficos en las premisas (Fig.5.12).



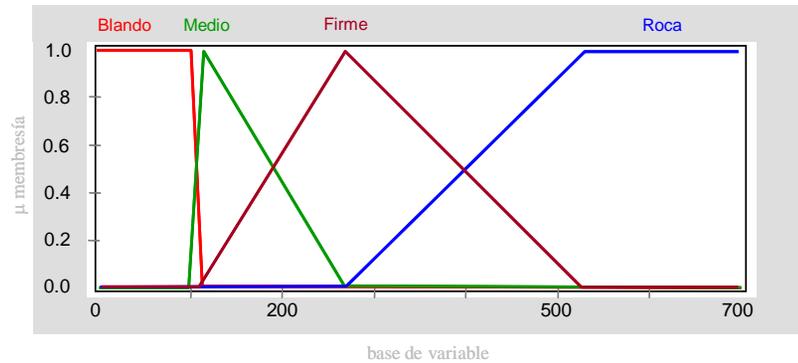
Término	Forma	Definición (base,membresía) PROPUESTA	Definición (base,membresía) después del entrenamiento NEURONAL
Superficial	lineal	(0,0);(10,1);(20,0);(70,0)	(0,1);(6.99,1);(26.54,0);(70,0)
Formación	lineal	(0,0);(10,0);(30,1);(50,0);(70,0)	(0,0);(6.99,0);(26.54,1);(40.86,0);(70,0)
Profundo	lineal	(0,0);(30,0);(50,1);(70,1)	(0,0);(26.54,0);(40.86,1);(70,1)

Figura 5.10 Funciones de Membresía (FMB) para la variable Profundidad, a) propuestas, b) resultado del entrenamiento neuronal

a) Propuestas



b) Resultado del proceso neuronal



Término	Forma	Definición (base,membresía) PROPUESTA	Definición (base,membresía) después del entrenamiento NEURONAL
Blando	lineal	(0,0);(100,1);(200,0);(700,0)	(0,1);(96.5,1);(104.9,0);(700,0)
Medio	lineal	(0,0);(100,0);(200,1);(300,0);(700,0)	(0,0);(96.5,0);(104.9,1);(264,0);(700,0)
Firme	lineal	(0,0);(200,0);(350,1);(500,0);(700,0)	(0,0);(104.9,0);(264,1);(525,0);(700,0)
Roca	lineal	(0,0);(400,0);(500,1);(700,1)	(0,0);(264,0);(525,1);(700,1)

Figura 5.11 Funciones de Membresía (FMB) para la variable Resistencia, a) propuestas, b) resultado del entrenamiento neuronal

Lago Virgen. Definida como función triángulo otorga el valor de pertenencia CERO al valor numérico inicial (cero). El típico (pertenencia UNO) se otorga cuando el usuario declare 20 unidades y a partir de este punto la membresía decrece hasta regresar a CERO en 40 unidades y hasta el límite de operación de 80 unidades.

Centro I. Definida como función triángulo otorga el valor de pertenencia CERO al rango 0→20 unidades. El típico (pertenencia UNO) se otorga cuando el usuario declare 40 unidades y a partir de este punto la membresía decrece hasta regresar a CERO en 60 unidades y hasta el límite de operación de 80 unidades.

Centro II. Definida como función triángulo otorga el valor de pertenencia CERO al rango 0→40 unidades. El típico (pertenencia UNO) se otorga cuando le usuario declare 60 unidades y a partir de este punto la membresía decrece hasta regresar a CERO en 80 unidades.

No usar la función hombro en los extremos *Lago Virgen* y *Centro II* se debe precisamente a la necesidad de cubrir las deficiencias en la definición de todas las clases. Cuando el usuario tenga muy pocos argumentos para decidir sobre otorgarle o no la etiqueta de “sitio típico” de cierta subzona a un patrón en particular basta con alejarse a la izquierda o hacia la derecha si las dudas sobre su pertenencia lo acercan o alejan (con evidencias) de cierta subzona.

- **Velocidad V_s**

Los cambios de velocidades ocurren de manera muy similar a los reportados en la descripción de la variable resistencia q_c . Para ser congruentes con las hipótesis declaradas en la elección de variables de entrada, las etiquetas definidas para q_c son el punto de partida en la declaración de las etiquetas de V_s . Los valores típicos y las fronteras de la NO pertenencia están basados en lo descrito en **Sistema** (Fig.5.13).

Baja. Definida como función triángulo otorga el valor de pertenencia CERO a la velocidad nula. A partir de este valor la membresía crece gradualmente hasta encontrar el valor típico UNO cuando V_s alcanza los 100 m/s. La pertenencia decrece a partir de 100 y hasta 200 m/s donde regresa a pertenencia CERO.

Media. Definida como función triángulo otorga el valor de pertenencia CERO al rango 0→100 m/s desde donde comienza a crecer la membresía hasta alcanzar el típico a los 200 m/s. De 200 a 300 m/s el valor de pertenencia descende y permanece en CERO hasta el límite de operación del sistema (700 m/s).

Alta. Definida como función triángulo otorga el valor de pertenencia CERO al rango 0→200 m/s desde donde comienza a crecer la membresía hasta alcanzar el típico a los 350 m/s. De 350 a 500 m/s el valor de pertenencia descende y permanece en CERO hasta el límite de operación del sistema.

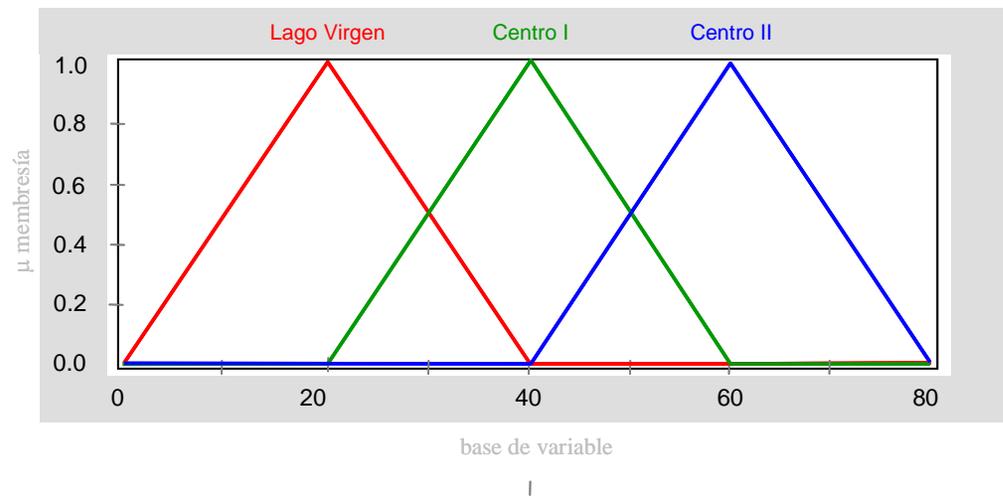
Muy alta. Definida como función hombro otorga el valor de pertenencia CERO al rango 0→ 400 m/s. A partir de este valor la membresía crece gradualmente hasta encontrar el valor típico UNO a las 500 m/s, siendo esta

resistencia el valor promedio de los reportados en capa dura para los sitios de la base de datos. Todas las resistencias más allá de este valor (hasta el límite de operación del sistema 700 m/s) serán típicas del término *muy alta*. Si los materiales y resistencias discrepan en este rango de velocidades se propone que la diferencia la marquen los valores de profundidad (asociada con la estratigrafía) y la zona geotécnica.

Funciones generadas a partir del entrenamiento Neurodifuso:

La aplicación de la tecnología neurodifusa permite la generación automática del sistema difuso (basado en el esquema propuesto) que combina la intuición y la heurística ingenieril a través de lenguaje práctico, sin necesidad de recurrir a modelos matemáticos rigurosos.

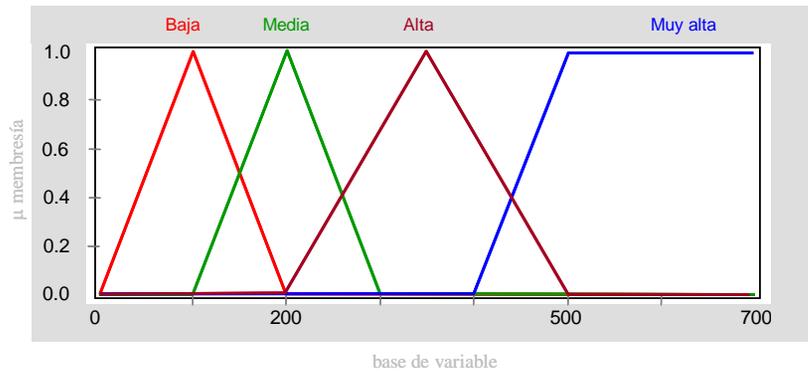
Hasta este punto se ha construido la estructura *vacía* del sistema de lógica difusa que estima V_s . Se definieron las variables lingüísticas, términos y funciones de membresía. Dentro de este sistema *vacío* existe un bloque de reglas (contiene 108) con todas las posibles combinaciones entre las premisas y las conclusiones. Todas las reglas inician con grado de soporte (DoS) CERO, lo que significa que el entrenamiento neurodifuso afectará mayormente a las reglas que tienen influencia significativa sobre el comportamiento global del sistema.



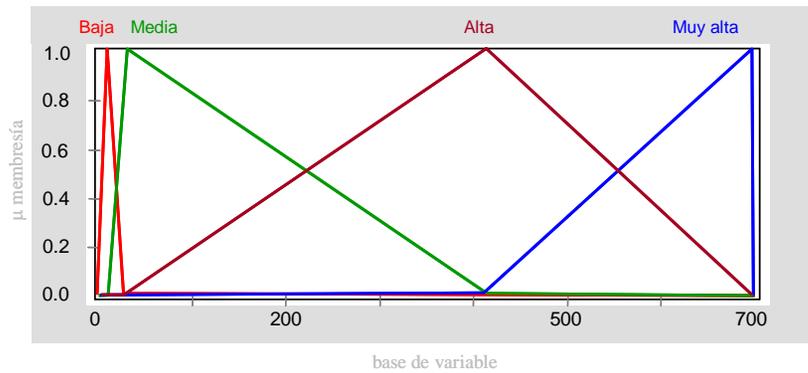
Término	Forma	Definición (base,membresía) PROPUESTA	Definición (base,membresía) después del entrenamiento NEURONAL
Lago Virgen	lineal	(0,0);(20,1);(40,0);(80,0)	no abiertos al aprendizaje
Centro I	lineal	(0,0);(20,0);(40,1);(60,0);(80,0)	no abiertos al aprendizaje
Centro II	lineal	(0,0);(40,0);(60,1);(80,1)	no abiertos al aprendizaje

Figura 5.12 Funciones de Membresía propuestas (FMB) para la variable Zona

a) Propuestas



b) Resultado del proceso neuronal



Término	Forma	Definición (base,membresía) PROPUESTA	Definición (base,membresía) después del entrenamiento NEURONAL
Baja	lineal	(0,0);(100,1);(200,0);(70,0)	(0,0);(11.1,1);(26.5,0);(700,0)
Media	lineal	(0,0);(100,0);(200,1);(300,0);(700,0)	(0,0);(11.1,0);(26.5,1);(413.4,0);(700,0)
Alta	lineal	(0,0);(200,0);(350,1);(500,0);(700,0)	(0,0);(26.5,0);(413.4,1);(698.9,0);(700,0)
Muy Alta	lineal	0,0);(400,0);(500,1);(700,0)	(0,0);(413.4,0);(698.9,1);(700,0)

Figura 5.13 Funciones de Membresía (FMB) para la variable Velocidad, a) propuestas, b) resultado del entrenamiento neuronal

Ya que un paradigma neurodifuso es altamente estructurado, es posible definir exactamente cuales componentes del sistema deben ser modificados en el entrenamiento e incluso pueden abrirse términos específicos o reglas individuales. En esta investigación la parte del sistema que fue enteramente sostenida por la *sabiduría* humana fue la variable *Zona* (con sus tres etiquetas). Las demás variables (incluidos todos sus términos) y todas las reglas en el único bloque construido fueron abiertas de tal forma que el entrenamiento completara o corrigiera los aspectos donde no existe suficiente experiencia (conocimiento) o donde esta erudición pudiera ser derivada de los datos.

Al tiempo que se desarrolla el entrenamiento, el sistema se optimiza de acuerdo con el error entre los valores estimados y los propuestos de prueba; sin embargo, y en contraste con las redes neuronales, el resultado del entrenamiento es un sistema de lógica difusa que puede ser optimizado *a mano*. La optimización *en línea* (cerrado el entrenamiento se propone un ejemplo de prueba y se ajustan los valores de los términos y de los grados de soporte de tal forma que se cumplan las condiciones que impone ese ejercicio en particular) permitió la corrección de algunos valores de variables para *típicos* que causaban que el sistema se *atascara* (generación de mismos valores de salida para valores de entrada distintos) en algunas importantes evaluaciones.

A continuación se describe el sistema de lógica difusa “puro” resultante, que puede ser implementado en microcontroladores, PC's, estaciones de trabajo e incluso en controladores tipo *PLC* (*Programmable Loop Controller*) y *PAL* (*Programmed Array Logic*).

Funciones resultado del Entrenamiento:

- **Profundidad Z**

Superficial. Propuesta como función *triángulo* fue modificada a función *hombro* con lo que se otorga el valor de pertenencia UNO a la cota 0+0.00 (superficie). El valor típico continúa hasta cerca de 10 m y a partir de este valor la membresía disminuye a CERO más allá de los 25 m. Resulta lógica esta nueva definición si se piensa que no crece la pertenencia a la *superficie* conforme se avanza en la columna estratigráfica, sino al contrario. El hecho de que exista un rango entre los 0 y casi 10 m donde las profundidades son típicamente superficiales es congruente con los espesores de costra en algunas zonas del valle.

Formación. Esta función se mantiene como *triángulo* y sigue otorgando el valor de pertenencia CERO al rango 0→casi 10 m. A partir de este valor la pertenencia crece gradualmente hasta encontrar el valor típico UNO poco antes de los 30 m, al mismo tiempo que se deja de ser *superficial*, esta es una modificación mínima en la definición numérica pero importante desde el punto de vista de modelado. Antes la pertenencia a este término se anulaba a los 50 m, después del entrenamiento se reconoce que deja de ser *Formación* a los 40 m y la pendiente derecha del triángulo cambió de tal forma que después de los 32 m la membresía a la serie arcillosa superior es menor de 0.5.

Profundo. Definida como función *hombro* mantiene el valor de pertenencia CERO en el rango 0→casi 25m. A partir de este valor la membresía crece gradualmente hasta encontrar el valor típico UNO cerca de los 40 m. Igual que en las funciones propuestas, el inicio del término profundo se localiza en el punto típico de la etiqueta formación, pero el sistema entrenado considera que este mismo punto (26.5 m) es la frontera de pertenencia a los estratos *superficiales*.

- **Resistencia q_c**

Blando. Definido inicialmente como función *triángulo* después del entrenamiento se convierte en función *hombro* con valor de pertenencia UNO en el rango de 0→casi 100 t/m². A partir de este valor la pendiente decreciente del medio trapecio es casi vertical –entre 100 y hasta cerca de 105 t/m² pasa de $\mu = 1$ a $\mu = 0$ –(la verticalidad indicaría una frontera cerrada).

Medio. La modificación de la función se llevó a cabo en la parte izquierda del *triángulo* que ahora presenta una frontera casi cerrada con el término que le antecede (*Blando*). Compartiendo la misma pendiente (invertida) que el extremo derecho de la función *hombro* que le antecede, otorga el valor de pertenencia UNO a las 105 t/m², desde donde decrece la membresía hasta hacerse nula a las 264 unidades. A partir de este valor la pertenencia permanece en CERO hasta el límite de operación del sistema. Si se analizan las fronteras casi verticales de las etiquetas *Blando* y *Medio*, se puede decir que el sistema finalmente considera que los materiales con resistencias de 0 a casi 100 t/m² son típicos de una etiqueta *nueva*, a partir de este rango decrece la pertenencia hasta anularse en 264 unidades, justamente cuando se alcanza la resistencia típica de un material *Firme*. El sistema trabaja realmente con tres etiquetas en lugar de cuatro como inicialmente se propuso. Esta fusión será llamada: término *Blando-Medio*.

Firme. La función *triángulo* inicial es expandida hacia la izquierda y se recorre el punto de arranque a 105 t/m². El valor típico disminuye 110 t/m² y a partir de este valor desciende hasta alcanzar CERO poco después de las 500 t/m², manteniéndose así hasta el límite de operación del sistema. Esta modificación se debe a la “nueva” etiqueta (*Blando-Medio*) y a la necesidad de generar, para suelos firmes, un típico menos lejano de los valores de resistencia para suelos blandos.

Roca. La función *hombro* se mantiene casi con el mismo rango de resistencias con valor típico de UNO (de 500 t/m² hasta el límite de operación del sistema). El cambio sucede en la pendiente creciente. Inicia en la nulidad de la etiqueta *Medio* y crece sobre la parte derecha de la etiqueta *Firme*. En la distribución propuesta se definió el rango [300-400] como valores propios de terreno *Firme*, no apropiados para ubicarlos en la etiqueta *Roca*. El sistema, al contrario, reconoce que el valor típico de *Firme* es correcto, pero cualquier otra resistencia en la base de la variable dentro del triángulo *Firme*, podrá pertenecer a otro término en cierto grado.

Es decir, para ambos lados del triángulo *Firme* existe la pendiente inversa, del lado izquierdo con *Medio* y del lado derecho con *Roca* (por ejemplo, 200 t/m² son 0.5-*Medio* y 0.5-*Firme*, mientras que 400 t/m² es 0.5-*Firme* y 0.5-*Roca*). Esto es una indicación de la existencia de patrones que requieren una explicación adicional de las relaciones entre resistencias, materiales y velocidades con las variables *Z* y *Zona*.

- **Velocidad V_5**

Baja. Definida como una función triángulo con una base de 200 m/s, después del entrenamiento neuronal se convierte en una función triángulo mucho más estrecho con una base de 11 m/s. A partir del típico alrededor de los 5 m/s, la membresía decrece gradualmente hasta CERO cerca de los 20 m/s. A pesar de este corto rango de operación esta etiqueta se mantuvo dentro del sistema (una posibilidad era su eliminación) y las reglas de operación asociadas a ella mantienen grados de soporte lejos del cero.

Media. La función triángulo ahora otorga el valor de pertenencia CERO al rango 0→5 m/s desde donde comienza a crecer la membresía hasta alcanzar el típico cerca de los 20 m/s. De 20 a 400 m/s el valor de pertenencia descende y permanece en CERO hasta el límite de operación del sistema (700 m/s). Es importante señalar que esta función recorrió su típico de 200 a 20 m/s pero extendió su base de operación de 200 a 400 m/s.

Alta. Esta función triángulo se define ahora con pertenencia CERO entre los 0 y casi 20 m/s desde donde comienza a crecer la membresía hasta alcanzar el típico a los 400 m/s. Al contrario de las funciones propuestas, la etiqueta *alta* opera hasta el límite del sistema.

Muy alta. Definida como función hombro es modificada a función triángulo con una frontera casi vertical cerca del límite de operación del sistema (700 m/s). Otorga el valor de pertenencia CERO al rango 0→casi 400 m/s. A partir de este valor la membresía crece gradualmente hasta encontrar el valor típico UNO poco antes de los 700 m/s. La pertenencia y límite casi vertical en los 700 m/s ejemplifica la condición extrema de este rango de velocidades, es decir, para ser considerada realmente alta debe ser ≈ 700 m/s, de otra forma puede pertenecer (en grado significativo) a la etiqueta *Alta*.

Si se observan las funciones modificadas se puede concluir que las velocidades *bajas* están bien acotadas por un rango muy estrecho (comparado con la dimensión de la base de variable) que hacia la derecha de este rango los valores no manifiestan una caracterización más detallada y que el extremo de operación con una frontera vertical indica que los patrones con valores cercanos a 700 m/s son típicos de una función triángulo isósceles cuya rama derecha se extiende más allá de los 700 m/s (no se puede pensar que la pertenencia de, por ejemplo, 710 m/s al término *Muy Alta* pueda ser CERO).

- **Bloque de Reglas**

El bloque de reglas contiene la estrategia de control del sistema de LD. Cada bloque confina todas las reglas para un mismo contexto. Un contexto está definido por las mismas variables de entrada y de salida. La parte “Si” de las reglas describe la situación para la cual se diseñaron las reglas. La parte “Entonces” describe la respuesta del sistema en operación. El grado de soporte (DoS) se usa para dar peso a cada regla de acuerdo con su importancia.

En esta investigación, el procesamiento de las reglas comienza con el cálculo de la parte “Si” con el operador MIN-MAX (el operador MIN es una generalización del Y boleano, mientras que el MAX lo es de O). La composición difusa (acción que combina las reglas para conseguir una conclusión) se desarrolla con el método MAX para que sólo las reglas dominantes sean evaluadas.

Todas las reglas del sistema “vacío” inician con nulo grado de soporte (DoS = CERO), lo que significa que el entrenamiento afectará mayormente a las reglas que tienen influencia significativa sobre el comportamiento global del sistema. Ejemplos de las reglas y los grados de soporte (después del proceso neuronal) se muestran en la Fig. 5.14

Profundidad Z		Resistencia q_c	Zona	DoS		Velocidad V_s	
Superficial	Superficial	Blando	Lago	0.98		Baja	
Superficial	Superficial	Blando	Lago	0.80		Media	
Superficial	Superficial	Blando	Centro I	1.00		Baja	
Superficial	Superficial	Blando	Centro I	0.70		Media	
Superficial	Superficial	Blando	Centro II	0.48		Baja	
Superficial	Superficial	Blando	Centro II	0.41		Media	
Formación	Formación	Medio	Lago	1.00		Baja	
Formación	Formación	Medio	Lago	1.00		Media	
Formación	Formación	Medio	Centro I	0.00		Alta	
Formación	Formación	Medio	Centro I	0.29		Muy Alta	
Profundo	Profundo	Blando	Centro I	0.00		Baja	
Profundo	Profundo	Blando	Lago	0.00		Baja	
Profundo	Profundo	Roca	Centro II	1.00		Alta	
Profundo	Profundo	Roca	Centro I	0.95		Muy Alta	

Figura 5.14 Algunos ejemplos de grados de soporte (DoS) obtenidos por entrenamiento neuronal para las reglas construidas en el sistema *vacío* original (mayor DoS, mayor influencia en las evaluaciones)

SALIDA

Un modelo, como conjunto de relaciones que se usan para representar de forma sencilla una porción de la *realidad* empírica, se construye para lograr consistencia con una base de datos. La consistencia entre los datos y el modelo no implica la consistencia entre el modelo y la *realidad*. Lo único que se puede afirmar es que las suposiciones del investigador no son contradictorias y por lo tanto pueden tomarse como válidas. Pero esta validez no significa que sean la única explicación del fenómeno objeto de estudio, ni que expresen suficientemente todos los comportamientos pertenecientes a la *realidad* estudiada. Bajo este contexto, ¿cuáles son las ventajas de usar un análisis de regresión sobre las operaciones difusas o viceversa?

El objetivo de una regresión matemática es analizar un modelo (función matemática) que explique el comportamiento de una variable (endógena, explicada o dependiente) utilizando la información numérica de un conjunto de variables (explicativas, exógenas o independientes). Los coeficientes (parámetros) denotan la magnitud del efecto de las variables explicativas, esto es, representan los pesos de la regresión o de la combinación de las predictoras sobre la variable explicada.

A pesar de que superficialmente la aplicabilidad de estos métodos resultaría ilimitada, cuando se adaptan a fenómenos *naturales* se debe tomar en cuenta que: 1) la asociación no implica causalidad, es decir, que exista una fuerte asociación entre dos (o más) variables no es suficiente para obtener conclusiones sobre relaciones causa→efecto, 2) la *exploración* de los datos no implica la *confirmación* de teorías; los parámetros asociados pocas veces tienen significado físico y los funcionales matemáticos son *rígidos* y poco *robustos* lo que hace muy probable que cuando las predicciones del modelo resulten absurdas la estructura matemática (y sus hipótesis) tenga que desecharse, y 3) los resultados de este tipo de análisis proporcionan una buena indicación del comportamiento simplificado de los individuos en la base de datos, es decir, gran cantidad de conocimiento debe ser obviado para *obligar* a datos particulares a ajustarse a planteamientos preconcebidos.

Por otro lado, el beneficio sustancial de la LD es la posibilidad de describir el comportamiento del sistema con relaciones simples Si→Entonces. La optimización del comportamiento del sistema de LD se puede hacer directamente a partir del conocimiento del ingeniero (o experto en el tema) y/o a través de entrenamiento (en esta investigación, neuronal) para extraer la información causa→efecto contenida en datos numéricos y lingüísticos. Un sistema de LD es *flexible* y *poderoso*, la interpretación de la información y las relaciones entre variables (entradas y salidas) es explícita y siempre ajustable. Las estimaciones con el conjunto de reglas y operaciones difusas tienen *significado natural* ligado con la experiencia, lo que trasciende en mejoras inmediatas al conocimiento.

A continuación se presentan perfiles de V_s calculados con el sistema difuso (optimizado neuronalmente) y las funciones semiempíricas de Ovando&Romo (1991) y Jaime&Romo (1988) (descritas en el Capítulo 2). En las mismas gráficas se incluyen las velocidades medidas en campo para sustentar las conclusiones acerca del desempeño (eficiente anticipación al comportamiento *natural*) de las herramientas presentadas.

Ejemplos de estimaciones para sitios incluidos en la Base de Datos de Entrenamiento

- Sitio: **Línea B** (Lago Virgen)

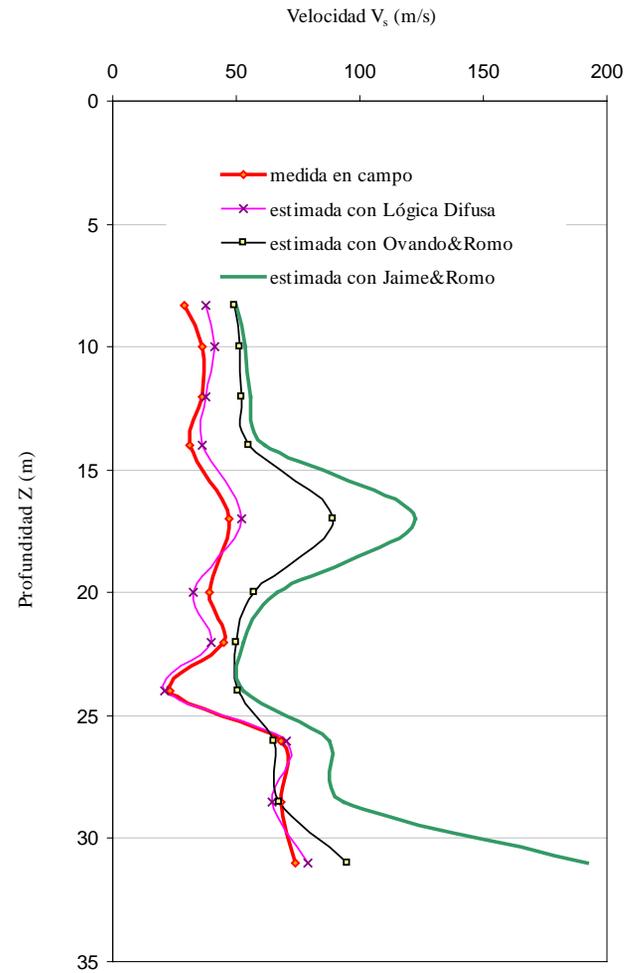


Figura 5.15 Perfiles V_s (medido y estimados) para el sitio Línea B

1. La tendencia en la variación de la velocidad con la profundidad (*casi* constante) es perseguida puntualmente por el modelo difuso a diferencia de los resultados obtenidos con los funcionales semiempíricos (Ovando y Romo, 1991; Jaime y Romo, 1988) que sobreestiman la mayor parte de las V_s y generan máximos de hasta más del 200% de los valores *reales* (Fig.5.15).
2. Uno de los puntos de mayor diferencia entre los valores de V_s medidos y estimados es a $Z= 17$ m ($\gamma= 1.3$ t/m³, $q_c= 100$ t/m² y $V_s \sim 45$ m/s). En los funcionales de Ovando&Romo y Jaime&Romo la magnitud de V_s es directamente proporcional al valor de γ y q_c . Los valores reportados de estas dos variables indican presencia de materiales *firmes*. Numéricamente y de manera *cerrada* los dos funcionales estiman velocidades *altas* pero la velocidad medida es *baja-media*. ¿Los valores registrados de γ y q_c están equivocados?, ¿las velocidades contienen tal grado de contaminación que debiera considerarse equivocado el valor medido durante el ensaye geofísico?. ¿Cuál descripción de material es la correcta, la que se deduce de la propiedad índice y mecánica o la que indica la propiedad dinámica?
3. Para el sistema de LD este patrón, como miembro de *Superficial* y de *Formación* en un mismo grado, con resistencia *Blanda-Media* (ambas en calidad de *típico*) y ubicado en la subzona *Lago Virgen*, activa reglas (mayor DoS) que dirigen el resultado hacia velocidades *Medias* (para zona *L*, resistencias *Medias* y profundidades *Formación* no hay activación *importante* de velocidades *Bajas*). Entonces para el sistema de LD no existen incongruencias entre la propiedad registrada y la descripción del material (V_s *difusa* ~ 55 m/s, velocidad *Media*). La estimación difusa es tan certera (muy cercana al valor medido en campo) porque usa la experiencia sobre estratigrafías del valle, involucra relaciones *naturales* entre las variables y trata con interpretaciones fenomenológicas (Fig. 5.16).

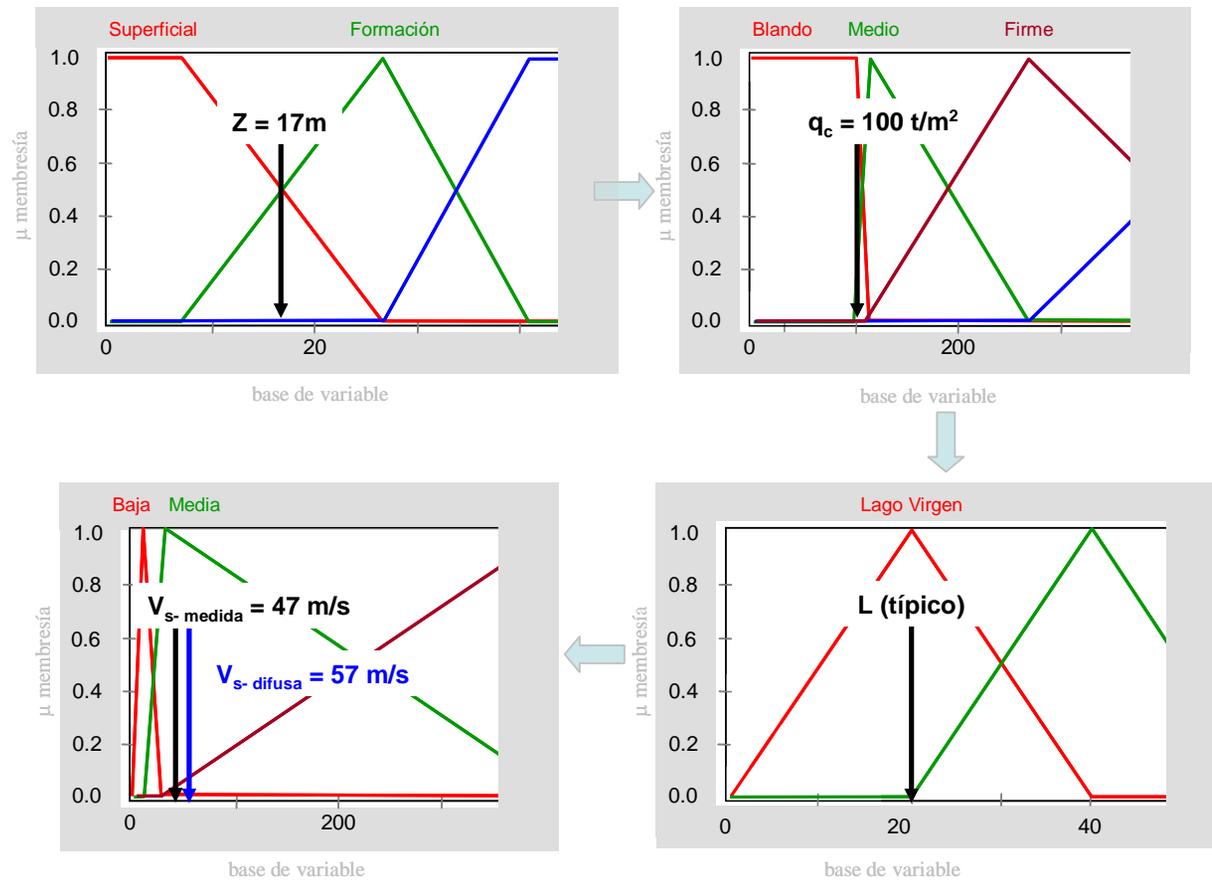


Figura 5.16 Descripción difusa de un patrón de entrada (Sitio: Línea B)

- Sitio: CAF (Centro I)

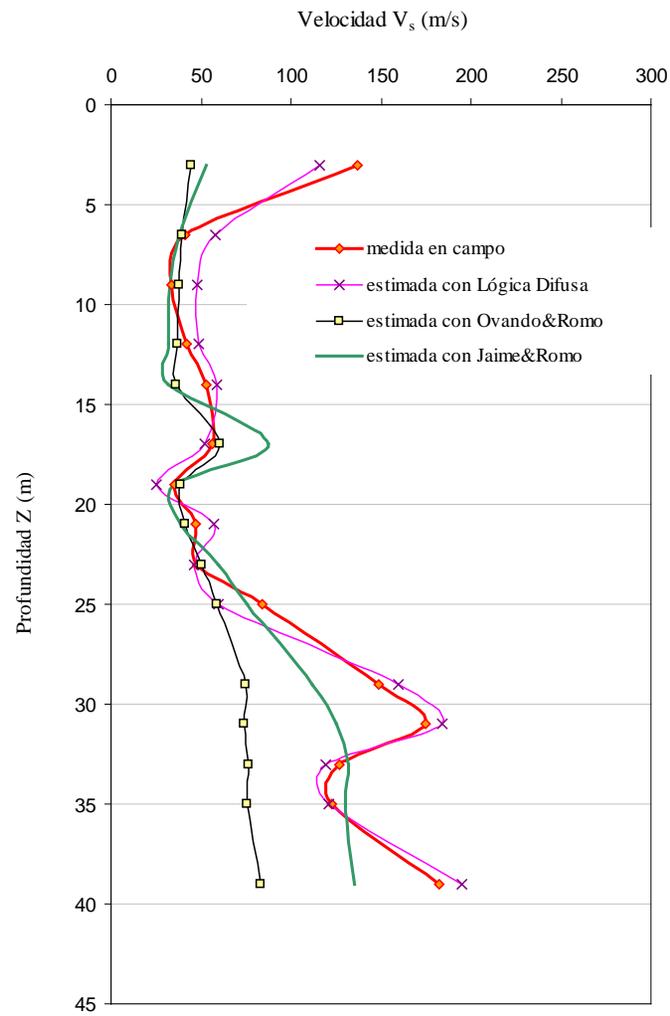


Figura 5.17 Perfiles V_s (medido y estimados) para el sitio CAF

1. Los valores medidos en campo indican la presencia de una capa de material más denso cerca de la superficie y a partir de esta zona un incremento constante de la resistencia (y las velocidades) con la profundidad. El hiperbólico de Ovando&Romo interpreta las variaciones de pesos volumétricos y resistencias con un perfil de velocidades casi constante con la profundidad. En este sitio la función semiempírica de Jaime&Romo persigue mejor la tendencia del comportamiento pero no identifica la costra superficial, ni el estrato más firme alrededor de los 30 m (Fig.5.17).

El primer punto de estimación en el perfil, la costra superficial, reporta las siguientes propiedades:

Z (m)	γ (t/m ³)	q_c (t/m ²)	V_s (m/s)
3	1.3	40	137

Es importante puntualizar que el parámetro peso volumétrico, se usa para identificar materiales en la mayoría de los modelos semi-empíricos que tratan con propiedades mecánicas y dinámicas. Observe cómo para un punto tan superficial el valor de γ es de los más altos sobre su base numérica pero la resistencia medida podría ser catalogada por un experto como propia de un suelo *blando*. Ambos funcionales (Ovando&Romo y Jaime&Romo) son más sensibles al valor de q_c que al de γ así que sus respuestas en términos de V_s son muy similares: velocidades *bajas*.

Sin embargo, la *realidad* es otra. Los niveles de V_s medidos corresponden a materiales *firmes* (costra superficial). De acuerdo con el sistema difuso, la respuesta (conclusión) surge de la combinación de entradas (premisas) que activa con DoS igual a UNO a la regla que estima velocidades *bajas*, con poco menos de UNO la de velocidad *media* y apenas arriba del 10% la de velocidades *altas*.

Si bien, la regla de mayor peso es la de velocidades *bajas* (con típico en ~ 25 m/s), existe la posibilidad de que se active (con DoS alto) la regla que genera una velocidad *media*. El valor medido está próximo a los 100 m/s. La respuesta inicial del sistema de LD (durante las primeras 100 iteraciones del proceso de entrenamiento) rondaba los 50 m/s. Las siguientes 100 iteraciones no mostraron mejoría en las evaluaciones así que se decidió *sujetar* este caso para generar una modificación *en línea* del comportamiento del sistema de LD.

Usando una herramienta gráfica difusa que permite modificar el valor de DoS neuronal con sólo mover la salida dentro del esquema de FMBs de esa variable (se coloca la flecha de resultado donde se necesita y se verifica que estos nuevos valores no afecten mayormente la correlación obtenida en los otros patrones hasta ese momento del proceso de entrenamiento), se *obliga* al sistema cerrado a acercarse a este valor a través de equilibrar los pesos de las reglas cercanas a las activadas. En un primer intento se logró un ajuste más cercano (~ 75 m/s) y a partir de este valor se re-abrieron los componentes del sistema al re-entrenamiento pero se concedió mínima libertad a las reglas modificadas *a mano*, de esta forma el sistema equilibra la modificación de pesos re-evaluando todo el bloque de reglas para verificar que el nivel de error se mantuviera dentro del criterio establecido en el arranque del proyecto.

Finalmente, el sistema incrementó el valor DoS de la regla que involucra a la velocidad *alta* y hubo un pequeño decremento en el DoS de la regla que involucra a los suelos *superficiales*, con resistencia *blanda*, típicos de CI que presentan velocidades *medias* (Fig. 5.18).

Profundidad Z	Resistencia q_c	Zona	DoS	Velocidad V_s
Superficial	Blando	Centro I	1.00	Baja
Superficial	Blando	Centro I	0.70	Media
Superficial	Blando	Centro I	0.20	Alta

Figura 5.18 Extracto del bloque de reglas del sistema de LD *cerrado*

- Sitio: CAO (Centro I)

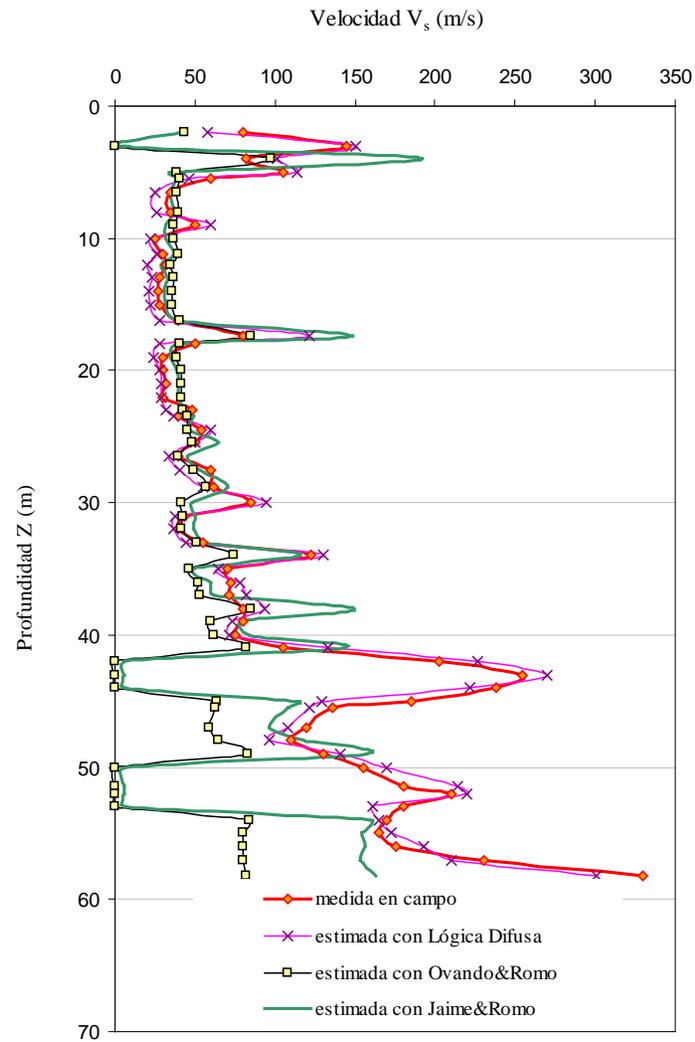


Figura 5.19 Perfiles V_s (medido y estimados) para el sitio CAO

1. Este es uno de los sitios más estudiados en todo el valle y del que se conocen más propiedades para definir su estratigrafía, condición que lo ha calificado como un típico adecuado para desarrollar funcionales (incluidos Ovando&Romo y Jaime&Romo). Si a través de sus relaciones numéricas se determinaron (modificaron) los parámetros asociados a la estructura matemática resulta axiomático que las estimaciones sean cercanas a los valores medidos en campo. Las velocidades en la formación arcillosa son bien evaluadas por los 3 métodos aunque las mayores diferencias se encuentran entre las mediciones y las estimaciones de Jaime&Romo. Acercándonos a los estratos más firmes ambos modelos semiempíricos fallan dramáticamente mientras que el sistema difuso persigue la tendencia de manera adecuada (Fig. 5.19).
2. Atención especial merecen las profundidades donde la prueba CPT indica AVANCE (valores con $V_s = 0$ en el gráfico anterior). Los AVANCES requieren de interpretación y el criterio para determinar su naturaleza contiene diferencias de acuerdo con el grado de experiencia y el nivel técnico del profesional que los analiza. En términos generales, cuando los puntos que anteceden a la profundidad con AVANCE reporten valores de resistencia *bajos*, se considera que el avance se debe a la presencia de suelos *blandos*, por el contrario, si lo anteceden resistencias CPT *altas* se considera que el material es tan *firme* que impidió el paso de la punta cónica. Entonces el ingeniero de la práctica dibuja su perfil como más convenga de acuerdo con estos lineamientos y el conocimiento que se tenga sobre las condiciones estratigráficas del área. La comparación de la actuación entre los tres modelos, en puntos AVANCE, no puede realizarse si se acepta que un análisis de regresión no calcula respuestas donde existan *vacíos* de información por lo que en estas profundidades no existe una estimación *cerrada* de velocidad. Como se observa en la Fig. 5.20, si se tuviera que tomar como válido el valor anterior al AVANCE, la velocidad resultaría demasiado baja, si por el contrario, se tomara el nivel del valor V_s que sigue al AVANCE la velocidad sería sobreestimada. No es práctica común calcular el promedio de velocidades.
3. Analicemos ahora qué sucede en los AVANCES cuando se aplica la LD. En los análisis con “valores desconocidos” es necesario determinar si la no-presencia se debe a una *pérdida* (no se consiguió monitorear el dato por errores en la operación) o si tiene significado físico (la *ausencia* representa un comportamiento propio del fenómeno analizado). En este caso, no contar con valor numérico de la variable q_c y contar con el término lingüístico AVANCE significa *algo* sobre la propuesta fenomenológica.

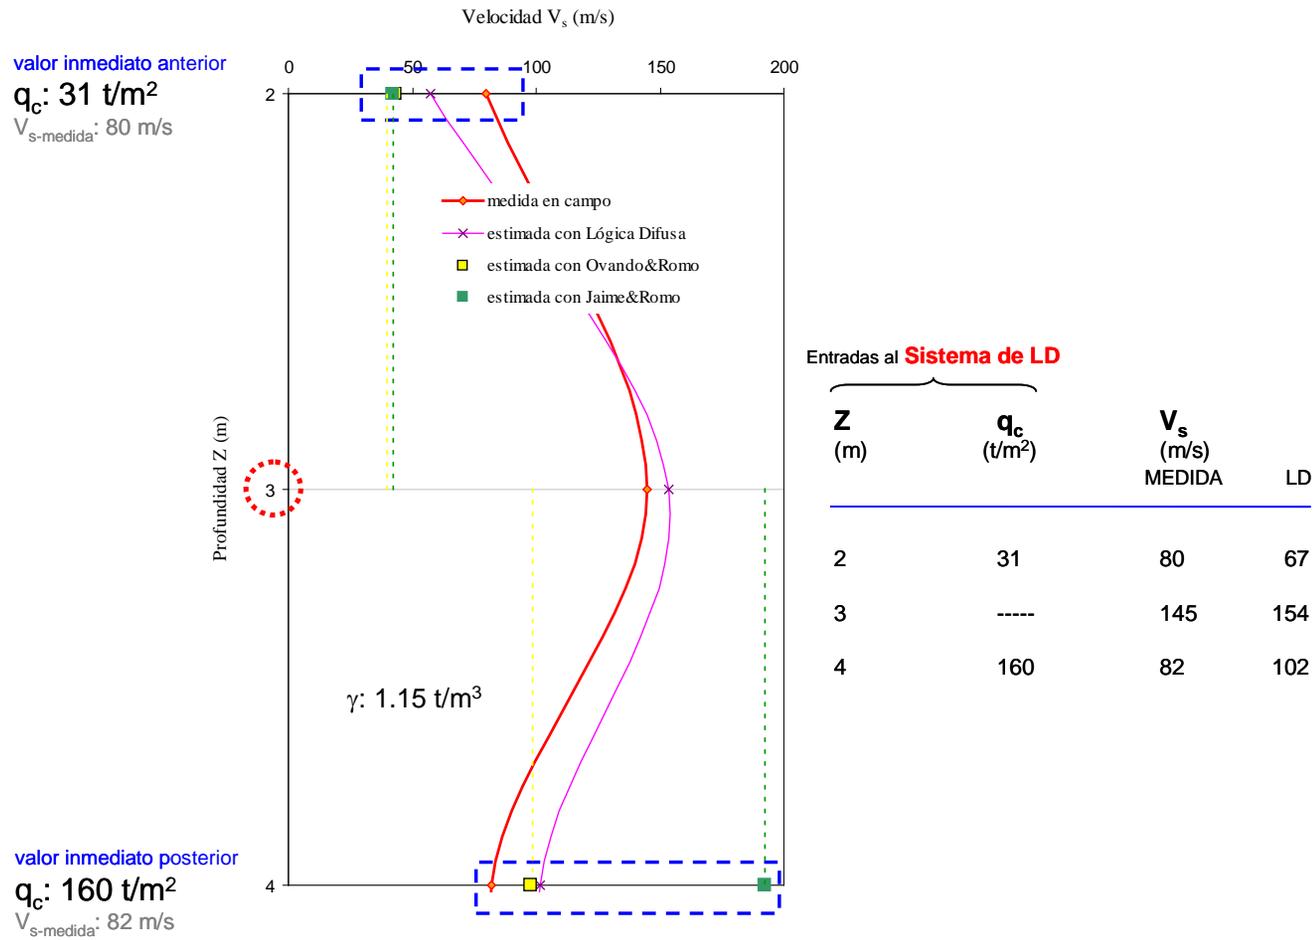


Figura 5.20 Análisis de AVANCE en puntos cercanos a la superficie

Se revisan las reglas activadas por los puntos anteriores y posteriores a la profundidad de avance y a través de las reglas con mayor peso (DoS) se decide sobre el valor más probable de V_s de acuerdo con: las condiciones estratigráficas para esa subzona geotécnica, la profundidad y los materiales que le conforman. Las reglas que fueron analizadas se muestran en la Fig. 5.21. El análisis difuso se dirige conforme el flujo de información mostrado en la Fig. 5.22.

La información contenida en las entradas (mismos valores de pesos volumétricos y diferencias en el valor de Z) indica que a los 43, 52 y 58 m de profundidad se tienen intercalaciones de material firme que alcanzan velocidades de hasta 350 m/s, ¿es esto cierto? (Fig. 5.23). La respuesta podría

ser “no”. Sin embargo, la LD permite, de la misma manera que lo hace el criterio práctico, seleccionar las reglas que se activan en la vecindad de los puntos con AVANCE y reconocer las condiciones (subzona y estratigrafía) para estimar una V_s más equilibrada. ¿Por qué es ventajosa la metodología difusa comparada con la convencional?. Porque la elección es sobre reglas y no sobre valores puntuales. Las reglas constituyen comportamientos y esto significa multidimensión. Las premisas y conclusiones que se usaron para generar el espacio de soluciones constituyen el conocimiento empírico y numérico que sobre el fenómeno se tiene, y la elección de una de estas ligas (Si→Entonces) no significa que las demás no estén actuando al mismo tiempo, una regla nunca es *individuo*, una regla es una parte del bloque que contiene a la estructura y a los parámetros.

Profundidad Z	Resistencia q_c	Zona	DoS	Velocidad V_s
Superficial	Blando	Centro I	0.70	Media
Superficial	Blando	Centro I	0.20	Alta
Superficial	Media	Centro I	0.10	Baja
Superficial	Media	Centro I	0.00	Media

Figura 5.21 Reglas activadas para el análisis de V_s

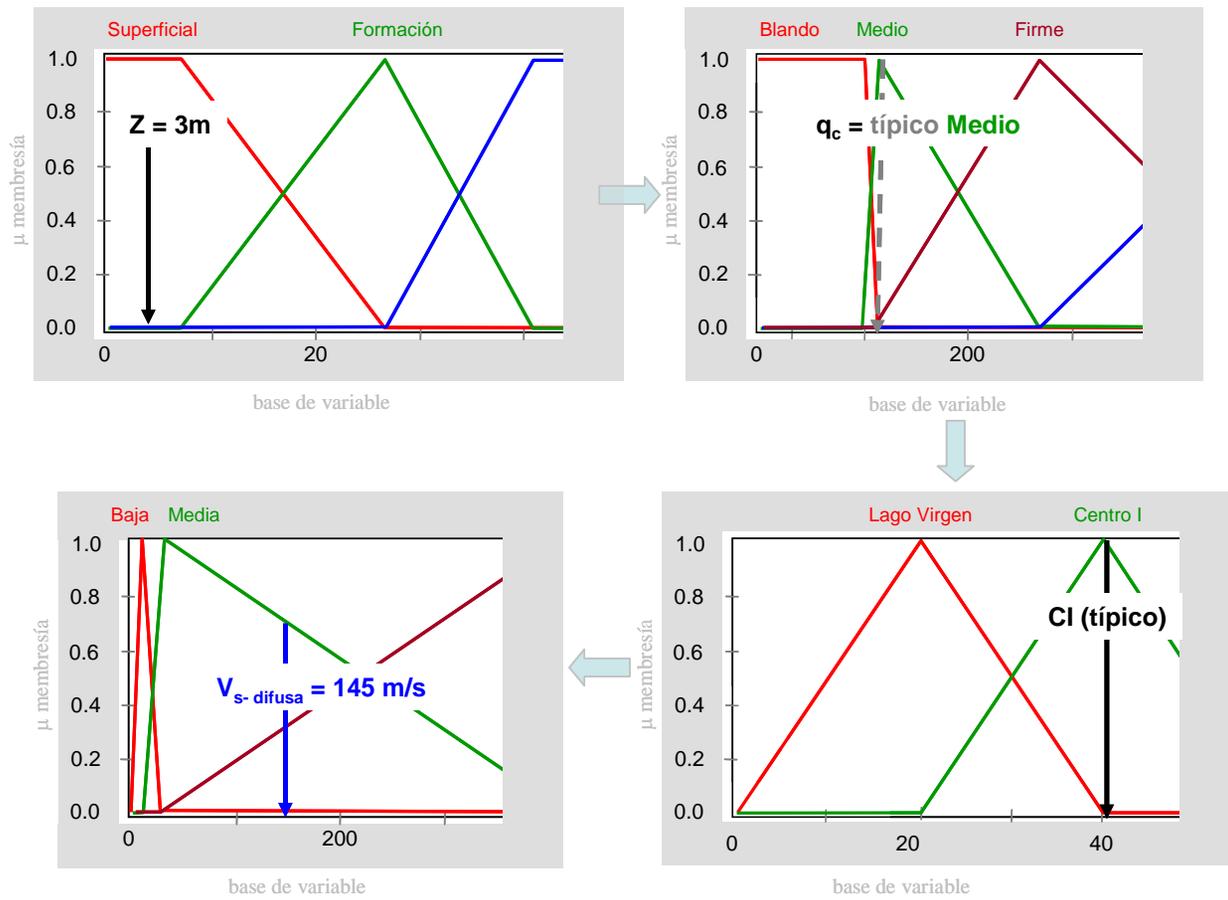


Figura 5.22 Flujo de información difusa para el sitio CAO

Sitio: Av. 510 (Lago Virgen)

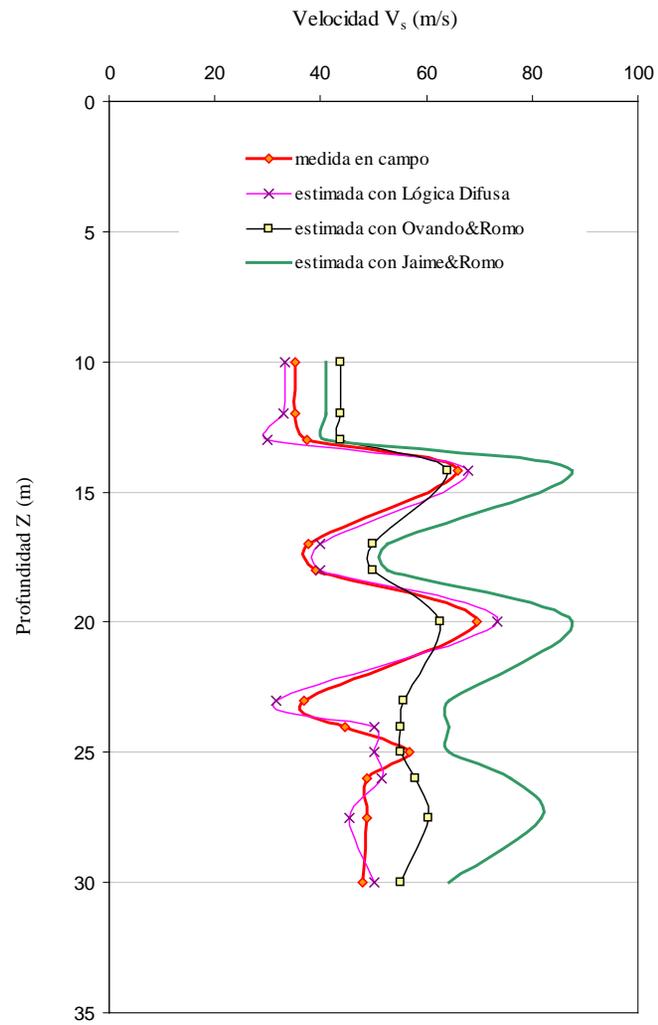


Figura 5.24 Perfiles V_s (medido y estimados) para el sitio Av. 510

1. Los tres modelos consiguen reproducir la tendencia de máximos y mínimos que presenta el perfil medido. El modelo de Ovando&Romo genera un perfil casi constante con la profundidad con sólo un máximo (a 15 m aprox.) producto del alto valor de resistencia reportado en campo para en ese punto. El caso de las estimaciones con Jaime&Romo son más certeras en la ubicación de los máximos y mínimos pero todas las evaluaciones sobrestiman los valores medidos (Fig.5.24).
2. Todos los patrones del perfil presentan resistencias etiquetadas como *blandas*, con profundidades que pasan de *superficial* a *formación* en un sitio típico de subzona *Lago Virgen*. El sistema de LD identifica claramente las intercalaciones de material *un poco* más denso pero no permite que las velocidades alcancen los valores de la siguiente etiqueta (*media*). Esto se debe a que para sitios de la subzona *L*, en este rango de profundidades y resistencias, las reglas activadas con mayor peso sólo tienen valores de salida con etiqueta *baja* (existen activaciones para etiqueta *media*, pero el proceso inverso difuso mantiene la respuesta en el rango de valores señalados).

En la Fig. 5.25 se presentan los comparativos para los restantes sitios incluidos en el archivo de entrenamiento. Para apreciar de mejor manera la remarcable habilidad del sistema de LD en la estimación *inteligente* de valores de V_s se eliminaron de los gráficos los perfiles de los funcionales semiempíricos, sin embargo es necesario puntualizar que las correlaciones más altas entre V_s medido y V_s estimado con Ovando&Romo y Jaime&Romo se consiguieron en los casos anteriormente comentados.

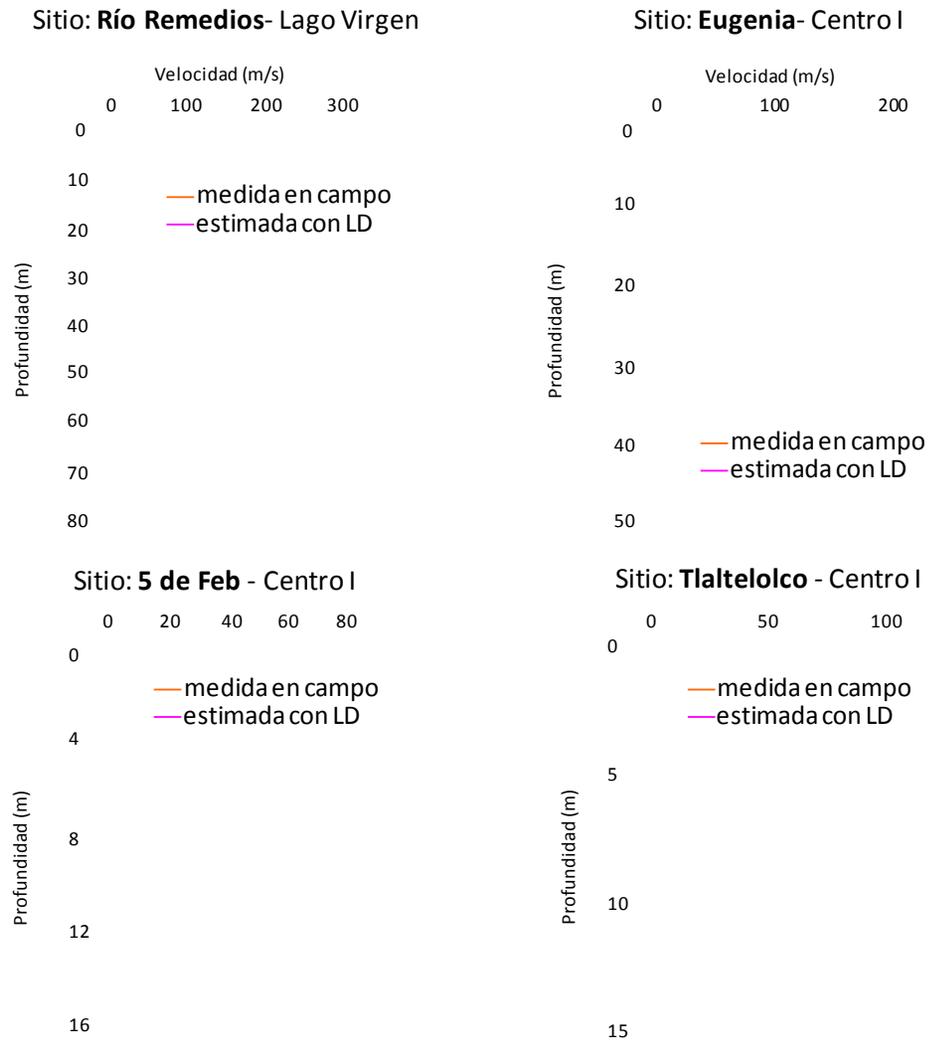


Figura 5.25 Perfiles V_s (medidos y estimados) para sitios incluidos en el archivo de entrenamiento

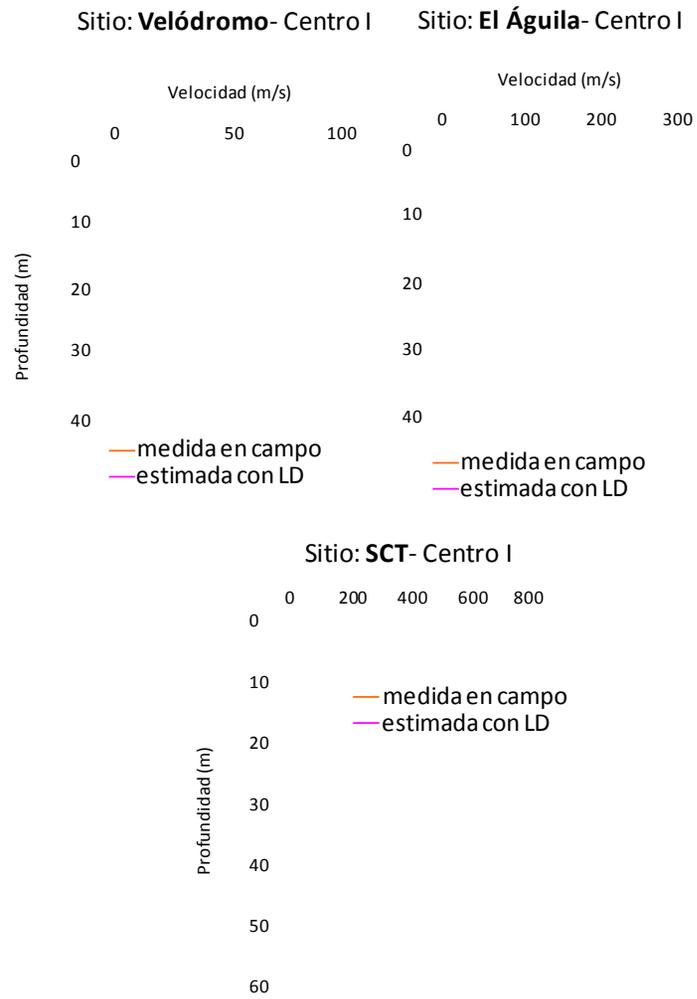


Figura 5.25 Perfiles V_z (medidos y estimados) para sitios incluidos en el archivo de entrenamiento (continúa)

Ejemplos de estimaciones para sitios no incluidos en la Base de Datos de Entrenamiento, etapa de Validación del sistema

- Sitio: Plaza Aragón (Lago Virgen)

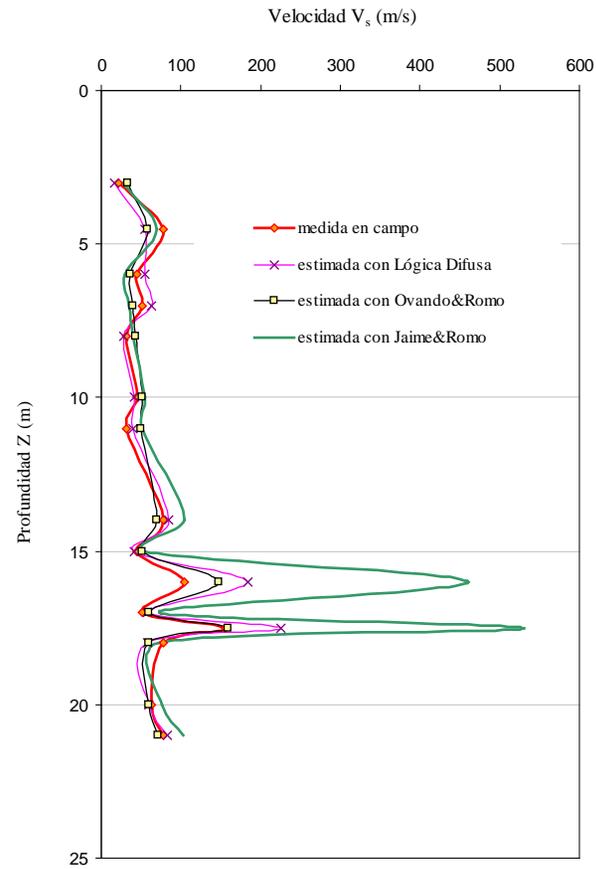


Figura 5.26 Perfiles V_s (medidos y estimados) para el sitio Plaza Aragón

Los patrones que constituyen este perfil no fueron incluidos en la base de entrenamiento por lo que las estimaciones representan casos prácticos de prueba para el sistema difuso, el autor desconoce si fueron sujetos de análisis durante el desarrollo de los funcionales semiempíricos.

1. El conjunto de velocidades *objetivo* es estimado adecuadamente por los tres funcionales en el rango $Z = 3 \rightarrow 15m$, las diferencias por encima de los criterios de ajuste se encuentran a partir de los 15 m (Fig.5.26).
2. En el caso de las velocidades que son sobreestimadas es necesario hacer un análisis adicional. El funcional empírico de Jaime&Romo estima velocidades *muy altas*, típicas de materiales *muy firmes*, debido al valor de resistencia que se obtiene de la prueba CPT en los puntos $Z= 16$ y 17.5 m. La aproximación que logra el esquema

de Ovando&Romo resulta muy adecuada en estas dos profundidades y equilibra los valores de pesos volumétricos con las elevadas resistencias para generar velocidades *medias*. Sin embargo, esta no es la constante de comportamiento para los 19 sitios analizados y el resultado presentado ratifica la manera cómo este funcional (Ovando&Romo) impone una severa restricción de crecimiento en los valores de V_s conforme Z profundiza si no se excede *cierto* nivel de resistencia (ejemplo adicional de este comportamiento en el gráfico del sitio SCT).

3. En el caso de la LD se tiene el siguiente planteamiento de información (Fig. 5.27):

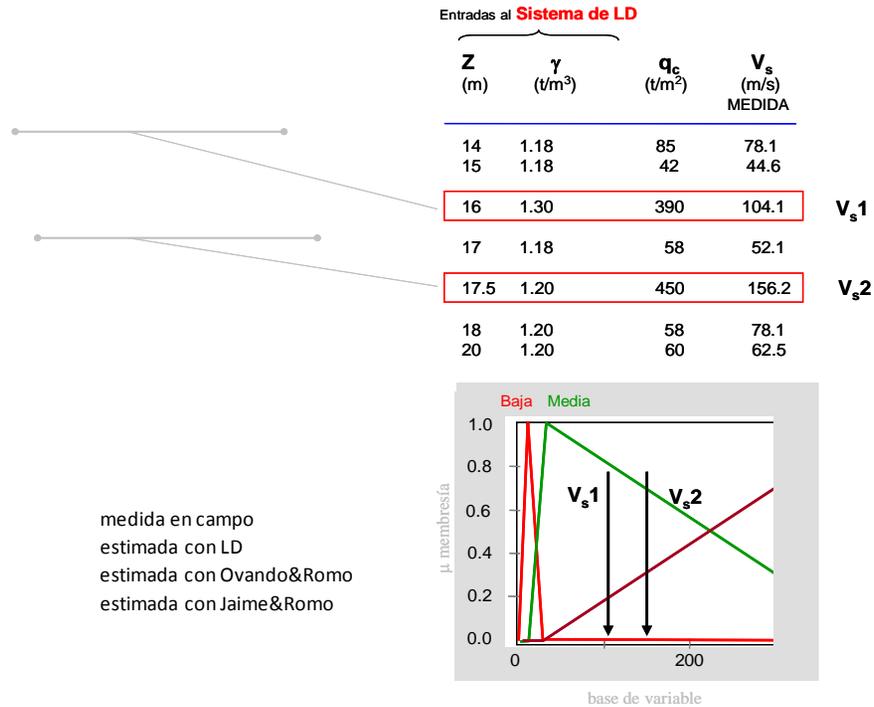


Figura 5.27 Análisis de entradas y V_s (medidas y estimadas)

Como se observa en la Fig. 5.27, los valores de peso volumétrico y de resistencia indican suelos más *firmes* por lo que se espera un gran incremento en la velocidad de acuerdo con las reportadas en Z 's menores. La interpretación difusa de esta evaluación es (Fig. 5.28):

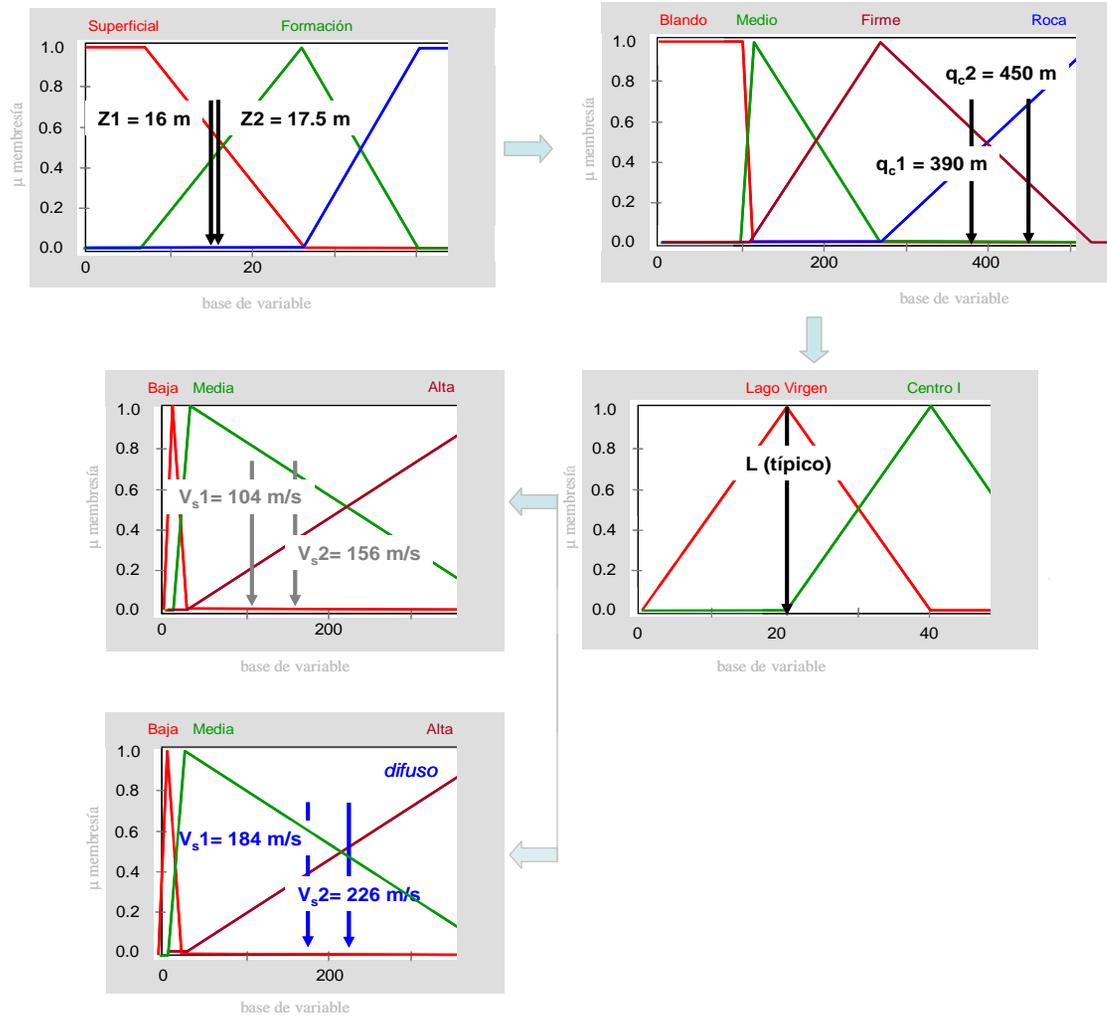


Figura 5.28 Interpretación difusa del cálculo de V_s

Las diferencias entre medidos y estimados con LD tienen una justificación de acuerdo con las descripciones del sitio (profundidades y subzona) y las resistencias de campo. Para suelos que presentan resistencias *firμες*, cercanas a las típicas de *roca*, aún perteneciendo a la subzona L, se activan reglas de comportamiento que dirigen las estimaciones hacia la zona de V_s *medias-altas* (Fig. 5.29). Los valores reportados en campo, tendientes a *bajos*, representan una contradicción numérica cuando se les sitúa en el espacio del **Sistema** (suelos del valle de México). Si bien estas incompatibilidades no son concluyentes, sí requieren de una consideración especial para la definición estratigráfica y la valoración de su respuesta ante carga dinámica.

Profundidad Z	Resistencia q_c	Zona	DoS	Velocidad V_s
Superficial	Firme	Lago Virgen	0.00	Baja
Superficial	Firme	Lago Virgen	0.85	Media
Superficial	Firme	Lago Virgen	0.60	Alta
Superficial	Roca	Lago Virgen	0.00	Baja
Superficial	Roca	Lago Virgen	0.75	Alta

Figura 5.29 Reglas activadas para solucionar la incongruencia entre resistencias y velocidades

- Sitio: CUPJ (Centro I)

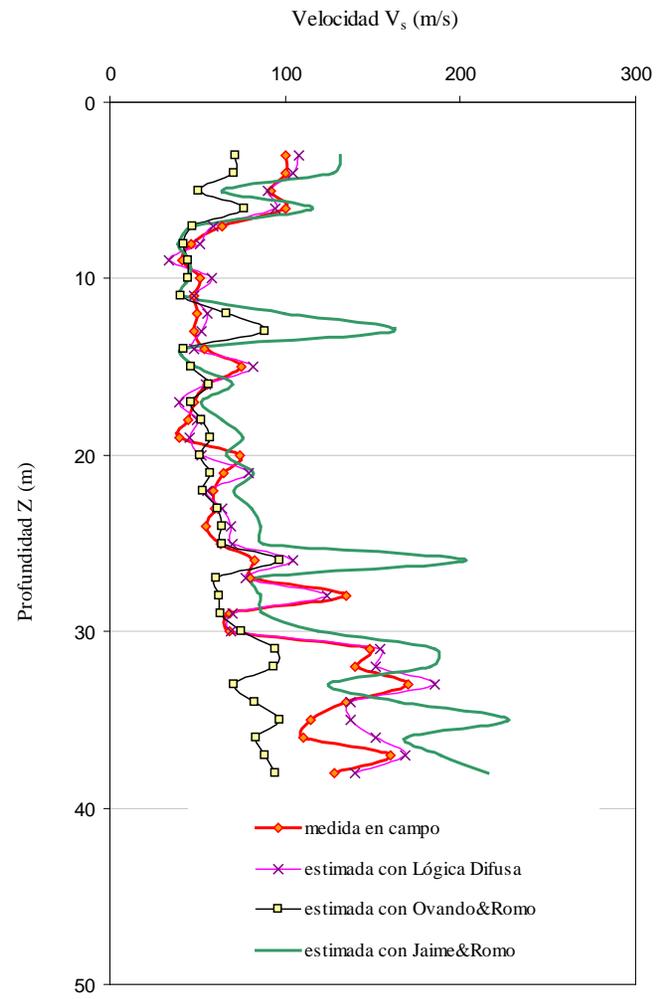


Figura 5.30 Perfiles V_s (medido y estimados) para el sitio CUPJ

1. La capacidad de generalización del sistema difuso y los funcionales empíricos pareciera muy similar cuando se observa el perfil de este sitio. La tendencia en el crecimiento de las velocidades conforme se avanza en la profundidad es reconocida por las tres metodologías. Incluso la formación arcillosa, con velocidades que oscilan entre 40 y 70 m/s, está identificada en la mayoría de los puntos de evaluación con desviaciones que no rebasan el 10% (Fig.5.30).
2. A ciertas profundidades se presentan diferencias entre lo medido y lo evaluado que pueden generar caracterización de materiales completamente diferentes (por lo menos en términos de respuesta dinámica). Observe los valores reportados en la Z más cercana a la superficie (Fig.5.31). El punto A es una subestimación de la V_s medida y significa que este funcional da un mayor peso numérico al valor de q_c mientras que en C se sobreestima la velocidad de acuerdo con un postulado que no equilibra la participación de q_c y γ , significado de la diferencia reportada.

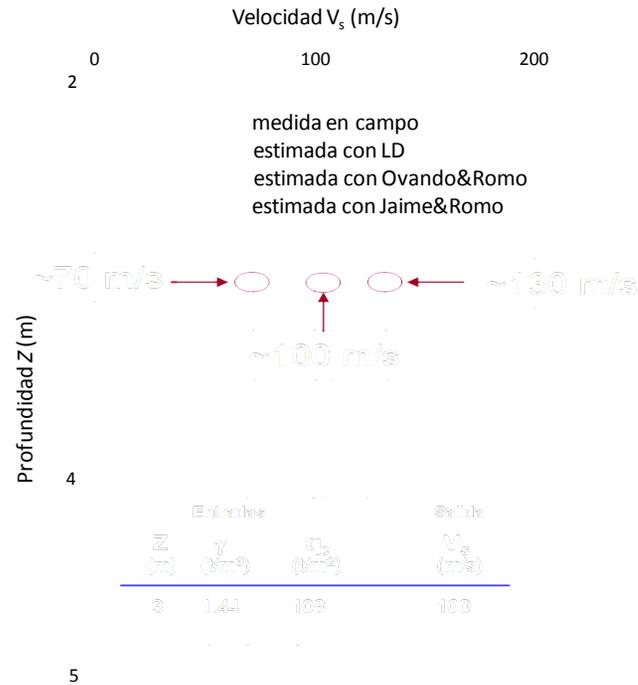


Figura 5.31 Análisis del punto más superficial

Revisemos qué significa este patrón para el sistema difuso (Fig.5.32):

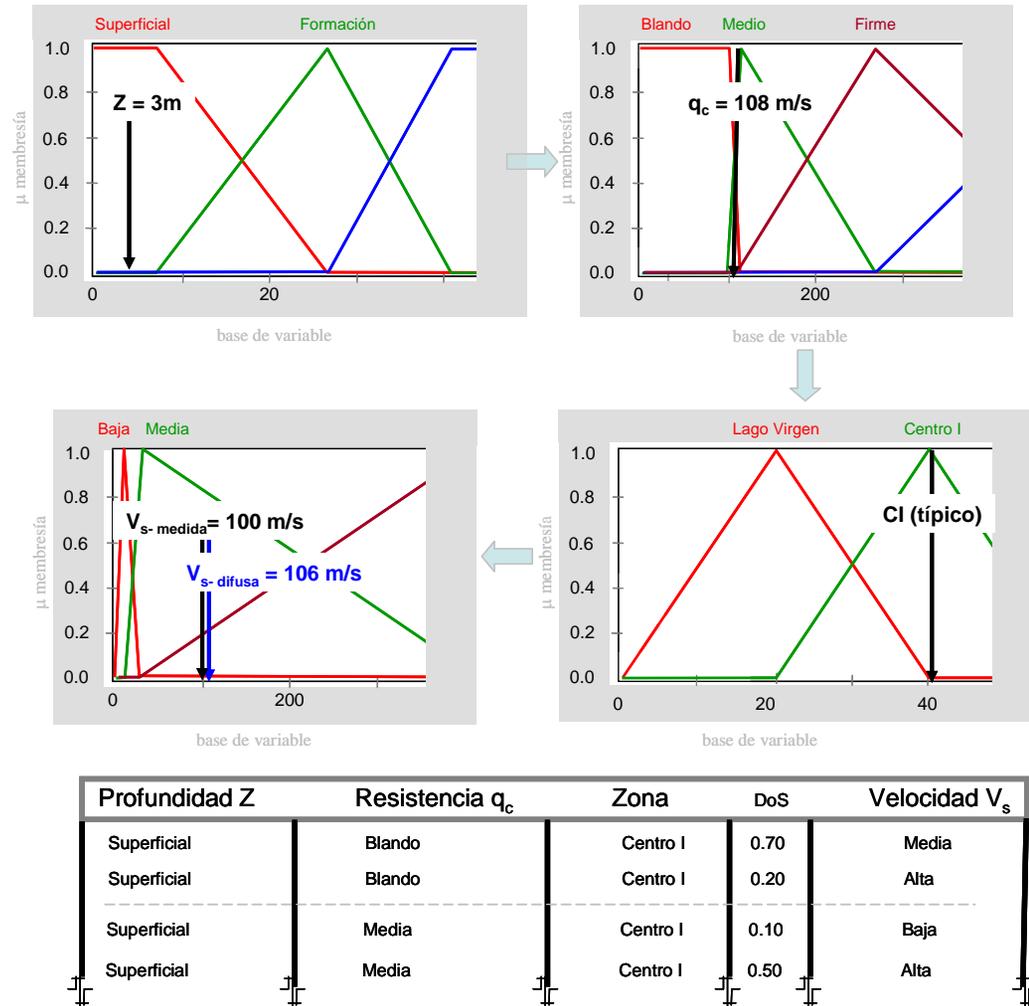


Figura 5.32 Flujo de información para calcular V_s

Siendo un patrón típico de *Centro I, superficial*, con pertenencia casi UNO a las etiquetas de resistencia *baja y media*, activa las reglas que dirigen el valor de V_s hacia valores *medios-altos*. Es notable la capacidad del sistema para mediar entre las características de costra superficial y el nivel de velocidades que un material de este tipo puede alcanzar, conocidas la resistencia y la zona del valle a la que pertenece el sitio. El hecho de que no se incluyan los valores de los pesos volumétricos y se obtengan eficientes resultados es una indicación de la contaminación de esta variable descriptiva (γ) y la dudosa representabilidad cuando tiene que actuar acoplada con otro parámetro más *natural* (medido en campo).

En la Fig.5.33 se muestran las estimaciones para los perfiles restantes del conjunto apartado para la prueba del sistema difuso.

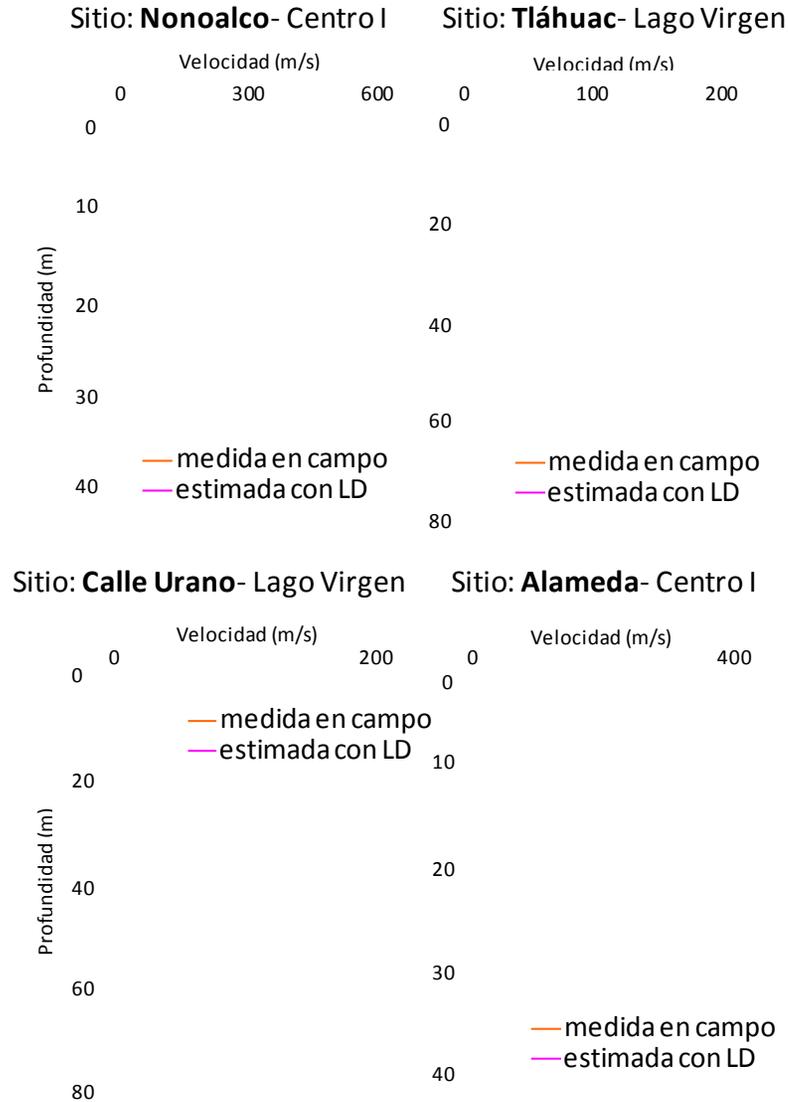


Figura 5.33 Perfiles V_s (medidos y estimados) para sitios no incluidos en el archivo de entrenamiento

Observando estos resultados se concluye que el sistema de LD demuestra ser una ventajosa alternativa para determinar valores de V_s a partir de pruebas de q_c . Si se considera que la estructura difusa es un software para PC que sólo requiere del usuario la declaración de las entradas (aceptando *vacíos* de información) y el ambiente en el que desea se presenten los resultados (gráfico, numérico o lingüístico), el desempeño de esta estructura es considerablemente más ventajoso que el de los modelos semiempíricos. Las mínimas diferencias entre lo medido y lo estimado y el reconocimiento de las variaciones en la velocidad con estimaciones *casi* consecutivas ($\Delta Z = 1m$) ponen de manifiesto la sobresaliente capacidad de generalización del sistema. A diferencia de los otros funcionales (los presentados en los comparativos y la mayoría de los reportados en la literatura sobre el tema), el sistema de lógica difusa sí cumple con las características de un buen modelo matemático:

- Es COMPLETO, es decir, es capaz de elaborar juicios y dictar sentencias sobre comportamientos en todos los estados que conforman el espacio de entradas y salidas.
- Es SIMPLE, es posible identificar los parámetros de trabajo (entradas) del modelo por medio de un número pequeño de pruebas estándar realizadas sobre los materiales.
- Es NATURAL, el modelo está fundamentado en interpretaciones físicas de las respuestas, contiene valores numéricos traducidos a instancias lingüísticas que es la manera en que los humanos reconocemos y aprendemos de nuestro entorno. Las estimaciones difusas tienen siempre una conexión con la experiencia por lo que *crecen* de acuerdo con las mejoras en los procesos de monitoreo y ensaye.

Descripción de la actuación del sistema ante un caso práctico:
Línea de Transmisión Chapingo-Lago

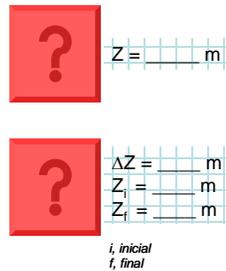
- Entradas:

1. Valor(es) de Resistencia (q_c). Seleccione la opción

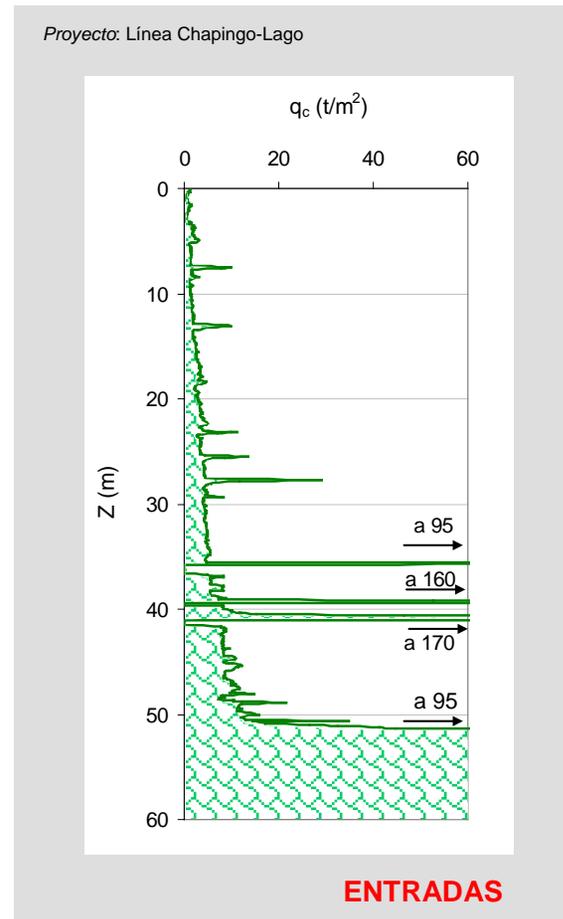


En el caso PUNTO aparece la pantalla para escribir el valor de q_c . En el caso VECTOR el usuario tiene oportunidad de *examinar* sus archivos para cargar la columna de resistencias o bien, declarar la existencia de un dispositivo acoplado a la PC (donde está instalado el sistema) a través del cual se harán las lecturas *en línea* (monitoreo de la prueba CPT en tiempo real, por ejemplo).

2. Profundidades asociadas a cada q_c .



Dependiendo de la opción elegida en el punto 1 aparecerá la opción para el valor puntual de Z o la opción que permite definir los límites y espaciamiento del nodo contador (nodo profundidad). En el caso que nos ocupa (sondeo localizado sobre la línea de transmisión Chapingo-Lago, Lago de Texcoco) se eligió la opción vector y se cargó información para hacer crecer Z desde los 2 a los 51 m de profundidad con un ΔZ de 1 m. La pantalla “perfil entradas” se presenta a continuación:



3. Subzona Geotécnica

En este apartado el usuario puede elegir entre

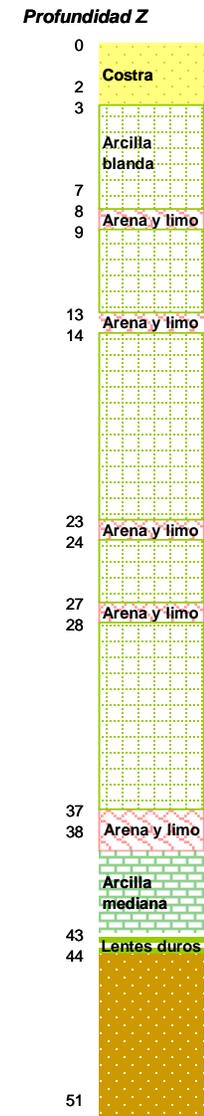


AYUDA



SUBZONA

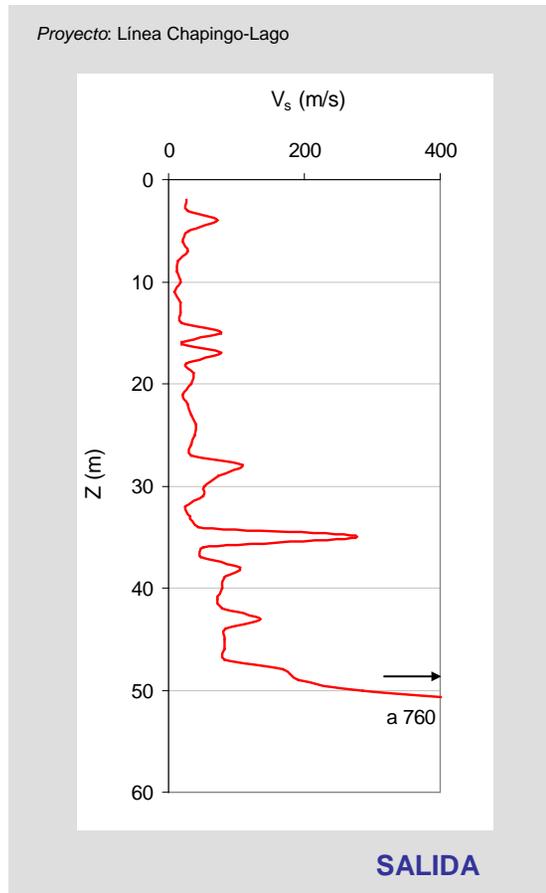
En el icono SUBZONA se requiere la declaración en términos lingüísticos [*típico de la zona o entre la zona - y la zona --*] de la pertenencia a alguna de las tres subzonas que aparecen en pantalla (ver Fig.5.3). El sistema traducirá numéricamente el término indicado. Cuando se elija AYUDA el sistema permite al usuario el cálculo de las tres opciones típicas (L, CI y CII) o bien, que se *cargue* una estratigrafía (descripción de materiales y profundidades) y gráficamente se compare con las típicas de cada subzona. Para el ejemplo analizado se tiene el siguiente reporte estratigráfico:



Cuando se realiza la comparación entre esta columna (además del comparativo entre el perfil de resistencias del sitio y los declarados como típicos en la Fig.5.2) y las almacenadas en la memoria del sistema difuso como propias de cada subzona, se concluye que el sitio tiene características de *Lago Virgen* y *Centro I* en igual proporción. Así, por medio de un análisis más conciente se puede seleccionar el valor numérico más adecuado para la variable *Zona* (=50).

- Salida:

La estimación reportada para el sitio Línea Chapingo-Lago, considerando un vector de profundidades (de 2 a 52 metros) al que se le asocia un vector de resistencias (con un máximo de 170 t/m²) y considerándole un sitio típico de *L* en la misma proporción que de *Cl*, es la siguiente:



Por ser este un sitio del que no se conoce con certeza su pertenencia a alguna subzona, como un ejercicio numérico se realizó una revisión de resultados para los tres casos típicos: L (*Zona=20*), CI (*Zona=40*) y CII (*Zona=60*). No se observa variación importante cuando se comparan los perfiles de velocidades para CI y CII, mientras que sí existen diferencias entre CI y L. Cuando se compara el perfil que pertenece a ambos subgrupos ($\mu_{CI} = 0.5, \mu_L = 0.5$) con el que sólo pertenece a uno de ellos se encuentran importantes diferencias en la localización del estrato firme.

Las conclusiones sobre el efecto mínimo de declarar pertenencia a CI o CII sobre los resultados de velocidades son consecuentes con algunos hallazgos durante la construcción y prueba del modelo difuso, pero es necesario realizar estudios con más sitios que pertenezcan a ambas zonas (la base de datos contiene 3 sitios de CII y 9 de CI) para poder ratificar la deducción sobre la existencia de sólo dos subzonas geotécnicas dentro de la zona del Lago, la Virgen y la Centro.

Aquí terminaría el análisis con el sistema difuso, sin embargo, para este sitio se cuenta con el perfil de V_s . En la Fig.5.34 se presentan los valores medidos en campo y su comparación con los estimados con lógica difusa para demostrar cómo la sencillez de operación y análisis no disminuye las habilidades predictivas del sistema.

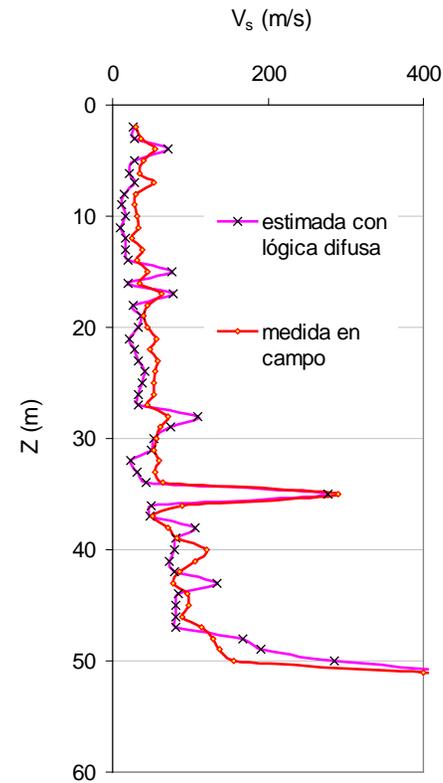


Figura 5.34 Resultados del sistema difuso para un ejemplo práctico

Estimación de G y λ

A continuación se presenta el esquema neuronal que modela la reducción de la resistencia al corte y el incremento del amortiguamiento del suelo arcilloso del valle de México y que completa la caracterización dinámica propuesta en este inciso de resultados.

Teniendo en cuenta las características del proceso empírico de creación de modelos, el planteamiento para obtener el módulo de rigidez al corte G y la relación de amortiguamiento λ en un rango de deformaciones por corte $\gamma\%$ útil en la práctica ingenieril, contiene:

- SISTEMA: Arcillas plásticas típicas del valle de México
- PROCESO: Reducción/Incremento de la/el resistencia/amortiguamiento por carga dinámica
- ENTRADAS (datos): Índice de plasticidad de la masa del suelo I_p y un vector de deformaciones $\gamma\%$
- MODELO: Red Neuronal RN
- SALIDA (resultados): $(G, \lambda) = f(\gamma\%, I_p)$

Es importante recordar que las relaciones empíricas, comúnmente usadas en ingeniería geotécnica para correlacionar propiedades, tienen como propósito estimar valores, necesarios en análisis y diseño, por medio del uso de alguna propiedad índice que sea relativamente más barata y más fácil de obtener. Si efectivamente existe una relación entre las propiedades, esto ofrece una manera eficiente (por lo menos económicamente hablando) de obtener los parámetros de suelo requeridos. La mayoría de las veces las relaciones empíricas están muy lejos de la perfección y las incertidumbres asociadas con estas aproximaciones difícilmente pueden ser cuantificadas para establecer la verdadera confianza sobre los métodos y sus resultados. De ahí la importancia de la generación de herramientas *inteligentes* que permitan trabajar en marcos de indeterminación paramétrica (conceptual y numérica) y que representen modelos estándar, aseguibles y prácticos.

La Fig. 5.35 muestra la aproximación de dos relaciones hipotéticas que han sido establecidas a partir de datos. Claramente, el uso de la relación A resultaría más confiable. Pero un ingeniero podría estar condicionado al uso de la relación B. ¿Cómo puede medir la consistencia de la función?, ¿la confianza en B puede ser mejorada si se incrementa el número de pruebas (directas o indirectas) usadas en la construcción del funcional?, ¿por cuánto?, ¿cómo puede decidir sobre la descalificación de alguna expresión (función matemática) bajo ciertas exigencias de estudio?.

Este tipo de dilema es propio del análisis y estimación de propiedades dinámicas. Sin intentar dar respuesta a los cuestionamientos anteriores (muy difícil en este *incierto* escenario teórico-práctico) el módulo neuronal presentado a continuación ejemplifica una aproximación robusta, flexible y de fácil comprensión, para la estimación preliminar de los parámetros G, λ dependientes de $\gamma\%$.

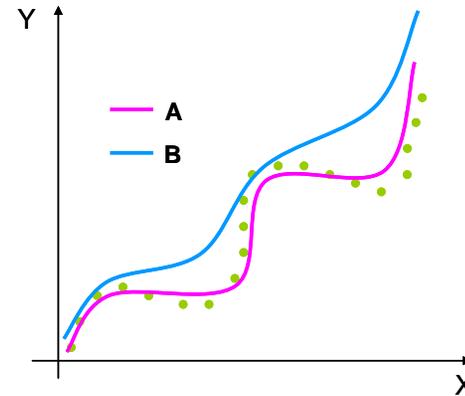


Figura 5.35 Ejemplos de funciones construidas a partir de datos

El siguiente planteamiento neuronal trata de cubrir respuestas generales y bajo ninguna circunstancia busca interpretar y concluir sobre lo acertado de expresar el complejo comportamiento dinámico de los suelos a través de dos parámetros (G, λ) ni ponderar el uso de las RNs sobre algunas otras herramientas o funcionales matemáticos. A través de la descripción de su construcción y su aplicación sobre algunos sitios estudiados con el módulo neurodifuso $V_s = f(q_c, Z, Zona)$, este esquema conexionista se ratifica como una buena alternativa de cálculo, consecuente con el grado de experiencia y conocimiento sobre el tema y la variabilidad reconocida en los ensayos de laboratorio.

Sistema

La descripción de los materiales que conforman los depósitos del valle de México se incluye en la sección anterior (**Sistema** en el **Modelo** neurodifuso), sin embargo, es importante mencionar algunas de las características básicas que dirigen la actuación del modelo neuronal *dinámico* (el término "*dinámico*" se deriva de "propiedad dinámica" y no se relaciona con RNs de retroalimentación).

La respuesta característica de las arcillas plásticas del valle de México la calificarían como un material, en cierto sentido, entre sólido y líquido (su incompresibilidad es muy elevada -109 N/m²- y su módulo de Poisson cerca de 0.499). Estudios en laboratorio realizados desde la década de los 80 reafirmaron el hecho de que las cargas dinámicas/cíclicas (compresión y corte) en estas arcillas blandas saturadas son normalmente "no drenadas". Debido a que el agua no tiene resistencia al corte, los esfuerzos dinámicos/cíclicos de corte "no drenados" son resistidos completamente por el esqueleto de suelo, lo que produce en las arcillas de muy alta plasticidad, un comportamiento fuertemente no lineal, histerético e irreversible, con una

gran disipación de energía asociada y una gran degradación de la resistencia durante los distintos ciclos de carga.

El comportamiento de una arcilla blanda bajo carga dinámica depende fuertemente del nivel de deformación de corte cíclica inducida al suelo $\gamma\%$. Para pequeñas deformaciones la respuesta esfuerzo-deformación es lineal, el suelo no disipa mucha energía en cada ciclo histerético (bajo amortiguamiento) y prácticamente no hay degradación de la rigidez/resistencia con el número de ciclos de carga. Para grandes deformaciones la respuesta esfuerzo-deformación de corte empieza a ser fuertemente no lineal con mucha más disipación de energía por ciclo (alto amortiguamiento) y con una considerable degradación de la rigidez/resistencia causada por la carga cíclica.

Las deformaciones para las cuales se produce la transición del comportamiento de pequeñas a grandes deformaciones dependen de la plasticidad de la arcilla y se acotan típicamente entre $10^{-2}\%$ y $10^{-1}\%$. Arcillas más plásticas (I_p más alto) tienden a localizar esta transición al final de este rango ($10^{-1}\%$), mientras que en arcillas de baja plasticidad y en otros suelos no plásticos, como en aluviones y arenas, ésta se localiza en el límite inferior ($10^{-2}\%$). Así, las arcillas con un alto I_p son más flexibles que los suelos menos plásticos y mantienen un comportamiento lineal (con poca energía de disipación sin degradación de la rigidez) para valores elevados de $\gamma\%$ (Fig. 5.36).

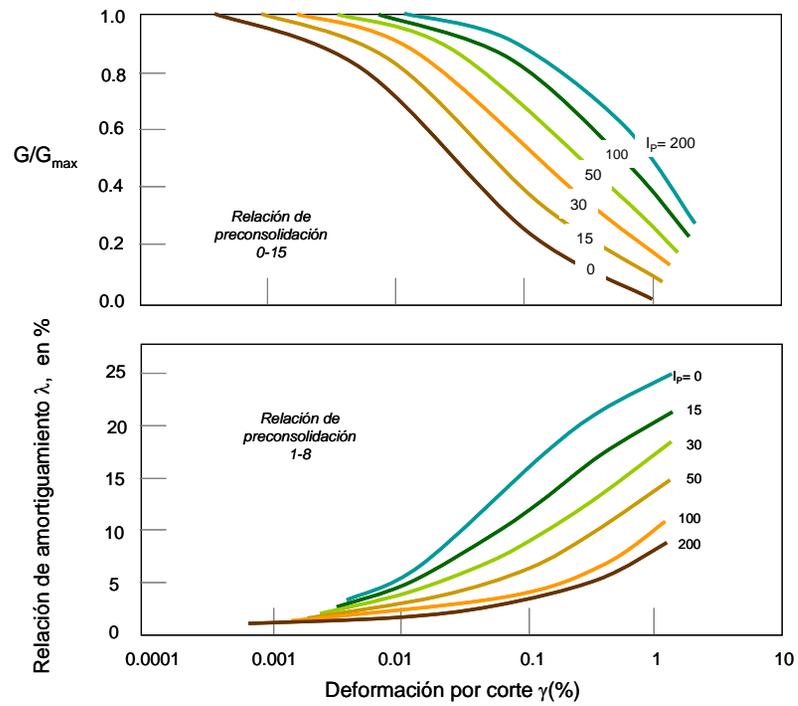


Figura 5.36 Efecto de la plasticidad de la arcilla sobre las curvas de degradación de módulo y amortiguamiento (modificadas de Kramer, 1996)

La arcilla de la Ciudad de México parece ser un caso extremo de esta familia de suelos flexibles y lineales (considerada en la literatura como una de las posibles causas del comportamiento de amplificación durante el terremoto del 19 de Septiembre de 1985). Con valores extremos de I_p , el suelo de la Ciudad de México durante algunos sismos ha presentado comportamientos verdaderamente lineales y exhibido menos amortiguamiento interno que otras arcillas (Fig. 5.37). Sin embargo, hay que apuntar que algunas arcillas plásticas de otros sitios del mundo, bajo ciertas condiciones, pueden también ser bastante lineales y aproximarse al comportamiento del suelo de la Ciudad de México.

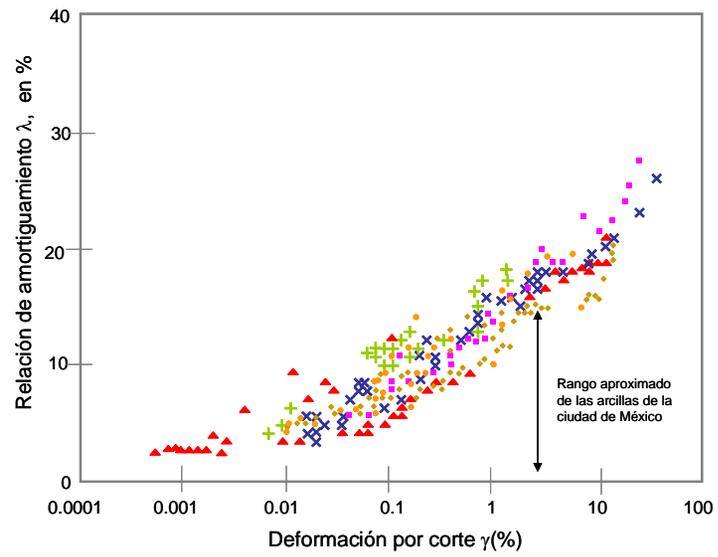
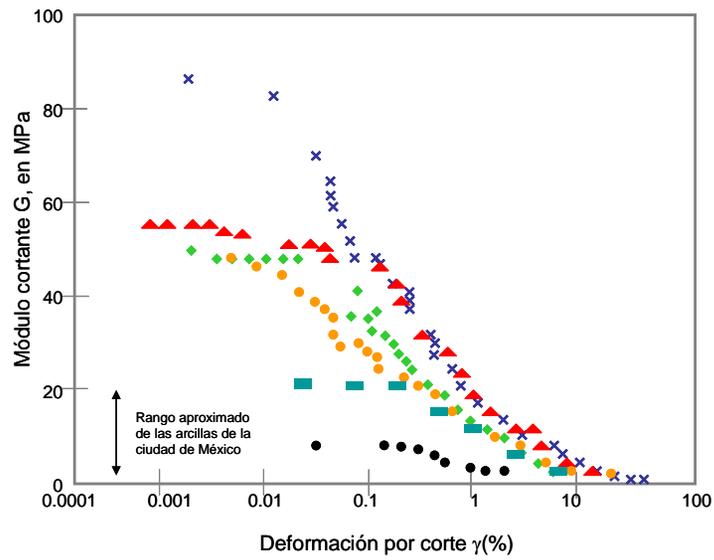


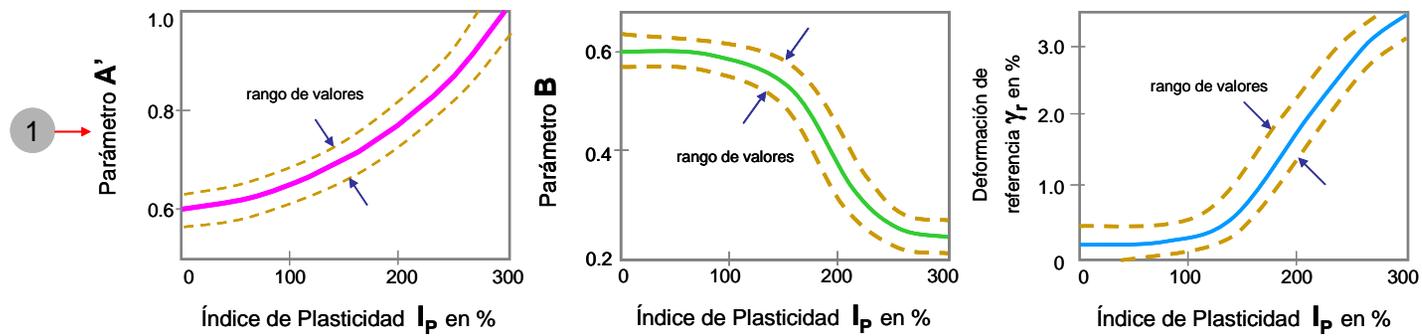
Figura 5.37 Comparación de la atenuación de la rigidez y aumento del amortiguamiento de las arcillas del valle de México y las arcillas marinas de la sonda de Campeche (modificada de Romo y Ovando, 1999)

Proceso

Para acoplar las hipótesis derivadas de la experiencia sísmica y las conclusiones resultado de exploraciones en laboratorio, el proceso se explica a través de funciones matemáticas que la práctica ingenieril ha establecido como válidas para interpretar el comportamiento dinámico de los suelos arcillosos. La incorporación a estos conocidos planteamientos de: i) *inteligencia* (unidades neuronales) y ii) *experiencia* (realimentación con resultados prácticos), modifica el paradigma otorgándoles flexibilidad y robustez ante situaciones de información incompleta o vaga.

El **Proceso** resulta de la concepción *lineal equivalente* de esfuerzo-deformación (materiales viscoelásticos lineales) donde se observa a los parámetros de amortiguamiento y resistencia como dependientes de la deformación angular. La resistencia del suelo se caracteriza por el módulo de rigidez al corte máximo G_{max} movilizado a bajas deformaciones y una curva de reducción de módulo normalizado G/G_{max} . El comportamiento amortiguador se caracteriza por la relación de amortiguamiento λ , la cual se incrementa con el crecimiento de la amplitud de deformación. La forma de las curvas de reducción de módulo y amortiguamiento son influenciadas, principalmente, por la plasticidad del suelo.

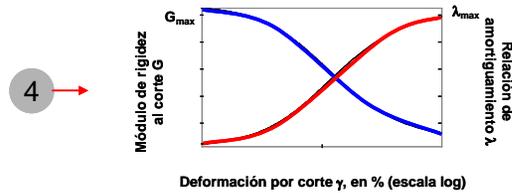
El uso de las velocidades de onda de corte V_s es, en general, la forma más confiable de evaluar G_{max} in situ ($G = \rho V_s^2$, donde ρ es la densidad de masa), mientras que para modelar la reducción (no lineal) del módulo G se utiliza el comportamiento inferido de la documentación de numerosos ensayos de laboratorio. La caracterización completa y detallada de este comportamiento es muy complicada y existen una gran variedad de puntos de vista para abordar el problema, todos de manera *aproximada*. Tomando esta tendencia como la más acertada para abordar una tarea tan compleja, en esta investigación se generó una RN que se sostiene de información *mecánica* (de acuerdo con el proceso de generación de curvas G/G_{max} versus $\gamma\%$ y λ versus $\gamma\%$ mostrado en la Fig. 5.38) e información *experimental pura* (algunos ejemplos de estos datos en la Fig. 5.39).



2 →
$$H(\gamma\%) = \left[\frac{(\gamma\% / \gamma_r)^{2B}}{1 + (\gamma\% / \gamma_r)^{2B}} \right]^A$$

$$G = G_{\max} (1 - H(\gamma\%))$$

3 →
$$\lambda = \lambda_{\max} (1 - G / G_{\max})$$



- 1 Con I_p obtenga A' , B y γ_r
- 2 Estime $H(\gamma\%)$
- 3 Calcule G y $\lambda = f(H(\gamma\%))$
- 4 Construya las curvas G y $\lambda = f(\gamma\%)$

Figura 5.38 Proceso de generación de la información *mecánica* (modificado de Romo y Ovando, 1996)

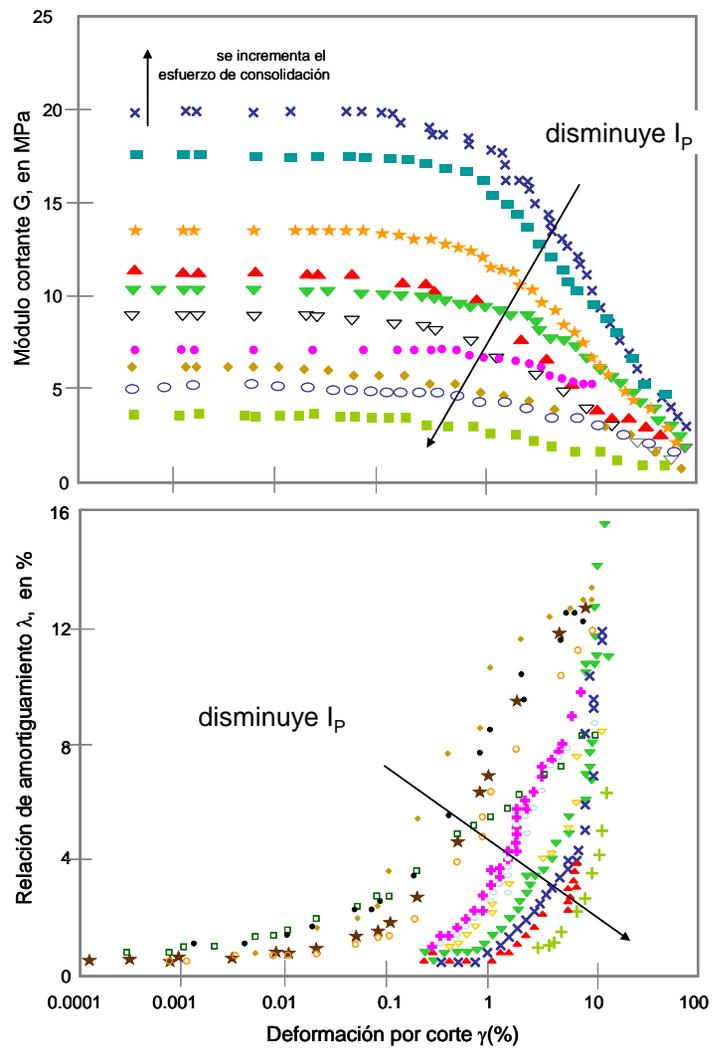


Figura 5.39 Algunos ejemplos de curvas de degradación de módulo y amortiguamiento obtenidas de ensayos realizados con materiales típicos del valle (modificado de Kramer, 1996)

Entradas

De entre los parámetros que dirigen la tarea por modelar, se reconoce que la forma de la curva de reducción del módulo G/G_{max} es influenciada más por el índice plástico que por la relación de vacíos (Dobry y Vucetich, 1987; Sun et al., 1988; Seed e Idriss, 1970) (Fig. 5.40) mientras que el efecto de la presión de confinamiento efectiva sobre el comportamiento del módulo es más notable en suelos de baja plasticidad (Iwasaki et al., 1978; Kokoshu, 1980) (Fig. 5.41).

Con base en esta evidencia práctica y las variables independientes que intervienen en los modelos hasta el momento desarrollados (como el hiperbólico), se propone como única entrada neuronal para describir las condiciones del material al índice de plasticidad I_p del suelo y a la deformación angular $\gamma\%$ como el nodo contador que dirige la construcción de las curvas paramétricas. La V_s y el peso volumétrico de la masa de suelo se usan en post-proceso para calcular externamente G_{max} y generar la curva de módulo normalizado G/G_{max} versus $\gamma\%$.

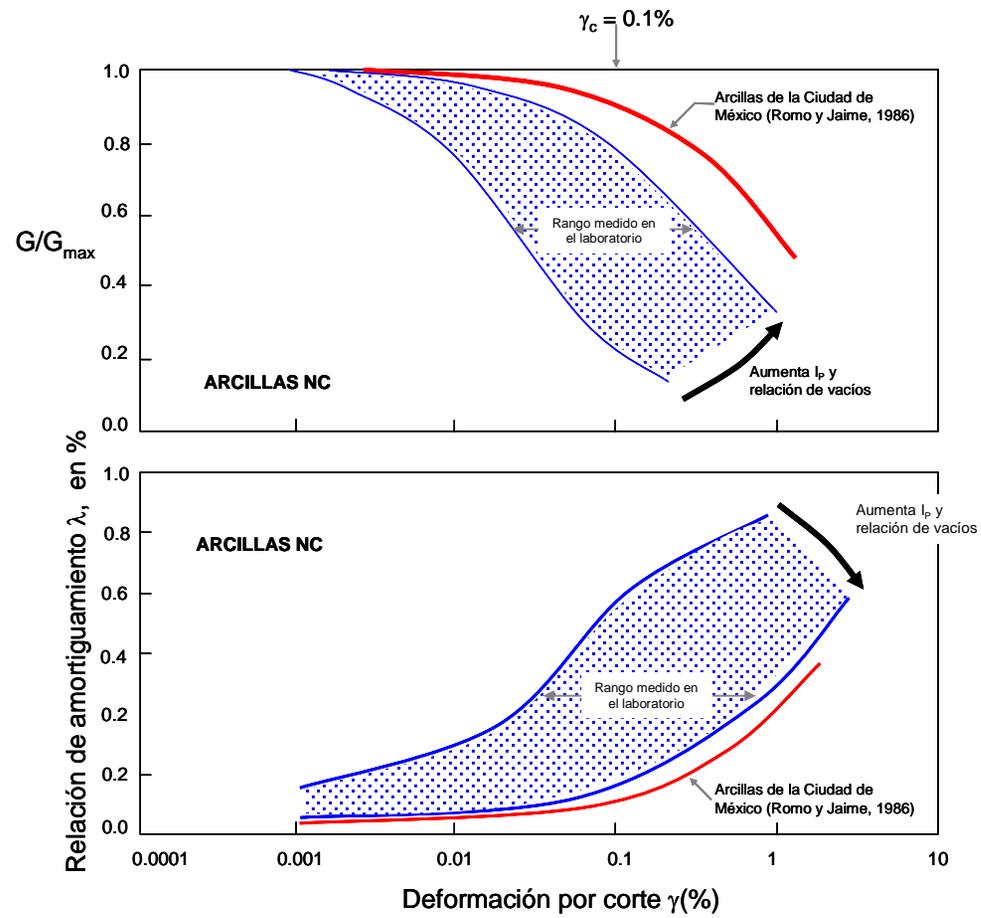


Figura 5.40 Efecto de la relación de vacíos sobre el comportamiento *dinámico* (modificada de Kramer, 1996) (revisar valores de las ordenadas de la curva del amortiguamiento)

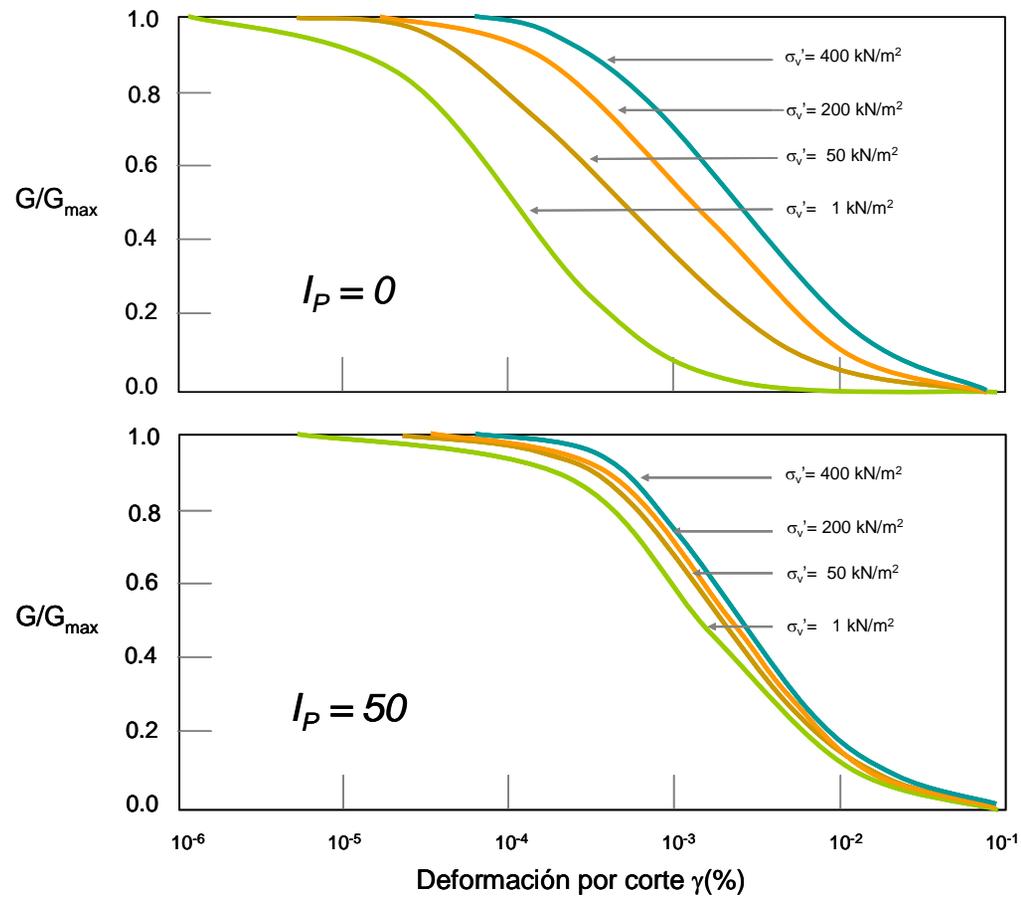


Figura 5.41 Efecto de la presión de confinamiento efectiva sobre el comportamiento *dinámico* (modificada de Kramer, 1996)

Modelo

Reconociendo la capacidad de las RNs de actuar como aproximadores universales de funciones, más concretamente, atendiendo al hecho de que una red, conteniendo al menos una capa oculta con suficientes unidades no lineales, puede aprender cualquier tipo de función o relación entre un grupo de variables de entrada y salida, en esta investigación se presenta un modelo neuronal para modelar el **Proceso** definido escasamente (paramétricamente) y con alto contenido de ruido (fallos implícitos en los datos).

Los datos de entrenamiento, como ya se declaró, se dividen en dos grupos: *mecánicos* y *experimentales puros*. Acoplar patrones *puros* a las estimaciones

mecánicas permite una mejor definición de los casos frontera (valores de I_p bajos y muy altos) y la eliminación de las ambigüedades que ocasionan las franjas de valores de los parámetros A , B y γ_r (misma entrada I_p diferentes valores de salida (G, λ)).

Una vez validada la base de datos de entrenamiento (verificación de congruencia entre patrones), se probaron diversas estructuras neuronales y bajo el criterio que jerarquiza como más apta a la red con menor número de nodos (menos tiempo-máquina) y mayor ajuste sobre los comportamientos objetivo, se concluyó que la combinación mostrada en la Fig. 5.42 es la más exitosa.

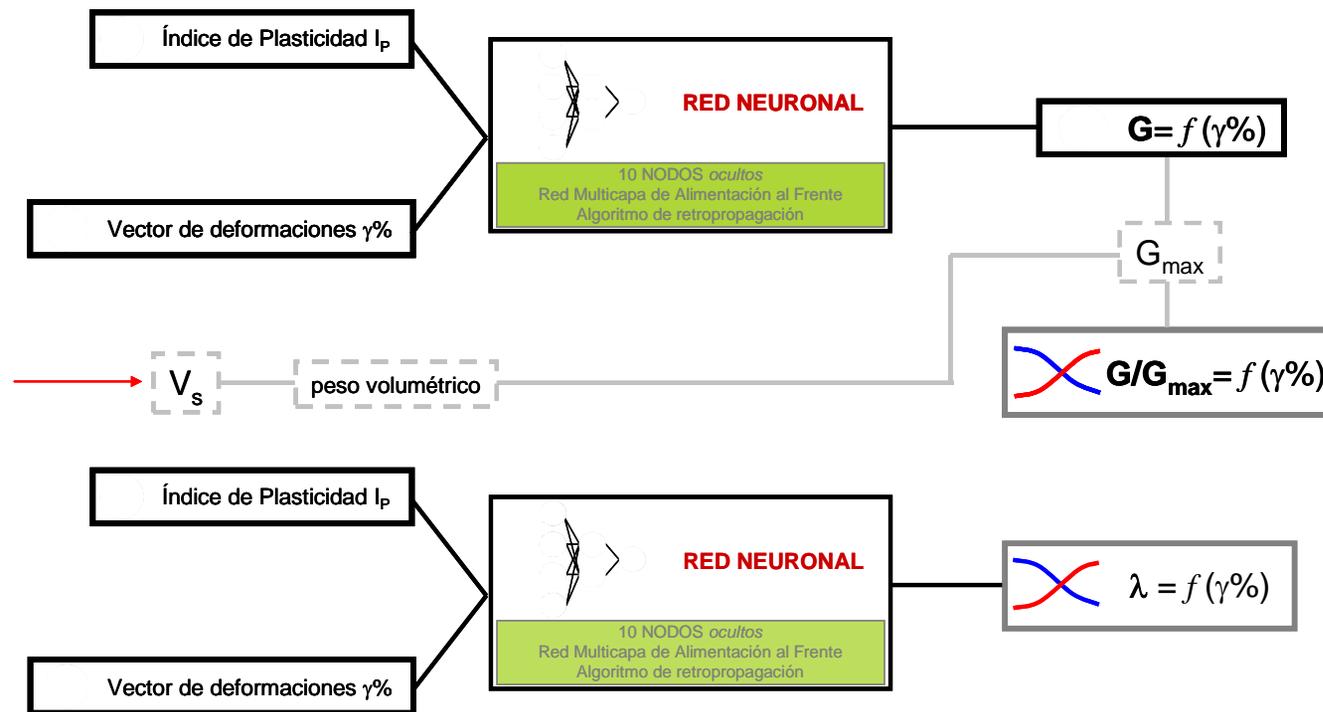


Figura 5.42 Topología más exitosa para modelar: $(G/G_{max}, \lambda) = f(I_p, \gamma\%)$

Salida

A continuación se presentan algunos ejemplos de las estimaciones neuronales para estratigrafías típicas del valle y que están incluidas en la base de datos del modelo neurodifuso $V_s = f(q_c, Z, Zona)$. El esquema neuronal, en una primera ventana de entradas, solicita los valores de I_p y $\gamma\%$ (Fig. 5.43). Posteriormente para la construcción de la curva del módulo G normalizado, el sistema requiere del valor de V_s y peso volumétrico. En caso de que el usuario desconozca la velocidad de ondas de corte, se llama al módulo neurodifuso $V_s = f(q_c, Z, Zona)$ para su estimación. En la Fig. 5.43 se presentan los resultados para los sitios SCT y CDAO, típicos de la Zona Centro I. Como se observa en la figura, el modelo neuronal responde satisfactoriamente al reto de caracterizar dos importantes aspectos del comportamiento dinámico de los suelos (G, λ) de manera simple y bajo conceptos racionales.

Entre los resultados para SCT y CDAO se encuentran puntos (para SCT en $Z=17\text{m}$ y 23m y para CDAO en $Z=33\text{m}$ y 43m) que representan ejemplos *típicos* de entrenamiento (patrones con los que se midió la actuación del modelo durante su construcción) y para sustentar lo dicho sobre la capacidad de generalización del modelo neuronal también se presentan soluciones en modo de trabajo *directo* o prueba (para SCT en $Z=5\text{m}$ y 20m y para CDAO en $Z=39\text{m}$ y 55m).

Como se observa en la Fig.5.43 las tendencias preconcebidas para los distintos materiales es bien reconocida por el modelo neuronal y estas curvas representan una manera sencilla, económica y directa de obtener estos importantes parámetros dinámicos a partir del I_p . Es necesario apuntar que el efecto del confinamiento no es nulificado en esta propuesta, se propone que el usuario mantenga una posición de alerta sobre la cualidad plástica del material que está estudiando y use el valor de I_p como más convenga a los efectos de su análisis. Como ya se ha mencionado anteriormente, las propiedades índice precisamente son sólo indicaciones de ciertas condiciones y cualidades de los materiales, pero es su vaga y simple naturaleza la que nos permite adicionarles criterios prácticos para enriquecerlas.

Los valores cerrados de I_p difícilmente pueden considerarse *naturales* y la extrapolación de estos resultados puntuales hacia cualidades de estratos de varios metros de espesor significa una simplificación a veces demasiado aventurada. Así, sabiendo que es sumamente sencillo obtener las curvas de degradación de módulo y amortiguamiento, un usuario con el reporte de un valor de I_p para un material extraído a una profundidad Z , y quizá con un parcial conocimiento del peso volumétrico y la historia de cargas, podría adherir criterios empíricos y modificar la expresión numérica de la cualidad de plasticidad o bien, calcular una banda de valores posibles en los que se podría ubicar el verdadero comportamiento de la masa de suelo.

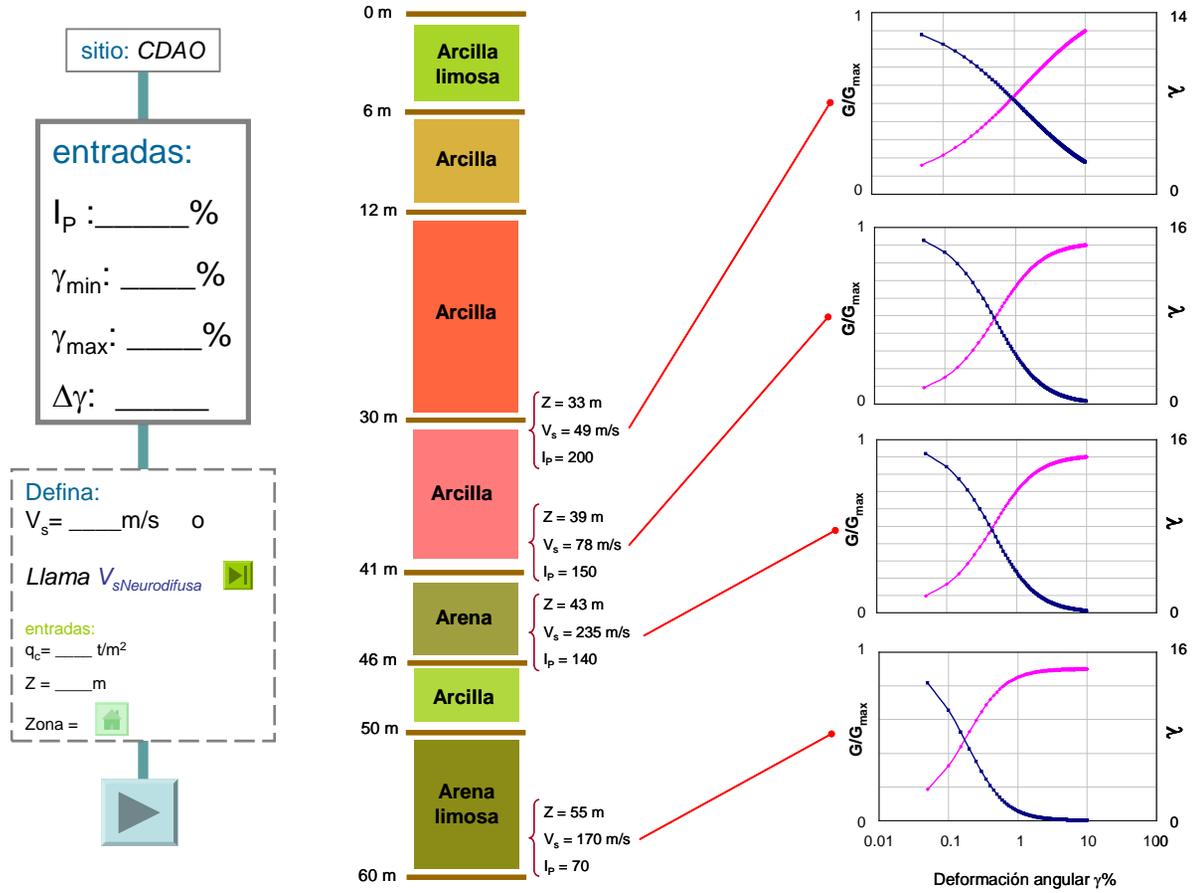


Figura 5.43 Estimaciones neuronales para algunos puntos sobre las estratigrafías de los sitios CDAO y SCT

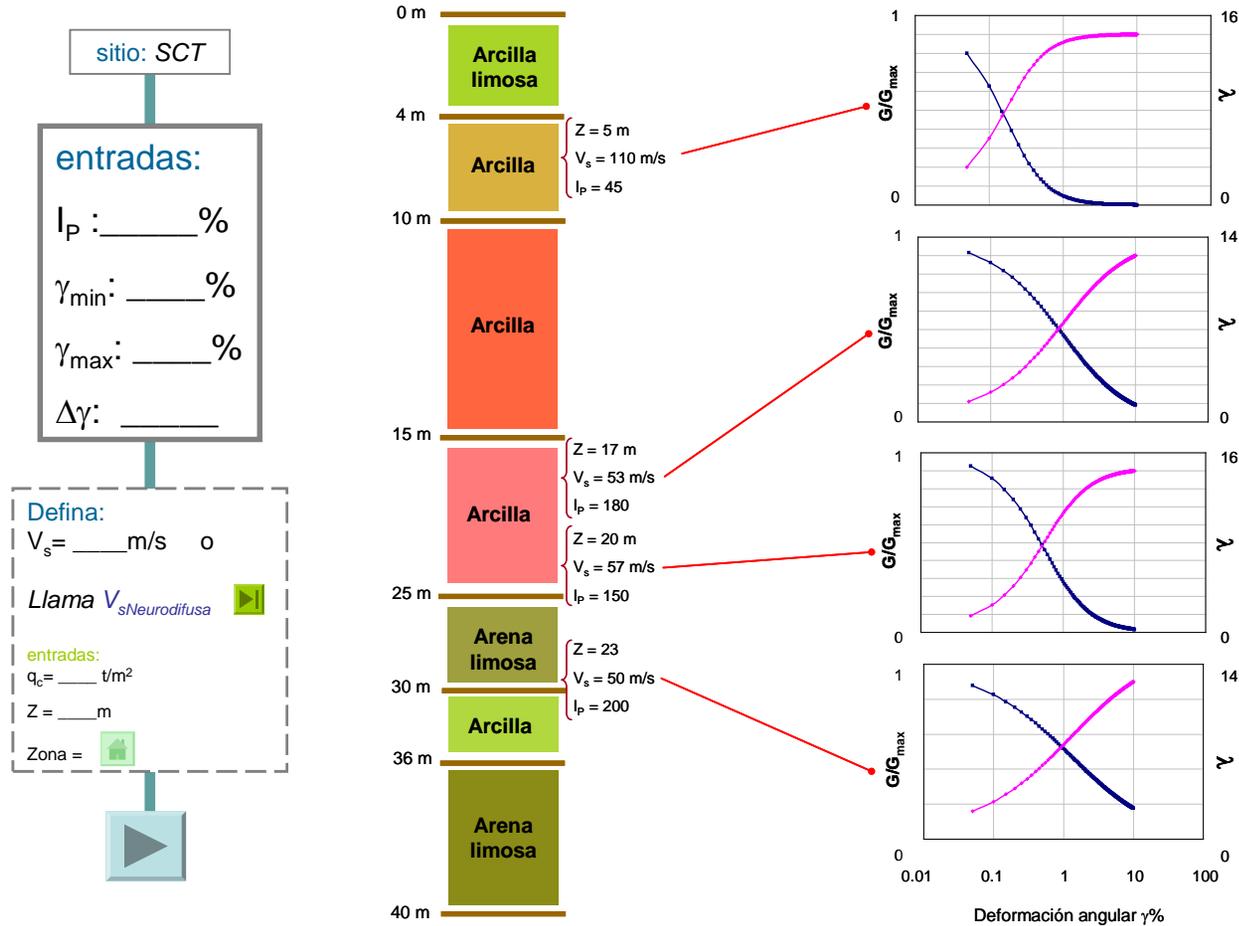


Figura 5.43 Estimaciones neuronales para algunos puntos sobre las estratigrafías de los sitios CDAO y SCT (continúa)

Hasta el momento se han detallado ventajosas características de la RN en cuanto a objetividad teórica, operación e interpretación de resultados. Para ilustrar la capacidad del modelo en casos prácticos, a continuación se presentan ejemplos del desempeño neuronal ante una situación práctica. En las Figs. 5.44-47 se muestran comparaciones entre los valores obtenidos de ensayos en materiales arcillosos de alta plasticidad de un sitio ubicado en el área de Texcoco (Zona de Lago) (Mayoral et al. 2007) y las curvas generadas con el módulo neuronal en modo de trabajo directo. Las arcillas ensayadas presentan índices de plasticidad que van de 100 a más de 250% y cubren profundidades de 2 hasta casi 23 m.

Las estimaciones neuronales a poca profundidad (Fig. 5.44) resultan muy cercanas a los resultados de laboratorio. Observe que, de entre los resultados presentados en esta batería de gráficos, éste es el correspondiente al valor de I_p más alto y la cercanía entre medido y estimado es la más notable. Este es un sesgo del modelo muy marcado, estimaciones más cerca del reporte de laboratorio conforme crece la plasticidad del suelo, mientras que para suelos menos plásticos los resultados neuronales se acercan más a lo que dicta el conjunto de datos *mecánicos*.

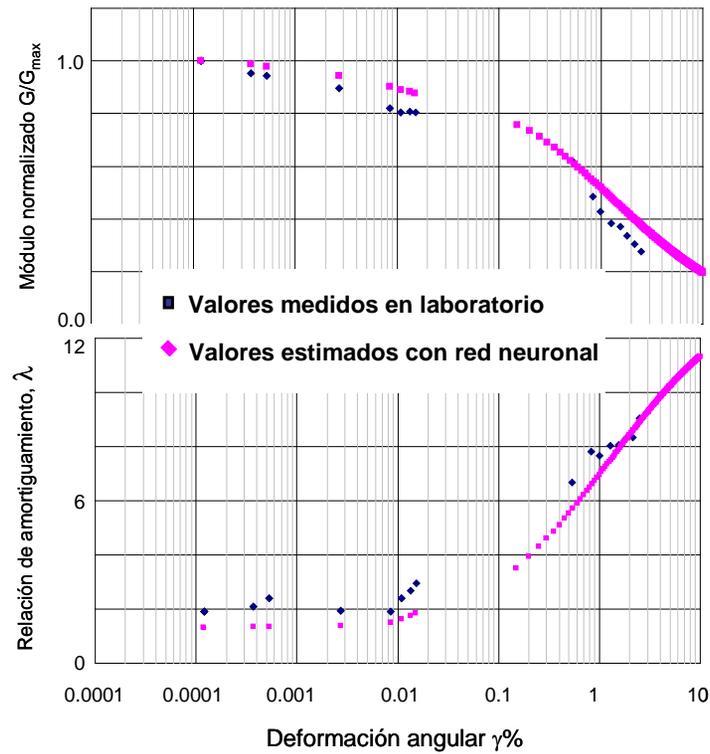


Figura 5.44 Estimaciones neuronales en modo de trabajo directo. Propiedades: $Z = 2.4$ a 2.6 m , $I_p = 265$

Las curvas mostradas en la Fig. 5.45 son las que mayores diferencias presentan en predicción, sin embargo es necesario apuntar que esto sólo sucede para niveles de deformación altos (arriba del 1%). Este efecto resulta lógico si se examinan las tendencias de las curvas *mecánicas* incluidas en el entrenamiento. No se considera que esta sea una indicación de un mal comportamiento del funcional neuronal, de hecho el promedio de los ejemplos estudiados con las mismas condiciones paramétricas (I_p , peso

volumétrico y estado de esfuerzos aproximado) guardan una tendencia más cercana a la curva neuronal que a la reportada de laboratorio. ¿Cuál de los dos comportamientos es el correcto?, ¿alguno podría ser mejorado?, ¿de qué manera?. Las respuestas a estos cuestionamientos están lejos del alcance de esta investigación, pero lo que sí se puede recomendar es que el uso posterior de las curvas (G, λ) debe mantener la sentido con la que han sido propuestas y determinadas: simpleza y fragmentación.

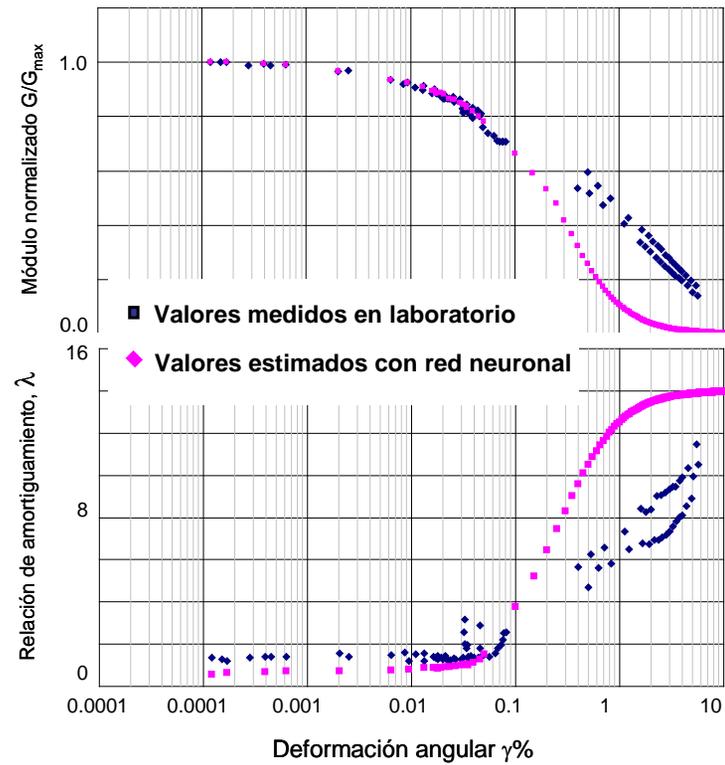


Figura 5.45 Estimaciones neuronales en modo de trabajo directo. Propiedades: $Z = 6.2$ a 6.4 m , $I_p = 106$

Los ejemplos restantes (Figs. 5.46 y 5.47) son considerablemente mejores que el anterior y el uso de cualquiera de las curvas, medida o estimada, no repercutiría en grandes diferencias si se usan en un programa de cálculo de respuestas sísmicas en suelos blandos.

Con base en toda la información gráfica y la propuesta del modelo como software ingenieril, se puede calificar a esta RN como una atractiva alternativa para la caracterización aproximada y preliminar del comportamiento dinámico de los suelos plásticos del valle de México.

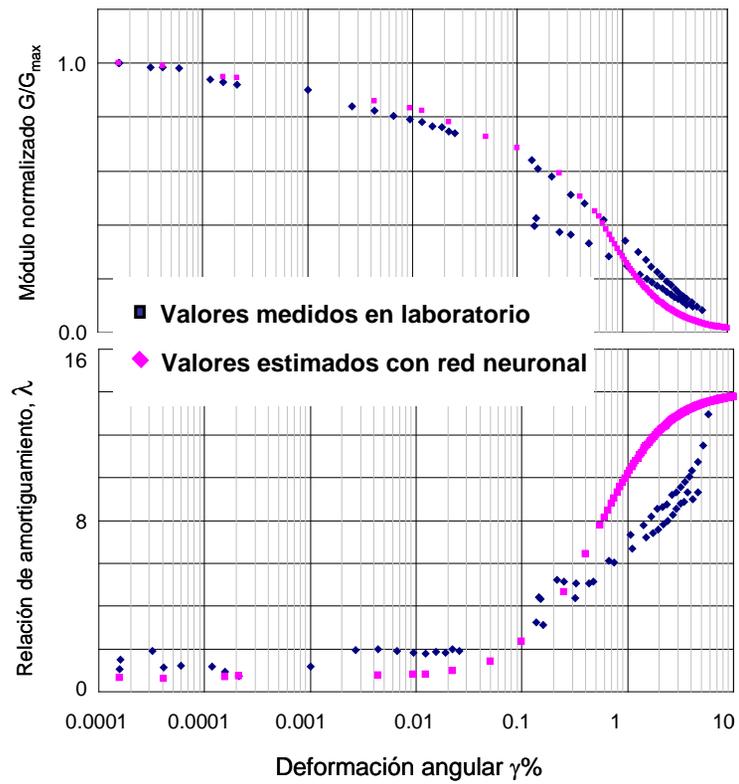


Figura 5.46 Estimaciones neuronales en modo de trabajo directo. Propiedades: $Z = 9.0$ a 9.2 m , $I_p = 139$

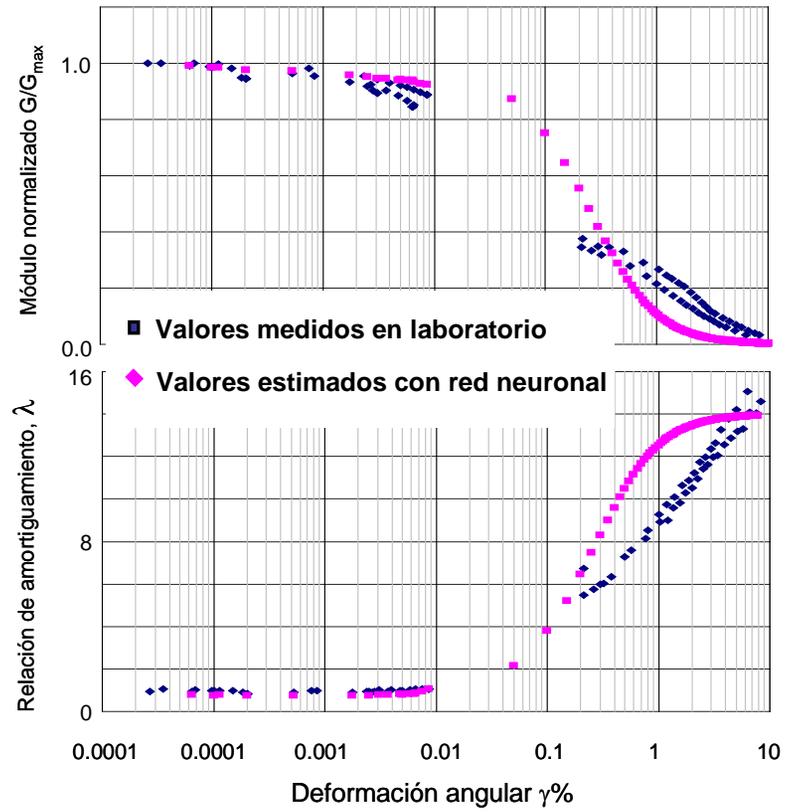


Figura 5.47 Estimaciones neuronales en modo de trabajo directo. Propiedades: $Z = 22.6$ a 22.8 m , $I_p = 100$

5.2 Estimación de movimientos de terreno en la Ciudad de México

En la Ciudad de México, como en muchos otros lugares del mundo, la amenaza de los sismos a las actividades humanas es suficiente para requerir su consideración cuidadosa en el diseño de estructuras. El objetivo del diseño sísmico es producir estructuras u obras civiles que resistan ciertos niveles de sacudidas sísmicas sin daños considerables.

La descripción de estas sacudidas (movimientos o respuestas de terreno) es uno de los problemas más importantes en ingeniería geosísmica. Bajo condiciones ideales, un análisis de respuesta de terreno *completo* debería modelar el mecanismo de ruptura en la fuente, la propagación de las ondas de esfuerzo a través de la corteza terrestre hasta la parte superior del manto rocoso (bajo un sitio en particular) y la modificación de este movimiento en roca por efecto de los suelos depositados sobre ella. En realidad, el mecanismo en la ruptura es tan complicado y la naturaleza de la transmisión de energía entre la fuente y el sitio tan incierto que un modelado completo no es práctico para aplicaciones comunes en ingeniería.

La tendencia funcional es que a través de métodos empíricos desarrollados con sismos registrados se generen relaciones predictivas *muy simples* donde se proponga el movimiento en la base rocosa y se cuantifique su transformación de acuerdo con propiedades dinámicas de los suelos.

Teniendo en cuenta estos fundamentos de análisis y de acuerdo con el proceso empírico de creación de modelos, se plantea el siguiente esquema de solución al problema de estimación de movimientos de terreno en la Ciudad de México:

SISTEMA: Depósitos de suelo del valle de México

PROCESO: Propagación de ondas sísmicas

ENTRADAS (datos): *Parámetros E* que describen la demanda sísmica (evento) y *Parámetros S* que describen al depósito (sitio)

MODELO: Red Neuronal RN

SALIDA (resultado): $ERA_{sitio}^* = f(\text{sismo}, \text{depósito de suelo})$

*Espectro de Respuesta de Aceleraciones

Es importante recordar que, actualmente, mucha de la dificultad en la especificación de movimientos de terreno resulta del crédito inevitable que se le otorga a decisiones subjetivas basadas en información *incierta o incompleta*. Un modelo alternativo debe evitar la inclusión de afirmaciones poco científicas sobre los **Sistemas** y más que acudir a simplificaciones sobre la naturaleza de los **Procesos**, debería minimizar el número de variables básicas para poder predecir las derivadas con suficiente aproximación y confiabilidad de acuerdo con los datos disponibles. Bajo un punto de vista ingenieril, un modelo así se prefiere porque simplifica las decisiones de diseño y genera procedimientos más robustos.

Sistema

El efecto del tipo de suelo sobre la amplitud y la naturaleza de las ondas sísmicas ha sido reconocido como crucial en la estimación del peligro sísmico. Esto es particularmente importante en las arcillas de la Ciudad de México cuyas características de plasticidad y linealidad a altas deformaciones la convierten en un interesante y muy valioso caso de estudio.

La Ciudad de México está localizada en la cuenca de un viejo lago, la parte oeste de la Ciudad yace sobre depósitos de suelo firme y roca, mientras que la parte este se encuentra sobre depósitos de arcilla suave que llenaron la cuenca del antiguo lago (Fig. 5.48). Entre la formación dura y los depósitos de arcilla se encuentra una zona de transición, donde el suelo presenta características de rigidez mayores pero involucra algunos estratos importantes de arcilla blanda. En el área del lago, los depósitos de arcilla se encuentran sobre formaciones muy duras cuyas velocidades de propagación de ondas de corte son comparables con las de una roca suave.

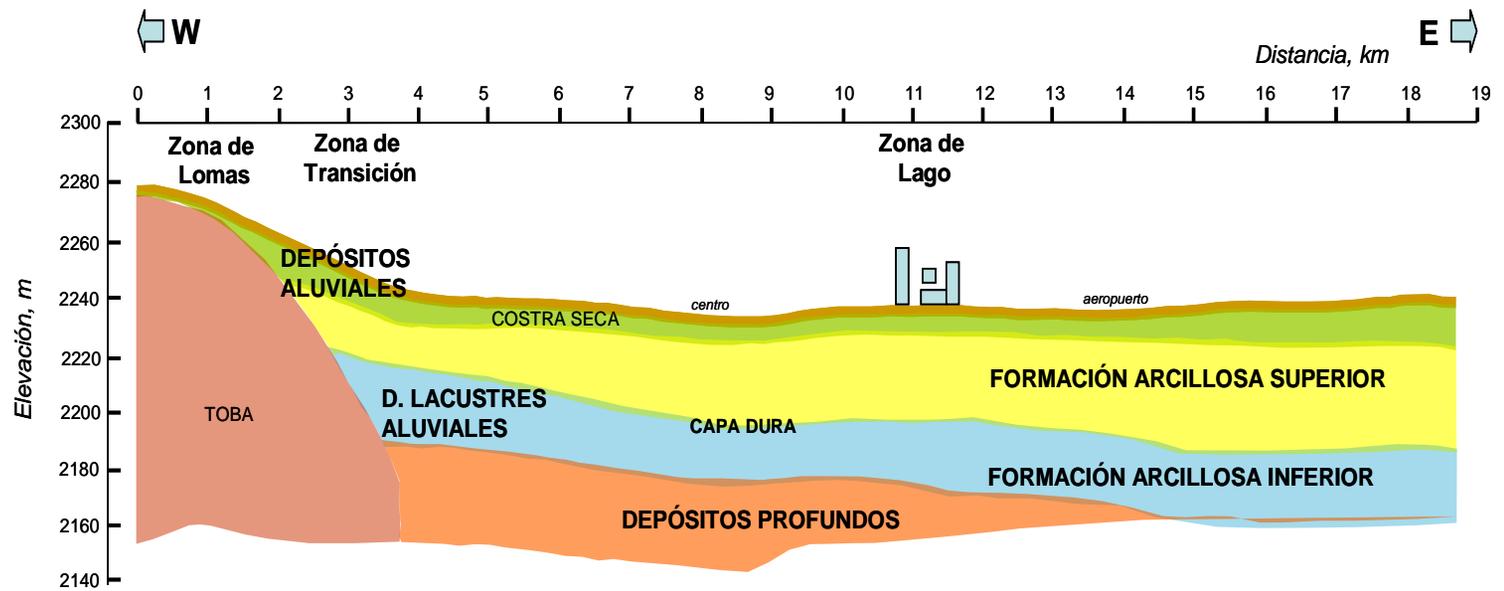


Figura 5.48 Estratigrafía general de la Ciudad de México (modificada de Mooser, 2000)

El reconocimiento de esta secuencia geotécnica generó hace más de 45 años la zonificación pionera de Marsal y Mazari (1959), la cual ha experimentado algunos cambios en la ubicación de las fronteras de cada zona pero la descripción de las características típicas de los materiales, a pesar de los sondeos y estudios desarrollados hasta la fecha, continúa siendo casi la misma dentro del código actual de construcción (Figs. 5.49 y 5.50):

Zona de Lomas (Zona I). Se encuentran formaciones de roca por derrame de lavas o suelos generalmente firmes (tobas volcánicas). Pueden encontrarse algunos estratos arenosos en estado suelto o cohesivos intercalados o en la superficie.

Zona de Transición (Zona II). Integrada por estratos arenosos y limo-arenosos intercalados con capas de arcilla lacustre. Su espesor varía entre decenas de centímetros y no más de 20 m a partir de los cuales se encuentran los depósitos profundos.

Zona de Lago (Zona III). Está constituida por depósitos de arcilla de alta compresibilidad y alto contenido de agua (espesores entre 20 y 100 m) con intercalaciones de capas areno-limosas o arcillosas de consistencia firme a muy dura con espesores variables de centímetros a varios metros. Estos depósitos arcillosos suelen estar cubiertos superficialmente por suelos aluviales y rellenos artificiales.

Es importante señalar que los suelos lacustres de la Ciudad de México han sido fuente de muchos problemas serios de ingeniería. Los tres principales problemas a los que se enfrentan los ingenieros durante el diseño y construcción de edificaciones y cimentaciones son:

- Las propiedades singulares de los sedimentos
- El hundimiento regional
- La alta sismicidad

Lo relativo a las propiedades, tanto físicas, químicas, mineralógicas, hidráulicas y mecánicas (estáticas y dinámicas) ya se mencionaron en los capítulos anteriores. El hundimiento de la Ciudad desde su descubrimiento en 1891 (inicialmente acotado entre 3-5 cm/año) aumentó a 15-30 cm/año en 1947 para situarse en la actualidad entre 5-7 cm/año. En algunos lugares de la Ciudad de México se presentan fuertes asentamientos e incluso llegan a experimentar la aparición de fisuras y grietas. Estos dos aspectos ligados con la particular sismicidad que afecta al valle, sin duda dibujan un panorama de análisis complicado y multifacético.

a) 1959

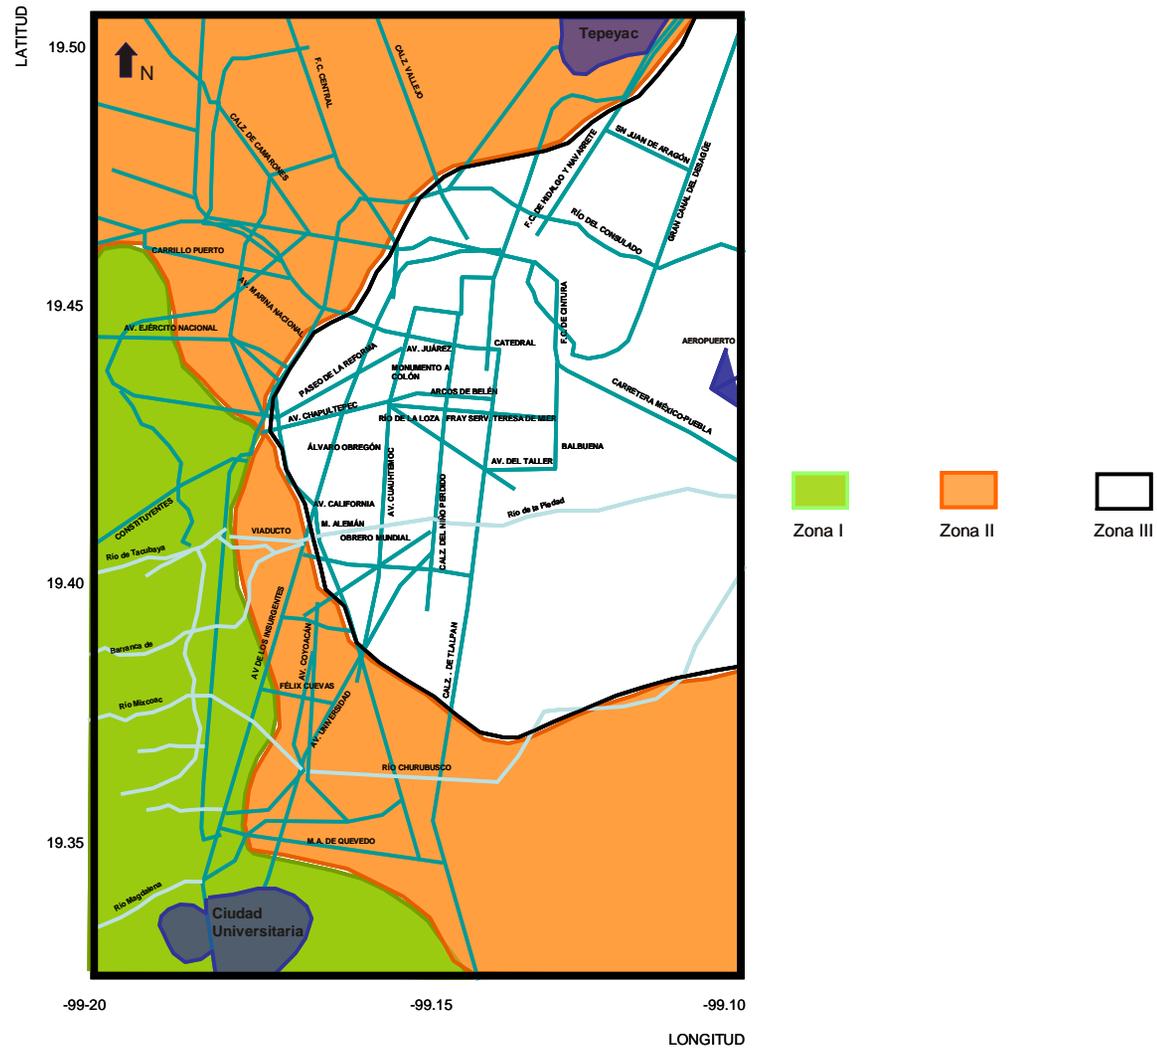


Figura 5.49 Zonificación geotécnica del valle de México: a) Marsal y Mazari (1959), b) Auvinet et al. (2000)

b) 2000

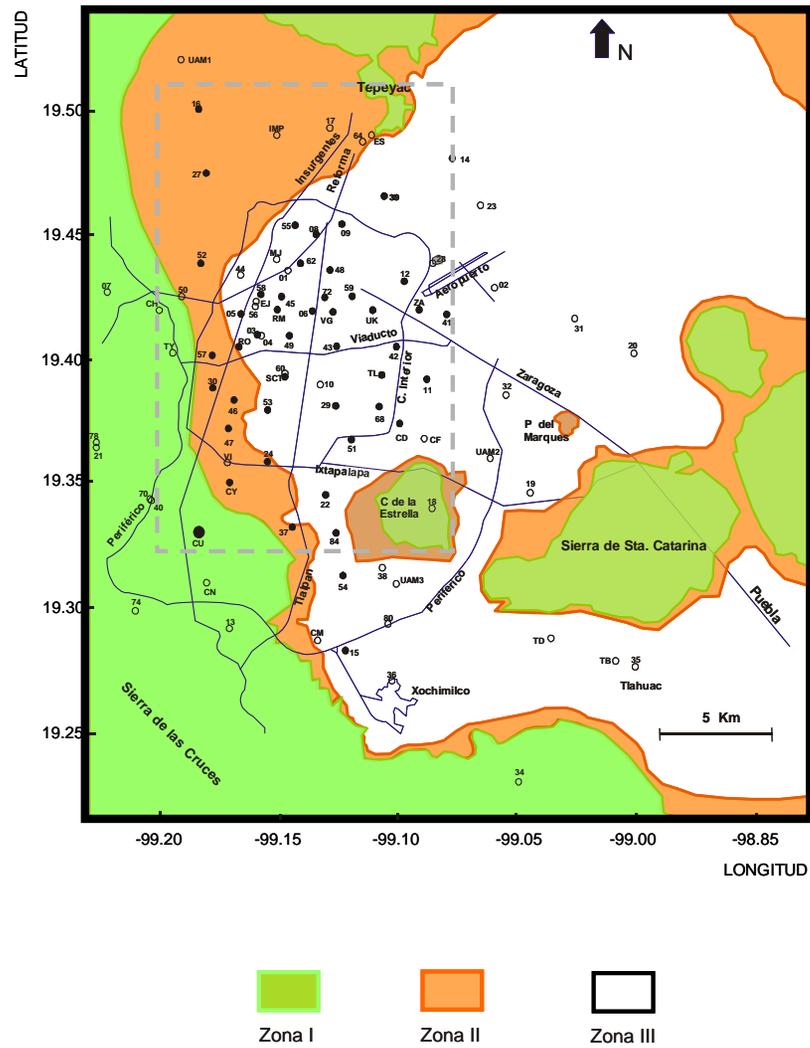


Figura 5.50 Zonificación geotécnica del valle de México: a) Marsal y Mazari (1959), b) Auvinet et al. (2000)

Proceso

La propagación de ondas sísmicas no se modela en el esquema matemático expuesto en este trabajo de investigación, sino que se vincula la expresión numérica (ERA en superficie) de una de sus manifestaciones más evidentes (movimiento de la masa de suelo) con algunos parámetros que caracterizan al evento sísmico generador del **Proceso**. La solución neuronal es un planteamiento *fenomenológico*, es decir, el modelo es capaz de describir las manifestaciones del **Proceso** y eventualmente de relacionarlas con *causas*, pero no de *explicar* la estructura que las generan (Fig.5.51).

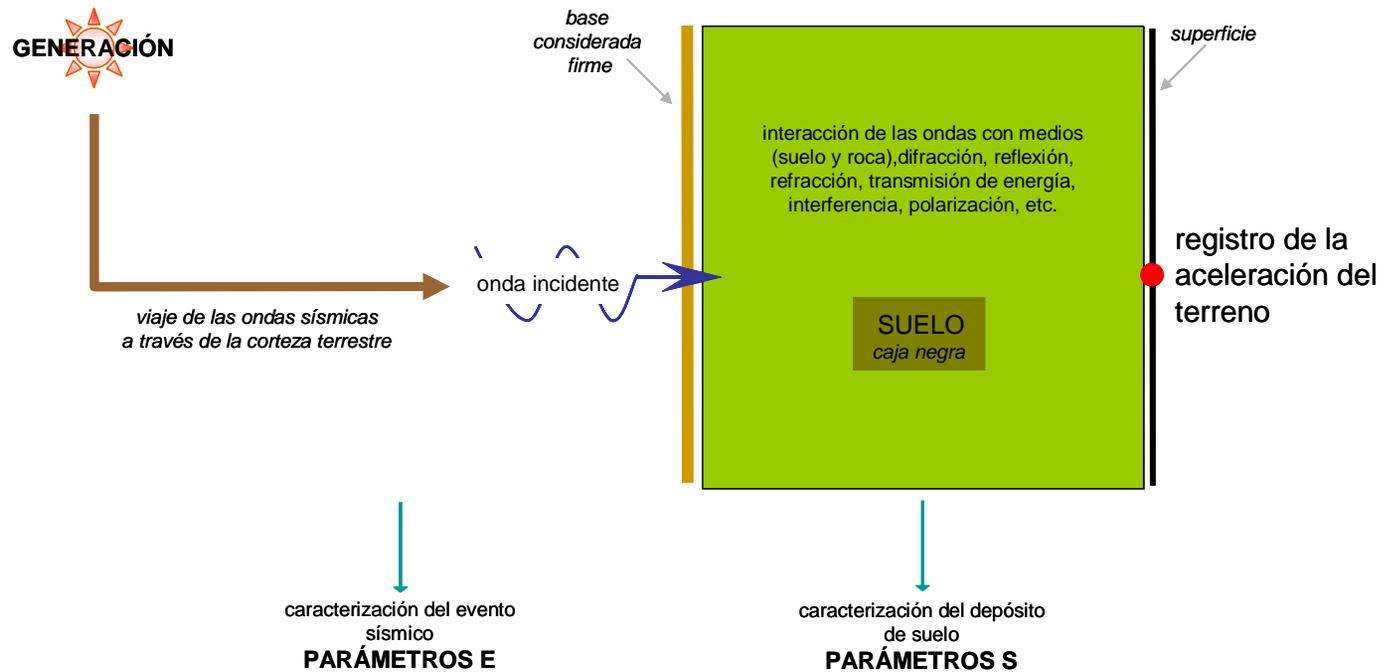


Figura 5.51 Planteamiento fenomenológico para evaluar la respuesta del terreno ante la ocurrencia de un sismo

El método conexionista que se describe a continuación, no intenta modelar el fenómeno de propagación de ondas sísmicas ni caracterizar integralmente la respuesta del valle, sino servir como una práctica herramienta *científica* para el reconocimiento de patrones de comportamiento y su predicción numérica. Esta aproximación permite: 1) estudiar formalmente el movimiento a través de Espectros de Respuesta de Aceleraciones ERA (5% de amortiguamiento) dentro de un ambiente de información escasa, incompleta y contaminada, 2) generar conclusiones *inteligentes* sobre los procesos (acción→reacción) y 3) delimitar nuestro conocimiento y dirigir futuras investigaciones a través de guías matemáticas con significado *natural*.

- Entradas

PARÁMETROS

En los análisis de respuesta de terreno básicamente lo que se hace es modificar los movimientos en roca, producto de la acción de fuerzas sísmicas, considerando el efecto de un perfil de suelo. Debe aclararse que este tipo de movimientos se refieren a un afloramiento rocoso relacionado con el sitio y no se asignan directamente a la base del perfil, ya que, a menos que la roca sea muy rígida, los movimientos en la base serán diferentes de aquellos en superficie.

La demanda sísmica, representada con el movimiento en el afloramiento rocoso, requiere de una adecuada caracterización por medio de *medidas*. Dentro de los cuantificadores más directos se encuentran los de amplitud (valores máximos de aceleración, velocidad y desplazamiento), los de frecuencia (espectros de Fourier y de Respuesta) y los de duración.

Amplitud. Es común en diseño y análisis caracterizar la fuerza de la sacudida sísmica usando un parámetro simple como la aceleración, velocidad o desplazamiento máximos. Estos parámetros han ganado gran aceptación porque son fácilmente incorporados en métodos estándar pseudo-estáticos, sin embargo, la caracterización de una historia de tiempo transitoria usando sólo un valor de amplitud resulta demasiado escasa.

Frecuencia. Para definir el contenido de frecuencias de la sacudida se requiere de un Espectro de Amplitudes de Fourier EAF o de un Espectro de Respuesta de Aceleraciones ERA. Los ERA, obtenidos aplicando movimientos de terreno a la base de un conjunto de osciladores de un grado de libertad 1GDL (con mismas relaciones de amortiguamiento) y graficando las respuestas máximas de cada oscilador como función de su frecuencia o periodo natural, son los más ampliamente usados en la ingeniería práctica porque describen las características de frecuencia en una forma directamente aplicable al diseño y análisis estructural.

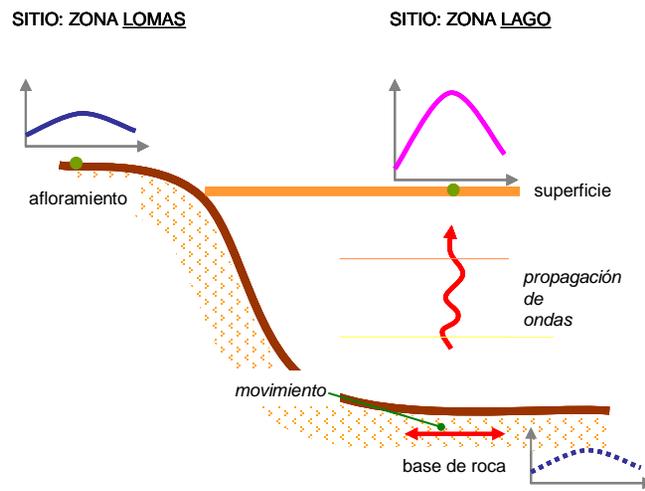
Duración. Además de la fuerza y el contenido de frecuencias, la duración de la sacudida tiene gran influencia en el comportamiento de las estructuras. La duración de la sacudida *fuerte* se incrementa con el crecimiento de la magnitud. El potencial de daño inducido por sismo es función de la duración de los movimientos de terreno *significativos* y es particularmente importante en la respuesta sísmica de estructuras dúctiles, la estabilidad de los suelos no cohesivos y el comportamiento de taludes y presas.

Para definir las variables de entrada de este postulado conexionista se tomaron en cuenta estas generales bases teóricas y las ventajas del modelado con RNs.

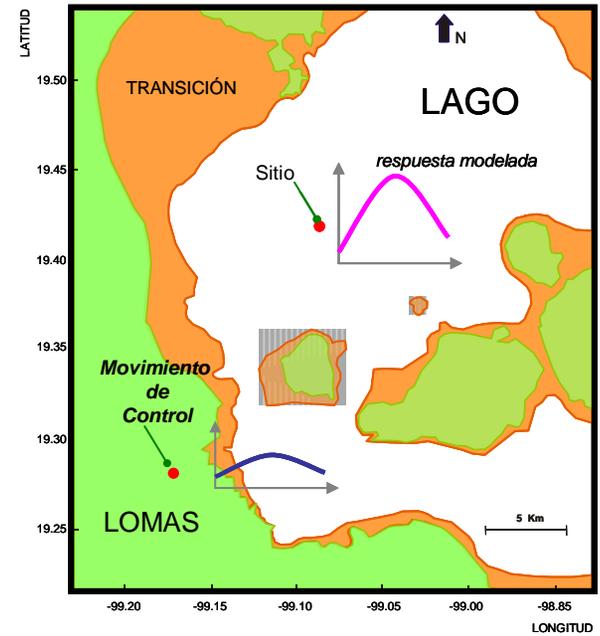
Entrada E-1. Movimiento de Control MC

Reconociendo la importancia del que se considera *movimiento en la base*, independientemente del método que se siga para su transformación, y sabiendo que los registros en afloramientos rocosos, como representaciones de las sacudidas en la base dura de los depósitos de suelo del valle de México, forman parte importante de las incertidumbres epistémicas en el modelado de movimientos de terreno, en esta investigación se propone un replanteamiento de la demanda sísmica como a continuación se describe:

- Revisando íntegramente el tipo y nivel de conocimiento disponible sobre esta entrada se plantea mudar el concepto *movimiento en la base* a *movimiento de control* (Fig.5.52). No se hacen hipótesis sobre la naturaleza ni expresión numérica de las sacudidas en la base firme de un depósito. El lugar de la demanda sísmica en el vector de entradas lo ocupa un ejemplo de respuesta registrado en superficie que *controla* las diferencias frecuenciales y de amplitud entre cada evento (Fig. 5.52b).
- La base de datos con registros de 22 sitios en zona de Lago, 10 en Transición y 1 en Lomas permite elegir de entre estos 33 depósitos el punto de control que funja como demanda sísmica. Si los materiales que conforman el depósito y el medio que rodea a la estación acelerográfica no han sufrido cambios sustanciales en el periodo que cubre la historia sísmica monitoreada, entonces las diferencias en los acelerogramas se deberán únicamente a la sismogénesis y a la trayectoria (dirección y distancia fuente→sitio). La selección del *movimiento de control* se basa en el número de eventos registrados y la validación de las comparaciones entre los resultados de esta tesis y los obtenidos de otros procesos numéricos. La estación CU (Ciudad Universitaria), sitio en roca blanda, fue elegida para controlar el aprendizaje neuronal *entrada→salida*.



a)



b)

Figura 5.52 Demandas sísmicas: a) Movimiento en la Base, b) Movimiento de Control

- Para ser consecuentes con las características que deben contener las demandas sísmicas, los registros en CU se transforman a dominios espectrales para señalar contenido frecuencial y amplitud. En esta investigación se compararon los EAFs y los ERAs de registros que cubren desde la década de los 60 y hasta el sismo de Tehuacán, Puebla, en 1999. En las Figs. 5.53 y 5.54 se muestran algunos ejemplos gráficos de estos vectores.

Debe recordarse que en un modelo neuronal toda la información se usa en la construcción de las relaciones paramétricas, así que de la adecuada expresión del fenómeno a través de las entradas dependerá el éxito de la aplicación. Sin polemizar acerca del significado de los espectros en el ámbito de las estructuras, de la sismología, de la geotecnia, incluso de las matemáticas y observando solamente los gráficos que despliegan (tenga en mente que finalmente son cadenas de números ante la red neuronal) ¿cuál de las dos expresiones, EAFs o ERAs, es más ventajosa numéricamente?

Los EAFs tienen distintas longitudes dependiendo de la señal que los origina por lo que su inclusión como columna o renglón en la matriz de entradas no es directa (deben ser el mismo número de nodos para todos los patrones). Un EAF es de alta complejidad numérica (crestas y valles consecutivos en todo el espectro) y la identificación de tendencias, frecuencias de corte, de esquina y las fundamentales requiere suavizar los espectros o trazar envolventes, procesamiento que no se realiza bajo argumentos fenomenológicos. Los ERAs, con una longitud pre-establecida para todos los registros, con simpleza de forma que permite ubicar detalles característicos en ciertos periodos y con una directa utilidad práctica en cada componente vectorial, se muestran como ventajosas alternativas para expresar el *movimiento de control*.

- Un ERA de CU es un vector de periodos y ordenadas espectrales (*T periodo, OE ordenada*) que la RN lee y busca las relaciones con condiciones particulares de respuesta en cada sacudida. ¿Es suficiente un ERA para representar numéricamente las diferencias paramétricas entre cada evento?. Observe de nuevo las Figs.5.53 y 5.54. La respuesta claramente es no. ERAs con mismo efecto de trayectoria (dirección y distancia fuente→sitio) parecen no responder a cambios en profundidad focal o magnitud, algunos otros espectros muy similares (numéricamente) provienen de epicentros muy lejanos con magnitudes separadas en más de dos unidades.

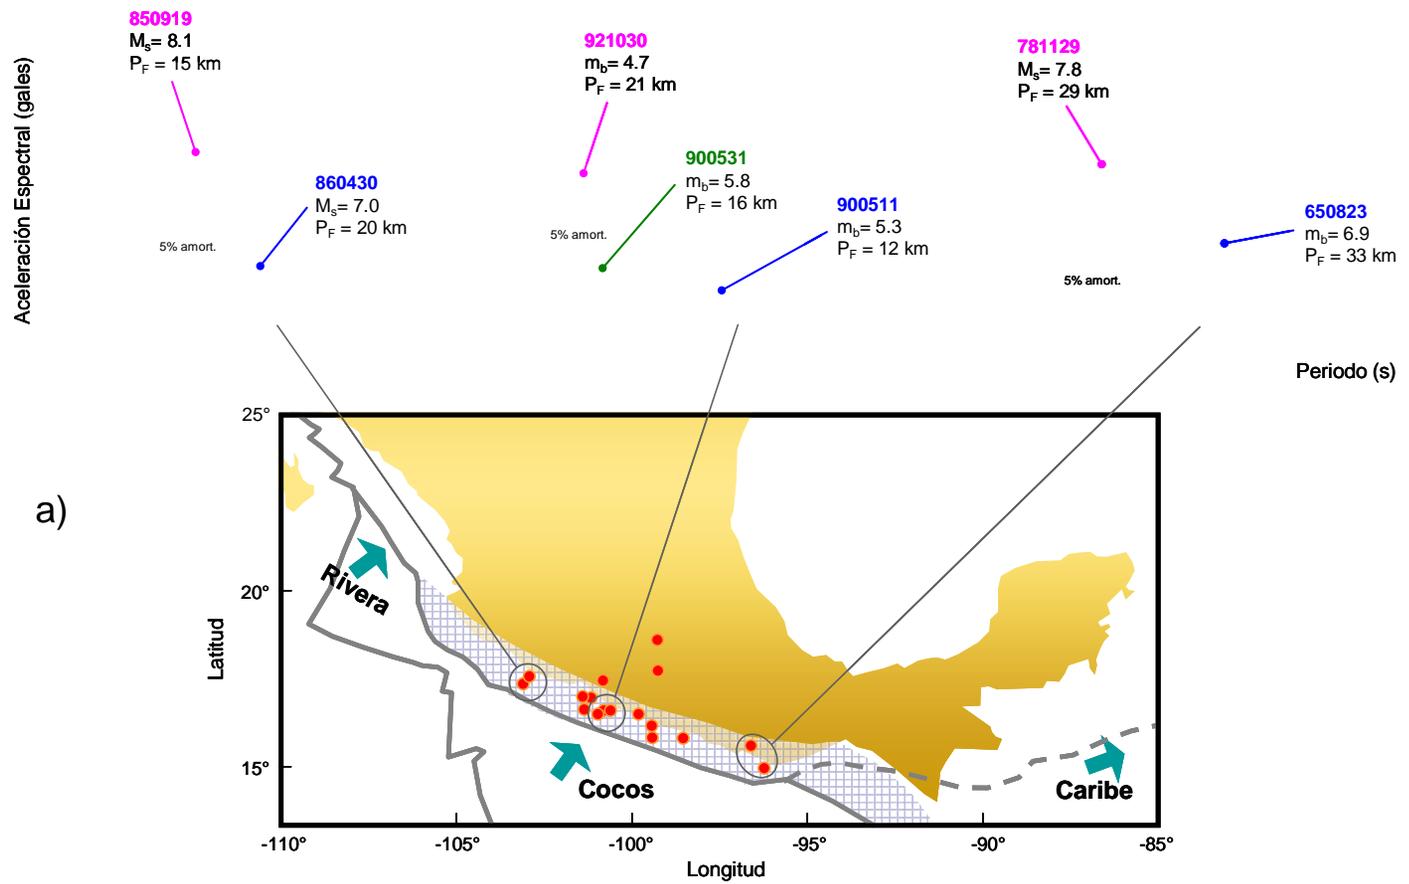


Figura 5.53 Algunos ejemplos de a) ERAs para sismos incluidos en la base de datos, CU-sitio en roca blanda

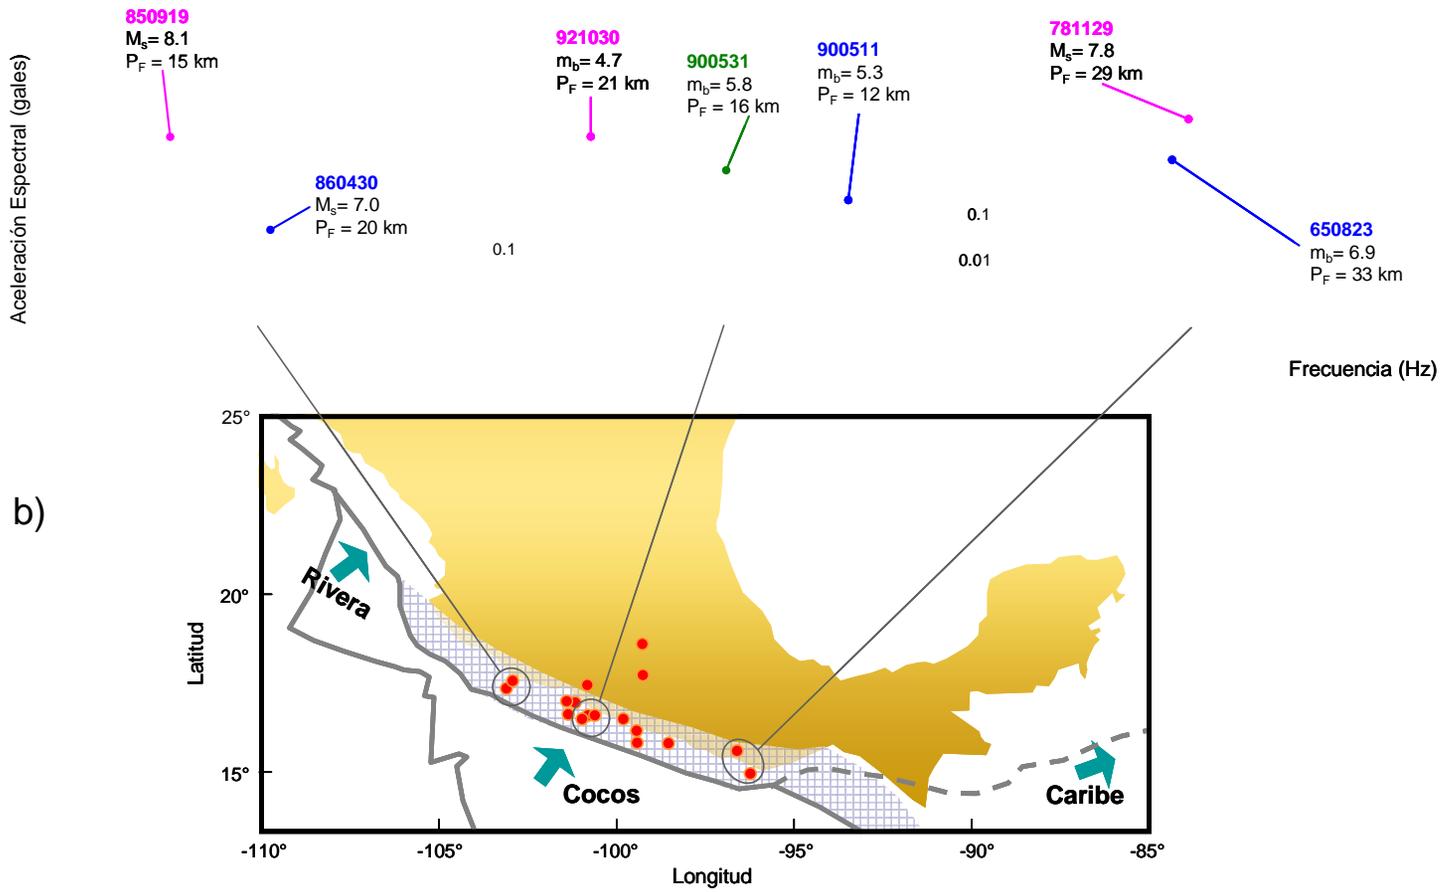


Figura 5.54 Algunos ejemplos de b) EAFs para sismos incluidos en la base de datos, CU-sitio en roca

Expresar cabalmente la tectónica mexicana (complejas señales no estacionarias producto de mecanismos *parcialmente* comprendidos) parece mucha responsabilidad para los ERAs de CU. En este trabajo de investigación se propone adicionar al vector (*T,OE*) información sobre la zona sismogénica, la magnitud, la profundidad focal y la distancia fuente-sitio para evidenciar características de cada historia de aceleraciones que pudieran estar enmascaradas por los ERAs.

Resulta indiscutible que éstas no son las únicas o las mejores variables para caracterizar comportamientos y respuestas sísmicas, incluso es imposible para un ser humano visualizar de qué manera se relacionan o integran con la información vectorial de un ERA y concluir acerca de su *real* utilidad, pero definitivamente la simpleza de estos parámetros en la interpretación del fenómeno sismo→movimiento es muy ventajosa y, como se demostrará posteriormente con las predicciones neuronales, resuelve eficazmente el problema de expresión de la demanda sísmica.

Entrada E-2. Tectónica de México TM.

Los grandes temblores en México ($M_s \geq 7.0$) a lo largo de la costa del Pacífico, son causados por la subducción de las placas oceánicas de Cocos y de Rivera bajo la placa de Norteamérica y por ello son conocidos como sismos de subducción (Kostoglodov y Bandy, 1994) (Fig. 5.55). El terremoto más grande que ha ocurrido en México en el presente siglo (Jalisco, 3 de junio de 1932, $M_s = 8.2$) ocurrió sobre la interfaz de la placa de Rivera y la de Norteamérica (Singh et al, 1985a) y muestra que una placa pequeña, joven y con una velocidad relativamente baja de subducción es capaz de generar grandes temblores.

Los grandes temblores también ocurren en el continente con profundidades de unos 60 km. (Fig.5.55, Zona generadora de sismos profundos). En este caso los temblores presentan un mecanismo de fallamiento normal que refleja el rompimiento de la litosfera oceánica subducida (Singh et al, 1985b). Son menos frecuentes pero se sabe que pueden causar grandes daños, ejemplos importantes son los sismos de Oaxaca -15/01/1931, $M_s=7.8$ -, el de Orizaba -23/08/1973, $M_s=7.3$ - y el de Huajuapán de León -24/10/1980, $m_b=7.0$ - .

En menor número se encuentran los temblores que han ocurrido dentro de la placa continental los cuales, dependiendo de su ubicación, han generado daños considerables en los asentamientos humanos ($M_s \geq 7.0$). Existe también lo que podría llamarse sismicidad de fondo, temblores con $M_s \geq 5.0$, cuyo origen no puede asociarse a ninguna estructura geológica en particular.

De acuerdo con lo expresado anteriormente, se pueden definir dos grandes zonas generadoras de sismos que afectan al valle de México: Zona de Subducción y Zona de Sismos Profundos. No se cuenta con un número suficiente de patrones (número de registros similar al de las otras zonas) generados en la placa Continental y debidos a la sismicidad de Fondo, además, considerando las incertidumbres que se tienen sobre los

mecanismos y su potencial de daño, los patrones cuyo epicentro los ubiquen en estas zonas se considerarán pertenecientes a la Zona de Sismos Profundos.

Entonces, es el epicentro del sismo el que dirige la declaración del nodo de clase *TM*. Cuando $TM = 0$ se trata de un epicentro en Zona de Subducción, en el caso de $TM = 1$ nos estamos refiriendo a un evento de la Zona de Sismos Profundos, Continental o de Fondo.

Entrada E-3. Magnitud M.

La magnitud (M_L, M_s, m_b, M_w , entre las más usadas) como dígito asociado a la cantidad de energía liberada o tamaño de un sismo tiene limitantes de aplicación bajo condiciones en el registro.

Es práctica común cuando se construyen relaciones para estimar aceleraciones de terreno que se elija alguna escala como base y a partir de ella los patrones (eventos) que por alguna razón no reporten el criterio seleccionado sean procesados para homogenizar magnitudes. Este proceso sobre *M* no repercute en mejoras a la expresión (caracterización) del tamaño del sismo (Huerta y Reinoso, 2002) sino que resulta de la búsqueda de mejores ajustes entre datos medidos y funcionales matemáticos. Para elegir la escala de entrada al esquema neuronal es necesario concienciar sobre la teoría que sustenta a cada alternativa.

La *magnitud*, teóricamente sin límite superior, está limitada por la resistencia de las rocas en la corteza terrestre y la longitud de ruptura *probable* en la falla. La magnitud local M_L , introducida por Richter, se determina a partir de la máxima amplitud registrada por un sismógrafo Wood Anderson. La magnitud de ondas superficiales M_s se basa en la amplitud máxima producida por las ondas superficiales Rayleigh. Debido a que M_s no aplica para sismos con profundidad focal mayor a 50 km (no se generan ondas superficiales con suficiente amplitud) fue creada la magnitud de ondas de cuerpo m_b basada en la amplitud de ondas de cuerpo con períodos cercanos a 1.0 s. M_s y m_b no reflejan adecuadamente el tamaño de sismos muy grandes pues subestiman su valor debido a la saturación de las escalas.

Reconociendo deficiencias en M_L, M_s y m_b se generó el concepto “momento sísmico” para designar el tamaño de un sismo en función directa de las propiedades físicas de la roca y de las dimensiones del área que sufre la ruptura. La magnitud de momento M_w , derivada del “momento sísmico”, es actualmente una de las escalas más usadas en estudios sísmicos. Las magnitudes de sismos *históricos* fueron recalculadas usando esta nueva escala y los cambios más notables se encontraron en sismos muy grandes, como el sismo de Chile de 1960 con una magnitud M_s de 8.3 y M_w de 9.5 convirtiéndose así en el sismo de mayor magnitud hasta hoy registrado.

Existe también la magnitud energía M_E que es una medida del potencial de daño a las estructuras y requiere del cálculo del flujo de energía sobre un amplio rango de frecuencias y la magnitud de duración M_d que es una variación del concepto de magnitud local que se emplea en algunas redes y es calculada con base en la duración del registro.

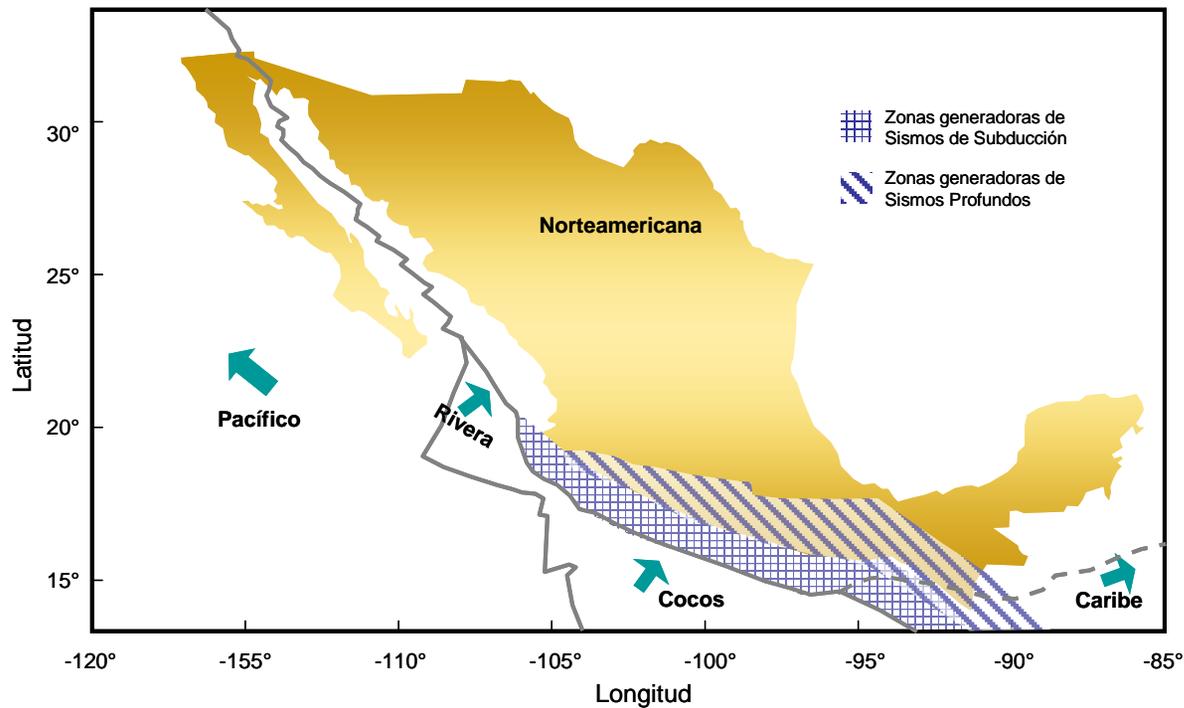


Figura 5.55 Grandes Zonas Sismogénicas de la República Mexicana

Con base en estas breves descripciones se puede concluir que i) existe una imprecisión inherente a todos los cálculos para obtener M , ii) cada escala cubre un aspecto importante del fenómeno pero ninguna hace uso del *conocimiento* en su totalidad y iii) la escala más usada y aceptada en la comunidad sismológica, M_w , es útil para *alejarse* a los sismos *extremos* de las densas nubes de eventos con intensidad *media*, donde la mayoría de las escalas reportan valores de M muy similares.

Por lo tanto podemos concluir que la *mejor* expresión para *medir* un sismo es aquella que sirva para los propósitos del modelo (*tarea*) y las transformaciones de escalas dependen exclusivamente de los criterios de ajuste numérico. M en un entorno neuronal puede ser expresada sin procesamientos, aprovechando las ventajas de las redes para trabajar en ambientes numéricos contaminados (incongruencias e indeterminaciones).

En esta investigación, considerando la naturaleza de la base de datos, se propone hacer uso del valor de magnitud más alto reportado en el acelerograma como una referencia *aproximada* de características

particulares de cada sismo. Para sismos de intensidad *media* la mayoría de los eventos contienen $M_L, M_s, o m_b$ y las diferencias entre ellas es de muy pocas décimas de punto y en el caso de eventos extremos se cuenta con M_w como el valor más alto reportado.

M neuronal es un dígito de clase con base numérica amplia. La RN identifica *individuos* tomando en cuenta las diferencias *importantes* o *sutiles* entre unidades de M . Las condiciones marcadas por las otras variables de entrada dirigen la ocurrencia de cierta M máxima. A diferencia de los funcionales tradicionales que persiguen congruencia entre M altas \rightarrow OE altas y M bajas \rightarrow OE bajas, en esta investigación, donde no se buscan leyes *no naturales* ni ajustar planteamientos subjetivos y *vagos*, se plantea tomar libremente el valor máximo de M y dejar que el *conocimiento* básico (expresado con las otras variables de entrada) sirva para que la red *aprenda* y genere las relaciones paramétricas sin hipótesis restrictivas.

Entrada E-4. Distancia Epicentral D_E .

En la literatura se pueden encontrar tantas maneras de medir la distancia fuente-sitio como funcionales sísmicos publicados. Esta medida (la distancia horizontal más cercana a la proyección vertical de la ruptura, la distancia más cercana a la superficie de ruptura, la distancia más cercana a la superficie de ruptura sísmogénica o la distancia hipocentral, por mencionar algunas) es, tradicionalmente, la manera como se expresa el fenómeno de propagación de ondas. Tal responsabilidad obliga a la definición, lo más cabalmente posible, de la dimensión de la fuente y la localización y profundidad epicentral.

En principio, con el tiempo, la estructura detallada 3D de la corteza terrestre podría ser conocida y un modelo de propagación de ondas podría ser determinado para cada fuente y sitio específicos, pero actualmente nuestro conocimiento y nuestra experiencia no nos permiten asegurar que los planteamientos sobre fuentes y epicentros están libres de incertidumbre. El argumento en el que se basa este trabajo de tesis para proponer la distancia fuente-sitio neuronal es que la variabilidad entre las relaciones de movimientos de terreno se debe al fenómeno de propagación de ondas y en ese sentido es mejor obviar cualquier descripción confusa.

En esta investigación se propone a la D_E , distancia calculada sobre la superficie de la Tierra entre el punto de observación y el epicentro del sismo (fácil de calcular, de interpretación simple y directa), como la descripción numérica *aproximada* del efecto de la distancia sobre el fenómeno de propagación de ondas sísmicas (Fig. 5.56).

Entrada E-5. Profundidad Focal P_F .

La profundidad focal es comúnmente usada como variable para etiquetar sismogénesis y su aplicación en regresiones se limita a marcador de clases. Para zonas de subducción, como la mexicana, 50 km es una frontera aceptada para separar sismos interplaca ($P_F < 50$ km) de los intraplaca ($P_F \geq 50$ km) (Tichelaar y Ruff, 1993; Youngs et al., 1997). Sin embargo, este tipo de límites son siempre motivo de discusión cuando se estudian fenómenos naturales: 49.9 km y 50.1 km pertenecen a sismogénesis distintas?. Una respuesta *inteligente* a este cuestionamiento involucra a P_F y al mismo tiempo a otros parámetros del fallamiento, por lo que declarar a P_F como nodo de clase genera planos que no expresan adecuadamente el fenómeno, lo que hacen es reducir la dimensión del problema a niveles manejables con herramientas matemáticas elementales.

P_F neuronal tiene la cualidad de nodo numérico. En esta investigación se considera que esta variable, en su forma *básica*, permite al modelo extraer mejores nexos paramétricos y no limita la flexibilidad conexionista. Diferenciar conjuntos (mecanismos de falla) a través de una frontera cerrada (50 km) no genera conexiones neuronales eficientes sino que agrega incongruencias a la expresión de cada evento.

La tripleta (TM, D_E, P_F) representa la información sobre la propagación de ondas permitiendo que (TM, M, [T,OE]) exprese la severidad y potencial de daño en la zona urbana del valle de México.

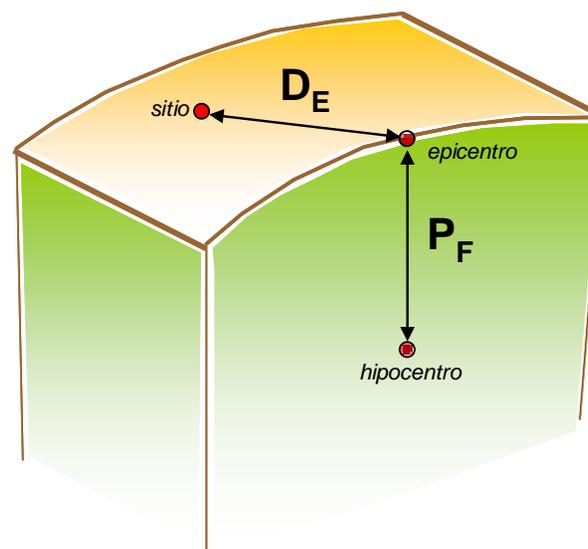


Figura 5.56 Parámetros de entrada directamente asociados a la geometría fuente-sitio

PARÁMETROS S

La influencia de las condiciones locales del suelo en la fuerza de la sacudida del terreno ha sido ampliamente reconocida como un factor que contribuye a la distribución geográfica de las fallas del terreno y daño estructural durante sismos. De particular interés es la amplificación de los movimientos de terreno y el progresivo ablandamiento de los suelos cohesivos (considerado comportamiento *no lineal*) durante sacudidas muy severas.

Registros obtenidos de eventos telúricos en todo el mundo han sido la base para estudios cuantitativos de la influencia de la respuesta del suelo en las características de los movimientos en términos de aceleración, velocidad, desplazamiento y amplitud espectral. Este tipo de estudios ha permitido definir un conjunto de factores (Tabla 5.3) como los operadores del desarrollo de movimientos significativos en cualquier rango de periodos.

Tabla 5.3 Resumen de factores que inciden sobre los movimientos debidos a sismos

SISMIOLÓGICOS	GEOLÓGICOS	GEOTÉCNICOS	OTROS
Intensidad de la sacudida, o entrada	Tipo (s) de Suelo (s)	Resistencia de los suelos a bajas deformaciones (velocidad de ondas de corte o máximo módulo cortante)	Efectos 2D y 3D (topografía de la sub-superficie de la base rocosa, efectos de cuenca)
Características frecuenciales del movimiento de entrada	Espesor del depósito de suelo	Contraste de resistencia (impedancia) entre el estrato rocoso y los suelos que lo sobreyacen	
Duración de los movimientos de entrada	Tipo de roca que subyace	Características de amortiguamiento de las unidades de suelo	
	Estructura geológica	Comportamiento degradante del módulo de corte dinámico de los suelos	
		Relación entre la deformación por corte y el esfuerzo cortante para unidades de suelo predominantes	
		Periodo del sitio	

En el caso de los depósitos de suelo de la Ciudad de México, estos factores se traducen en características locales de respuesta dinámica de estratos de arcillas blandas de alta plasticidad y compresibilidad alternadas por lentes más duras de arena, y una particular relación entre la disposición y geometría de estos estratos y la morfología de la cuenca (depósitos de arcilla muy delgados comparados con su extensión lateral). La observación cuidadosa de esta situación y la historia sísmica registrada, ha llevado a pensar que en la mayor parte de la Ciudad la respuesta dinámica del suelo puede ser estudiada por medio de la teoría de propagación unidimensional de ondas -1D- (Rosenbleuth, 1952; Herrera y Rosenbleuth, 1965; Seed e Idriss, 1969; Romo y Jaime, 1986 y Romo y Seed, 1986).

El razonamiento básico en la teoría 1D dicta que, cuando una falla rompe, las ondas de cuerpo viajan en todas direcciones reflejándose y refractándose en diferentes materiales geológicos y que debido a la diferencia entre las velocidades de propagación de ondas entre los materiales (en materiales poco profundos *generalmente* menores a las de los materiales más

profundos) los rayos inclinados que inciden en los contactos entre capas horizontales *normalmente* se reflejan hasta que en las inmediaciones de la superficie llegan a ser prácticamente verticales.

Después, es necesario concienciar sobre las siguientes hipótesis: i) todos los contactos entre capas de material son horizontales, ii) la respuesta de un depósito de suelo está predominantemente causada por la propagación vertical de ondas SH a partir del lecho rocoso que se extiende por debajo de las capas superficiales del terreno, iii) el suelo (homogéneo e isótropo) y el lecho rocoso son infinitamente extensos en la dirección horizontal y iv) los suelos pueden ser caracterizados como un conjunto de materiales o estratos elástico-viscosos por medio de su rigidez al corte, G , y su amortiguamiento, λ .

Con respecto al suelo, los parámetros de caracterización dinámica se consideran primero lineales y posteriormente se aproximan a la no linealidad mediante un proceso *equivalente* donde se buscan valores de (G, λ) compatibles con ciertos niveles de deformación $\gamma\%$.

En el caso de que el perfil del terreno tenga varios estratos de materiales diferentes (suelo estratificado), el proceso puede generalizarse resolviendo la ecuación de propagación de ondas para cada estrato con las condiciones de contorno, en los contactos entre ellos, de igualdad de desplazamientos y de tensión tangencial.

Mientras los modelos de suelo elástico, uniforme e isótropo son muy útiles para ilustrar la influencia de las condiciones del suelo en las características del movimiento del terreno, no son del todo útiles para el análisis práctico de los problemas de respuesta del terreno. Los problemas *reales* de respuesta normalmente consisten en depósitos de suelo con estratos de diferentes características de rigidez y amortiguamiento y con contornos en los cuales la energía de la onda elástica incidente puede reflejarse y/o transmitirse.

Así, después de esta breve revisión teórica del modelado *tradicional* de la respuesta sísmica debemos apuntar que, si bien nuestras actuales estimaciones representan una formidable cantidad de trabajo, meritorias aproximaciones intelectuales y significativos avances técnicos, todavía está lejano el día en el que podamos dejarnos seducir por el confort de nuestros, ahora, *familiares* argumentos y sentarnos a esperar a que la ciencia computacional desarrolle máquinas más veloces y poderosas. Una crítica científica podría argumentar que las más elaboradas de nuestras investigaciones no son más que *castillos de naipes* construidos sobre modelos simplistas con cimientos débiles anclados a relativamente pocas observaciones. Es claro que una postura así es muy radical pero convendría *equilibrar* y aceptar que se requieren *mejores* herramientas de análisis para un manejo *inteligente* de las observaciones (experiencia) si de lo que se trata es de avanzar en el conocimiento.

Mi percepción es que muchos ingenieros eluden la conclusión de que los procesos sísmicos tienen un alto grado de variabilidad y que nuestro conocimiento actual sobre ellos es muy incierto, por la manera en que somos socializados y entrenados como científicos para buscar siempre patrones en las observaciones. En esta investigación se propone mantener esta posición de búsqueda sin dejar de reconocer que el tipo de información, nuestro nivel de conocimiento y la *verdadera* capacidad de las actuales herramientas de análisis nos obligan a buscar alternativas para abordar el modelado de un fenómeno tan complejo como la respuesta sísmica.

Revisemos los aspectos referidos al suelo que deben tomarse en cuenta cuando se modelan respuestas de sitio. Como se observa en la Fig. 5.57 la mayoría de los parámetros de suelo reconocidos, por medio de la experiencia sísmica, con influencia en la magnitud de los efectos de sitio están relacionados con su aplicación en la teoría de propagación de ondas 1D.

Para responder a las hipótesis teóricas sobre los materiales y la propia naturaleza del fenómeno se incluyen características geométricas, de impedancia, resistencia, y comportamiento dinámico con traducción *incierto* a la respuesta observada en campo. En otros capítulos de esta tesis ya se ha abordado el problema de extrapolar condiciones puntuales a estratos de varios metros de espesor, las precauciones necesarias cuando se trabajan

parámetros obtenidos de pruebas in situ, y el debate sobre la linealidad o *casi*-linealidad del comportamiento dinámico de las arcillas de la Ciudad de México.

Se propone entonces concentrar la descripción de las características del suelo en las condiciones más *naturales* registradas numéricamente y obviar las variables derivadas de otros postulados de análisis.

El “tipo de suelo” y el “espesor del estrato”, a pesar de contener cierta subjetividad en su determinación, representan las variables más *básicas* de toda la columna (ver Fig. 5.57). Sin embargo, la determinación lingüística y numérica de estos parámetros contiene un alto grado de subjetividad.

La codificación establecida en el SUCS (Sistema Unificado de Clasificación de Suelos) representa un planteamiento bien organizado y una estructura de análisis muy clara, pero transportar estos lineamientos a materiales dispuestos masivamente en la naturaleza requiere de experiencia y estudios adicionales a las pruebas recomendadas en el propio Sistema. En el caso de estudios en la Ciudad de México hay quienes *prefieren* discretizar los depósitos en un mínimo de estratos y por otro lado, se han desarrollado análisis minuciosos que involucran un volumen importante de capas y propiedades. La definición de las fronteras estratigráficas así como de las propiedades promedio en cada capa repercute significativamente en los resultados finales de los análisis 1D. Antes de presentar la manera en que se expresará al *suelo* neuronalmente es necesario convenir en los siguientes razonamientos:

- a) Los registros en superficie contienen información de cada una de las capas, superficiales y profundas, que conforman un depósito.
- b) Inmersos en cada acelerograma están el espesor, material y número de estratos, las impedancias entre capas, las características dinámicas de las masas de suelo interactuando como miembros de una misma columna, la topografía que afecta al sitio e, incluso, aspectos de la propagación de ondas que no distinguimos en este tipo de historias de tiempo.
- c) Considerar todas las variables que intervienen en la propagación de ondas es prácticamente imposible si se intenta disgregar o reducir el fenómeno a unidades simples de análisis. En la aproximación neuronal se reconoce la relación espacial entre las historias registradas en todo el valle y se asocian en un planteamiento multidimensional.
- d) Dentro de este enfoque, las diferencias entre los ERAs registrados en un mismo sitio se deberán únicamente a factores sismogénicos y de directividad, de la misma manera, las diferencias entre los ERAs registrados durante un mismo sismo en sitios aledaños se refieren a condiciones de suelo y topografía particulares.

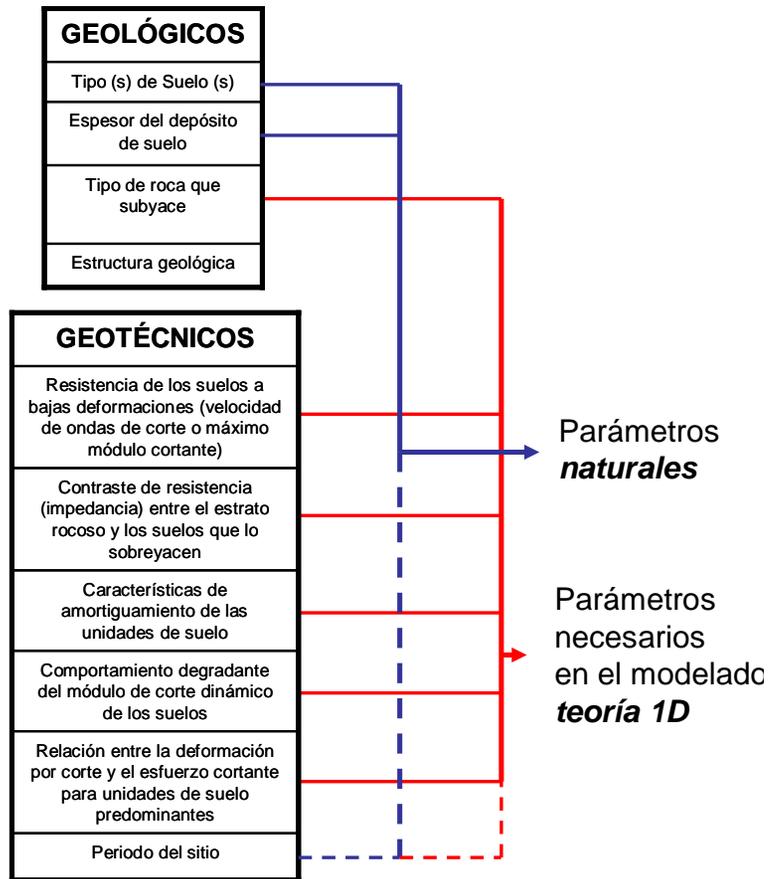


Figura 5.57 Factores relacionados con los suelos y que tienen influencia en los efectos de sitio

En la Fig. 5.58 se observa el resumen gráfico del planteamiento anterior. El **Sistema** lo conforman la cuenca y los suelos depositados. El monitoreo en un punto es parte de una respuesta global. En este modelo no se busca dar solución a la ecuación de propagación de ondas ni se pretende que el esquema neuronal sea una formulación *alternativa* a dicha ecuación.

La idea de modelado neuronal es *inductiva*, siendo la herramienta para inferir el fenómeno la red neuronal y las observaciones para lograrlo los registros sísmicos y algunas características de los depósitos de suelo.

Si el **Sistema** y las estaciones de monitoreo se mantienen, describir al suelo se reduce a caracterizar la situación de la estación dentro del **Sistema** (Fig. 5.59) dejando a un lado la controversial tarea de definir completamente el comportamiento de los suelos ante cargas dinámicas.

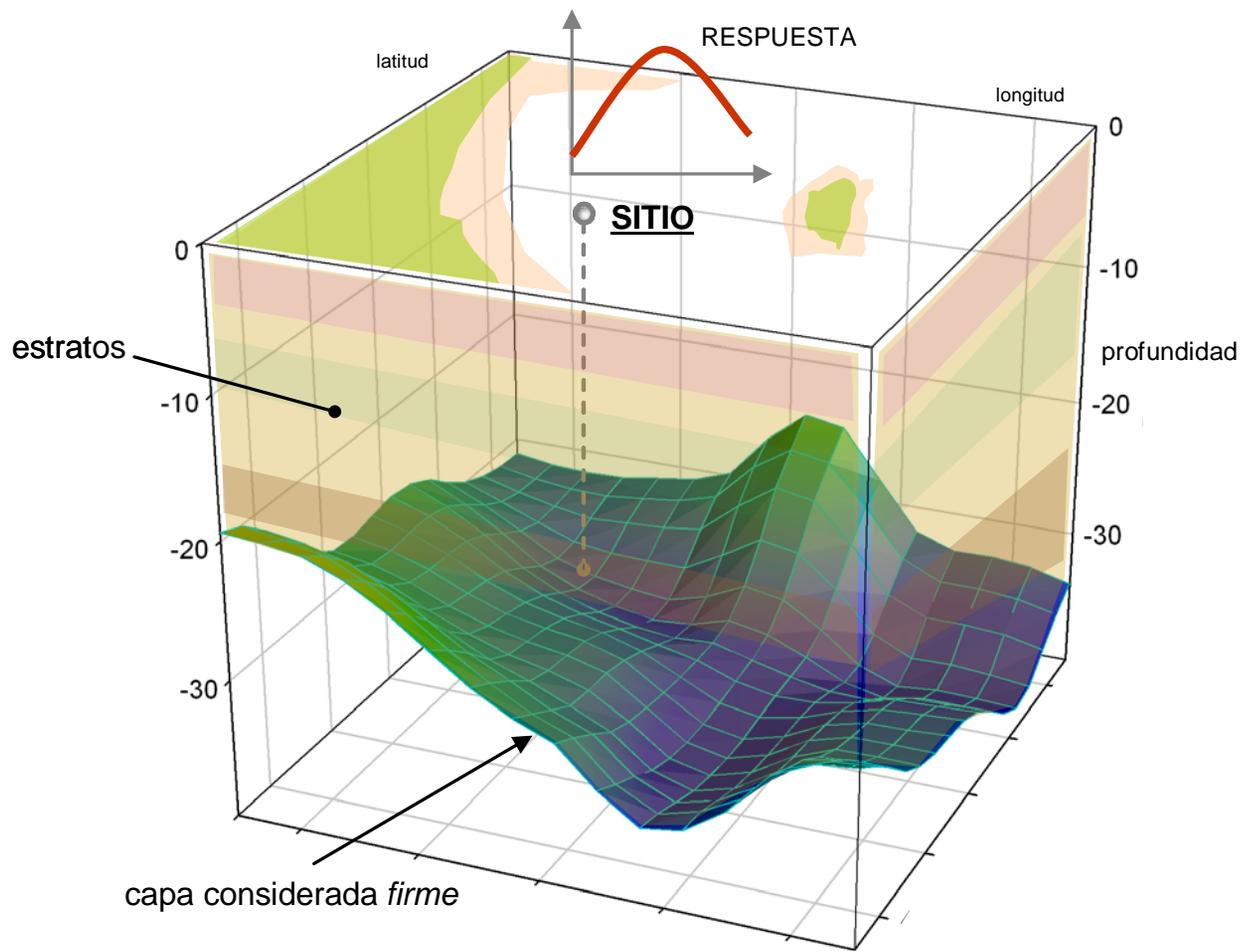


Figura 5.58 Resumen gráfico del Sistema

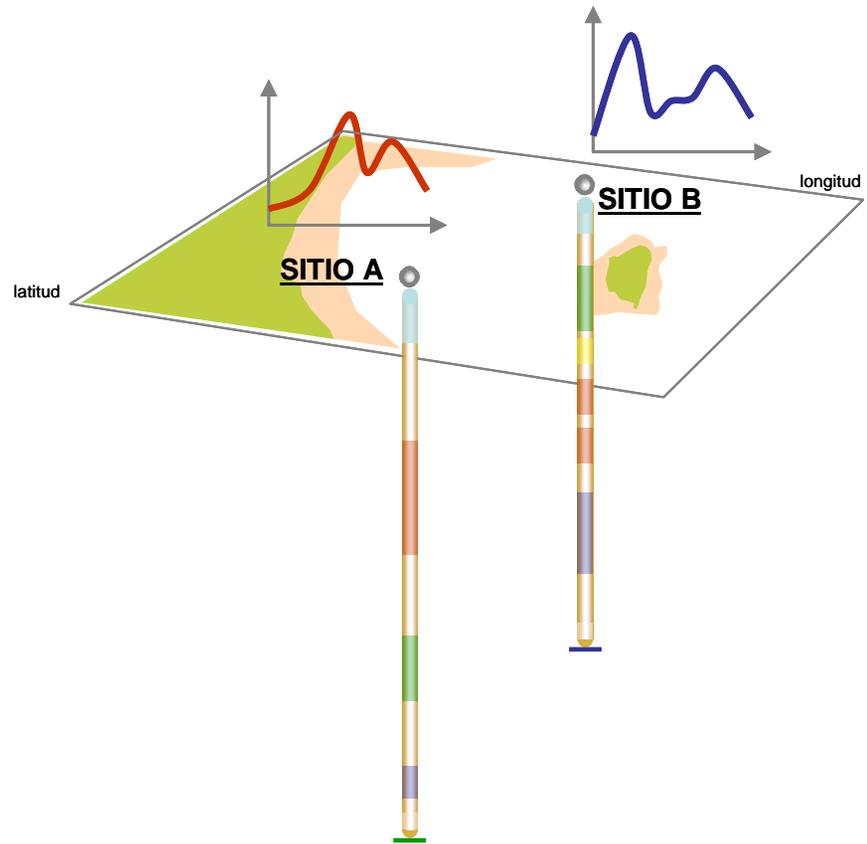


Figura 5.59 Representación de las respuestas medidas dentro del *espacio*

La propuesta de esta investigación es considerar la expresión del periodo fundamental proporcionada por el clásico modelo 1D de propagación vertical de ondas de corte $T_s = 4H/V_{S(P)}$ (H es el espesor del depósito y $V_{S(P)}$ la velocidad de onda de corte promedio) para caracterizar con variables *naturales* al depósito de suelo.

Es importante señalar que no es competencia de esta variable dirigir las respuestas espectrales máximas de la RN, estrictamente sirve para caracterizar con pocos dígitos la situación de las estaciones. De entre otros parámetros T_s se eligió porque i) el valor de H varía sobre el valle de acuerdo con (X,Y) , ii) $V_{S(P)}$, aún como parámetro promedio, da idea de la rigidez del depósito y su valor, por ser obtenido *in situ*, tiene referencia *espacial (Sistema)*.

Con base en estudios de campo y laboratorio que fueron desarrollados para evaluar la rigidez dinámica de los estratos de suelo se definieron los periodos de los sitios contenidos en la base de datos (Tabla 5.4) (Sarmiento, 2001; Lermo et al., 1988).

Algunos de los sitios de los enlistados en la Tabla 5.4 reportan el mismo valor de T_s lo que numéricamente para la RN representaría estaciones que, ante un mismo evento, generan una misma respuesta. Después de verificar en la base de entradas→salidas que esto no siempre, sucede se decidió cambiar el valor calculado por uno más *conveniente*.

La variación, como se observa en la última columna de la Tabla 5.4, se aplica a los decimales del periodo lo que no representa ninguna incongruencia fenomenológica (modificar *un poco* $V_{S(P)}$ o H generarían estos nuevos valores) y numéricamente incide en la creación de un ejemplo diferente. En la Fig. 5.60 se muestra la situación sobre la zonificación geotécnica de los sitios usados durante el entrenamiento de la RN.

Tabla 5.4 Sitios contenidos en la base de datos

Zona: Lago

No.	Clave (mapa)	Nombre estación	Lat (N)	Long (W)	T _s	T _s final
1	JC54 (54)	Jard de Coyoacán	19.313	99.127	1.20	1.20
2	MI15 (15)	Miramontes	19.283	99.125	1.30	1.30
3	DFRO (RO)	Roma	19.405	99.166	1.30	1.35
4	IB22 (22)	Ibero	19.345	99.130	1.40	1.40
5	CH84 (84)	Culhuacán	19.330	99.125	1.40	1.44
6	SI53 (53)	San Simón	19.375	99.148	1.40	1.48
7	SCT (SCT)	SCT	19.393	99.147	2.00	2.00
8	CJ03 (03)	CU Juárez	19.410	99.157	2.05	2.05
9	TL08 (08)	Tlatelolco	19.450	99.134	2.10	2.10
10	C105 (05)	Cibeles	19.419	99.165	2.10	2.13
11	TL55 (55)	Tlatelolco 2	19.436	99.143	2.15	2.15
12	RMA5 (RM)	Roma A Sup	19.420	99.155	2.20	2.20
13	GA62 (62)	Garibaldi	19.439	99.140	2.20	2.24
14	LI58 (58)	Liverpool	19.426	99.157	2.20	2.28
15	VG09 (09)	Valle Gómez	19.454	99.123	2.40	2.40
16	BL45 (45)	Balderas	19.425	99.148	2.40	2.45
17	RM48 (48)	Rodolfo Méndez	19.436	99.128	2.50	2.50

Zona: Lago

No.	Clave (mapa)	Nombre estación	Lat (N)	Long (W)	T _s	T _s final
18	HJ72 (72)	Hospital Juárez	19.425	99.130	2.60	2.60
19	XP06 (06)	Xochipilt	19.420	99.135	2.60	2.65
20	BO39 (39)	Bondojito	19.465	99.105	2.70	2.70
21	BA49 (49)	Buenos Aires	19.410	99.145	2.80	2.80
22	VM28 (28)	Villa del Mar	19.381	99.125	2.90	2.90
23	CA59 (59)	Candelaria	19.426	99.118	3.00	3.00
24	JA43 (43)	Jamaica	19.405	99.125	3.00	3.05
25	AP68 (68)	Apatlaco	19.381	99.107	3.10	3.10
26	AR14 (14)	Aragón	19.481	99.076	3.40	3.40
27	CDAO (CD)	Central Abastos Oficina	19.372	99.096	3.50	3.50
28	UNKS (UK)	Un Kennedy Sup	19.419	99.111	3.50	3.55
29	TLAS (TL)	Tlacotal Sup	19.397	99.105	3.60	3.60
30	DM12 (12)	Deport Moctezuma	19.431	99.096	3.60	3.65
31	ZARS (ZA)	Zaragoza Sup	19.419	99.088	4.00	4.00
32	HA41 (41)	Hangares	19.418	99.079	4.00	4.05
33	AU11 (11)	Autódromo	19.392	99.067	4.20	4.20

Tabla 5.4 Sitios contenidos en la base de datos

Zona: Transición

No.	Clave (mapa)	Nombre estación	Lat (N)	Long (W)	T _s	T _s final
1	CO47 (47)	Coyoacán	19.371	99.170	0.50	0.50
2	DR16 (16)	Deport Reynosa	19.501	99.183	0.55	0.55
3	COYS (CY)	Esta. 6 Coyoacán	19.348	99.169	0.60	0.60
4	EO30 (30)	Esparza Oteo	19.389	99.177	0.65	0.65
5	GR27 (27)	Granjas	19.475	99.180	0.80	0.80
6	ES57 (57)	Escandón	19.402	99.177	0.85	0.85
7	AU46 (46)	Ángel Urraza	19.383	99.168	0.85	0.88
8	ME52 (52)	Marianao Escobedo	19.438	99.182	0.90	0.90
9	DX37 (37)	Xotepingo	19.332	99.144	0.95	0.95
10	AO24 (24)	Alberca Olímpica	19.358	99.154	1.00	1.00

Modelo

En la Fig. 5.61 se muestra la propuesta de topología neuronal para estimar las respuestas en el valle. A pesar de los intentos por simplificar la representación numérica entradas→salida, la distribución de los ejemplos (un ejemplo es una respuesta en un sitio relacionada con un evento) se observa poco eficiente.

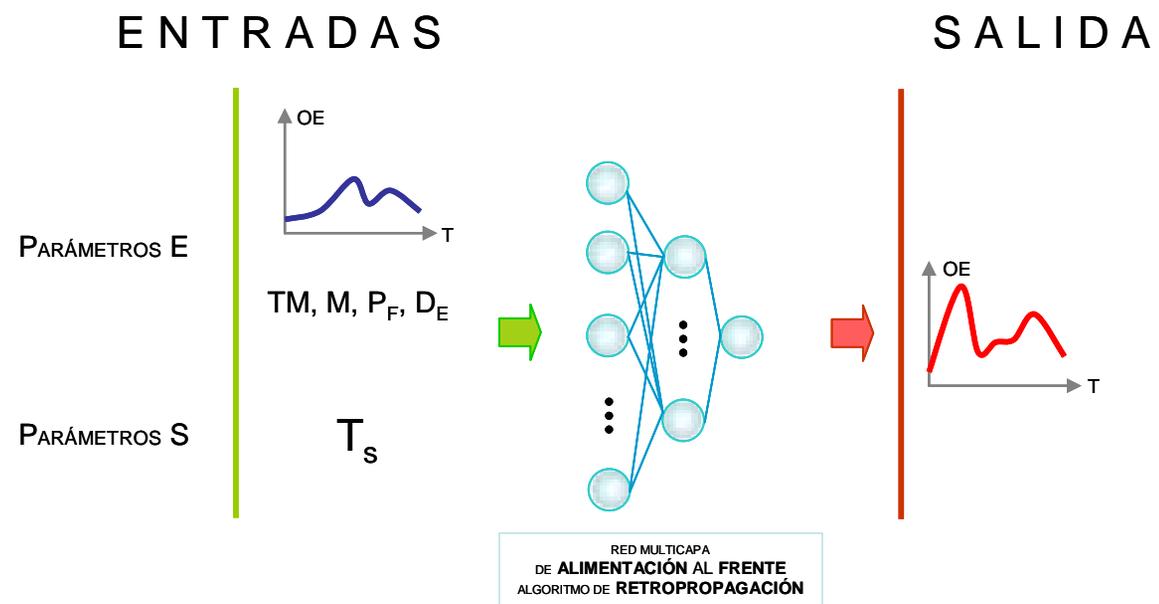


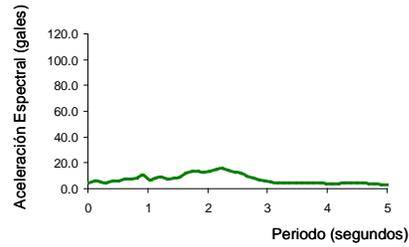
Figura 5.61 Esquema neuronal para la estimación de las respuestas en el valle de México

Observe la Fig. 5.62. Un ERA con 50 puntos ($\Delta T= 0.1$, desde $T= 0$ hasta $T= 5$ s) es un ejemplo compuesto de 50 líneas o patrones de comportamiento asociados al vector [TM,M,D_E,P_F] de valores numéricos constantes, durante el análisis de un mismo sismo.

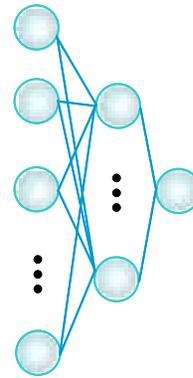
El vector T indica la longitud de cada ejemplo y asocia directamente los valores de acción→reacción (ordenadas espectrales de entrada y salida). El nodo casificador T_S, constante al analizar un mismo sitio, indica la situación en superficie.

En cada uno de los 43 sitios se cuenta con una historia sísmica registrada que genera cerca de 300 posibles ejemplos, por lo que espectros con 50 puntos generarían una base de datos con al menos 15000 líneas. Este acomodo (ERAs en columna) permite detallar las relaciones periodo a periodo pero acarrea un problema de dimensión.

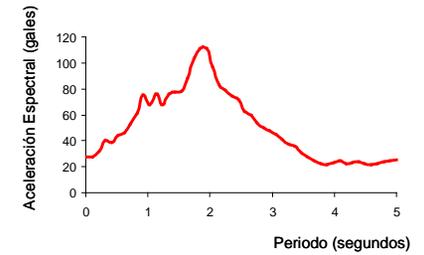
ENTRADAS



T	OE	T _s	TM	M	P _F	D _E
0.01	4.85	2	0	6.5	30	320
0.11	5.74	2	0	6.5	30	320
0.21	5.34	2	0	6.5	30	320
0.32	4.83	2	0	6.5	30	320
0.42	5.79	2	0	6.5	30	320
0.52	6.20	2	0	6.5	30	320
0.62	7.13	2	0	6.5	30	320
0.72	7.41	2	0	6.5	30	320
0.82	8.13	2	0	6.5	30	320
0.93	10.50	2	0	6.5	30	320
1.03	7.08	2	0	6.5	30	320
1.13	8.42	2	0	6.5	30	320
1.23	8.88	2	0	6.5	30	320
1.33	7.71	2	0	6.5	30	320
1.44	8.41	2	0	6.5	30	320
1.54	9.28	2	0	6.5	30	320
1.64	11.92	2	0	6.5	30	320
⋮						
4.39	4.40	2	0	6.5	30	320
4.49	4.56	2	0	6.5	30	320
4.59	4.29	2	0	6.5	30	320
4.69	3.80	2	0	6.5	30	320
4.80	3.56	2	0	6.5	30	320
4.90	3.29	2	0	6.5	30	320
5.00	3.01	2	0	6.5	30	320



SALIDA



OE _{sitio}
27.58
27.84
31.92
40.45
38.93
43.80
46.40
53.20
60.80
75.10
68.18
75.78
67.76
75.66
77.81
78.13
88.30
⋮
23.68
22.25
21.78
22.61
23.65
24.66
25.30

Figura 5.62 Representación de la demanda y respuesta sísmica: ERAs en columna

La tarea que se le asigna a la RN es encontrar, para cada conjunto que describe la acción de un sismo, las relaciones entre las ordenadas del ERA de control y las del sitio de análisis cuando de 6 entradas, el valor de 4 unidades permanecen constantes, un nodo funge como contador y sobre la variación del nodo OEcontrol reside principalmente el comportamiento de la OEsalida.

Ahora, comparando los conjuntos de un mismo evento registrado en diferentes sitios, éstos se componen de un nodo contador, cuatro unidades de entrada constantes (incluida la OEcontrol) y es T_s el nodo que se encargaría de describir dentro del esquema neuronal los cambios entre las ordenadas espectrales registradas en CU y las medidas en distintos puntos sobre la superficie del valle.

A pesar de los intentos por minimizar la complejidad del fenómeno *efecto de sitio* al emplear funciones lineales o cuasi-lineales para transferir la información registrada en roca hacia la superficie del terreno por medio de factores simplistas, las respuestas en suelos blandos son una tarea multidimensional y no lineal. Entonces habrá de reconocerse que, alimentar al modelo con sólo un nodo conductor de respuesta, a pesar de la robustez de las RNs, no corresponde al orden de complejidad de la tarea asignada.

Observe la Fig. 5.63. Los ERAs en renglón generan una base de datos con 55 unidades de entrada. Si cada línea, o patrón de comportamiento, es un ejemplo de una respuesta en un sitio debida a la acción de un sismo, entonces la base se compone de cerca de 300 líneas.

En esta representación el nodo T no es necesario si cada OE se ubica en una posición inamovible durante el modelado. $[TM, M, D_E, P_F]$ y T_s se colocan al lado de las posiciones espectrales y el mapeo se realiza hacia las 50 salidas que constituyen el ERA de respuesta.

Este acomodo, con la verdadera participación de todos los nodos para indicar variaciones en el ERA de salida, se vislumbra más adecuado. Sin embargo, la base de datos tiene características particulares que la hacen todavía muy compleja: i) la historia registrada no es proporcional en todas las estaciones, ii) el número de ejemplos resulta *corto* comparado con el número de entradas, y iii) el rango numérico de los Parámetros E y S no se cubre *ordenadamente* (pocos ejemplos de eventos extremos, gran población sobre la media).

Dentro de estas condiciones existe una constante y es el desequilibrio entre el despliegue de múltiple información en las entradas y el tamaño (en número de ejemplos) de la base de datos.

Con base en todo lo descrito anteriormente, se advierten claramente los aspectos conductores del modelo neuronal:

- NO se conoce la estructura matemática que relaciona al evento con la respuesta
- NO se puede afirmar sobre la suficiencia ni pertinencia de las variables que describen al fenómeno
- NO se extrae completa ni congruente información a través de ERAs vectoriales
- NO se representa, en la historia sísmica registrada, un vasto conjunto de combinaciones paramétricas.

En esta investigación estos puntos conforman el contexto de modelado y no, como en análisis lineales convencionales, se trata de obstáculos insolubles objetos de evasión.

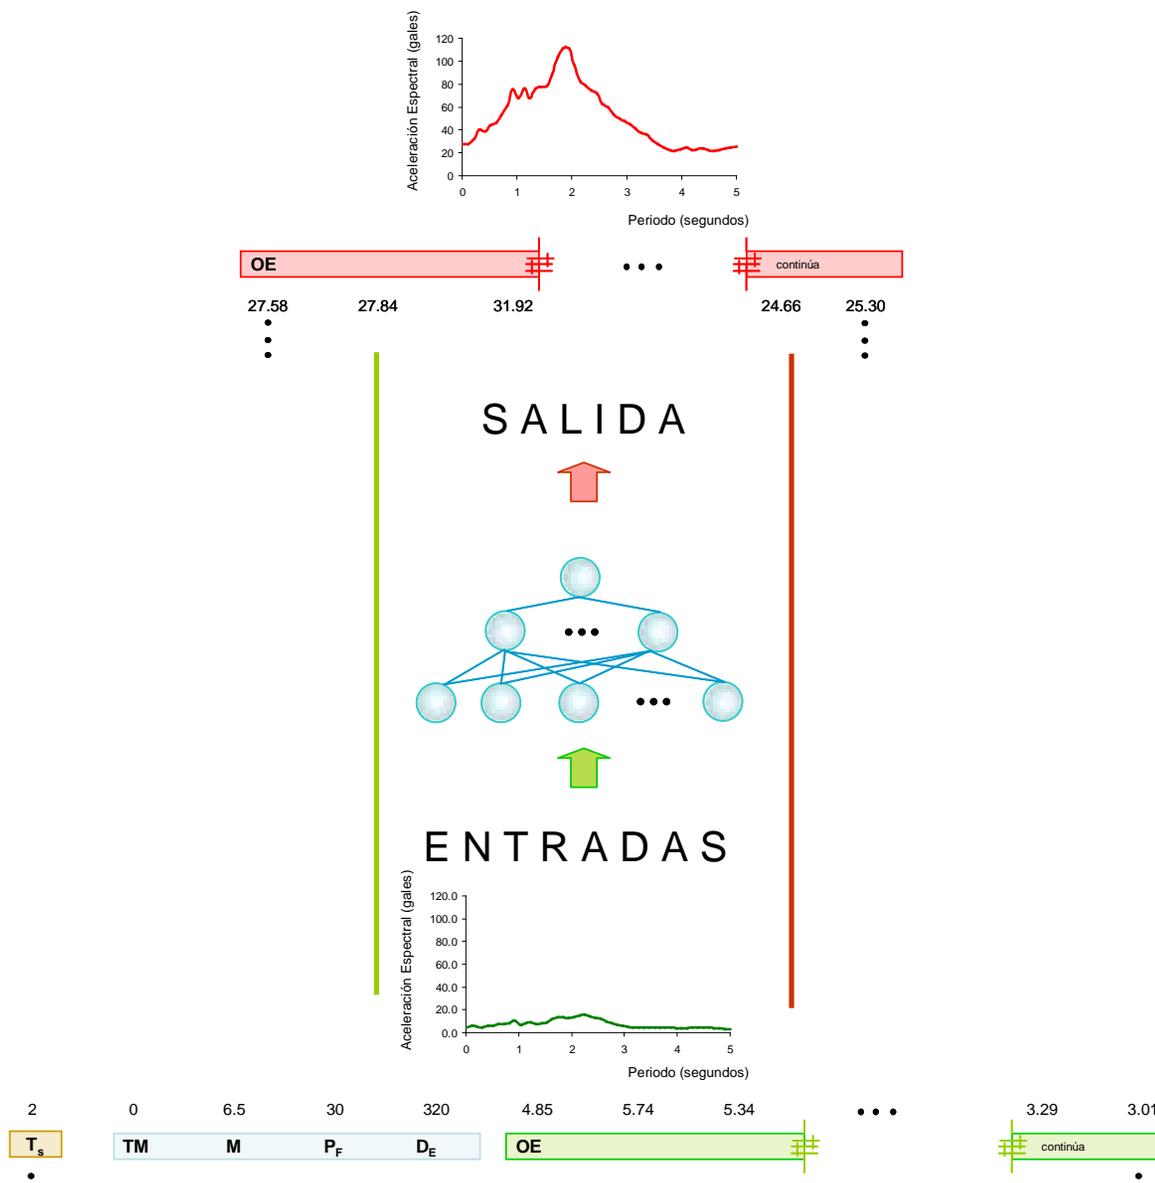


Figura 5.63 Representación de la demanda y respuesta sísmica: ERAs en renglón

- Pre-procesamiento de los ERAs

Los suelos, como sistemas reales, se caracterizan por un cierto número de estados coexistiendo y por la presencia de fluctuaciones. Sistemas de este tipo no deben ser resueltos analíticamente simplificándolos hacia sistemas lineales porque se estarían eludiendo las partes del sistema que interfieren, cooperan, compiten o interactúan de maneras muy complejas.

Aplicando la Teoría de Sistemas Dinámicos en el estudio de la respuesta sísmica de depósitos de suelo blando, en particular aplicando los Mapas de Recurrencia MR, se intenta extraer información relevante a partir de un análisis inverso: dada una respuesta monitoreada se dibujan sus trayectorias en espacios *convenientes* y a partir de ellas se encuentran las *soluciones geométricas* sin resolver las ecuaciones que gobiernan al propio sistema.

Para generar los MR de nuestro conjunto de datos experimentales el primer paso es reconstruir la dinámica embebiendo la serie de tiempo unidimensional (ERA) en el espacio de reconstrucción dimensional usando el método del retraso de coordenadas. Existen interesantes trabajos (Iwansky y Bradley, 1998) donde se demuestra que los MR de datos experimentales parecen ser independientes cuantitativa y cualitativamente de la dimensión embebida, por lo menos en términos de análisis geométrico de las estructuras que se despliegan.

En esta investigación se hará uso de la unidimensión porque precisamente se busca desplegar información geométrica de los sistemas de suelo y sus patrones de respuesta sin buscar contundencias sobre naturalezas aleatorias o deterministas.

En el cálculo de la distancia entre OEs se usa la máxima norma (en 1D la máxima norma es equivalente a la p-norma euclidiana) por su facilidad de implementación y la posibilidad de hacer comparaciones directas entre los MRs generados usando diferentes valores sin re-escalar los mapas.

Por cuestiones de espacio y dado que el entendimiento humano (*promedio*) no detecta patrones entre cientos de multiestructuras, sólo se muestran algunos casos representativos de la base de datos para establecer la lectura de un MR, la interpretación de las estructuras que despliega, y para tratar su introducción dentro de un contexto sísmico.

En la Fig. 5.64 se muestran las partes que componen un MR construido a partir de información de un ERA. Todos los MR construidos en esta tesis partieron de ERAs de 1000 puntos por lo que las imágenes son la expresión gráfica de matrices de 1000x1000 píxeles. En las ordenadas y abscisas se cuenta con 1000 posiciones donde se coloca el valor de la distancia entre puntos ij (para detalles vea el Capítulo 4).

Una vez que se tienen las diferencias referidas a cada posición ij se codifican con base en un esquema de colores en el que conforme se avanza de colores cálidos a fríos las distancias entre puntos se van haciendo mayores: inicia en BLANCO para valor nulo y culmina en NEGRO para la máxima distancia calculada. Cada MR cuenta con la misma barra de colores “espectral” cambiando sólo los valores acotados en sus extremos dependiendo de las amplitudes del ERA y las relaciones entre las máximas respuestas de osciladores de diferentes periodos.

Interpretación gráfica de un MR. Para mostrar las estructuras típicas en MRs de ERAs se muestran los MRs de los registros obtenidos en SCT, CDAO, Hangares, Balderas, Garibaldi, Candelaria y el sitio de *control* (CU-roca).

Cuando se exploran las estructuras desplegadas en un MR se deben verificar condiciones globales y particulares que en conjunto describen la *imagen* de la dinámica del sistema reconstruido. Ciertas características se identifican e interpretan de manera directa, como la homogeneidad para señales estacionarias o en sistemas puros estocásticos los agregados de puntos desestructurados.

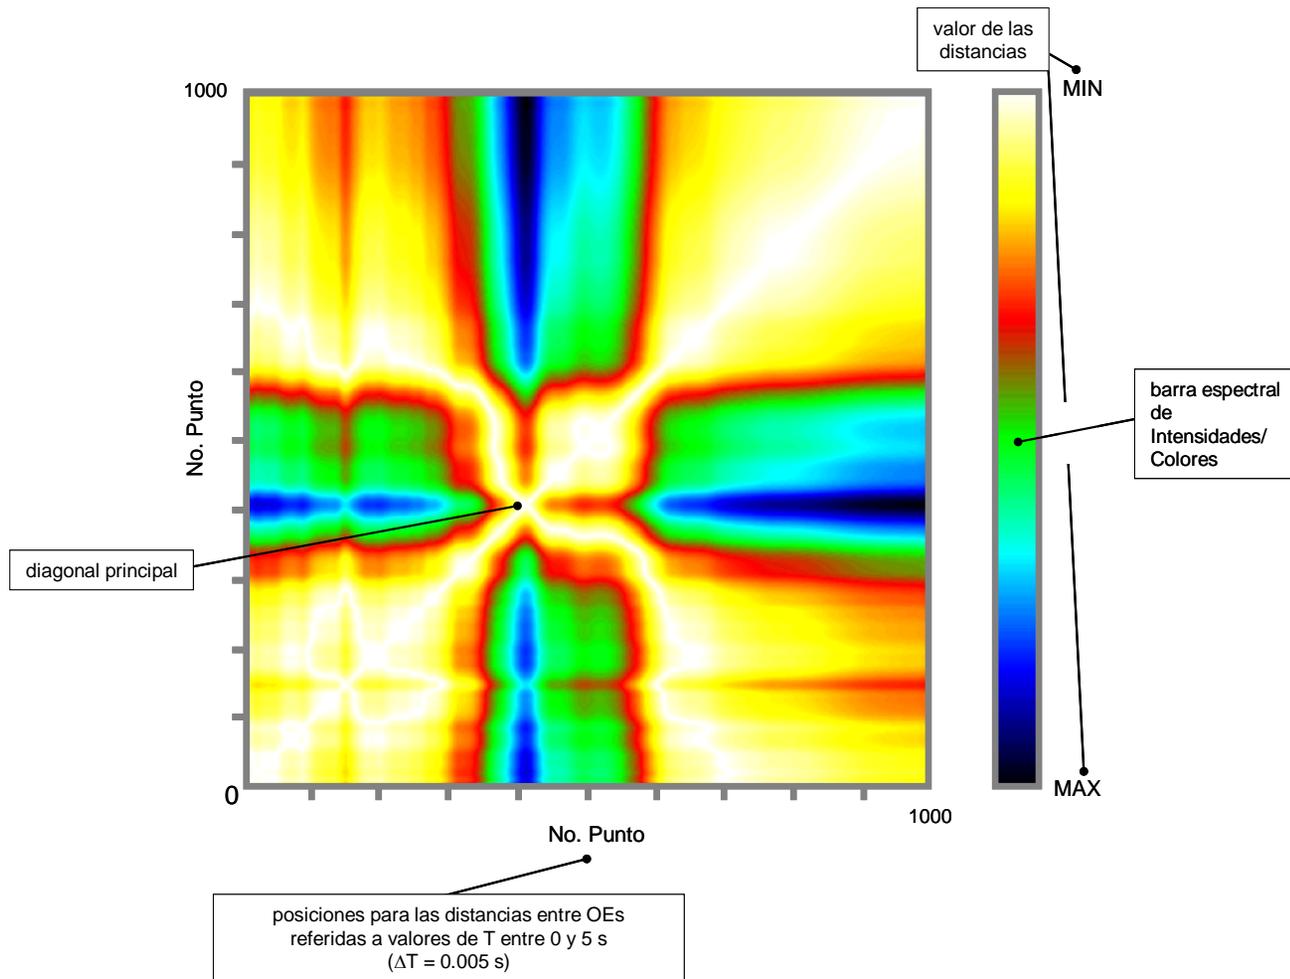


Figura 5.64 Componentes de un MR

Observe los MR mostrados en la Fig. 5.65. El MR en la posición (a.1) muestra un evento crítico definido por las amplias zonas claras que rodean una angosta banda bien localizada (línea oscura alrededor de la posición 250). Si transmutamos esta deducción hacia el significado de un ERA podemos decir que sólo un oscilador (con aproximadamente $T_s = 1$ s) responde de manera importante a la acción sísmica mientras que los otros estados (osciladores de otros periodos) no cambian o lo hacen muy lentamente.

En los MR mostrados en la Fig. 5.65 línea (b), se observan bandas oscuras (van del verde hacia el azul y negro) en las zonas donde el ERA presenta el máximo valor de OE.

Las bandas del MR en (b.1), centradas alrededor de la abscisa 900, representan la diferencia de comportamientos entre osciladores con periodo fundamental entre 1 y 3 s. En el caso (b.2) se pueden observar áreas blancas iniciales que indican poco movimiento de los osciladores con T_s menores a 2.5 s y un fuerte incremento de la respuesta para los osciladores con valores de T_s cercanos a los 4 s.

Activar las respuestas de osciladores con T_s altos generando una estructura en forma de “flecha” indica *tendencia* en el comportamiento que se ve acentuada por las áreas blancas en la esquina superior derecha (alrededor de la posición 750). Las bandas oscuras en el lado superior indican una posible desviación de los comportamientos de osciladores con $T_s > 5$ s.

El caso del mapa mostrado en la posición (c.1) muestra una banda fría (colores oscuros) delimitada por coordenadas horizontales [350-450] y rodeada de un área verde entre [300-500]. Esta *imagen* representa una fuerte diferencia entre las respuestas de los osciladores con periodos menores a 2 s y mayores a 2.5 s lo que puede llamarse un evento *severo* (sólo se observan mínimos cambios en los demás puntos).

Los mapas mostrados en la línea d, columnas 1, 2 y 3, muestran casos con grandes áreas blancas que significan periodos de estacionalidad, traducido a ERAs, amplios rangos de T_s donde no se aprecian cambios sustanciales en los patrones de respuesta, aunque debe apuntarse que las bandas oscuras en los extremos (fronteras del mapa) indican posibles desviaciones (pueden ser de importancia) del comportamiento promedio mostrado por los osciladores analizados.

Este tipo de MR muestra características especiales de ERAs, como fuertes *tendencias* (las flechas se marcan más sobre la diagonal principal, observe los colores claros) negativas (creciendo de izquierda a derecha), es decir, potentes máximos en los comportamientos de osciladores con periodos cercanos al origen y una tendencia a decrecer fuertemente hacia la zona extrema derecha, con el resto del mapa bastante homogéneo, lo que se traduce en estacionalidad.

Incluso los casos (d.2) y (d.3) asemejan el MR de una función *logarítmica* decreciente con signos de periodicidad enmascarados por el ruido entre las respuestas de todos los osciladores. En la Tabla 5.5 se presenta un resumen de las estructuras típicas y una interpretación física muy general.

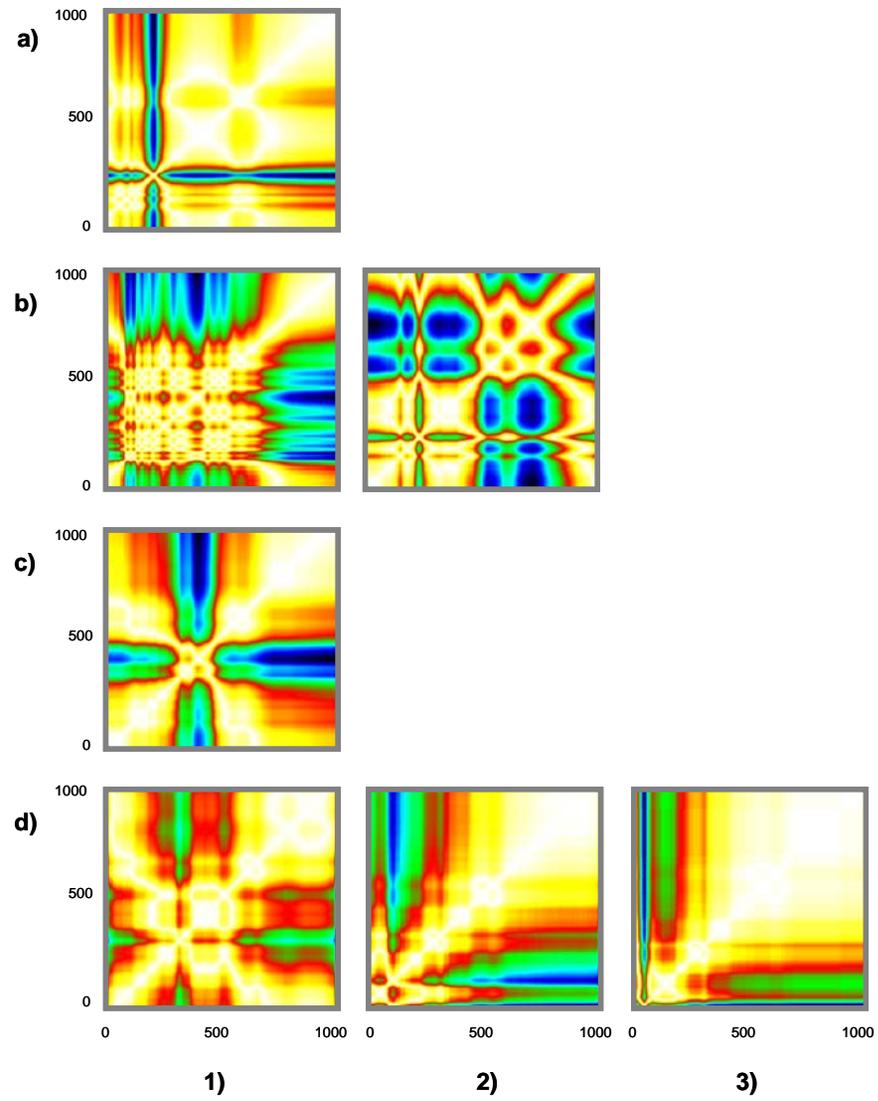


Figura 5.65 Ejemplos de estructuras de recurrencia mostradas por ERAs

Tabla 5.5 *Significado* general de un MR

CARACTERÍSTICA GEOMÉTRICA	INTERPRETACIÓN FÍSICA
Homogeneidad	Estacionalidad
Oscurecimiento desde las esquinas	No estacionalidad: desviaciones y tendencias
Bandas oscuras	No estacionalidad: algunos estados del sistema están lejos de la evolución media o pueden pertenecer a una transición
Patrones periódicos	Existen evoluciones cíclicas del sistema; la distancia entre patrones periódicos es el periodo
Puntos recurrentes aislados	Fluctuaciones rápidas del sistema que pueden ser aleatorias; de hecho el ruido blanco parece un conjunto de puntos aleatorios aislados
Líneas diagonales paralelas a la diagonal principal	La evolución del sistema es similar a diferentes tiempos; el sistema podría ser determinista
Líneas verticales u horizontales	Algunos estados del sistema no cambian o lo hacen muy lentamente

Entradas Sísmicas

Algunos ejemplos de los ERAs de entrada se muestran en las Figs. 5.66, 5.68 y 5.70. Para facilitar el manejo e interpretación de la información, los ERAs han sido separados de acuerdo con el valor de M generando las siguientes clases: sismos débiles ($M \leq 6$), sismos moderados ($6 < M \leq 7$) y sismos severos ($M > 7$). Los MR de estos movimientos de control (registros en CU) se presentan en las Figs. 5.67, 5.69 y 5.71. A continuación se presentan las consideraciones topológicas descubiertas a través de la expansión 2D y su relación con la noción básica de un vector ERA.

I. MR de sismos débiles (Figs. 5.66 y 5.67):

Sobre las estructuras y comportamiento de los estados (osciladores):

Común en todos los mapas es la presencia de bandas frías (verdes a azules) que parten de la esquina inferior izquierda indicando que algunos de los estados del sistema (osciladores con periodos menores a 1.2 s aproximadamente) están lejos de la evolución promedio o pueden corresponder a una transición. Las grandes áreas blancas en las esquinas superiores derechas pueden corresponder a periodos estacionarios (en un ERA significa que existen diferencias mínimas entre respuestas de osciladores con $T_s > 1.2$ s).

Las bandas azulosas en el inicio del MR (coordenada [0,0]) son típicas de desviaciones importantes entre estados por lo que se puede decir que durante sismos débiles, el comportamiento en CU es extremo en osciladores de periodos naturales muy cercanos a la unidad.

En los cinco MR, el área rojiza acotada por $Y = 200$, $Y = 250$ corresponde a mínimos muy profundos para osciladores de aproximadamente 2 s. Después de estos mínimos las OEs aumentan un poco pero los máximos ubicados en periodos menores a la unidad generan una flecha de tendencia (fuerte descenso del gradiente entre las respuestas conforme avanza el periodo) que se dibuja sobre la diagonal principal moviéndose hacia la esquina superior conforme la magnitud del sismo aumenta.

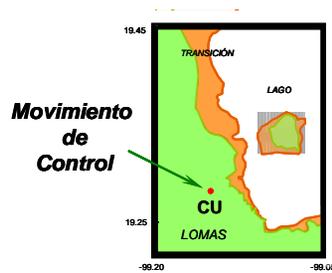
Sobre las características de los suelos y los sismos:

De acuerdo con la ubicación de los epicentros y la similitud de las estructuras mostradas en los MR de sismos débiles ($M \leq 6$) se puede asumir que los estados representados en estos movimientos de control son independientes de la sismogénesis.

El rango de las P_f y de aceleraciones máximas (A_{max}) en los acelerogramas del sitio CU cubiertos en este análisis, complementan la aseveración de que ERAs con intensidades bajas conforman sistemas con estados que siguen una especie de función logarítmica descendiente con una zona extrema localizada en periodos menores a los 1.5s. Esto es, los movimientos débiles en el sitio en roca afectan a los osciladores con T_s cercanos a 1s ($\pm 0.25s$) y los demás estados permanecen inalterados si se comparan con las respuestas máximas obtenidas para $T_s = 0$ s.

Si el sitio es el mismo (léase mismo depósito de suelo) y las magnitudes (interprete intensidades) entre los sismos son muy cercanas, entonces las diferencias estructurales de los MR ponen de manifiesto condiciones frecuenciales que afectan a la respuesta de los osciladores y que son muy difíciles de detectar a través de expresiones numéricas como los ERAs vistos en el plano XY.

Las descripciones anteriores y la información mostrada en la Fig. 5.66 permiten concluir que la escasa representación de un ERA podría ocasionar fuertes contradicciones en las respuestas estimadas si se reconoce que los modelos convencionales fundamentalmente modifican punto a punto el movimiento en la base a través de alguna simulación numérica.



A	B	C	D	E
930729 P _F : <5 km D _E : 266 km M _s = 5.0 A _{max} : 0.7 g	900511 P _F : 117 km D _E : 308 km M _s = 5.1 A _{max} : 1.6 g	880208 P _F : 19.2 km D _E : 291 km M _s = 5.5 A _{max} : 2.2 g	940523 P _F : 23 km D _E : 205 km M _s = 5.6 A _{max} : 4.5 g	930515 P _F : <5 km D _E : 326 km M _s = 5.8 A _{max} : 1.44 g
Periodo en s	Periodo en s	Periodo en s	Periodo en s	Periodo en s

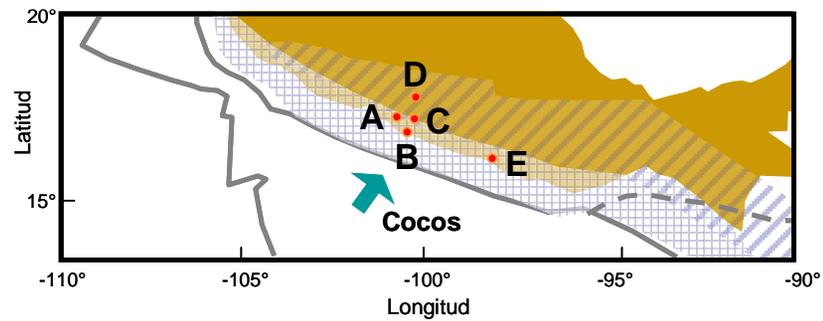


Figura 5.66 Ejemplos de ERAs en CU, sismos débiles

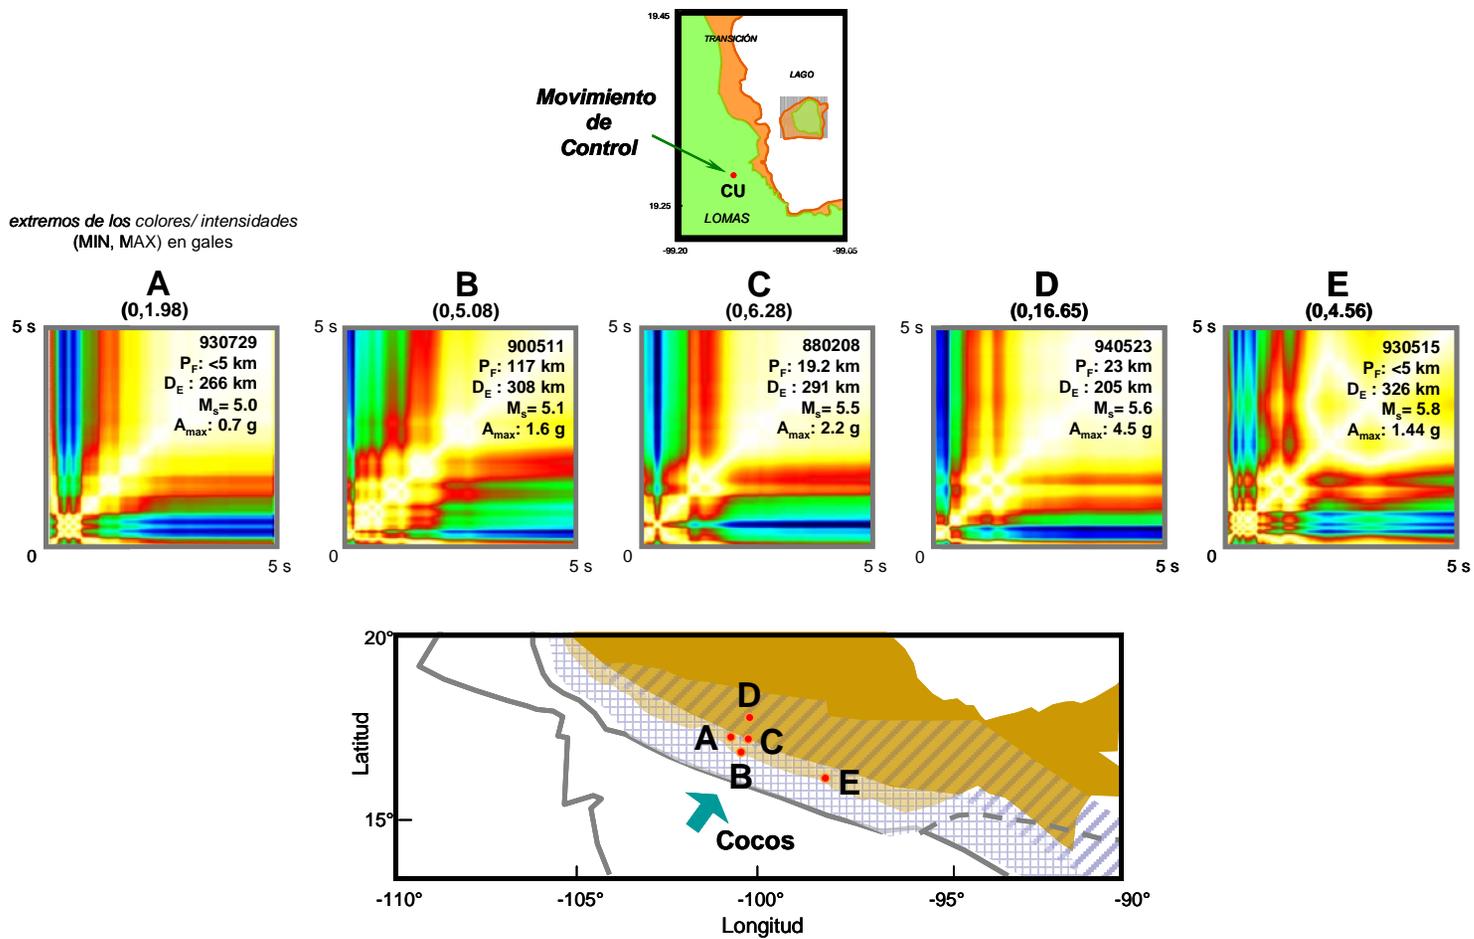


Figura 5.67 Ejemplos de MR en CU, sismos débiles

II. MR de sismos *moderados* (Figs. 5.68 y 5.69):

Sobre las estructuras y comportamiento de los estados (osciladores):

Los estados representados en estos MR apuntan hacia la activación de un mayor número de osciladores para cada evento. Las bandas frías (verdes a azules) se localizan ahora desde $T=1$ s y hasta $T=3$ s. El ancho de las bandas indica el rango de periodos fundamentales donde el comportamiento se dispara del que se presenta en $T_s = 0$.

Las transiciones entre estados son menos abruptas y ahora los cambios de colores fríos a cálidos muestran mayor importancia de los tonos rojizos. Las zonas de mínimos profundos no pueden ser localizadas fácilmente como en el caso de los MR de sismos *débiles*, la mayor parte de las zonas “claras” se concentran sobre la diagonal principal.

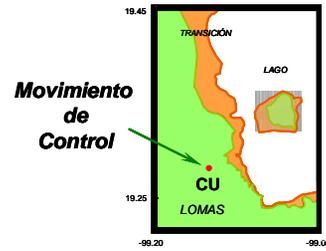
No hay tendencias (*flechas*) ni se presentan bandas de desviación de comportamientos, los mapas lucen más homogéneos que los de los sismos *débiles*. Los MR de los sismos A, B y D exhiben una cierta periodicidad local (observe la trama de cuadros en el extremo inferior izquierdo) lo que puede traducirse como evoluciones de comportamiento sin extremos y con amplios rangos de T (estados) donde las respuestas difieren poco entre ellas, haciendo sólo evidente el cambio respecto a la respuesta del oscilador en $T=0$ s.

Sobre las características de los suelos y los sismos:

Las estructuras en los MR con magnitudes *moderadas* difieren claramente de las obtenidas en sismos *débiles*, incluso para sismos con epicentros muy cercanos (compare MR *débil*-B con MR *moderado*-E) lo que permite concluir que el efecto de la *intensidad* en la respuesta monitoreada en el sitio de *control* CU es más evidente que el de la sismogénesis.

Los periodos donde se ubican las OEs más altas en los espectros deben coincidir con las zonas o líneas más oscuras en cada mapa, entonces para este sitio en roca no se puede hablar de un periodo fundamental en el sentido estricto del término ya que los sismos con intensidades *bajas* dibujan estados con el evento extremo en $T < 1.5$ s mientras que para los sismos *moderados* las OEs máximas se localizan entre 1.25 s y 2.5 s.

Ya no se pueden encontrar relaciones entre los MR a simple vista, el incremento de la intensidad parece complicar las geometrías y su relación con los parámetros sísmicos reconocidos. Si esto se acepta, se puede decir entonces que conforme la intensidad y por tanto la complejidad de los comportamientos crecen, la posibilidad de predecir la respuesta de los osciladores ante eventos “distintos” a través de relaciones “directas” entre vectores ERAs, disminuye.



A	B	C	D	E
941210	931024	940314	990615	890425
P_F : 20 km	P_F : <5 km	P_F : 95 km	P_F : 92 km	P_F : 19.0 km
D_E : 290 km	D_E : 321 km	D_E : 770 km	D_E : 220 km	D_E : 304 km
M_s = 6.3	M_s = 6.5	M_s = 6.5	M_s = 6.7	M_s = 6.7
A_{max} : 5.9 g	A_{max} : 4.1 g	A_{max} : 0.6 g	A_{max} : 11.85 g	A_{max} : 10.3 g
Periodo en s	Periodo en s	Periodo en s	Periodo en s	Periodo en s

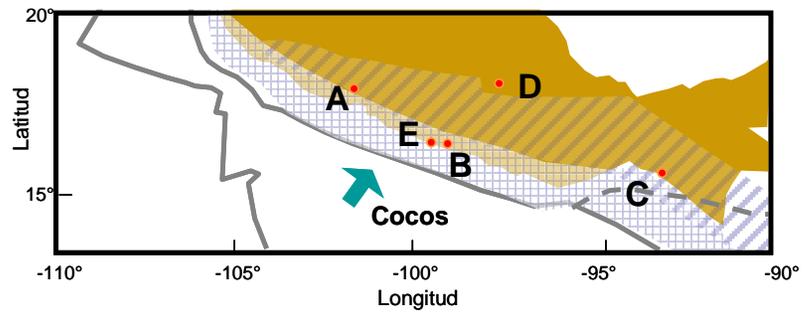


Figura 5.68 Ejemplos de ERAs en CU, sismos moderados

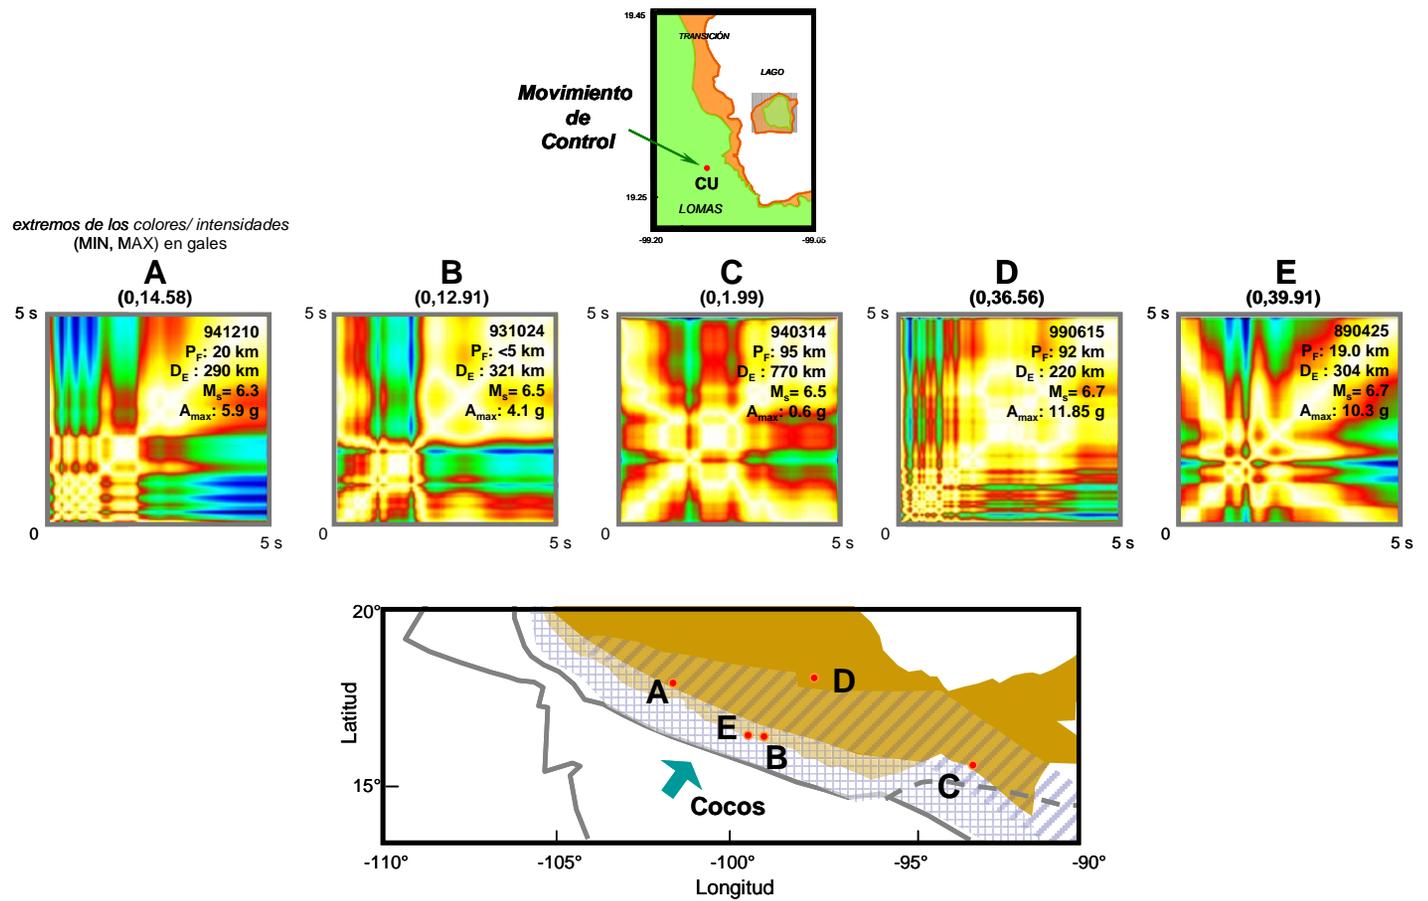


Figura 5.69 Ejemplos de MR en CU, sismos moderados

II. MR de sismos *severos* (Figs. 5.70 y 5.71):

Sobre las estructuras y comportamiento de los estados (osciladores):

Las transiciones ya no son abruptas y no existen zonas de mínimos, las zonas “claras” se concentran sólo en la diagonal principal.

Sin la presencia de bandas de desviación de comportamientos los mapas lucen homogéneos. En periodos menores a 2.5 s se distinguen tramas de cuadros que se traducen como periodicidad local.

Los estados representados exhiben estructuras similares a las desplegadas en MR de eventos *moderados* con un ligero aumento del rango de periodos donde se localizan las bandas frías (verdes a azules). A simple vista no se distinguen diferencias importantes entre colores y geometrías entre sismos *moderados* y *severos*.

Sobre las características de los suelos y los sismos:

Debido a las similitudes entre las estructuras de los eventos *moderados* y *severos* no es posible abundar sobre detalles del comportamiento del sitio pero se pueden extraer algunas particularidades sobre los sismos considerados *extremos*.

El ERA del 97/01/11, con casi la totalidad del MR en tonos blancos/amarillos, no muestra diferencias entre las respuestas de los osciladores. Es notoria la presencia de un máximo puntual (semejante a un pequeño pulso), abrupto y carente de sentido si se le compara con los MR B,C y D. Un mapa como el A se relaciona con un ERA-línea horizontal, lo que resulta especialmente importante si este sismo es usado para el cálculo de funciones de transferencia o relaciones de amplificación.

Las estructuras en C y D, semejantes a algunas obtenidas para sismos *moderados*, están constituidas por una especie de *meseta* contaminada por ruido. Se observan amplias zonas verdes con intercalaciones delgadas de tonos rojizos que significan un conjunto de osciladores con el mismo nivel de respuesta y ligeras diferencias entre valores intercalados de T , diferencias que pueden adjudicarse a una componente ruidosa más evidente en sismos *severos*.

Hablando de la unicidad del sismo del 19 de septiembre de 1985, en la literatura se ha señalado que éste tuvo características de intensidad y temporo-frecuenciales *extremas* o muy distintas a las registradas en la historia reciente del valle de México. El nivel de respuesta en el MR-1985, en términos de amplitudes espectrales, marca el *extremo* numérico de la base de entradas (OE_{maxima} alrededor de 130 gales) con valores promedio de 7 gales para sismos *bajos*, 20 gales en *moderados* y del orden de 30 gales en los demás sismos *severos*.

Sin embargo el MR de la respuesta registrada en CU (entrada o movimiento de control), que debiera describir geoméricamente la hipótesis de unicidad, es similar (en términos de respuestas o estados) al de un sismo *moderado* de la zona de subducción alejado del epicentro del sismo de Michoacán por varios kilómetros (Fig. 5.72).

En los dos MR mostrados en la Figura 5.72, se mantienen activados los mismos osciladores (desde 1 s hasta más allá de 2.5 s) y las franjas rojizas aparecen con similar participación. La única condición *extrema* que se observa es la intensidad. Esta similitud señala que el ERA del sismo del 85 muestra efectos sobre *estados* que ya se habían, y se siguen presentando, bajo la acción de sismos de magnitud *moderada*.

La única distinción topológica de este sismo es su *tendencia*, el MR del 85 presenta una *flecha* positiva ($X= 1s/ X= 2.5s$). Las OEs de este mapa son las únicas con *tendencia* de crecimiento, el resto de los sismos en la base de datos dibujan máximos por debajo de los 2 s y decrecen con una ley muy similar a una logarítmica descendiente.

La emisión de energía anormalmente alta desde la fuente, los efectos de trayectoria y la mínima atenuación que sufrieron las ondas sísmicas propagadas hasta la Ciudad de México son aspectos que no se pueden estudiar únicamente bajo las características del MR en CU, así que lo particularmente importante a tomar en cuenta dentro de este modelo es que el MR del 850919 expresa características geométricas contenidas en la historia sísmica en CU y la variante extraordinaria es únicamente la *intensidad*, las respuestas obtenidas debido a la *modificación* de esta entrada deberán ser explicadas bajo esta perspectiva.

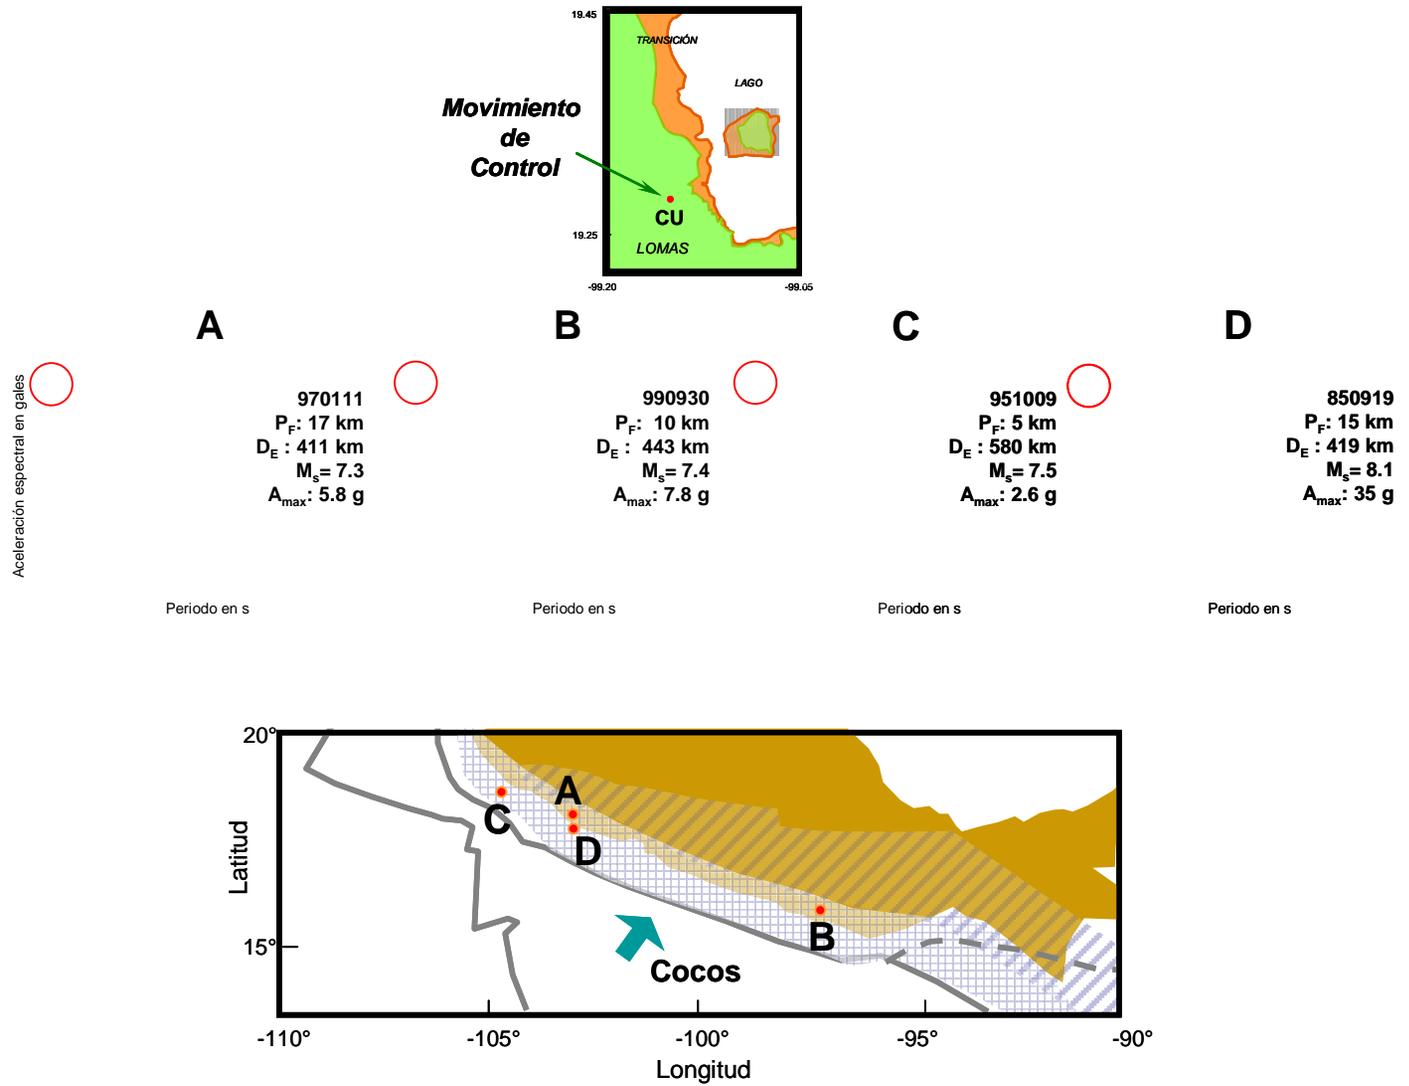
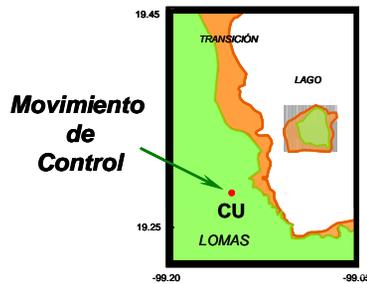


Figura 5.70 Ejemplos de ERAs en CU, sismos *severos*



extremos de los colores/ intensidades
(MIN, MAX) en gales

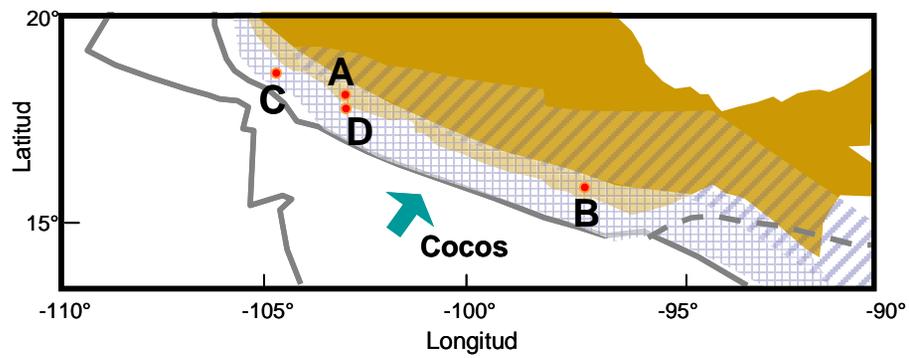
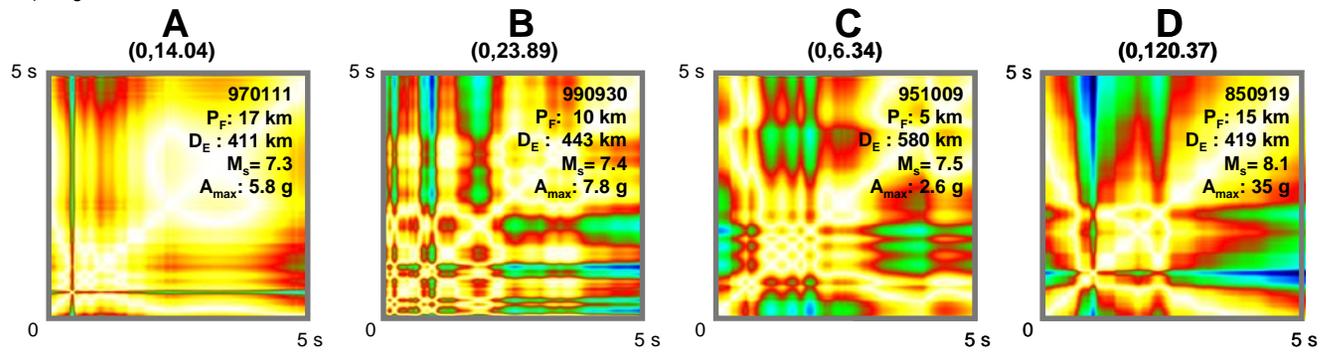


Figura 5.71 Ejemplos de MR en CU, sismos *severos*

extremos de los colores/ intensidades (MIN, MAX) en gales

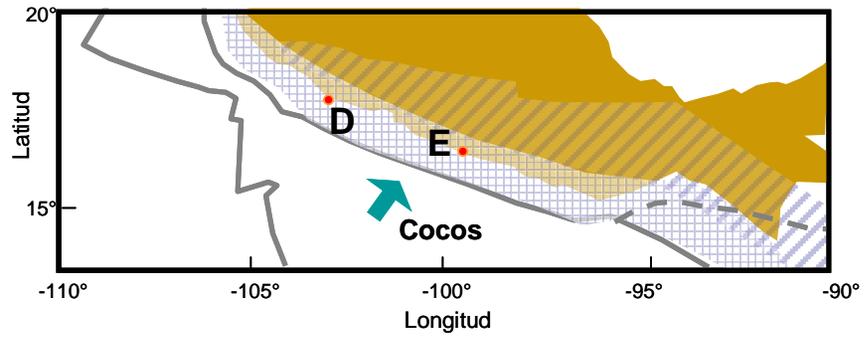
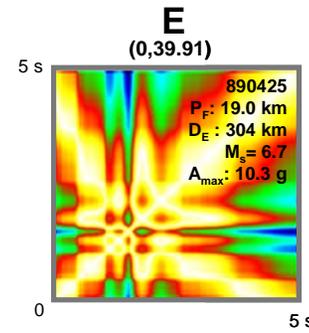
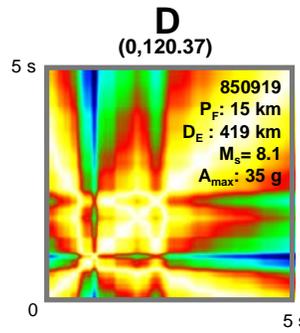
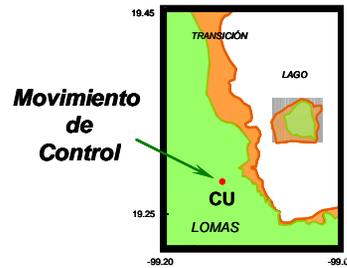


Figura 5.72 Comparación de geometrías en el MR de CU para el sismo más severo, 850919

Salidas: Respuesta en sitio

Los ERAs de los sitios estudiados (vea Tabla 5.2) han sido expandidos hacia sus MR de tal forma que se obtenga coherencia entre la información sobre los sismos y los comportamientos de los depósitos de suelo.

Las conocidas observaciones sobre los suelos de la Ciudad de México, como periodos dominantes del suelo de hasta 5 segundos, factores de amplificación hasta de 50 en espectros de amplitudes de Fourier y entre 10 y 15 en términos de aceleraciones espectrales (con 5 % de amortiguamiento) y un gran efecto de interacción suelo-estructura están contenidos en los MR que se obtuvieron.

Una tarea formidable resultaría desplegar en este trabajo de tesis el total de los MR de manera que quedaran descritas cada una de las particularidades de los suelos debajo de las 33 estaciones acelerográficas, por lo que sólo se eligieron algunos sitios que, de acuerdo con su periodo fundamental y ubicación, representen ejemplos gráficos de respuestas típicas.

Se recuerda que el papel de T_s en el modelo neuronal es de caracterización espacial. Se advierte al lector que su valor numérico no significa lo que en la teoría 1D de propagación de ondas. En esta investigación únicamente sirve para definir la situación de una estación. Por medio de un número reglamentado (curvas de isoperiodos publicadas en el Reglamento de Construcciones del Distrito Federal) y de amplio y fácil manejo en análisis y diseño, se relaciona la ubicación geográfica con las condiciones generales del depósito al tiempo que se genera un nodo espacial de extrema simpleza.

El mismo criterio de generación de conjuntos (valor de M) usado en los MR de entrada es empleado en la presentación de los eventos registrados en cada sitio. Las siguientes descripciones intentan abundar sobre las características de respuesta de los depósitos y cómo se identifican en las topologías desplegadas.

Sitio: **Secretaría de Comunicaciones y Transportes SCT**

T_s : 2.0 s

En la Fig. 5.73 se observan los MR construidos de registros con magnitud menor a 6 grados. Se distingue claramente el máximo valor de OE sobre la línea del T_s . Si se comparan las estructuras de los sismos *débiles* con las mostradas en la Fig. 5.74 para sismos de magnitud *moderada*, se reconoce que no hay cambio sustancial entre los osciladores activados en ambos rangos de intensidades.

Sobre la geometría global de los MR *moderados*, aparecen unas líneas verticales y horizontales alrededor de los 1.2 s que concuerdan con el segundo modo del sitio SCT. El ancho, pero sobre todo, la intensidad de estas líneas (banda verde con alma azul/negra) es mayor en el sismo de Tehuacán, Puebla (99/06/15) respuesta que difiere notablemente del patrón mostrado en los demás eventos.

Las condiciones geométricas para los sismos *severos* presentan diferencias más relevantes (Fig. 5.75). Las bandas delgadas de activación y las zonas amplias de estados (osciladores) con mínima respuesta se modifican y ahora la banda fría, aún con eje de simetría en 2 s, es más ancha y su dominio crece hasta casi 2 s (todos los osciladores dentro de una banda de 2 s –de 1.8 s hasta 2.8 s– tiene activación importante) en el MR del sismo del 85. Se minimiza la participación del segundo modo de vibrar dejando zonas amplias de mínima actividad antes y después del periodo fundamental.

La respuesta general en SCT, en términos geométricos, se puede considerar constante. El modelo neuronal en este caso debe generar multi-relaciones que dirijan el crecimiento de la banda fría en ancho (estados que se activan) y en intensidad de la respuesta (en gales) de acuerdo con la fuerza de la sacudida sísmica y en menor grado con la zona sismogénica, directividad y distancia fuente-sitio.

extremos de los colores/ intensidades
(MIN, MAX) en gales

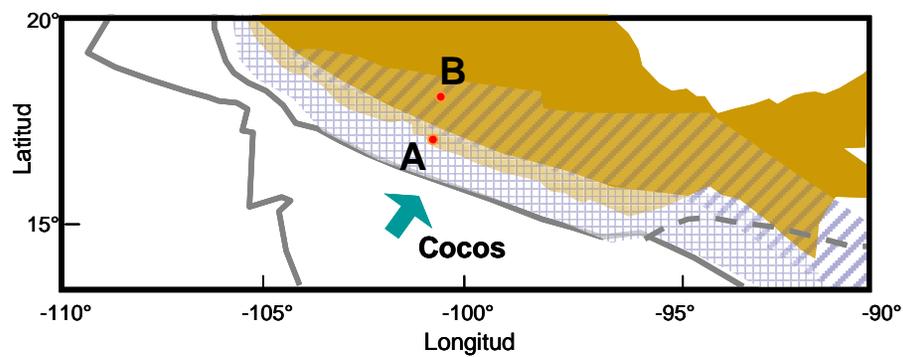
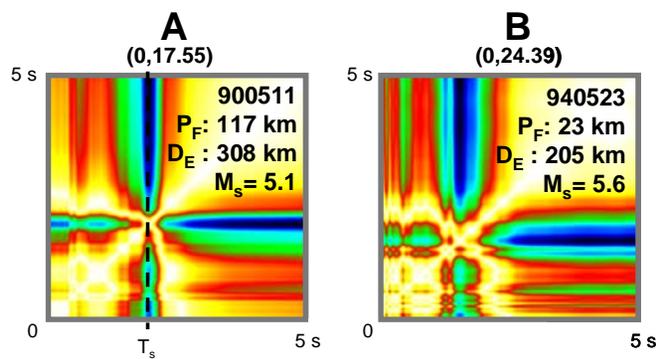
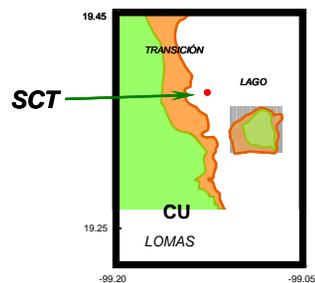


Figura 5.73 MR de SCT para sismos débiles

extremos de los colores/ intensidades
(MIN, MAX) en gales

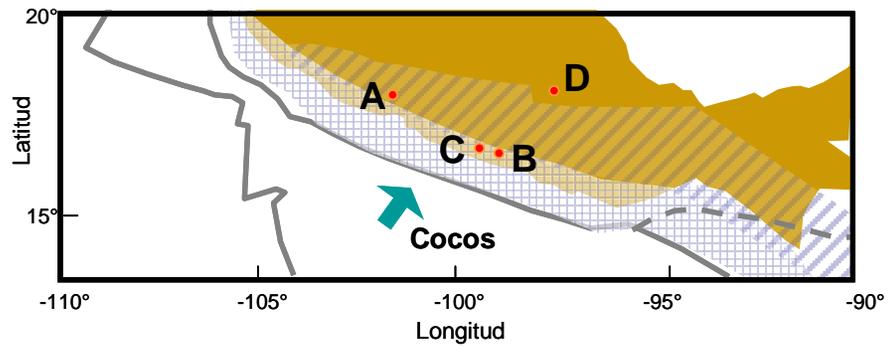
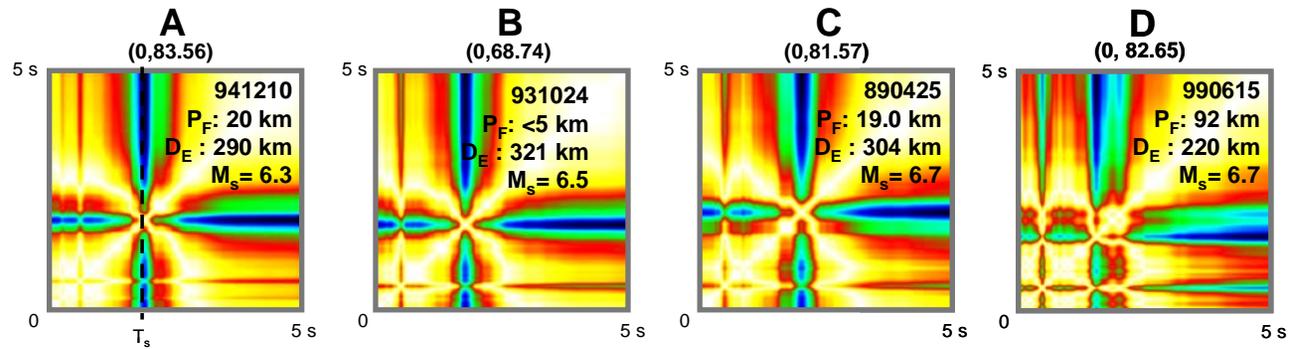
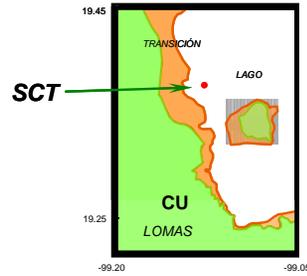


Figura 5.74 MR de SCT para sismos *moderados*

extremos de los colores/ intensidades
(MIN, MAX) en gales

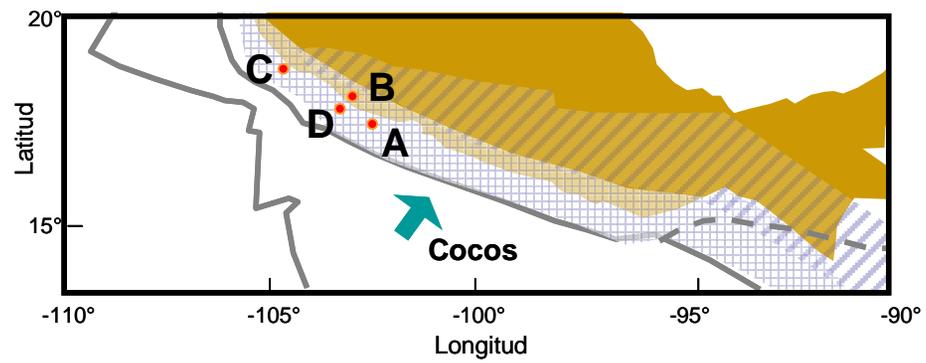
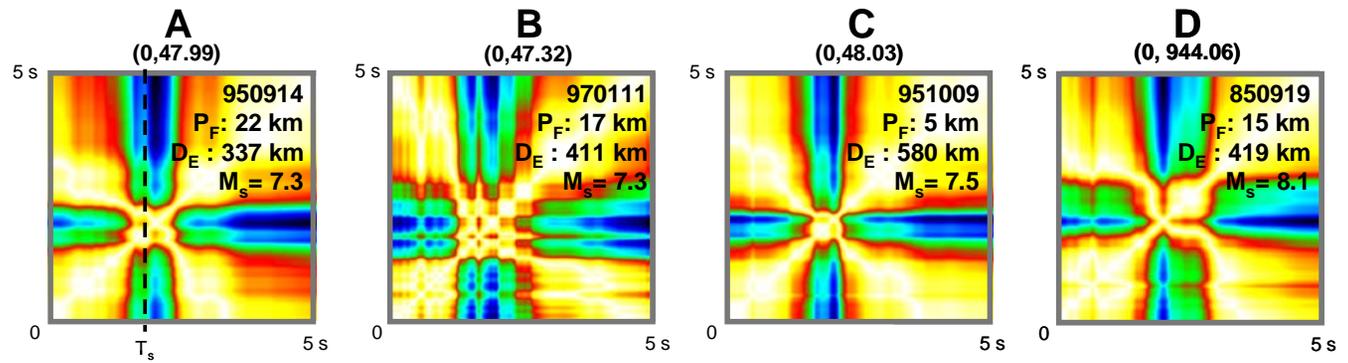
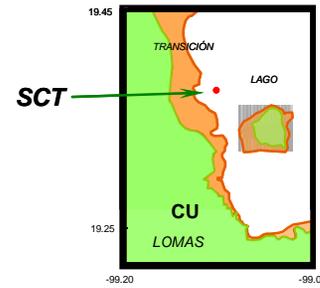


Figura 5-75 MR de SCT para sismos *severos*

- Sitio: **Garibaldi**

T_s : 2.24 s

Las Figs. 5.76, 5.77, y 5.78 muestran los MR para los registros de eventos *débiles*, *moderados* y *severos*, respectivamente. Las diferencias geométricas parecen evidentes entre los tres grupos pero es arriesgado concluir sobre las desplegadas en sismos con magnitudes *débiles* y *moderadas* debido a la componente ruidosa que se aprecia en las bandas *frías*. Lo claro en este rango de M ($M < 7$) es que las OEs máximas no se localizan sobre T_s y que las activaciones son importantes en una amplia zona de osciladores (*meseta*, similar a un ERA de diseño) con OE importantes desde $T = 0$ s y hasta 3 s.

La evidencia indica que conforme las amplitudes de la sacudida sísmica crecen, las componentes ruidosas se minimizan y se clarifica el periodo donde se concentran las máximas respuestas, las bandas *frías* se reducen y la estructura luce más homogénea. Una observación interesante es que la topología en los sismos *severos* es muy similar a las del sitio SCT para este rango de magnitudes, condición importante cuando se traduzcan los resultados neuronales que se obtengan para sitios distintos (caracterización espacial con T_s distinto).

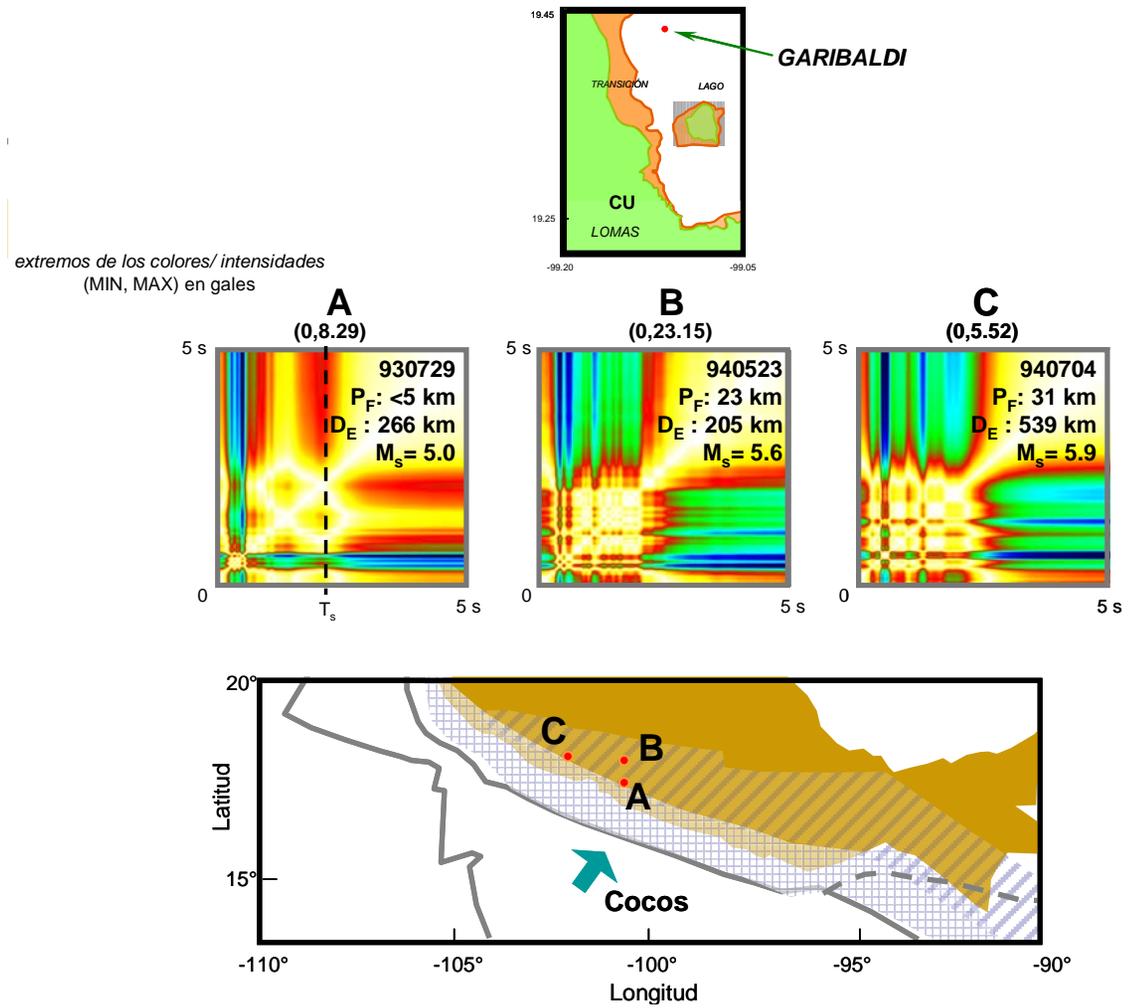


Figura 5.76 MR de Garibaldi para sismos débiles

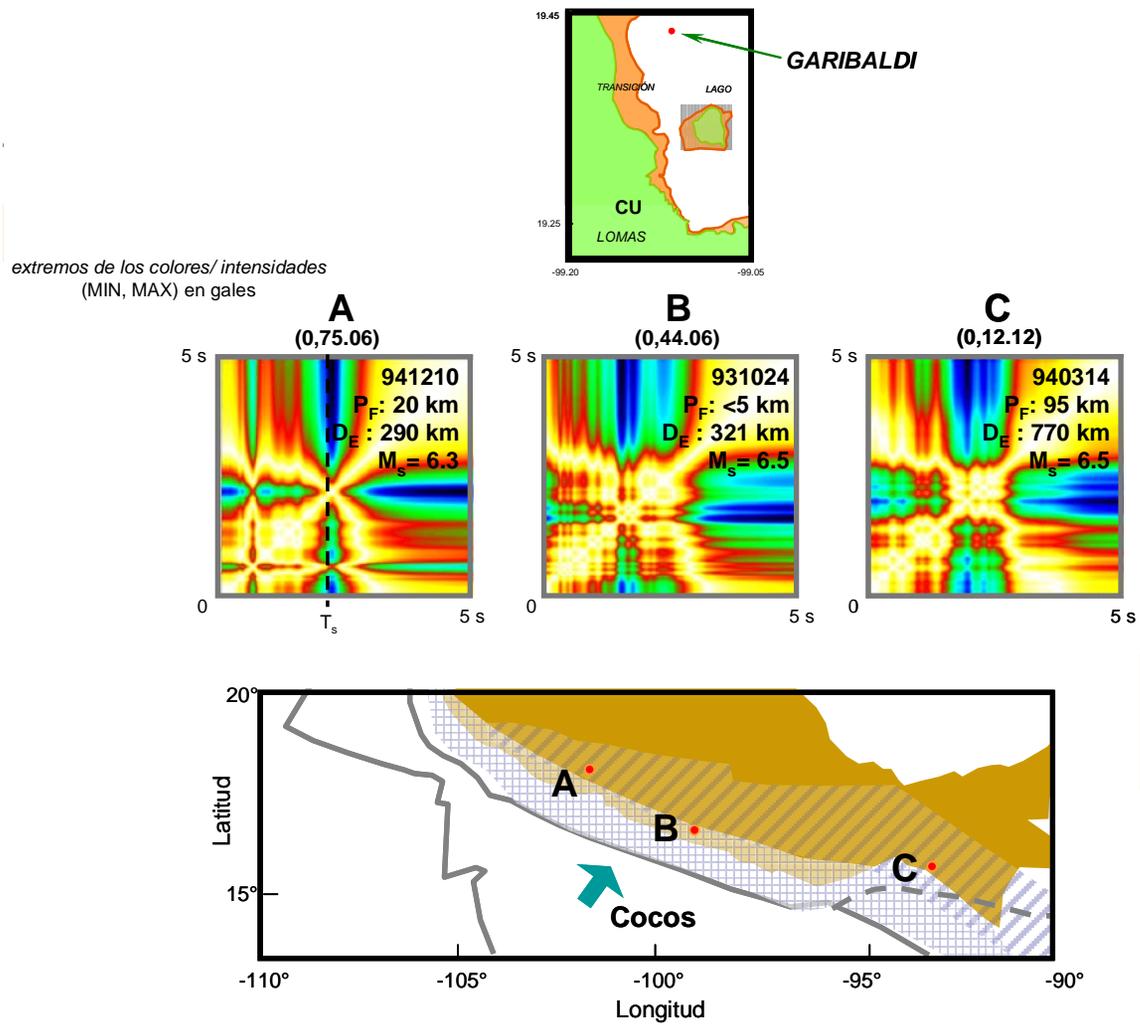


Figura 5.77 MR de Garibaldi para sismos moderados

extremos de los colores/ intensidades
(MIN, MAX) en gales

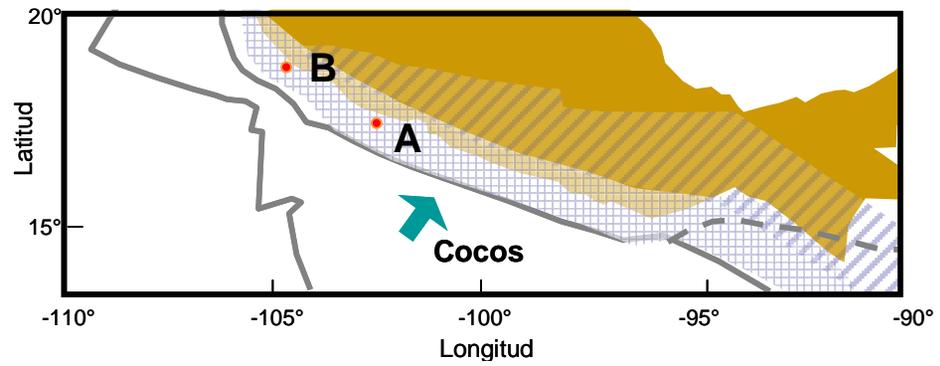
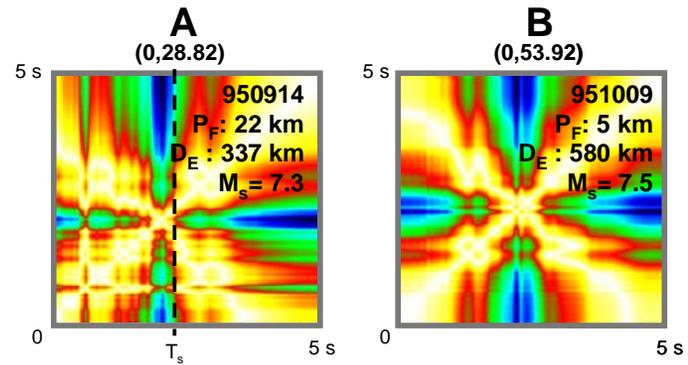
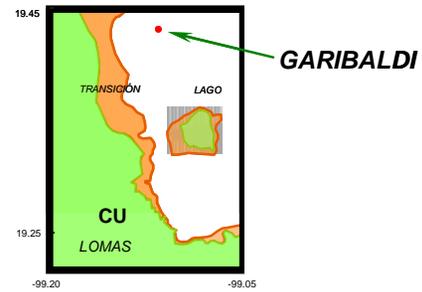


Figura 5.78 MR de Garibaldi para sismos *severos*

- Sitio: **Balderas**

T_s : 2.4 s

Las respuestas, en términos de MR, para sismos *débiles* parecen desvinculadas y se reconocen algunas geometrías muy similares a las registradas en terreno firme (Fig. 5.79). Las componentes ruidosas son altas y las OEs máximas no se localizan cerca del periodo fundamental. Cuando se analizan las topologías debidas a eventos *moderados* (Fig. 5.80) se verifican algunas estructuras comunes con un cuadro de comportamiento semi-periódico (entre 0.5 y 3.5 s) donde se podría localizar el máximo y éste podría caer en el T_s del sitio, pero es difícil de evaluar si la componente de ruido sigue siendo tan evidente (observe los “cortes” de las bandas *frías* en A, C y D).

Existen mejores argumentos para concluir sobre la posición de la OE máxima, pero sigue siendo aventurado concluir que para estas intensidades se localiza sobre el periodo fundamental del sitio.

Estructuras igualmente confusas se aprecian en la Fig. 5.81 para las sacudidas más *severas*. El sismo A presenta una gran meseta donde las respuestas máximas se localizan alrededor e incluso sobre T_s lo que ratifica el hecho de que las alteraciones ambientales que afectan a todos los registros obtenidos en el sitio Balderas no permiten elaborar juicios prudentes sobre la conducta del depósito de suelo.

La aparente mínima sensibilidad a la sismogénesis y a la directividad debería ponerse en duda cuando se analizan estas respuestas. La inserción de estos MR en la base de entrenamiento será cautelosa y en los procesos de aprendizaje y prueba los resultados neuronales serán analizados de la misma forma. Este tipo de patrones, aún con las alteraciones reconocidas por el entorno de la estación acelerográfica, en muchos sentidos son útiles para generar una mayor flexibilidad en modelos conexionistas (vea el Capítulo 3 Cómputo Aproximado).

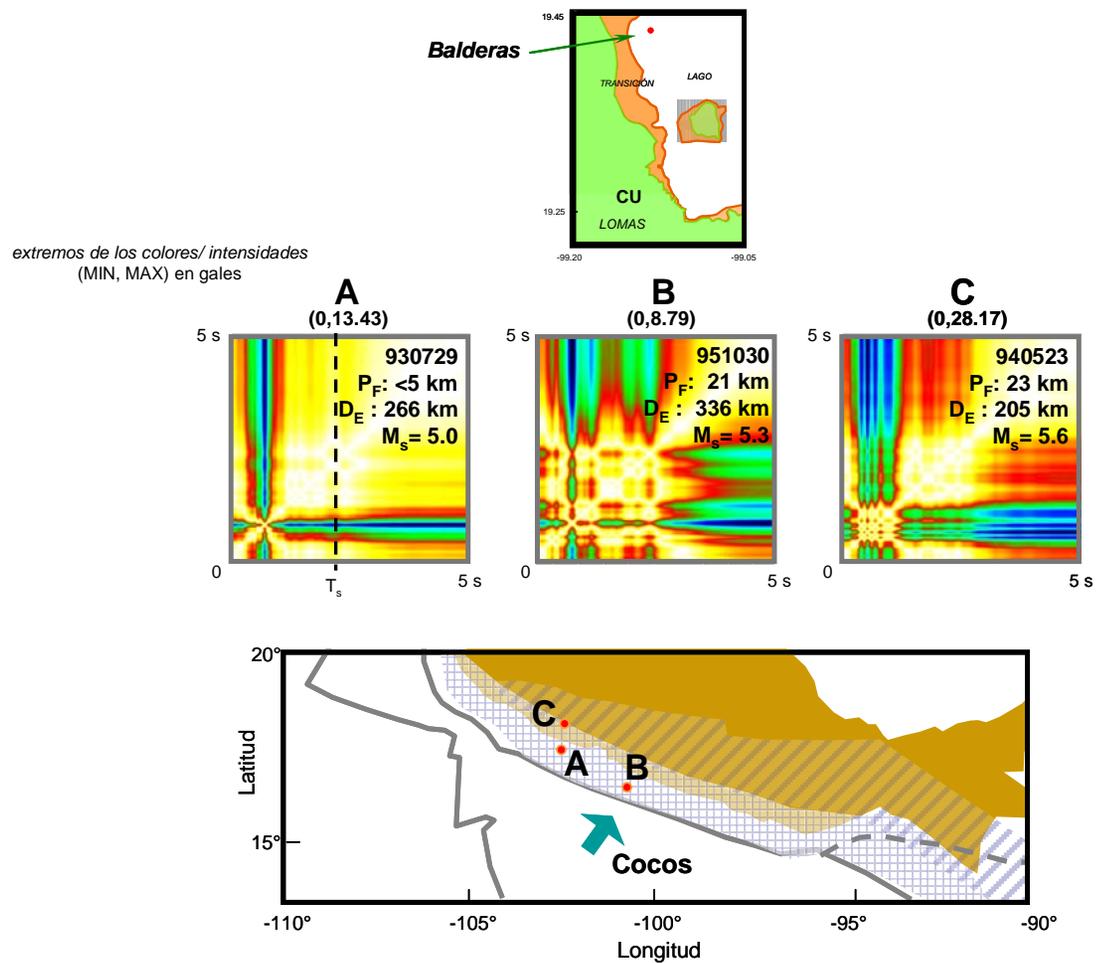


Figura 5.79 MR de Balderas para sismos débiles

extremos de los colores/ intensidades
(MIN, MAX) en gales

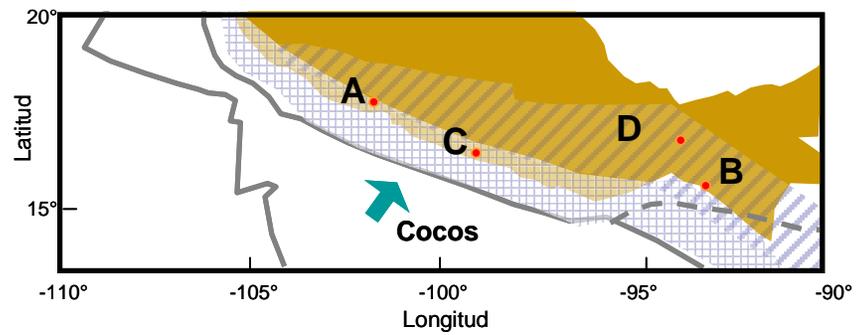
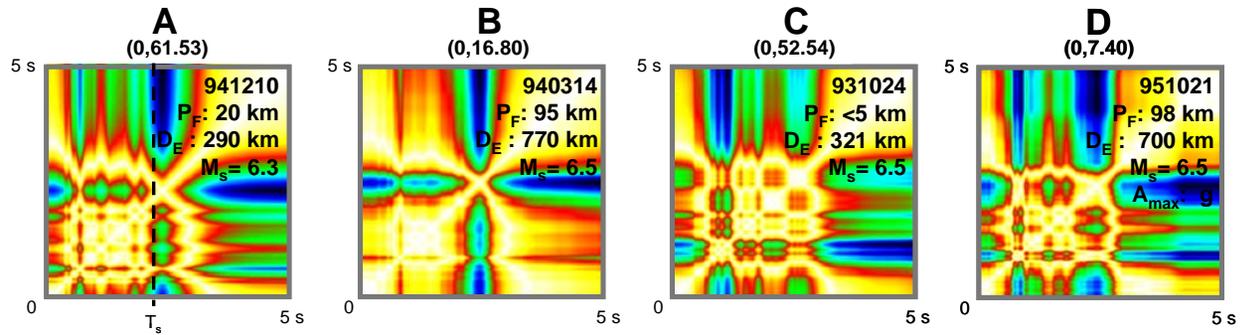
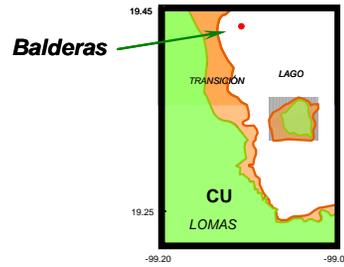


Figura 5.80 MR de Balderas para sismos moderados

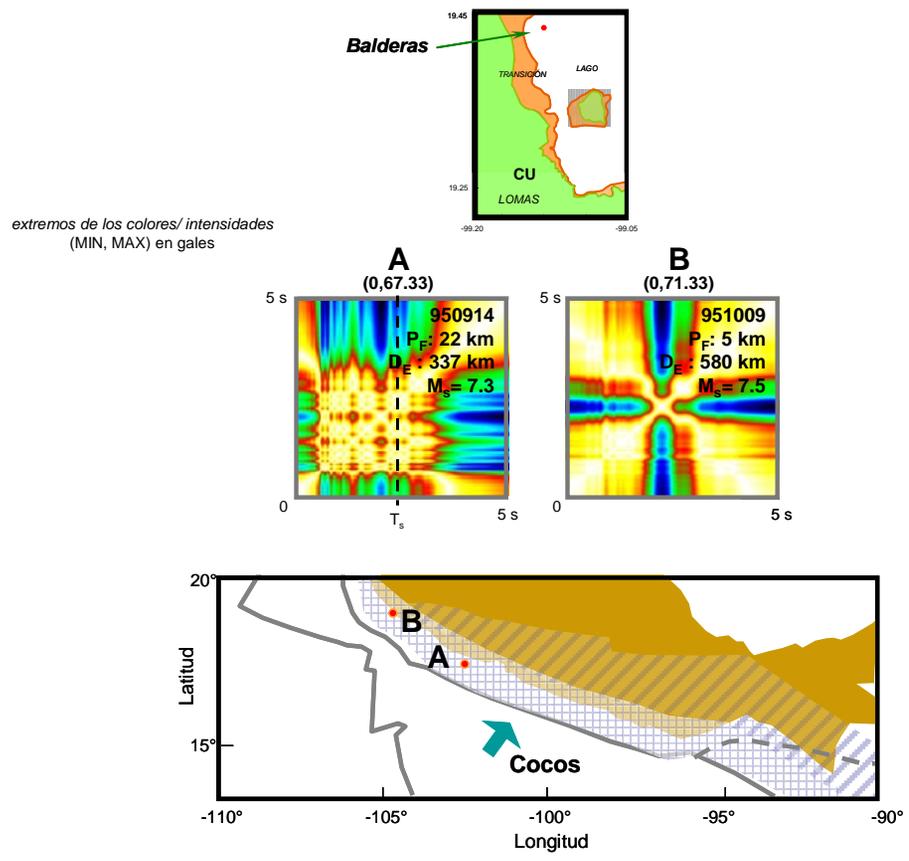


Figura 5.81 MR de Balderas para sismos *severos*

- Sitio: **Candelaria**

T_s : 3.0 s

Muy similar a las desligadas respuestas del sitio Balderas, los MR de la Fig. 5.82 correspondientes a sismos *débiles*, no presentan características comunes, ni en términos geométricos ni de intensidad. Registros de amplitudes muy bajas, debido a su relación aceleración/ruido, generan ERAs casi horizontales en grandes zonas de periodos. Esto se comprueba con la *especial* intensidad reportada para el sismo B que produce un MR con marcadas líneas verticales y horizontales y una OE máxima alrededor de 1 s.

Las mejores definiciones en las geometrías de sismos *moderados* (Fig. 5.83) comienzan a separarse de la tendencia topológica mostrada en SCT. Se muestra la participación igualmente importante de dos periodos (el fundamental y un segundo modo alrededor de los 1.2 s) y esto se conserva en lo reportado para sismos *severos* (Fig. 5.84). El depósito de alguna manera mantiene este patrón de comportamiento para amplitudes espectrales desde los 10 y hasta los 60 gales.

Evidente es la complejidad de las relaciones entre las geometrías, las intensidades y los aspectos sísmicos zona sísmica, distancia epicentral, directividad, profundidad focal e incluso el valor de la magnitud.

extremos de los colores/ intensidades
(MIN, MAX) en gales

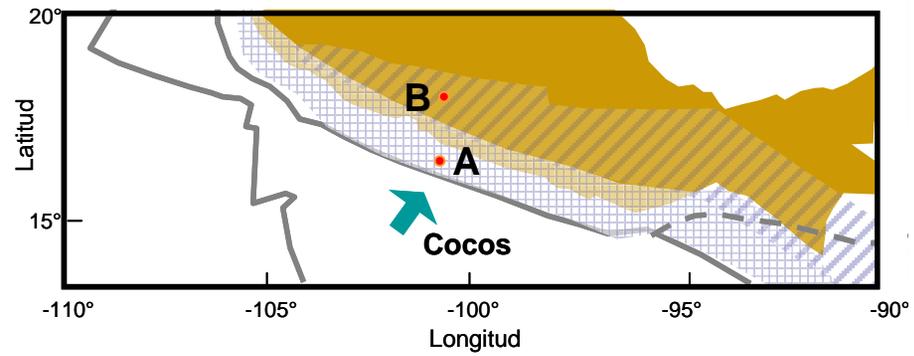
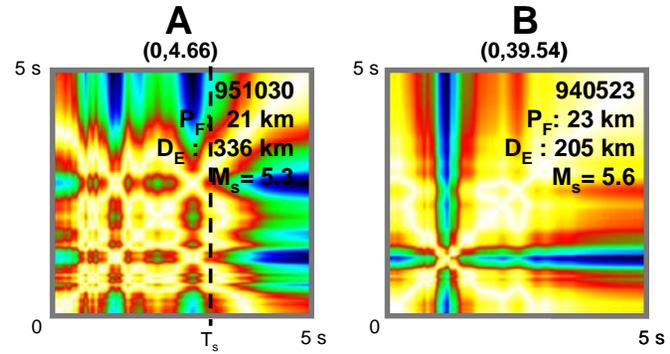
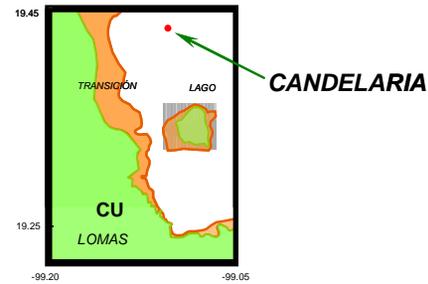


Figura 5.82 MR de Candelaria para sismos débiles

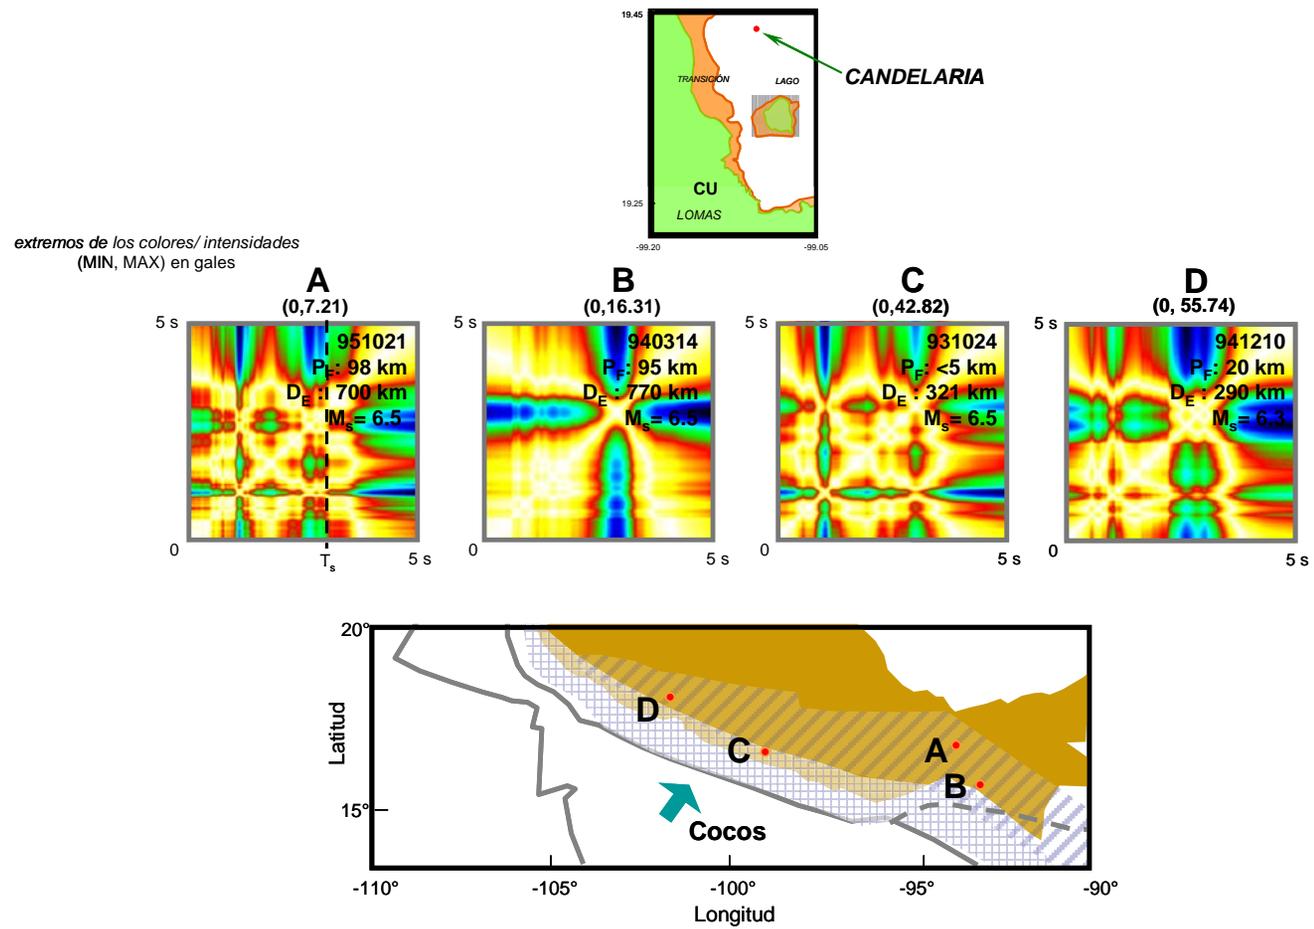


Figura 5.83 MR de Candelaria para sismos *moderados*

extremos de los colores/ intensidades
(MIN, MAX) en gales

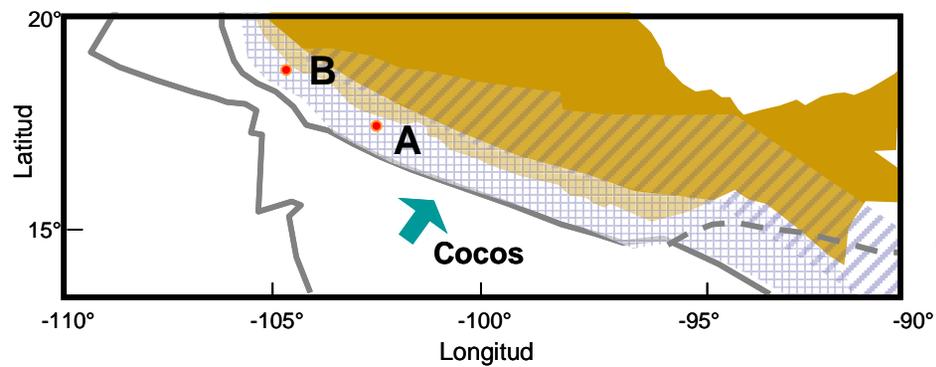
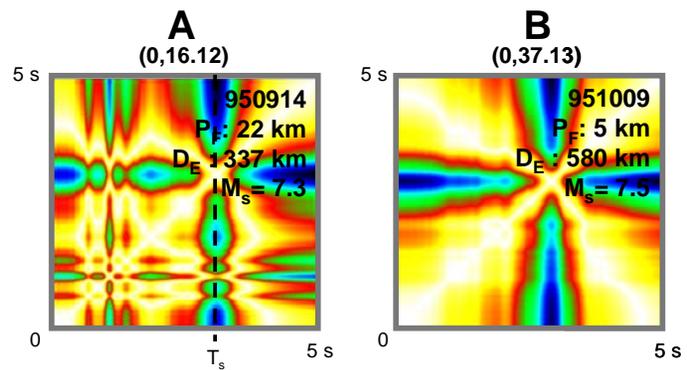
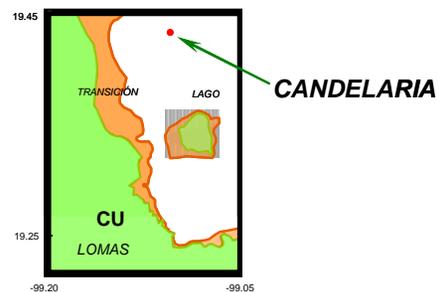


Figura 5.84 MR de Candelaria para sismos *severos*

- Sitio: Central de Abasto Oficinas CDAO

T_s : 3.5 s

El sitio CDAO es uno de los que, dentro de la base de datos, cuenta con menos información registrada. A pesar de esta escasez se distinguen tendencias interesantes en los MR analizados. En la Fig. 5.85 se presentan los dos MR construidos para sismos *débiles*. A partir de ellos se argumenta que las estructuras (geometrías) con mínima alteración para la mayoría de los osciladores (blancos y amarillos) y una puntual respuesta alrededor de 1s, se presentan en todos los sitios de acuerdo con un cierto nivel de sacudida pero la topología se mantiene a pesar de las diferencias en la condición espacial y por ende, estratigrafía.

El caso CDAO permite y obliga a combinar las observaciones hechas en sus MR de eventos *moderados* y *severos* (Figs. 5.86 y 5.87). Las respuestas máximas (0Es) se localizan en las cercanías del T_s y en su segundo modo de vibrar alrededor de los 1.2 s.

La ancha banda con eje sobre el periodo fundamental es más evidente conforme crecen las amplitudes espectrales. No se reconoce un máximo extremo y se puede hablar de una respuesta extrema de un conjunto de osciladores.

El depósito parece responder bajo un cierto patrón geométrico independiente de las zonas sismogénicas, las condiciones epicentrales y las profundidades focales.

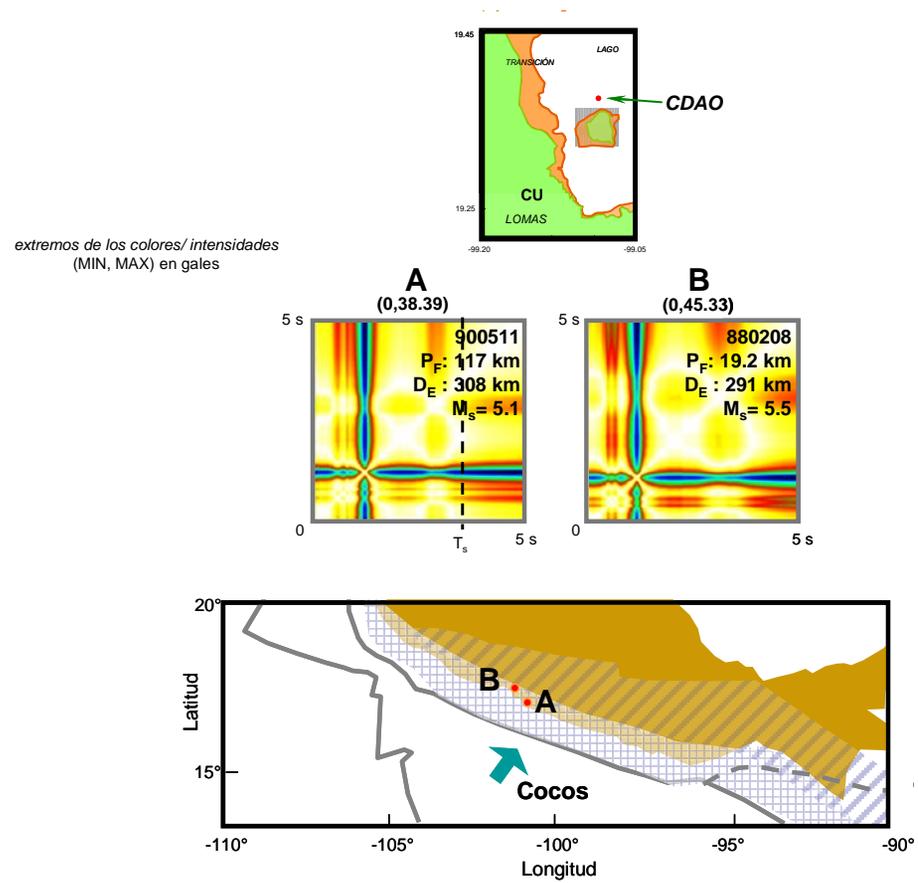


Figura 5.85 MR de CDAO para sismos débiles

extremos de los colores/ intensidades
(MIN, MAX) en gales

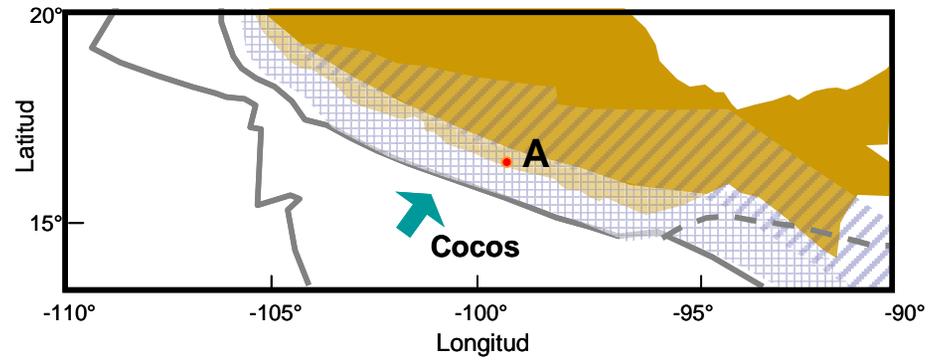
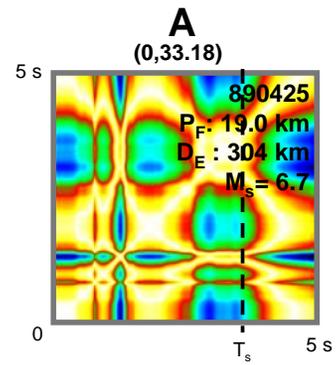
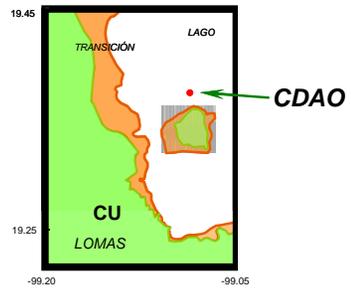


Figura 5.86 MR de CDAO para sismos moderados

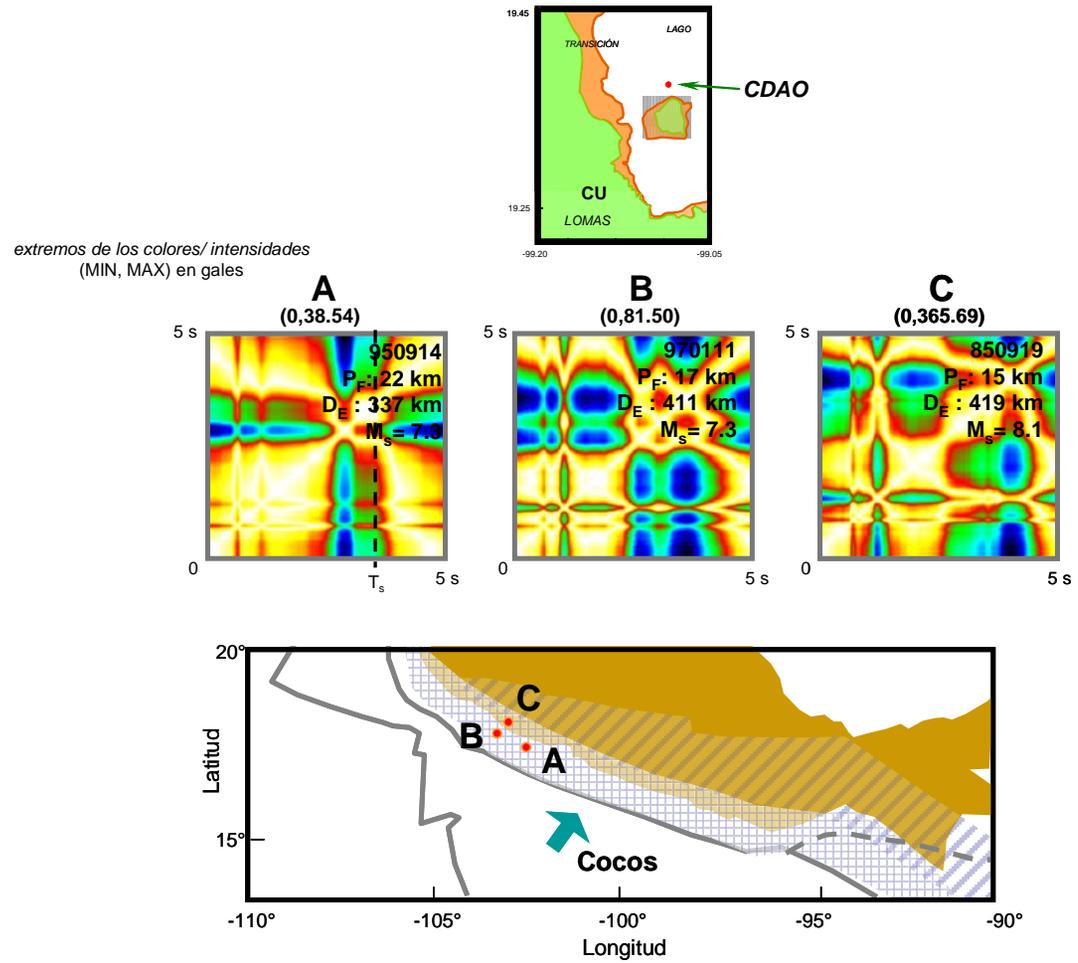


Figura 5.87 MR de CDAO para sismos *severos*

- Sitio: **Hangares**

T_s : 4.0 s

Las respuestas en este sitio, con periodo fundamental alto, verifican la hipótesis de la existencia de un mismo patrón de respuesta (geometría) en las Zonas de Lomas y Lago para sismos de intensidad menor (Fig. 5.88). Las bandas presentes de nueva cuenta presentan puntuales máximos en 1.2 s y 2.3 s, lejanos del valor de T_s para el sitio.

Los mismos periodos activados con las OE máximas en sismos *débiles* se repiten bajo la acción de algunos sismos *moderados* (Fig. 5.89) aunque no así la estructura general del mapa. Se puede apreciar que el incremento de fuerza sísmica origina un corrimiento hacia los periodos mayores de la zona de máximas OEs (banda verde).

En la Fig. 5.90 se presentan los dos MR de eventos *severos* registrados en el sitio. Esta información, similar a la desplegada en la Fig. 5.89, permite afianzar la deducción de que las estructuras de algunos sitios parecen no modificarse aún con el incremento de la intensidad en la sacudida (sin tomar en cuenta ningún evento *extremo*). Particularmente se distingue la participación importante de tres periodos, no coincidentes con el T_s del RCDF para Hangares.

Se recomienda precaución sobre estas conclusiones debido a la fuerte componente de ruido ambiental.

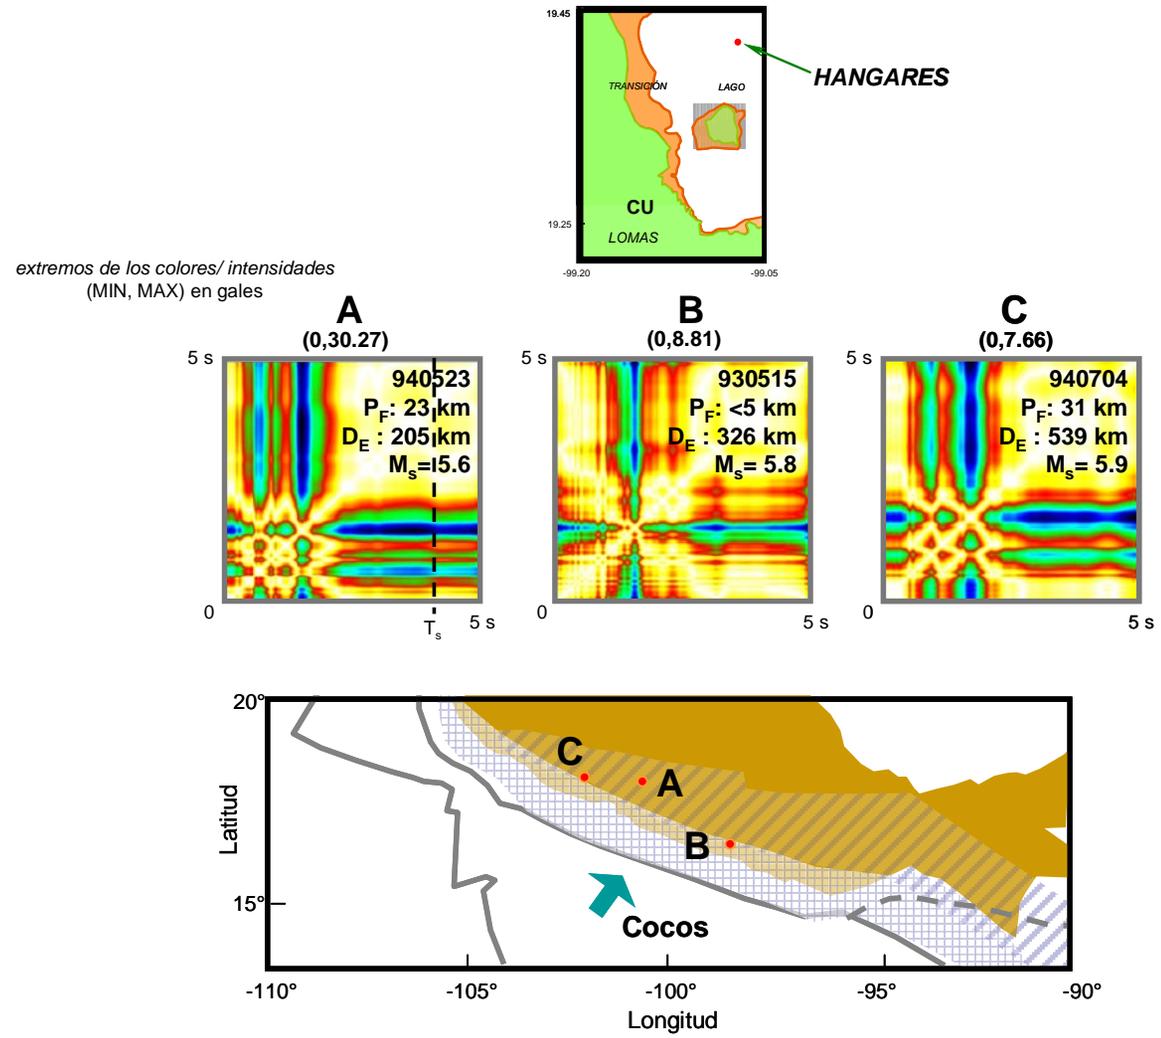


Figura 5.88 MR de Hangares para sismos débiles

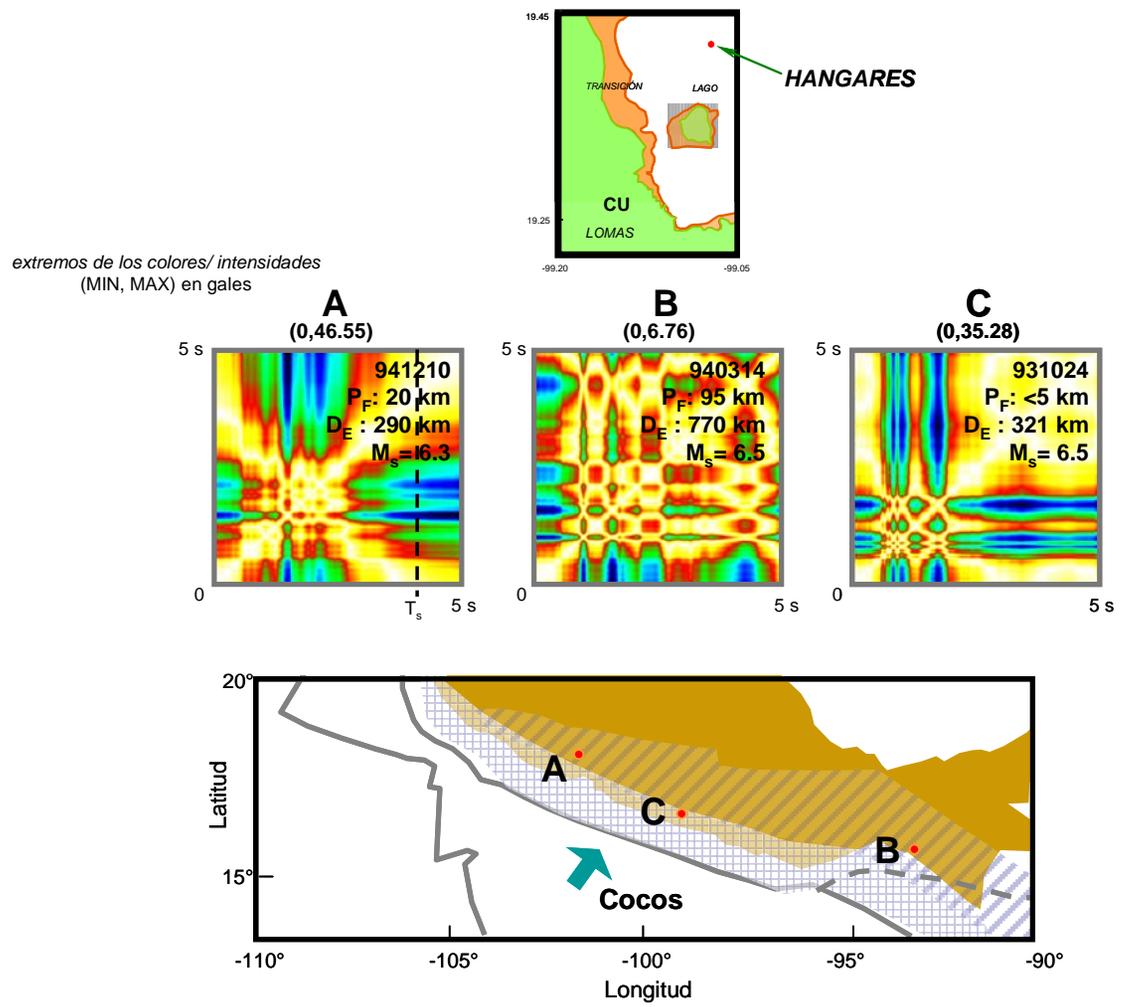


Figura 5.89 MR de Hangares para sismos *moderados*

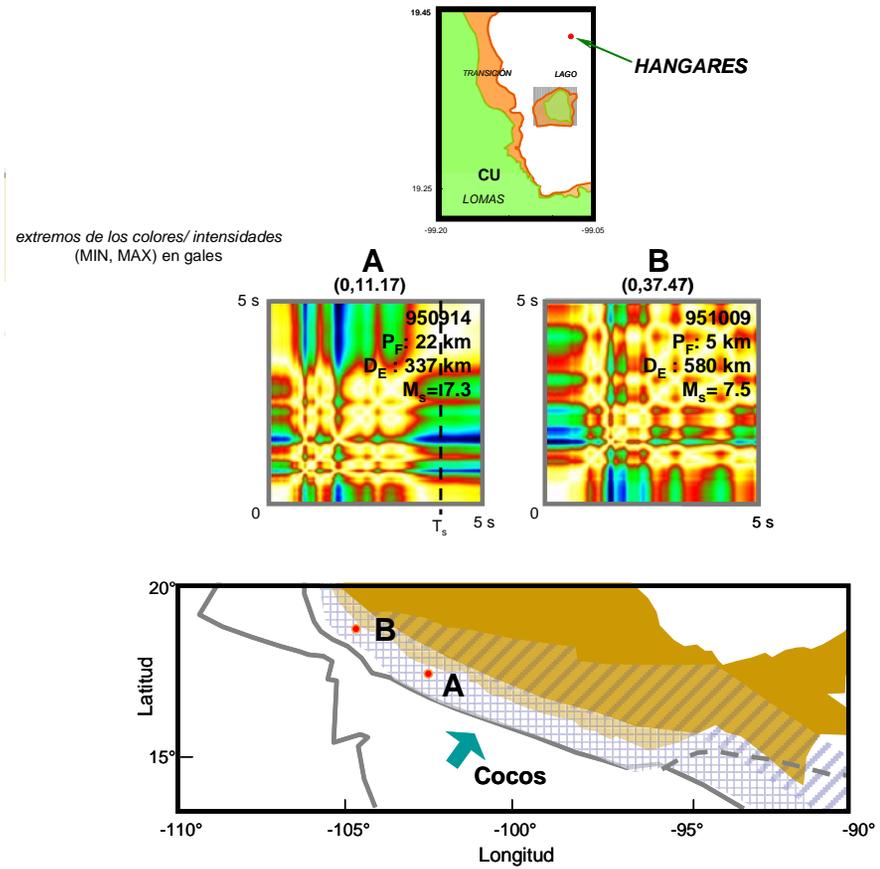


Figura 5.90 MR de Hangares para sismos *severos*

Algunas observaciones sobre los *Sismos* y los *Sítios*

El uso de los MR en el análisis de respuesta de sitio permite esclarecer algunos de los puntos que deben dirigir el comportamiento del modelo neuronal y que a su vez constituyen las estimaciones críticas y los puntos de divergencia teórica entre éste y los esquemas de cálculo convencionales. Es complejo y poco eficiente ejemplificar estas consideraciones usando toda la información disponible por lo que a continuación se presentan sólo ciertos esquemas comparativos que permitan al lector tener una idea general del tipo de mapeo que realizará el modelo conexionista propuesto en este trabajo de tesis.

En la Fig. 5.91 se muestran similares MR obtenidos para los seis sitios analizados, a manera de ejemplo, de lo contenido en la base de datos. El Parámetro E común detrás de estas geometrías (una marcada línea vertical y horizontal con el valor máximo -color azul/negro- alrededor de $T=1$ s) es sólo la magnitud por debajo de los seis grados (evento *débil*). Los epicentros cubren una zona muy amplia y las profundidades focales van desde los 5 hasta más de 100 km.

Las condiciones de los depósitos en el área cubierta por los sitios elegidos son cambiantes y no pertenecen todos a la zona del Lago (potentes estratos de arcilla lacustre con altísimos contenidos de humedad). No es lógica la búsqueda de coincidencias en materiales, profundidades y espesores. Entonces existen condiciones sísmicas que hacen que una gran parte de la Zona de Lago genere movimientos semejantes y sean la *situación* (disposición) de los suelos quienes dirijan la intensidad de la respuesta.

Manteniendo fijo el evento y comparando las respuestas de los sitios, se puede argumentar que en sismos *débiles* (Fig. 5.92) es notable la tendencia a presentar los máximos por debajo del periodo fundamental del sitio y muy cerca del periodo del sitio en roca. La banda que contiene al valor máximo de OE está claramente definida y las zonas claras (mínima activación de los otros periodos) son muy extensas.

Si se refiere este comportamiento a la acción básica en la estimación de respuesta (modificación del movimiento en el afloramiento rocoso debido a la presencia del suelo) entonces todas las variantes en disposición y materiales en cada sitio no sugieren un cambio sustancial del artificio numérico con el cual se transforma la entrada. SCT es un caso excepcional. En toda la base de datos no se encuentra un depósito que presente respuestas tan constantes (en términos geométricos) y sólo parezca responder en diferentes niveles de intensidad a los valores de energía de entrada.

Conforme las magnitudes crecen las diferencias entre las respuestas son más claras en términos geométricos pero no en términos de intensidad (OEs) (Figs. 5.93 y 5.94). Los máximos valores espectrales comienzan a coincidir en posición con el T_s del sitio, siendo evidente que este concepto físico aplica de mejor manera para sismos *severos*.

Es importante señalar que el incremento de la fuerza sísmica activa un mayor número de *estados* en los MR y al minimizar los efectos del ruido ambiental permite analizar mejor los *estados* fundamentales, concepto propuesto en este trabajo de tesis y análogo al de *periodo* fundamental. Más adelante se retoma y analiza ampliamente esta idea.

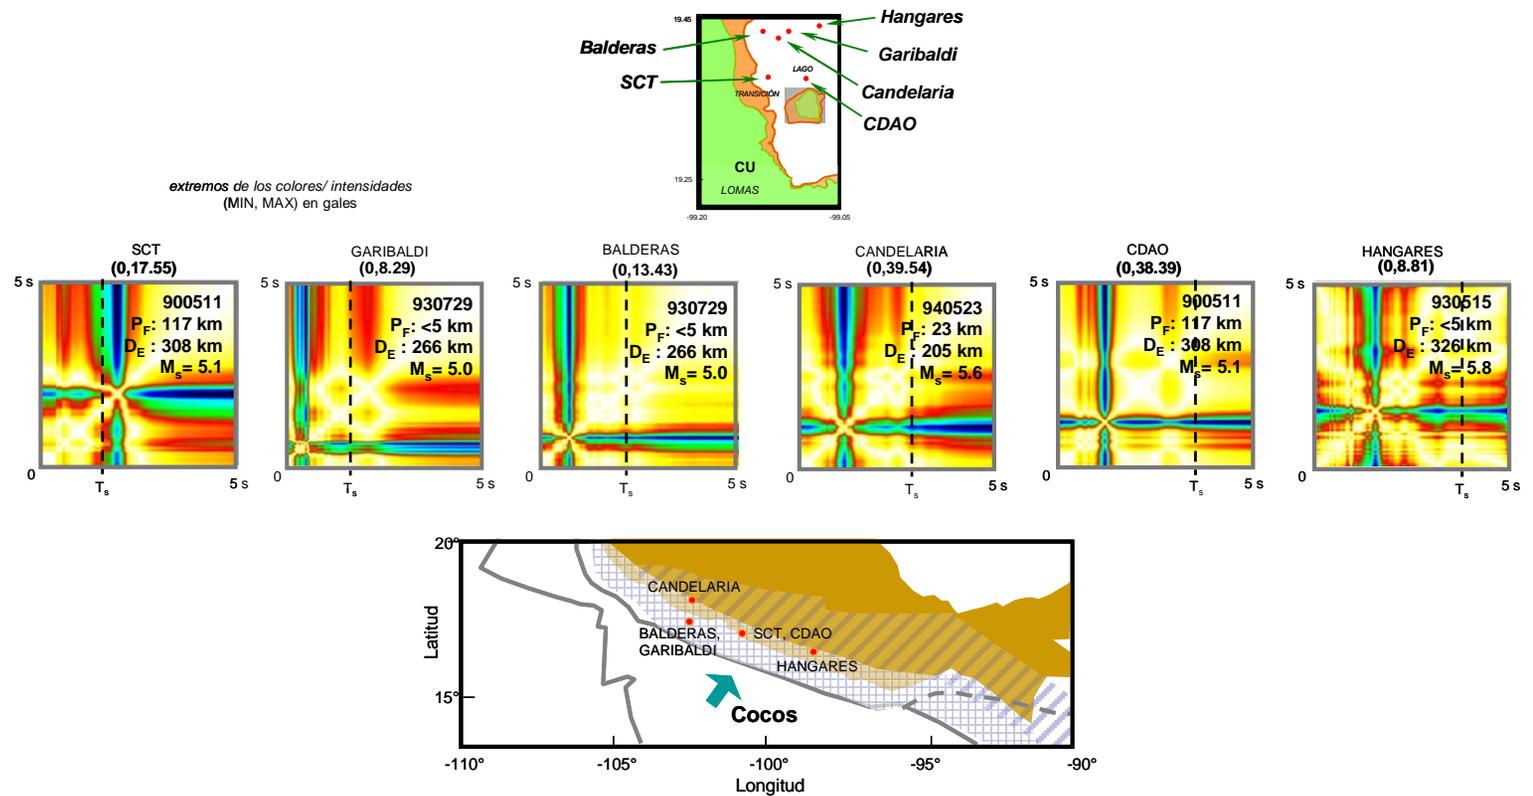


Figura 5.91 MR de depósitos de suelo distintos con geometrías similares

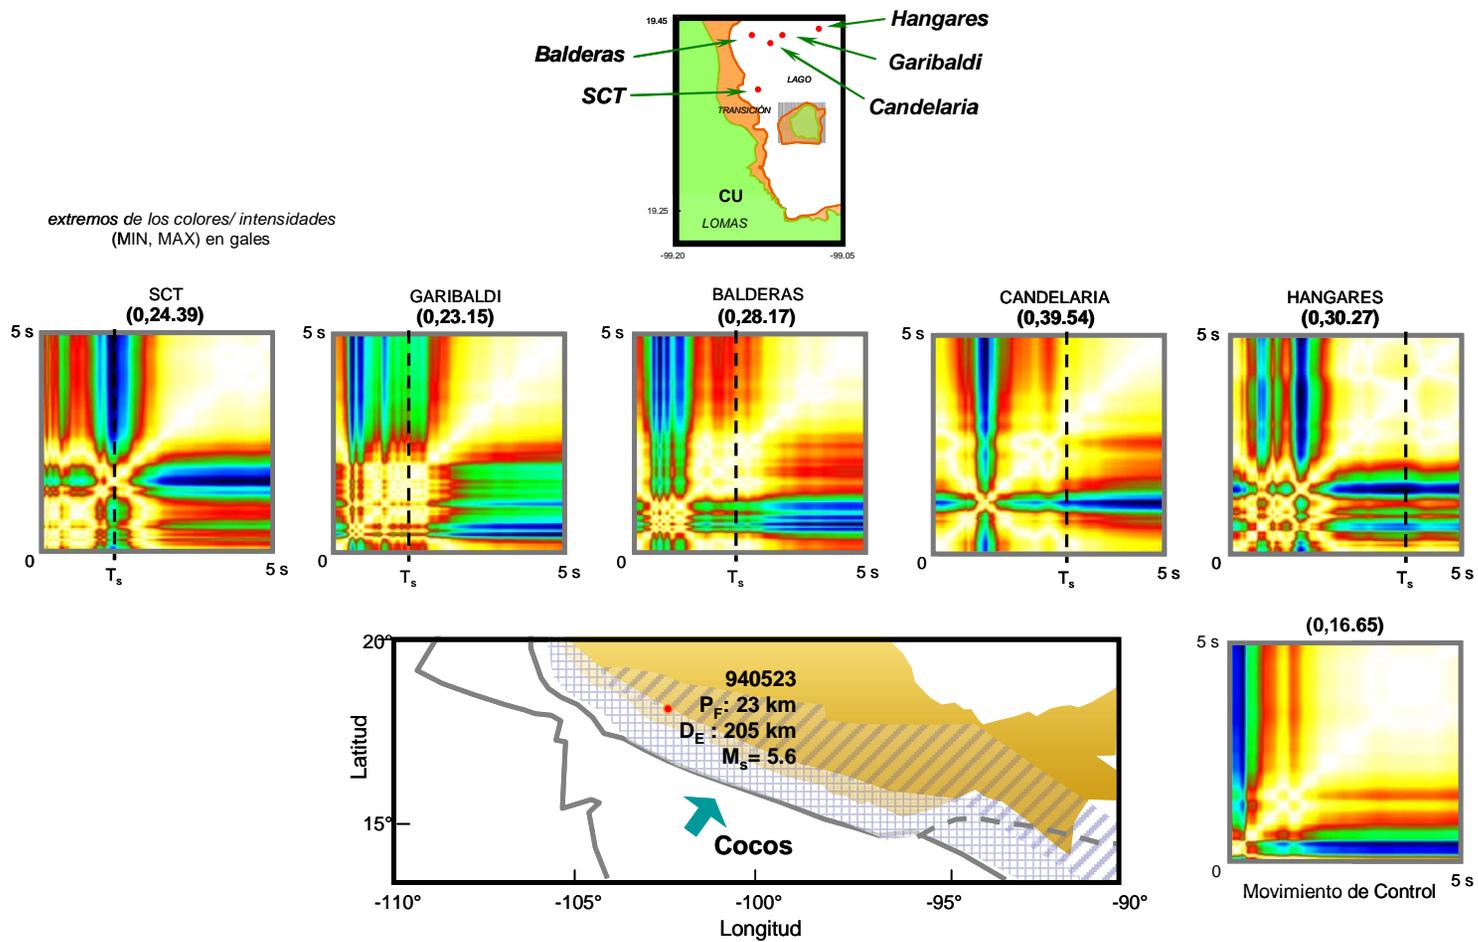


Figura 5.92 Ejemplos de MR de depósitos de suelo distintos, sismos débiles

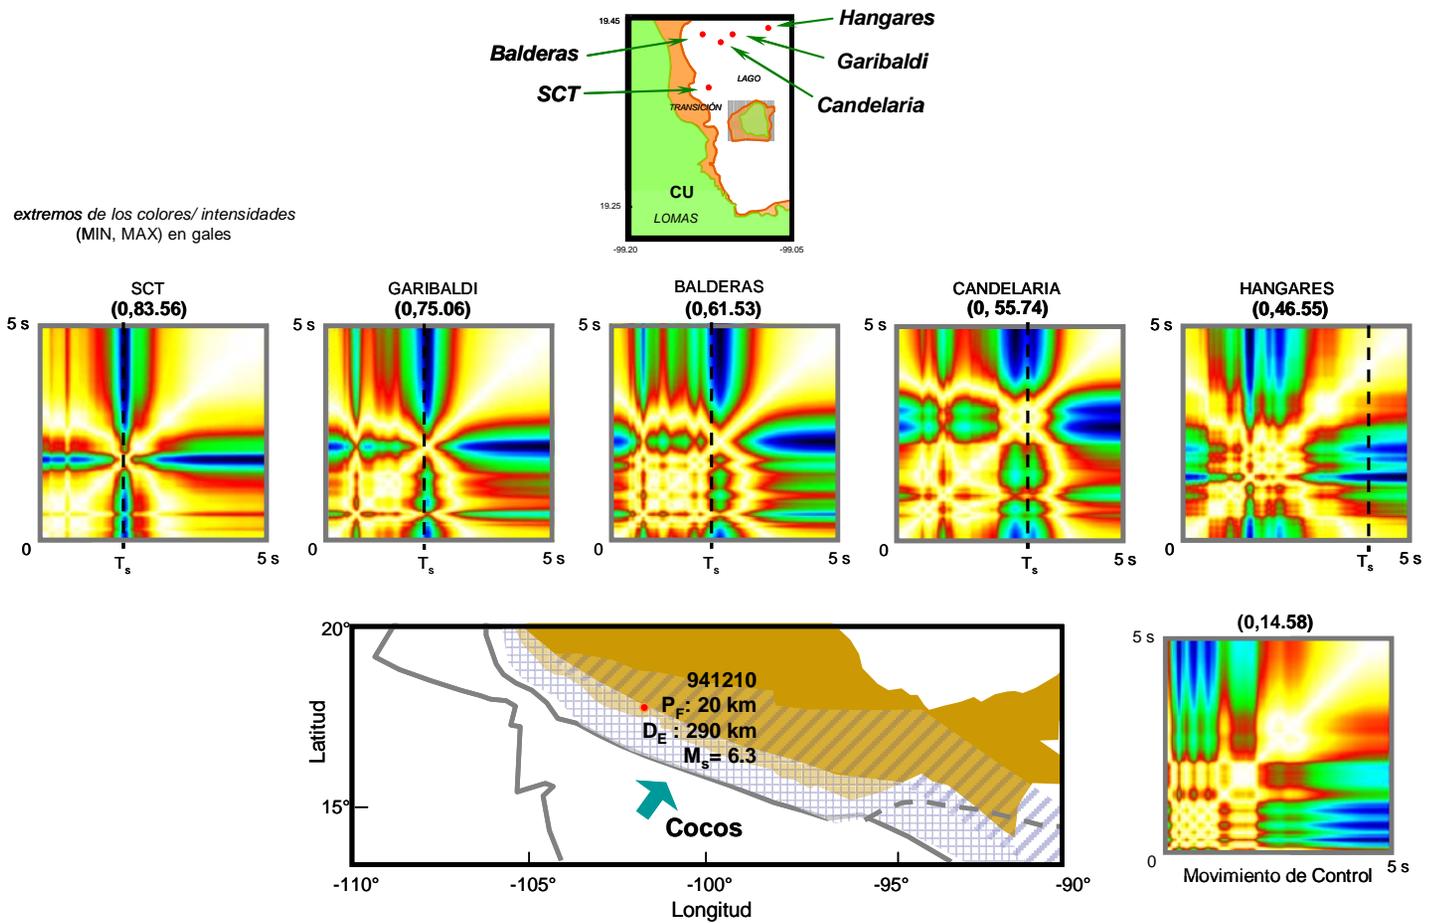


Figura 5.93 Ejemplos de MR de depósitos de suelo distintos, sismos *moderados*

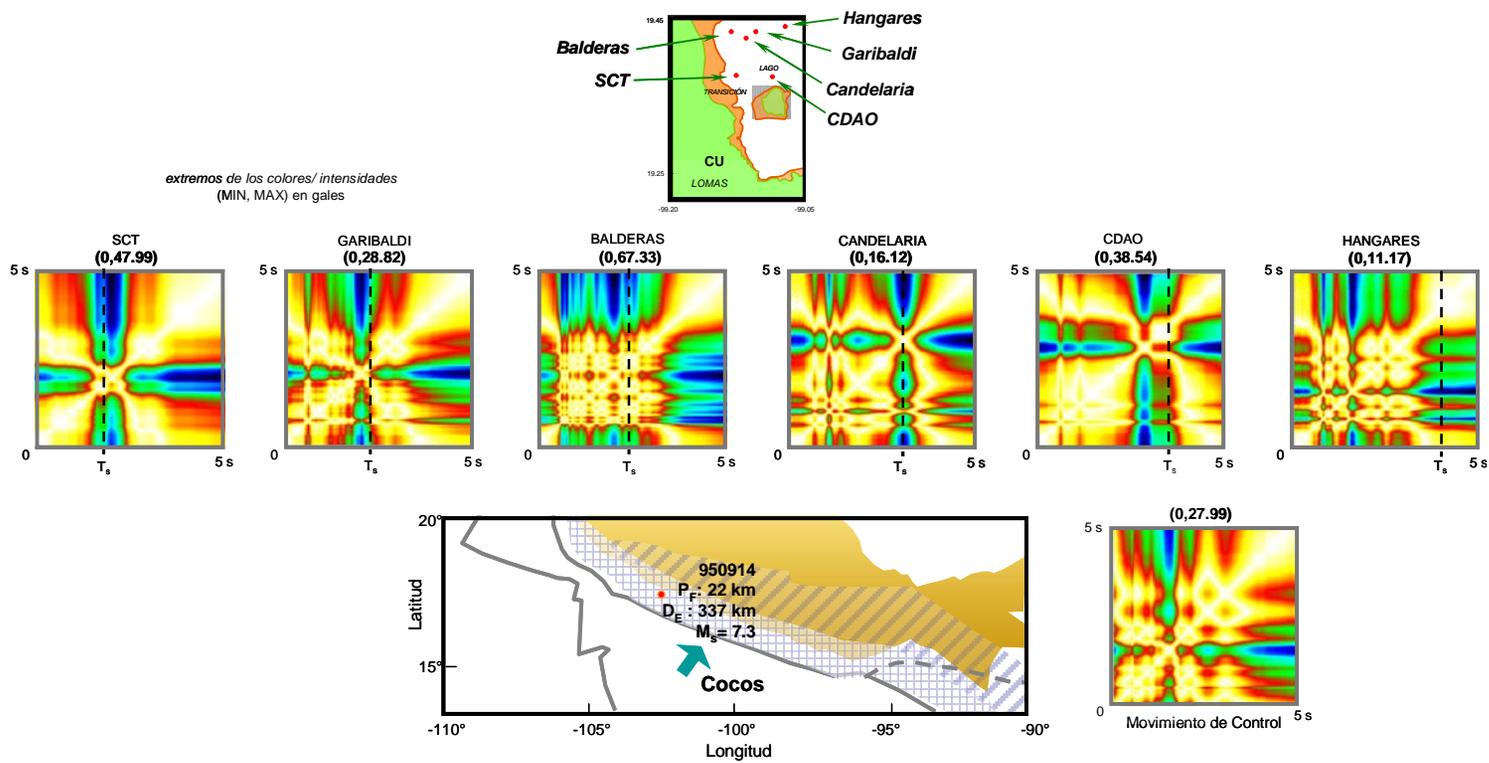


Figura 5.94 Ejemplos de MR de depósitos de suelo distintos, sismos *severos*

Entonces se puede hablar de una cota en las aceleraciones de entrada donde el Lago se comporta de manera muy similar, hablando de *estados*, y las diferencias entre las OE de los ERAs son sutiles. Más allá de este límite los estados que se activan comienzan a cambiar y se observan importantes diferencias de estructuras desplegadas en los sitios con $T_s < 2.5$ s y los que sobrepasan este valor. Las geometrías son más complejas para sitios con T_s altos y los comportamientos más constantes (líneas y zonas de máximos que se repiten en eventos *moderados* y *severos*). Se pueden generar conclusiones valiosas sobre las respuestas mínimas pero en el caso de eventos *extremos*, se cuentan con sólo tres registros del terremoto de 1985. Los MR de los dos sitios en Lago y el de control se muestran en la Fig. 5.95.

extremos de los colores/ intensidades
(MIN, MAX) en gales

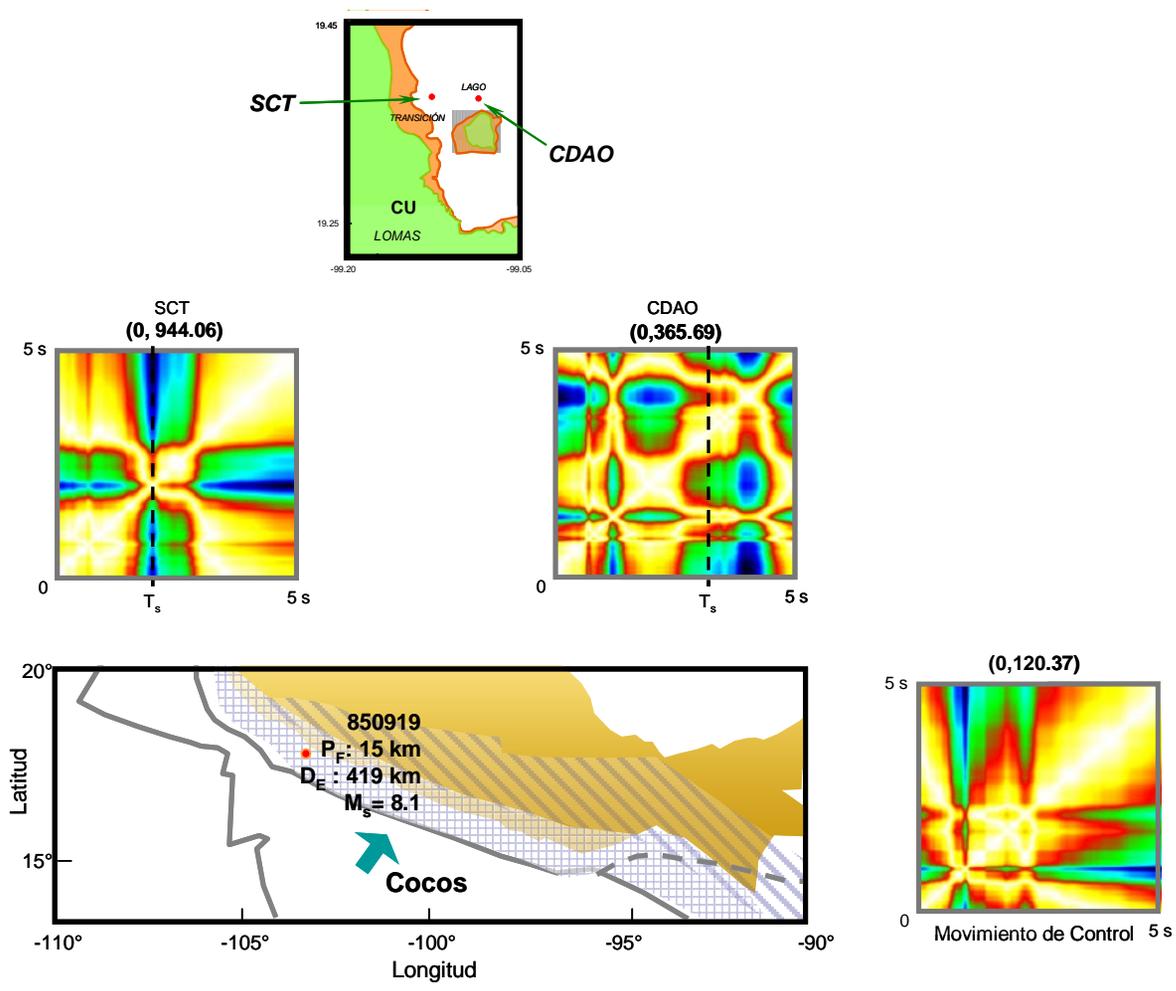


Figura 5.95 MR de los sitios SCT y CDAO para el sismo del 19 de septiembre de 1985

Como ya se apuntó, el movimiento de control muestra una geometría muy distinta a las registradas en toda la historia sísmica de la estación CU. OEs máximas alrededor de 1s con una zona de respuestas importantes (manchas verdosas) desde los 0.5 s y más allá de los 2.5 s. El MR de este evento es incluso similar a algunos considerados típicos de sitios en la zona del Lago. Contrario a este anómalo comportamiento en CU, los sitios SCT y CDAO despliegan estructuras semejantes a las vistas en otros sismos de magnitud moderada. La típica presencia de franjas sobre el T_s para SCT y la sobresaliente participación de los dos modos de vibrar para CDAO son modificadas ligeramente durante el sismo del 85 en el primer caso, con el ensanchamiento de la banda fría creciendo hacia los 3 s (presencia de verdes hasta los 3.2 s) y en el caso CDAO con una disminución de la participación del primer modo de vibrar (referido a las OE en el segundo modo ≈ 1.2 s) que se desplaza hacia los 4 s.

La hipótesis de un umbral de intensidad sísmica debajo del cual la mayoría de los sitios responden de manera muy similar se refuerza si comparamos las Figs. 5.95 y 5.96. Las estructuras que caracterizan a un sitio aparecen cuando la sacudida es suficientemente fuerte pero no así cuando el evento es de menor importancia.

Es fundamental y conveniente a nuestro modelo conexionista que el movimiento de control contenga particularidades que lo separen del resto de los MR de entrada (geométricos y de fuerza) para lograr que la RN reconozca las condiciones especiales que generan las respuestas extremas (por lo menos en intensidad) en los sitios del Lago.

Resulta evidente que es una tarea muy compleja encontrar a simple vista las relaciones entre MRs o dilucidar sobre las geometrías desplegadas y su interpretación de acuerdo con las aceleraciones espectrales y los otros parámetros de entrada, por lo que no se pre-clasifican los mapas, no se añaden variables ligadas a las observaciones antes descritas ni se dirige de alguna otra manera el flujo de información/aprendizaje neuronal. Se obliga al modelo a comportarse como de reconocimiento y clasificación de patrones con fines de predicción numérica.

En la Fig.5.97 se muestra el nuevo esquema neuronal con la sustitución de los ERAs por el conjunto de sus MR. Como ya se ha mencionado y ejemplificado, la inclusión de los MR expande el *conocimiento* y aumenta la confianza en las *predicciones* neuronales, pero impone un importante reto: la eficiencia numérica. Si cada mapa ha sido construido con ERAs de 1000 puntos (mínimo suficiente para desarrollar análisis de recurrencia -identificación e interpretación de estructuras-) entonces las entradas y salidas neuronales se convierten en paquetes matriciales de dimensiones gigantescas.

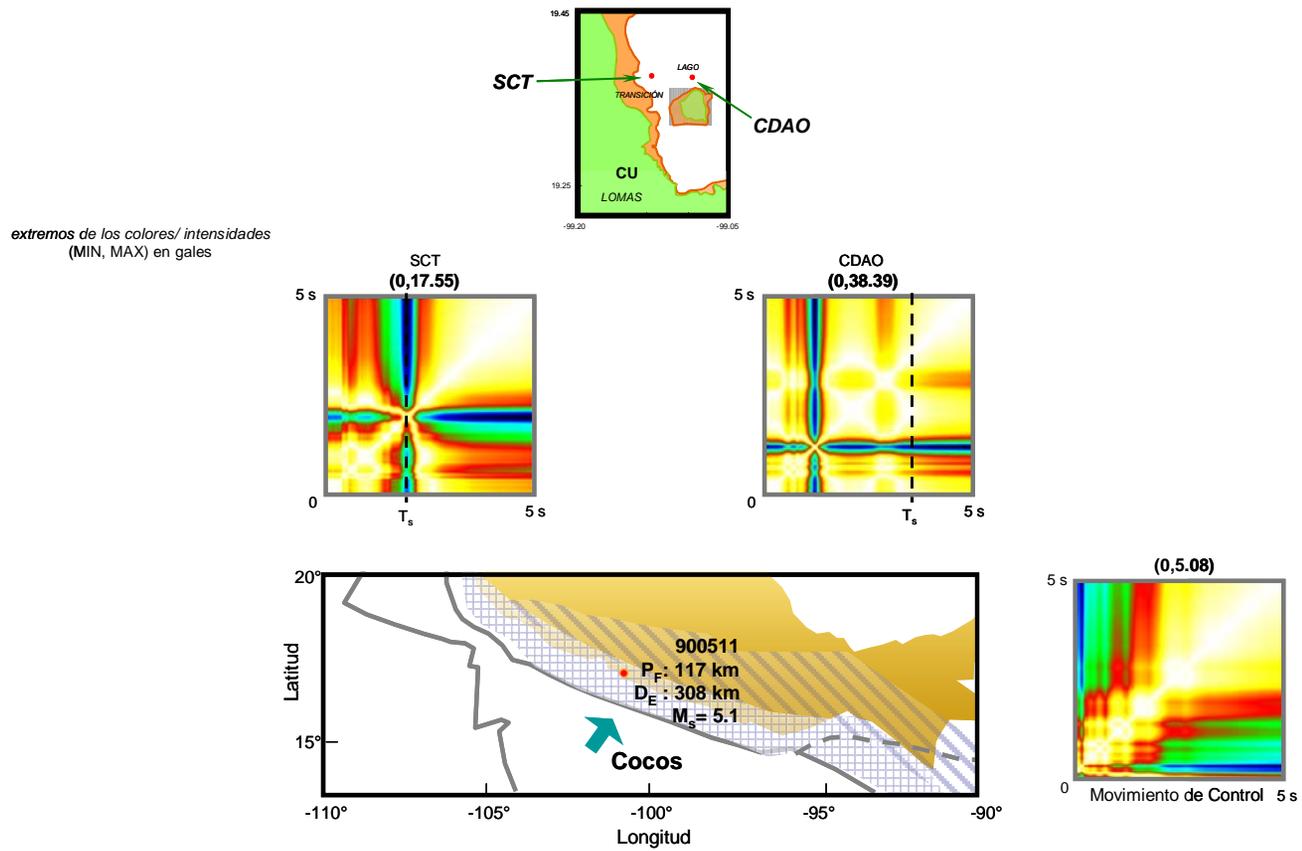


Figura 5.96 MR de los sitios SCT y CDAO para el sismo del 11 de mayo de 1990

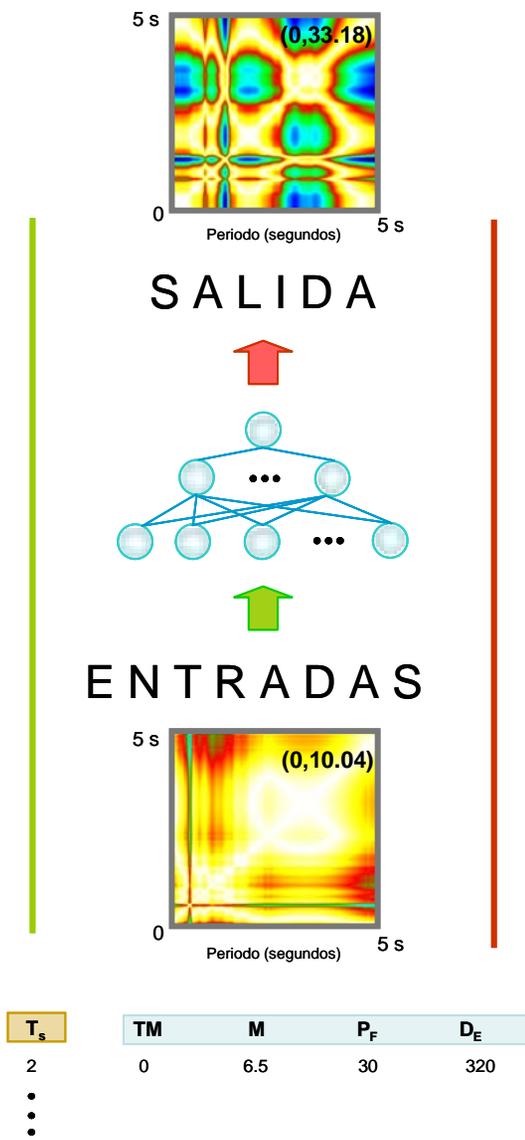


Figura 5.97 Sustitución de los ERAs por MR en el modelo neuronal

Involucrar de forma equilibrada a los cuatro Parámetros E con 1000 columnas y 1000 renglones (10,000 números que constituyen el MR de entrada -CU-) tal que se expresen correctamente las relaciones con el Parámetro S y las 10,000 salidas (1000 renglones y 1000 columnas del MR de salida -sitio-) para más de 150 patrones o ejemplos de comportamiento, es el problema por resolver. Es un hecho que las ventajas de los MR radican en sus características visuales y su actuación dentro del conjunto de manifestaciones del **Proceso**, así que en esta investigación se propone el uso de las Eigenfaces EFs, técnica de reconocimiento de rostros, para la inspección, almacenamiento y disposición eficiente de este enorme conjunto de MR.

La dupla MR-EFs, como mancuerna en el procesamiento de señales, permite expandir la información de un conjunto de vectores (1D) hacia la bidimensión con fines de categorización, almacenamiento (como miembros de un espacio) y compresión (versiones simplificadas de la expansión 2D), con el beneficio de la transformación inversa en cualquiera de sus etapas.

Análisis de Series de Tiempo a través de MR-EFs

La metodología presentada aquí puede ser aplicada al estudio de cualquier serie de tiempo. Las condiciones y procesos matemáticos para la construcción de MR y el análisis de imágenes a través de EFs se detallan en el Capítulo 4 de esta tesis por lo que en esta oportunidad sólo se describe la secuencia para su aplicación acoplada. De acuerdo con las operaciones generales de la Fig. 5.98, en pre-proceso,

- a) dado un conjunto de series de tiempo (en este caso vectores ERA),
- b) se calcula el MR de cada una de ellas y
- c) se encuentra el espacio de fase correspondiente al conjunto
- d) para expresar al MR como una combinación lineal de las eigenfaces y convertirlo en un punto,

y en post-proceso,

- a) conocido un punto
- b) se refiere a un espacio de fase conocido y
- c) a través de sus eigenfaces se calcula su MR
- d) para definir la serie original (en este caso vector ERA) correspondiente a ese MR.

El espacio de fase resulta de arreglar el conjunto de MR como matriz (cada columna es un MR expresado como vector) y calcular sus eigenvectores. Una vez construido el espacio de fase, cada MR puede ser expresado como una combinación lineal de las eigenfaces, convirtiendo un MR *completo* en un punto en el espacio de fase representado con unos pocos valores. Note que la dimensión de los vectores en el espacio de fase será igual al número de vectores usado como la base ortogonal del espacio de fase, es decir, el número de MR en la base de datos. Los eigenvalores más grandes representan la información sustancial de la imagen por lo que se puede usar un subconjunto de éstos para representar el elemento (MR) completo, abreviando el vector correspondiente.

Este proceso puede ser aplicado cuando: a) se requieran descripciones detalladas de señales que, en conjunto, expresan un mismo fenómeno y b) se necesite manipular grandes volúmenes de información numérica en esquemas de modelado con múltiples entradas y salidas.

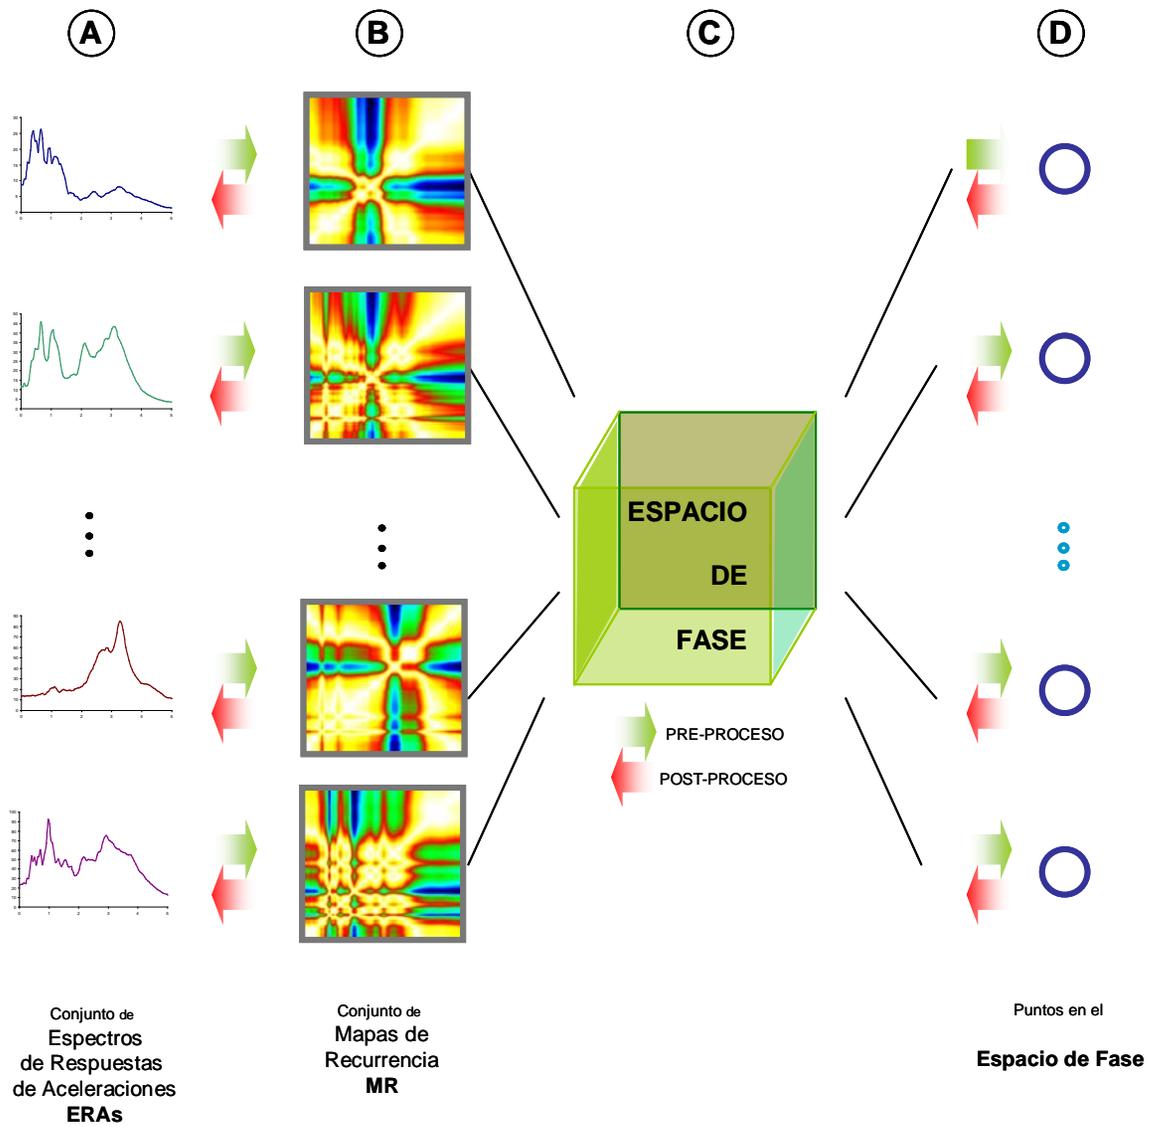


Figura 5.98

Proceso de análisis de ERAs usando la dupla MR-EFs

- Ejemplo de aplicación

Considere tres series de tiempo de entrada, cada una con 2000 valores, como las mostradas en la Fig. 5.99. El primer paso en la etapa de pre-procesamiento es calcular el MR de cada serie de tiempo de entrada.

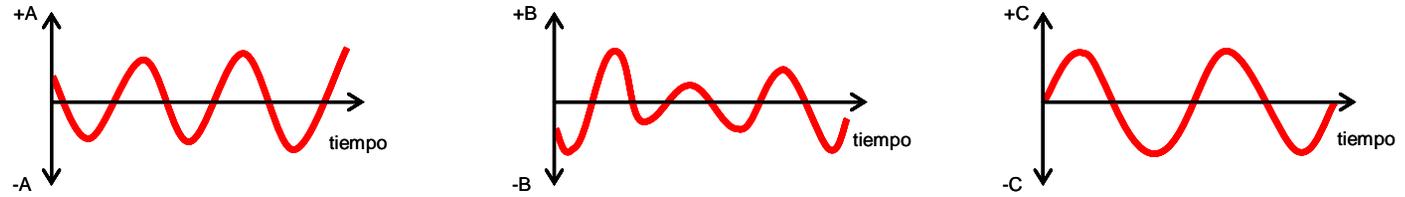


Figura 5.99 Ejemplos de Señales

Los MR resultantes se muestran en la Fig. 5.100. El siguiente paso es la generación del conjunto de eigenfaces de los MR mostrados anteriormente. Estos eigenfaces forman el espacio de fase y por lo tanto son tratados como una unidad. Un ejemplo de eigenface para un MR se muestra en la Fig. 5.101.

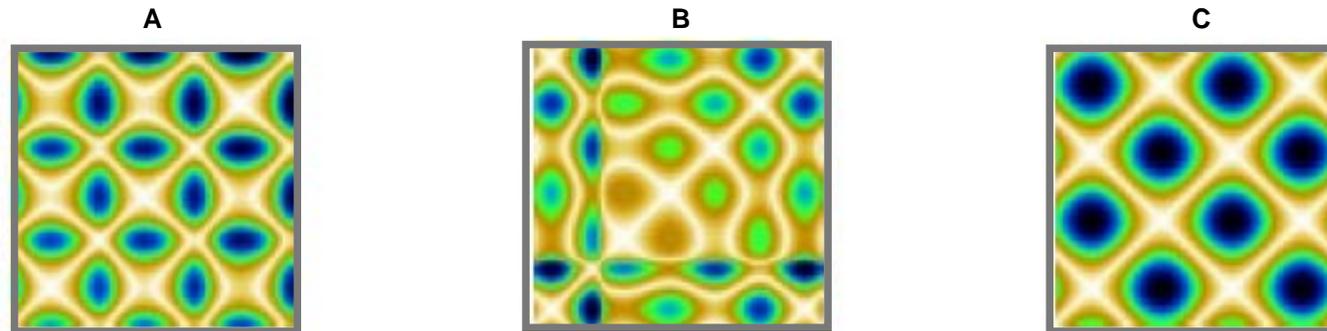


Figura 5.100 MR de las señales

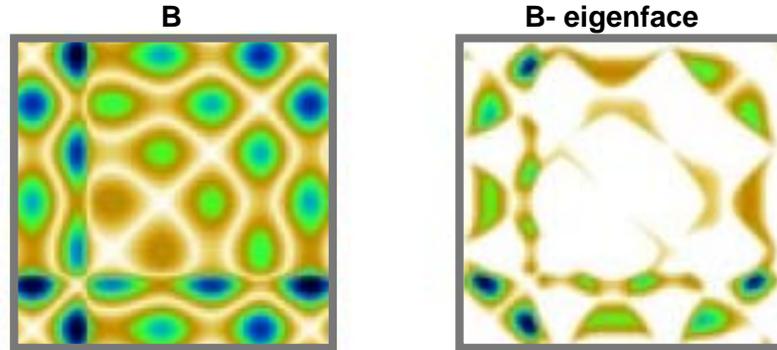


Figura 5.101 Ejemplo de MR-eigenface

Los vectores en el espacio de fase muestran el peso que cada eigenface tiene en el MR. Estos vectores no-normalizados se muestran a continuación (se mantiene el orden de los MR anteriores):

```
(777.1191573465204, -494.3188957993881, 12.325170500631794)
(1448.5151494857735, 268.12345386239616, 6.803736657263384)
(138.87833187137394, -30.50296638025993, -139.9314167509452)
```

Dados los vectores en el espacio de fase, los MR originales y las series de tiempo originales pueden ser recuperadas con gran precisión, como lo muestra la Fig. 5.102.

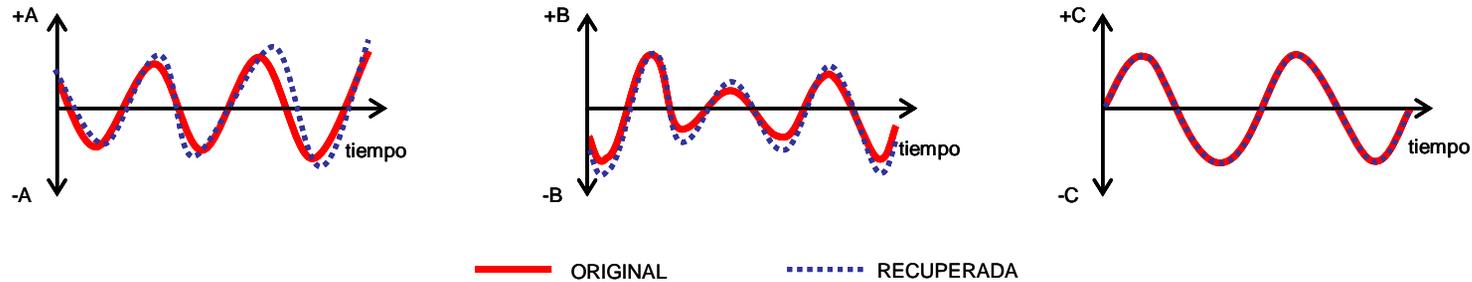


Figura 5.102 Señales recuperadas usando la dupla MR-EFs

Red Neuronal

Finalmente, el modelo neuronal se transforma en lo que se muestra en la Fig. 5.103. Este esquema exhibe las etapas de operación del sistema conexionista, donde la Dinámica No Lineal y el reconocimiento de imágenes forman parte de la presentación y manipulación de la información, pero la RN continúa siendo el cerebro funcional. Son 168 los patrones que conforman el conjunto de entrenamiento (de 198 ERAs en la base de datos, fueron separados 30 para la prueba del modelo) por lo que 168 es el número máximo de componentes vectoriales (longitud máxima de los eigenvectores).

Después de una serie de evaluaciones tipo “prueba y error” se decidió que la longitud óptima para reconstruir MR sin pérdidas que repercutieran en la calidad de los ERAs recuperados es 112 componentes vectoriales. Se tienen entonces 117 entradas y 112 salidas de 168 patrones de comportamiento. Comenzando con topologías *escasas* (mínimo número de nodos ocultos) se entrenaron redes monocapa con 150 y hasta 500 nodos ocultos (incrementos de 25 nodos en cada operación) generando resultados en etapa de entrenamiento muy por encima del criterio de terminación $(= ||\text{ERA}_{\text{medido}} - \text{ERA}_{\text{calculado}}|| \leq 10 \text{ gales})$.

Debido a la complejidad del problema es necesario realizar los ensayos con dos capas ocultas de tal forma que las conexiones eleven la dimensión del funcional neuronal. Las estructuras parten de 100 x 100 (no. de nodos_{1a.capa} x no. de nodos_{2da.capa}) y si el modelo no cumple con ϵ se aplica un incremento de 25 nodos en la primera capa y segunda capa en oportunidades diferentes. La estructura nodal más exitosa ($\epsilon \leq 7 \text{ gales}$) se detalla en la Fig. 5.104.

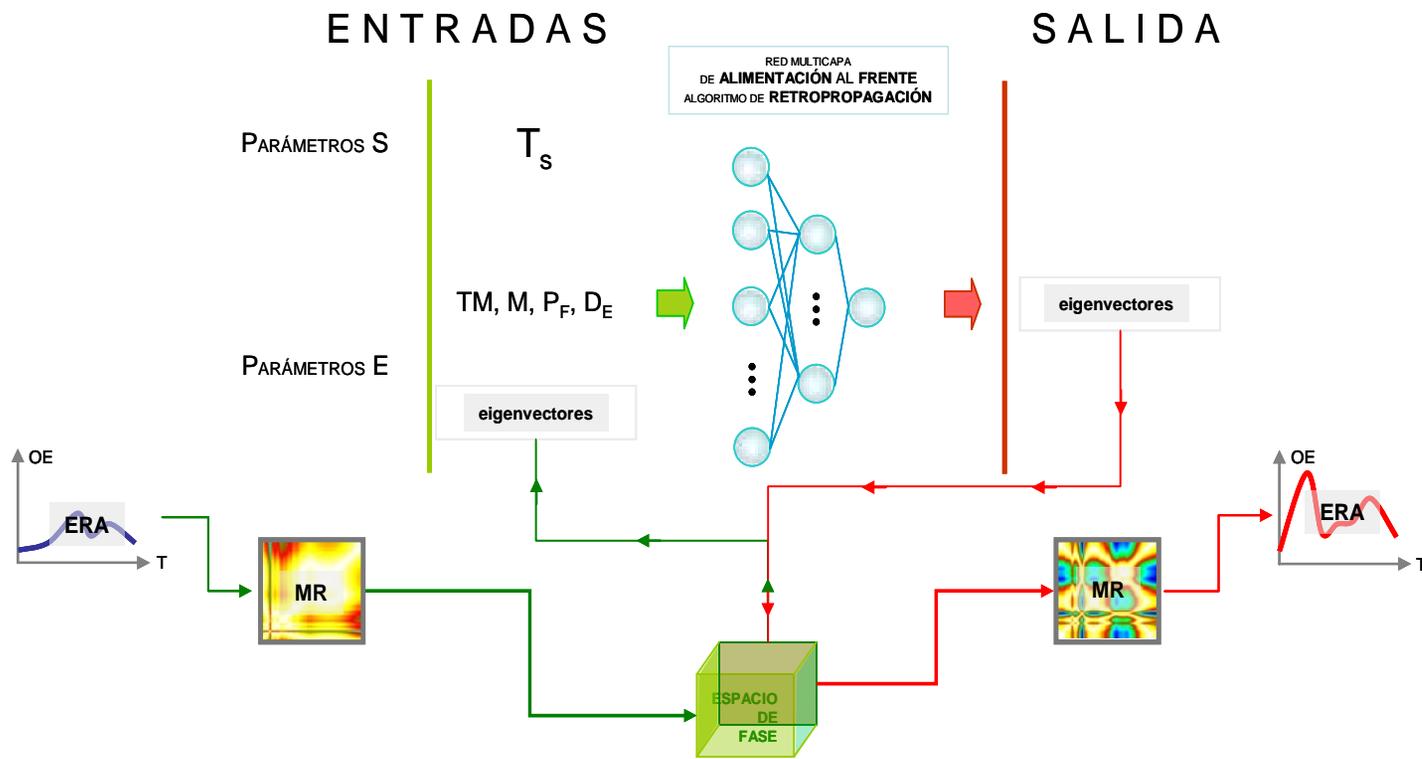


Figura 5.103 Señales recuperadas usando la dupla MR-EFs

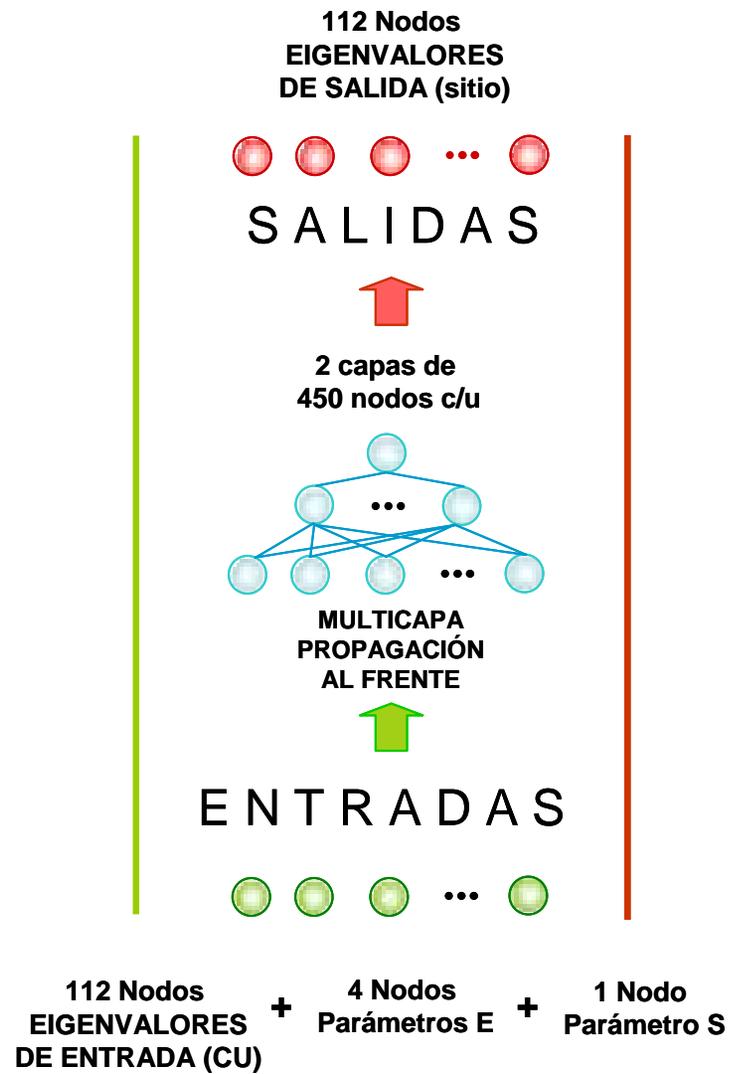


Figura 5.104 Estructura nodal del modelo neuronal

Entonces la RN mapea la información:

- de Entrada

Los eigenvalores de la historia sísmica de CU conforman el espacio de fase que contiene las posibles condiciones sismogénicas a través de características expuestas en los MR. Las condiciones de entrada se expanden de sólo parámetros sísmicos (como en el caso de una ley de atenuación) a una imagen que deberá ser *distorsionada* de acuerdo con un parámetro (T_S) que ubica y distingue al depósito de suelo.

Piense que los MR estudiados se comportan como puntales del espacio construido y entre estos soportes se encuentran condiciones sísmicas y de suelo no monitoreadas pero posibles. Como la información dentro de los mapas es compleja e incluso en algunos aspectos escapa de nuestra percepción del fenómeno, se adhieren *explícitamente* los factores que nuestra experiencia dicta como conductores de los efectos sísmicos para modificar las entradas, aún cuando se debe entender que en los MR están *implícitos* el efecto de la fuente, el de la trayectoria, el de la fuerza de la sacudida e incluso el de comportamiento del sitio de control.

Los cambios en los Parámetros E son fácilmente comprendidos por los ingenieros de la práctica, pero la modificación de las estructuras en los MR de CU deben ser dirigidos con otro esquema *inteligente*. En este trabajo de tesis, para estimar respuestas a eventos no incluidos en la base de datos, sólo se permite al usuario modificar los valores de [TM, MP_F, D_E] y escalar las intensidades de los MR. Fuera del alcance de esta investigación se encuentra la manipulación del movimiento de control en su expresión 2D.

Es importante señalar que la *experiencia* se genera a partir de efectos observados de donde se *infieren* las causas, los patrones y los esquemas de modelado. No existen condiciones bien conocidas para deducir universos específicos, así que la concepción hipotética de estar creando un espacio *completo de respuestas del valle* (del que no se pueden expresar numéricamente los límites ni las leyes que lo gobiernan) no resulta absurda y sí muy útil para plantear los *números* en las entradas y las salidas.

hacia la

- de Salida

Son los eigenvalores CU (abreviación de la información de ERAs en bi-dimensión) y los Parámetros E los que generan el patrón de cambio en los MR de respuesta (nivel de intensidad) y las relaciones entre estos vectores y T_S los que precisan las estructuras (*estados*) propias de cada depósito.

El *espacio de fase* contiene (o eventualmente puede contener) todas las respuestas a la acción sísmica que amenaza al valle. Para *navegar* en este *espacio* se utiliza al sistema conexionista. La entrada, como ya se explicó, es alimentación directa (en pre-proceso se calculan los eigenvectores y el usuario decide sobre los Parámetros E y S que más le convengan). La salida puede ser un eigenvector sin transfigurar (si la entrada es un MR y una combinación paramétrica *conocida*) o transfigurado (si los componentes

vectoriales son modificados por la RN para que respondan a una combinación MR-CU-Parámetros S/E distinta a las contenidas en el archivo de entrenamiento) y requiere de un post-proceso para trasladarlo a una expresión útil en ingeniería práctica. El *cerebro* (RN) es usado entonces como un *conductor* y *traductor* de información y el fenómeno y sus leyes quedan implícitos en el espacio de fase.

En este punto es notable la diferencia entre el sistema propuesto y los esquemas de reconocimiento de caras que utilizan la técnica de EFs. En el caso de las herramientas desarrolladas para ubicar personas la tarea se concentra en la *clasificación*: rostro conocido/no conocido. Cuando se trata de una cara que no está incluida en la base de datos (no conocido) simplemente se agrega como un nuevo individuo y se amplía el espacio de fase.

En el sistema conexionista cuando un MR-CU y combinación paramétrica son conocidos, entonces la respuesta pertenece a una de las codificadas en el espacio de fase. En el caso de predicción de respuestas, el *cerebro* modifica los eigenvectores bajo las relaciones que generó de acuerdo con la *experiencia* sísmica, los eigenvectores transfigurados se proyectan en el espacio de fase y se genera el MR del punto encontrado. El sistema puede ser re-alimentado periódicamente conforme sucedan más sismos, agregar nuevos ERAs incrementa la calidad del *espacio de respuestas* sin necesidad de modificar funciones, ajustar parámetros ni replantear teorías.

Los fundamentos básicos del modelo en su etapa de construcción y operación son: i) las hipótesis no sustentadas en la física del problema son excluidas y ii) las herramientas de otros campos de la ciencia (funciones y parámetros) sin empatía con las observaciones *naturales*, no son invocadas.

Salida (resultados)

ESPACIO DE FASE. Los ERAs de salida provienen del *espacio de respuestas* (composición del espacio de fase y la RN). El *espacio* (esquemáticamente mostrado en la Fig. 5.105) compuesto de respuestas en superficie caracterizadas espacialmente (referidas a su situación geográfica X-Y y materiales específicos en Z), un administrador de información (espacio de fase) y un cerebro de cálculo (RN), representa la solución global a la tarea planteada en este segundo inciso de análisis.

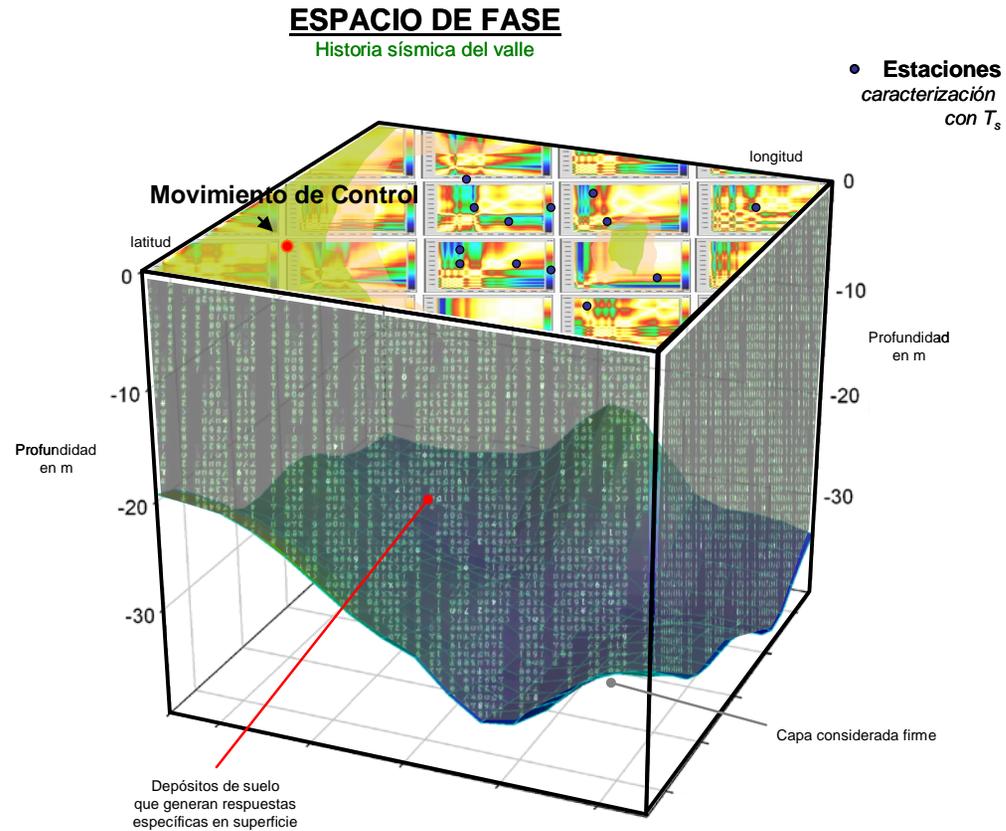


Figura 5.105

Espacio de respuestas: espacio de fase + RN (esquemización)

Los resultados que se presentan a continuación ejemplifican la competencia del modelo y fueron desarrollados sobre los sitios usados en la descripción de la metodología de análisis para darle sustento a las hipótesis expresadas sobre el **Sistema** y el **Proceso**.

- Sitio: **Secretaria de Comunicaciones y Transportes SCT**

T_s : 2.0 s

En la Fig. 5.106 se comparan las estimaciones neuronales y los ERAs calculados de las señales medidas en el sitio durante sismos *débiles*. Como se observa, las evaluaciones en prueba y entrenamiento son satisfactorias.

La RN *entendió* las OEs en intensidad y periodos (en el proceso de *aprendizaje* cuando nuestras respuestas son correctas se dice que hemos *entendido*).

La Fig. 5.107 contiene las respuestas que pertenecen a la categoría sismos *moderados*. Mientras que los ERAs de entrenamiento mantienen diferencias mínimas con los ERAs de señales *medidas*, el evento de prueba ya no es tan cercano al objetivo como en el caso de los sismos *débiles*.

No existen discrepancias importantes entre lo "real" y lo calculado, pero se debe señalar que debido a los invariables MR de SCT (estructura que se repite en todos los eventos), el sistema aprendió una geometría básica y consideró que los cambios (más delgadas y en mayor número las bandas *frías*) no son la constante en el comportamiento estudiado.

Los sismos *severos* (Fig. 5.108) incluso son los casos donde se reporta el mejor comportamiento en modo de entrenamiento y prueba. Es remarcable la capacidad del modelo para distinguir clases ya que SCT es el único sitio con este comportamiento de entre los 33 sitios de la base de datos.

Todos estos atributos permiten señalar a SCT como uno de los sitios donde los modelos de análisis bien estructurados, deben llegar a respuestas muy cercanas a lo que se experimenta durante las sacudidas si se consigue una buena ley de amplificación. Sin que esto signifique que este depósito se comporta linealmente, el hecho es que el patrón geométrico (respuestas en términos de *estados*) es el mismo en sismos de cualquier intensidad y sismogénesis, incluso en el evento anómalo del 85/09/19 (año, mes día).

El sismo de Tehuacán, Puebla de 1999 (99/06/15) (Fig. 5.108), con elementos sismogénicos únicos en la historia sísmica de entrenamiento, se presenta como una buena prueba del comportamiento descrito.

La excelente predicción que el modelo ha hecho sobre un sismo de entrada con características tan distintas (en geometría) nos lleva a pensar que la RN reconoce la intensidad de entrada y genera un resultado más o menos intenso pero con modificaciones en cuanto a estructura. Los cambios topológicos se dan en la intensidad de las respuestas en el estado T_s y en el segundo modo de vibrar $T_s = 0.6 s$.

El ERA presentado en la Fig. 5.109 es la evaluación hecha para el sismo de Oaxaca del 30 de septiembre de 1999 (990930). La *doble joroba* que presenta el ERA medido no es reproducida totalmente por el modelo neuronal ya que no hay un comportamiento de ese tipo en la historia de entrenamiento de SCT.

Como el modelo está cerrado, se debe decidir sobre su inclusión como nuevo miembro del *espacio de respuestas* o calificar como adecuada la predicción de la RN por considerar que estas dos $OE_{máximas}$ no representan el comportamiento *natural* del sitio sino una desviación por las incertidumbres adheridas al proceso.

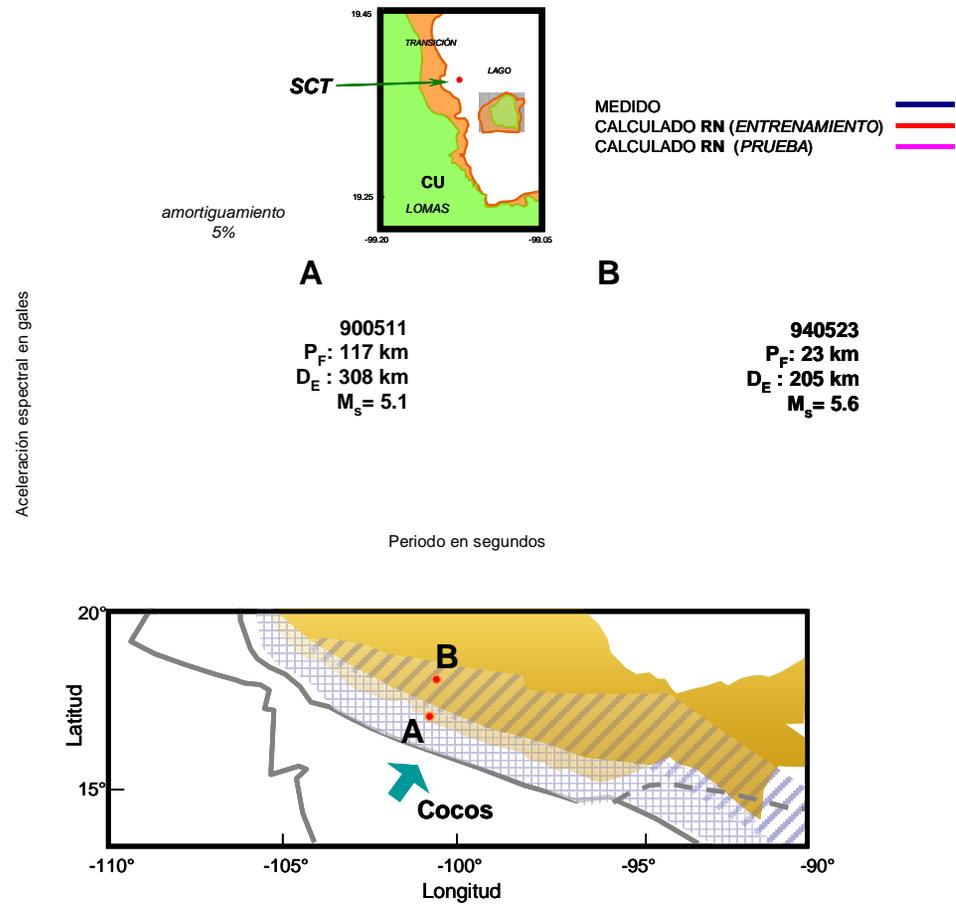


Figura 5.106 Respuestas en entrenamiento y prueba del modelo neuronal para SCT, sismos débiles

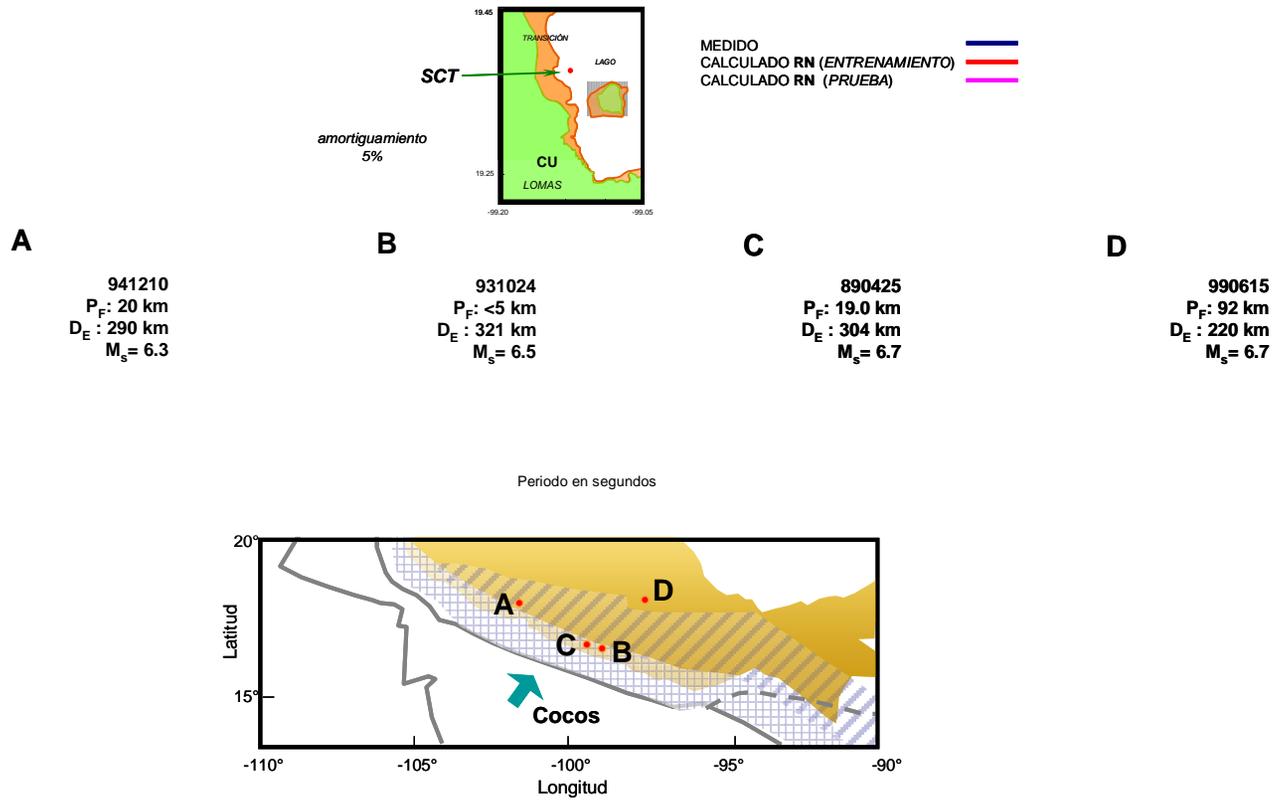


Figura 5.107 Respuestas en entrenamiento y prueba del modelo neuronal para SCT, sismos *moderados*

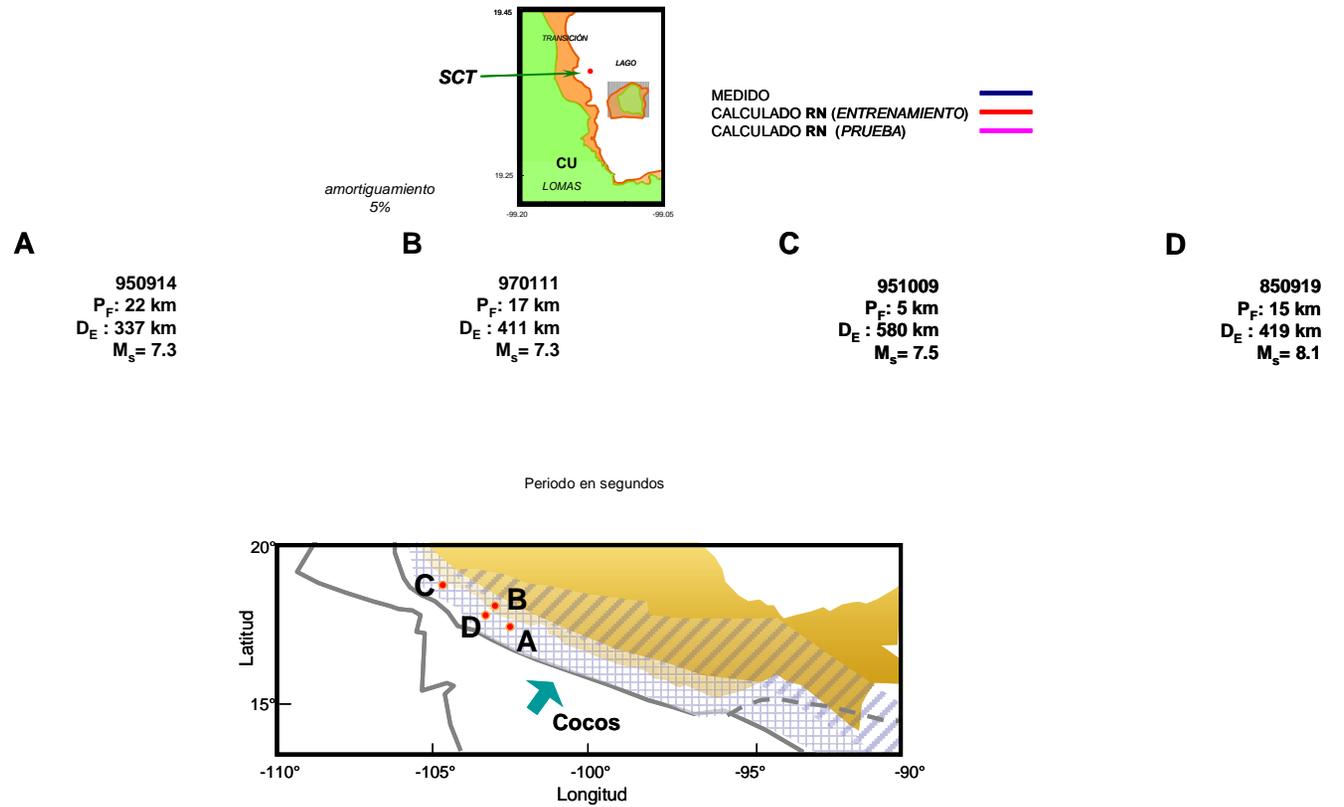


Figura 5.108 Respuestas en entrenamiento y prueba del modelo neuronal para SCT, sismos *severos*

Presentar los MR de las respuestas estimadas resulta un despliegue redundante. Sólo para mostrar los subproductos del procedimiento, en la Fig. 5.110 se incluye el MR obtenido al alimentar al modelo con el movimiento de control CU-97/01/11 y los parámetros S ($T_s = 2.0$ s) y E ($TM = 0, P_F = 17$ km, $D_E = 411$ km, $M = 7.3$). Se aprecia en la figura el inmejorable reconocimiento del modelo de la estructura básica del sitio SCT.

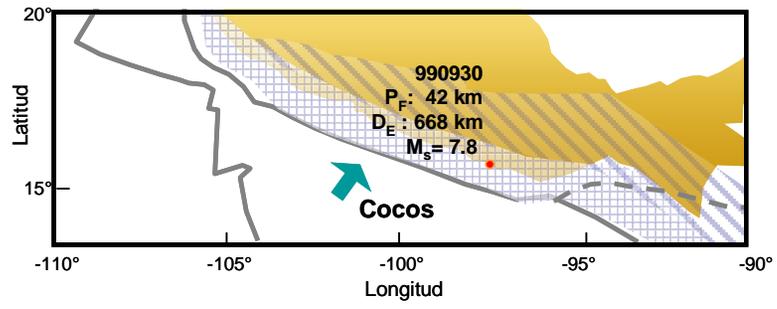
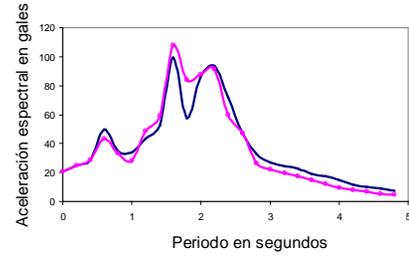
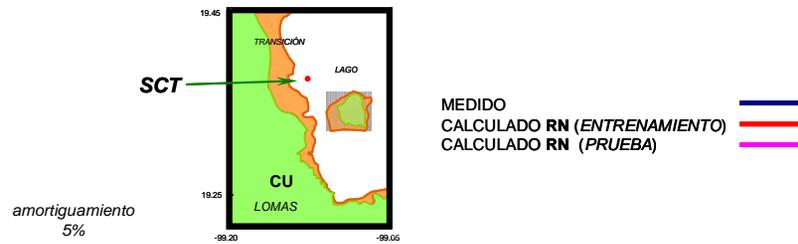


Figura 5.109 Predicción neuronal para SCT de un sismo *severos*

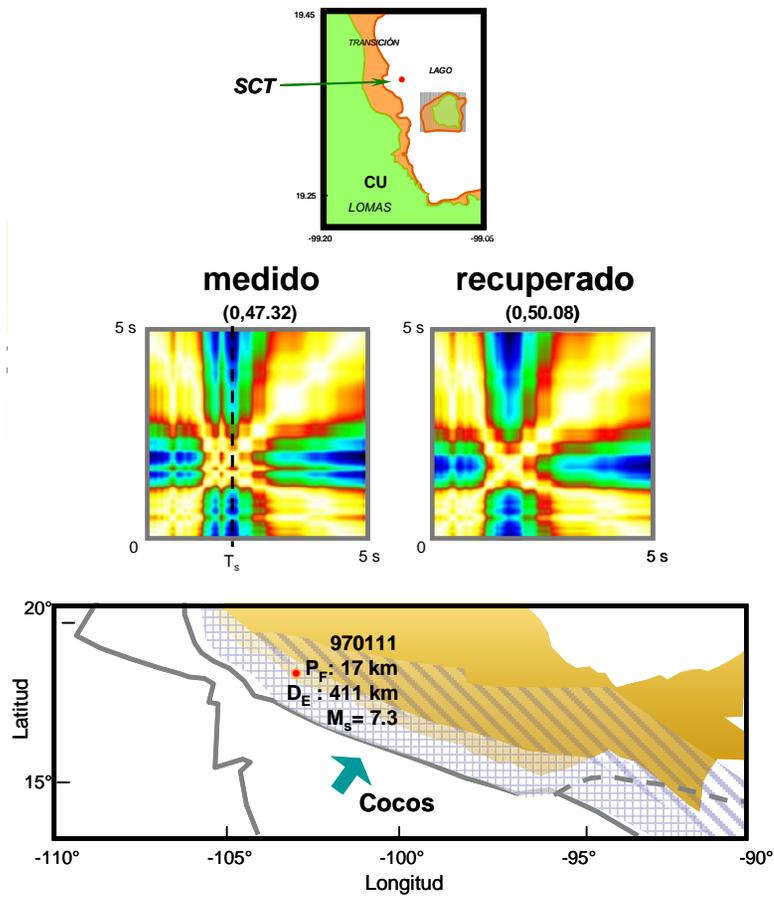


Figura 5.110 MR obtenido del eigenvector calculado por la RN para un sismo *severos*

- Sitio: Garibaldi

T_5 : 2.24 s

Las diferencias entre los ERAs de sismos *débiles* estimados por la RN y los ERAs medidos son más grandes de las alcanzadas en las respuestas en SCT. Sin embargo, como se aprecia en la Fig. 5.111, las estructuras fueron *entendidas* y las $OE_{máximas}$ ajustadas eficientemente en intensidad y periodo (Fig. 5.112). Las predicciones neuronales en entrenamiento y prueba para sacudidas más severas son mejores. El comportamiento general ratifica la hipótesis de que existe un grupo de estados que se activan en sacudidas *débiles* y otro conjunto de osciladores que lo hacen bajo la acción de eventos *fuertes* (Figs. 5.113 y 5.114). Particularmente para el sitio Garibaldi existe una marcada diferencia entre los patrones de respuesta a eventos *débiles* y los de *severos*.

Esta particularidad le da sentido a las recomendaciones *prácticas* de usar modelos específicos sólo para sismos *fuertes* (so pretexto de que son los que importan finalmente en diseño) y eliminar de las bases numéricas los sismos que no se ajustan a las tendencias pre-establecidas, es decir, los *débiles*.

La RN significa una mejora al modelado y sobre todo al conocimiento: la RN *entendió* que existe una relación y es capaz de manejar globalmente el fenómeno, sin calificar el comportamiento del depósito (lineal o no lineal), sin ajustar y discriminar patrones que no se ajusten a teorías o funcionales, y sin obligar a los *camino*s de información que se comporten como lo dicta nuestro nivel de conocimiento.

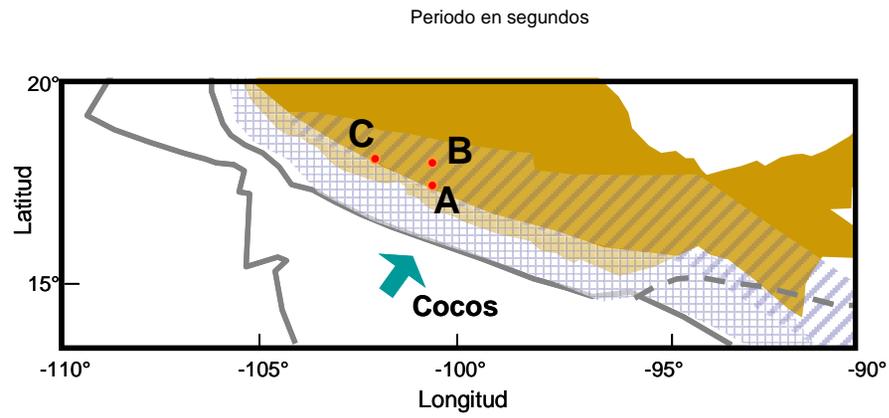
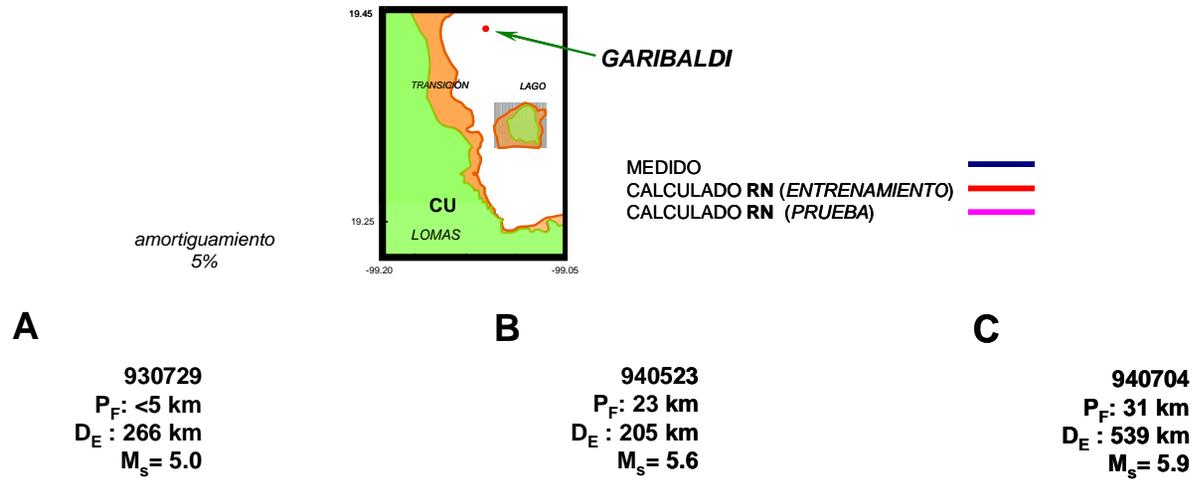


Figura 5.III Predicción neuronal para Garibaldi, sismos débiles

extremos de los colores/ intensidades
(MIN, MAX) en gales

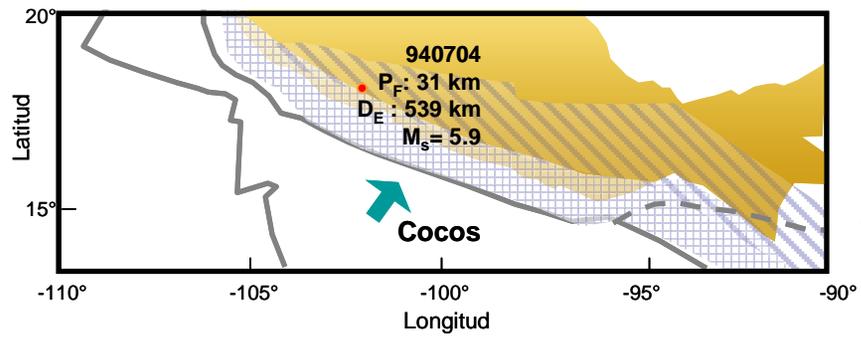
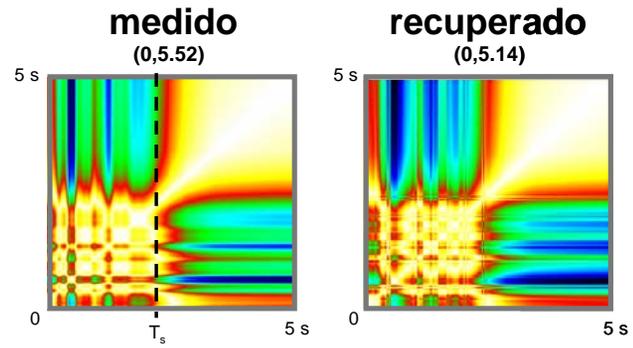
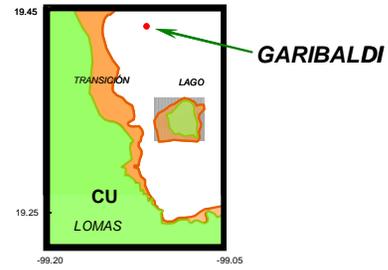


Figura 5.112 MR obtenido del eigenvector calculado por la RN para un sismo *débil*

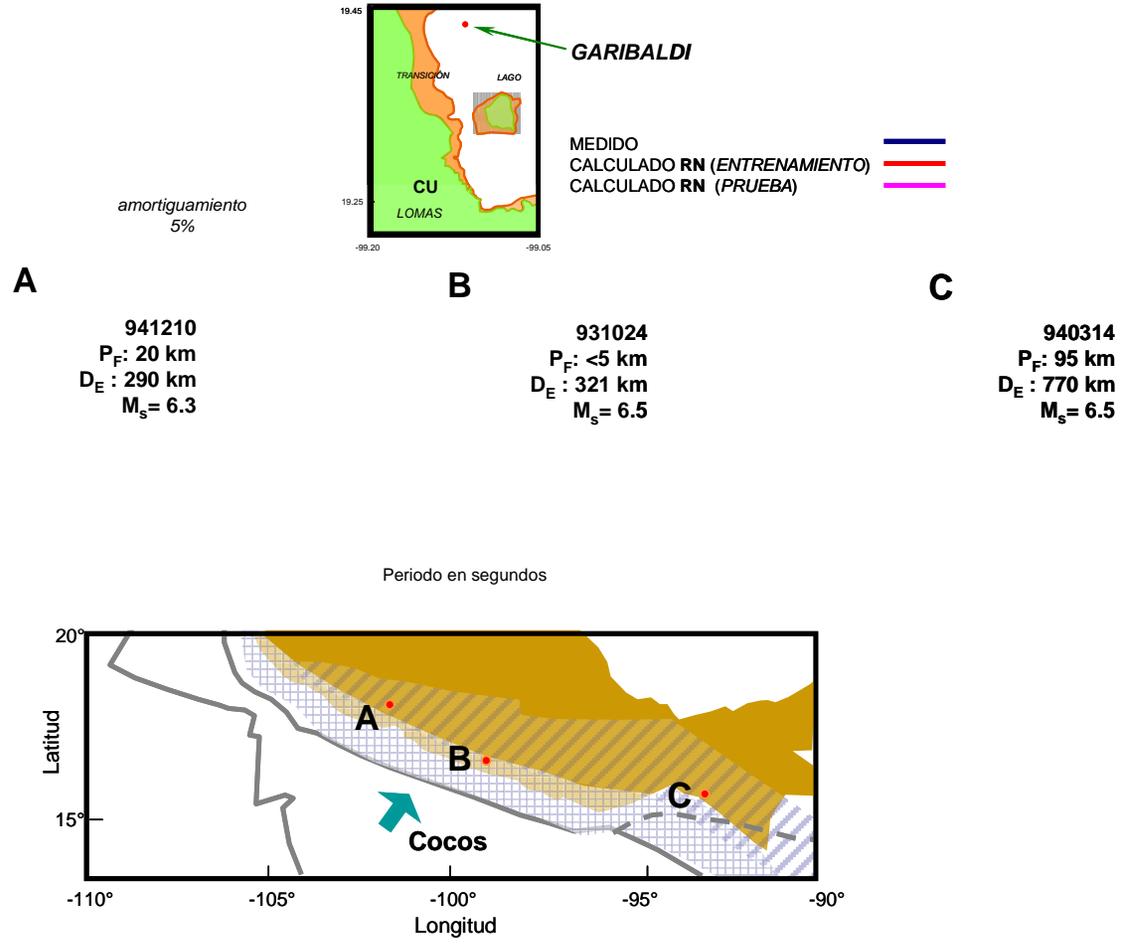


Figura 5.113 Predicción neuronal para Garibaldi, sismos moderados

Aceleración espectral en gales

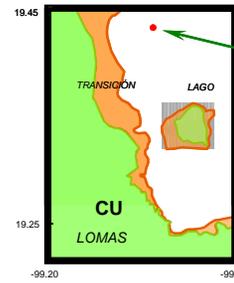
amortiguamiento
5%

A

950914
P_F: 22 km
D_E: 337 km
M_S = 7.3

B

951009
P_F: 5 km
D_E: 580 km
M_S = 7.5



GARIBALDI

MEDIDO
CALCULADO RN (ENTRENAMIENTO)
CALCULADO RN (PRUEBA)



Periodo en segundos

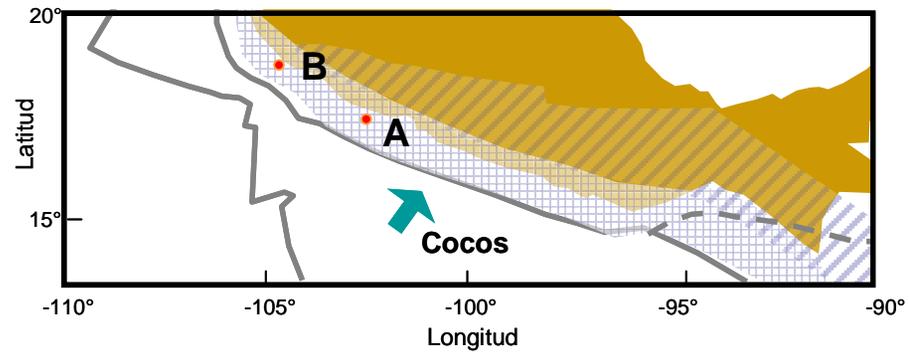


Figura 5.114

Predicción neuronal para Garibaldi, sismos *severos*

- Sitio: **Balderas**

T_S : 2.4 s

El caso del sitio Balderas resulta particularmente interesante por la aparente compleja estructuración de sus MR. En el apartado donde se describen las geometrías y sus relaciones con el conocimiento sísmico se calificó el comportamiento del depósito como *errático*. No se encontraron relaciones “claras” entre intensidades, sismogénesis, incluso se discurre sobre el efecto que el ambiente que rodea a la estación tiene sobre las señales registradas y sus componentes ruidosas. Los óptimos resultados presentados en las Figs. 5.115, 5.116, y 5.117 manifiestan: i) la individualidad del sitio dentro del espacio de fase, y ii) la habilidad de la RN para detectar los patrones geométricos (estados) que nuestra visión no advierte.

A pesar de que las predicciones en modo de trabajo directo no son tan cercanas como en otros sitios, el comportamiento para sismos importantes (*severos*) es bastante aceptable.

Note que las respuestas calculadas con RN se alejan más de las medidas conforme la intensidad del sismo crece lo que puede deberse a la mínima presencia de sacudidas fuertes en los datos que caracterizan a Balderas. Conforme se integre más información al espacio de fase se puede esperar una mejora en la generalización neuronal y definiciones más claras en el cambio de formas espectrales cuando se sujeta al depósito a distintos niveles de cargas dinámicas.

Aceleración espectral en gales

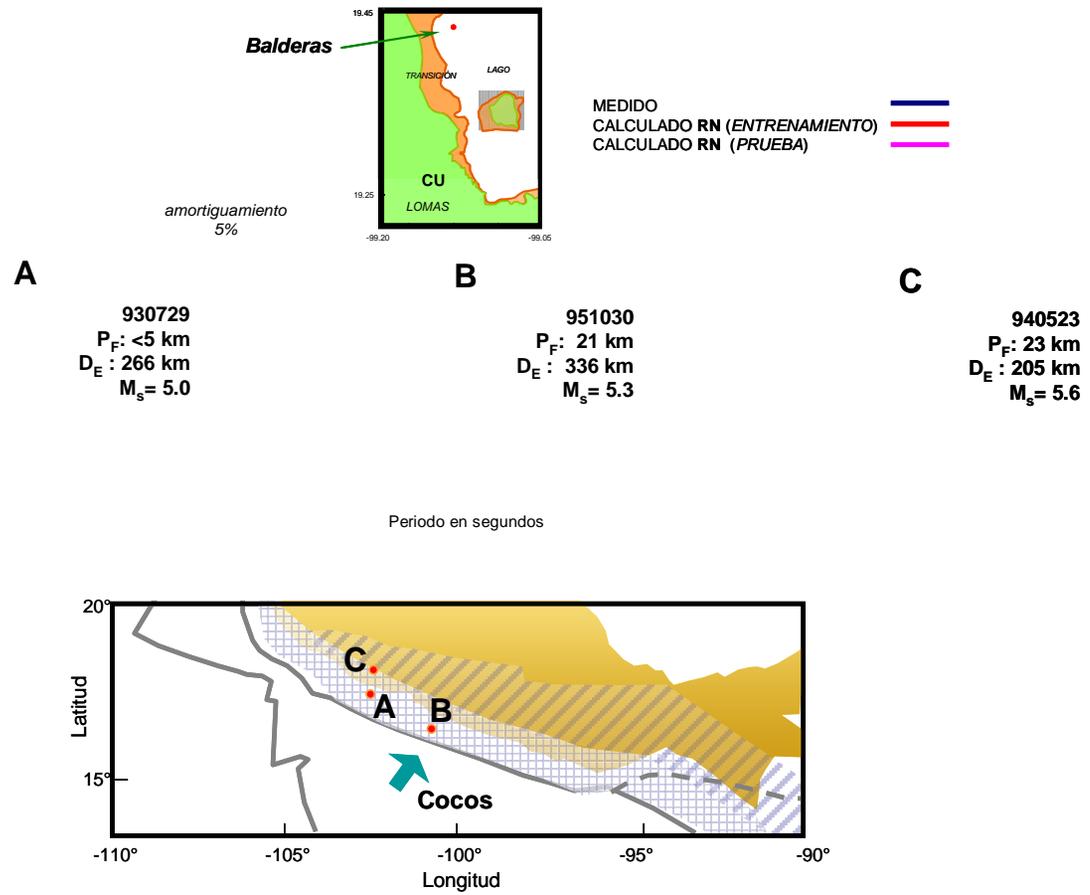


Figura 5.115 Predicción neuronal para Balderas, sismos débiles

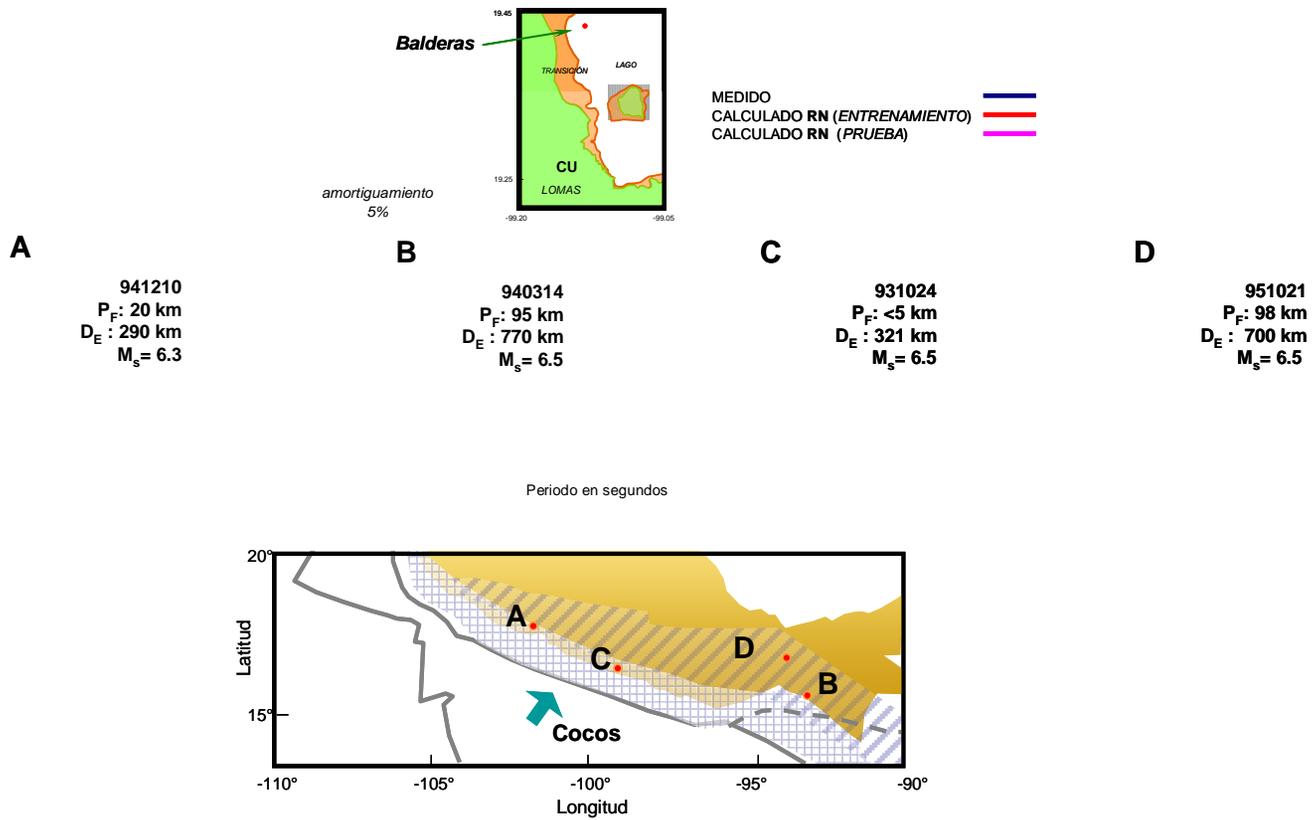


Figura 5.116 Predicción neuronal para Balderas, sismos *moderados*

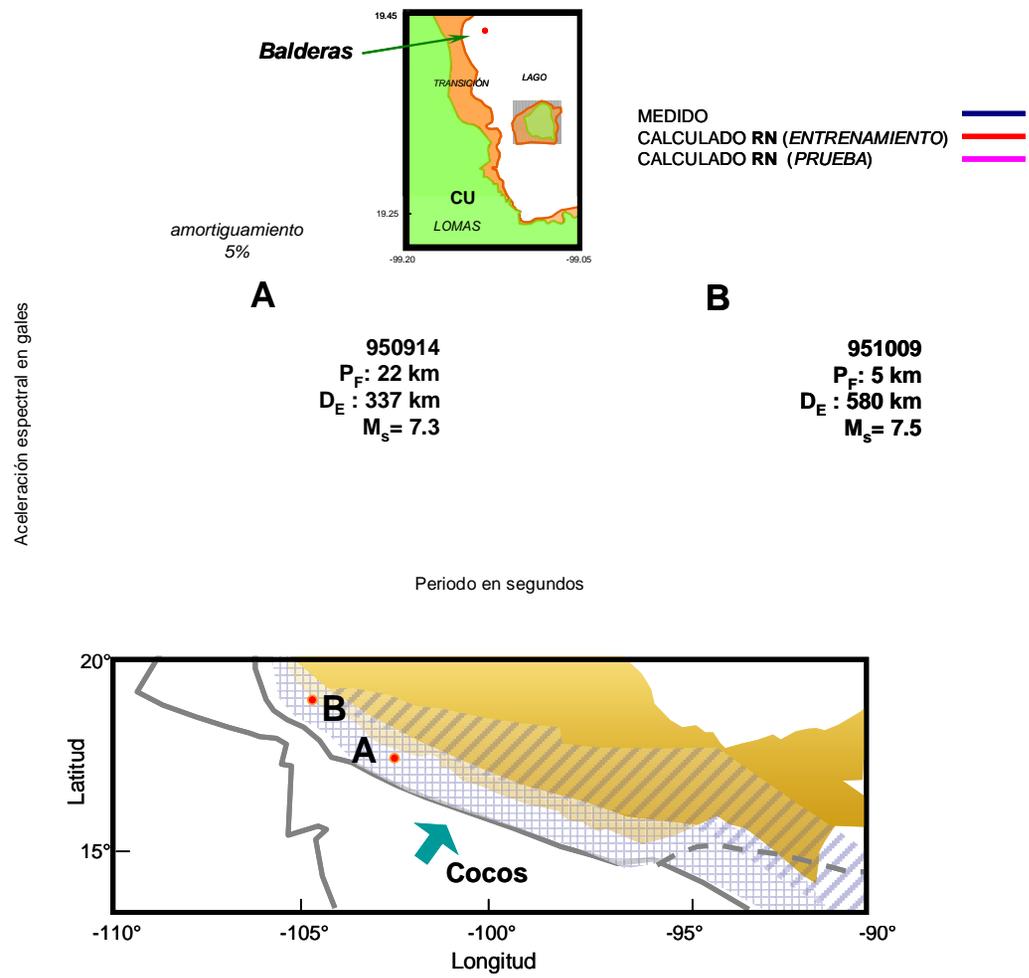


Figura 5.117 Predicción neuronal para Balderas, sismos *severos*

- Sitio: **Candelaria**

T_s : 3.0 s

En la Fig. 5.118 se muestran los resultados obtenidos en etapa de entrenamiento para sismos *débiles*. Las distancias entre los estados “reales” y los calculados son más grandes que en los depósitos anteriores, aunque la RN mantiene su buen comportamiento en la predicción de $OE_{máximas}$ y los periodos donde ocurren.

Como se observa en las Figs. 5.119 y 5.120 las predicciones en prueba y entrenamiento mejoran considerablemente conforme el sismo es más intenso. Las respuestas neuronales son más “suaves” que los ERAs medidos pero el ajuste promedio en el conjunto de las OEs es favorable.

Observe cómo las formas espectrales estimadas provienen de una geometría constante. En este depósito se reconocieron estados activados que cambian muy sutilmente en el rango de sacudidas estudiado. Al igual que el sitio SCT, las amplitudes son las que se modifican más drásticamente pero los estados (T) que se activan se mantienen en los ERAs presentados.

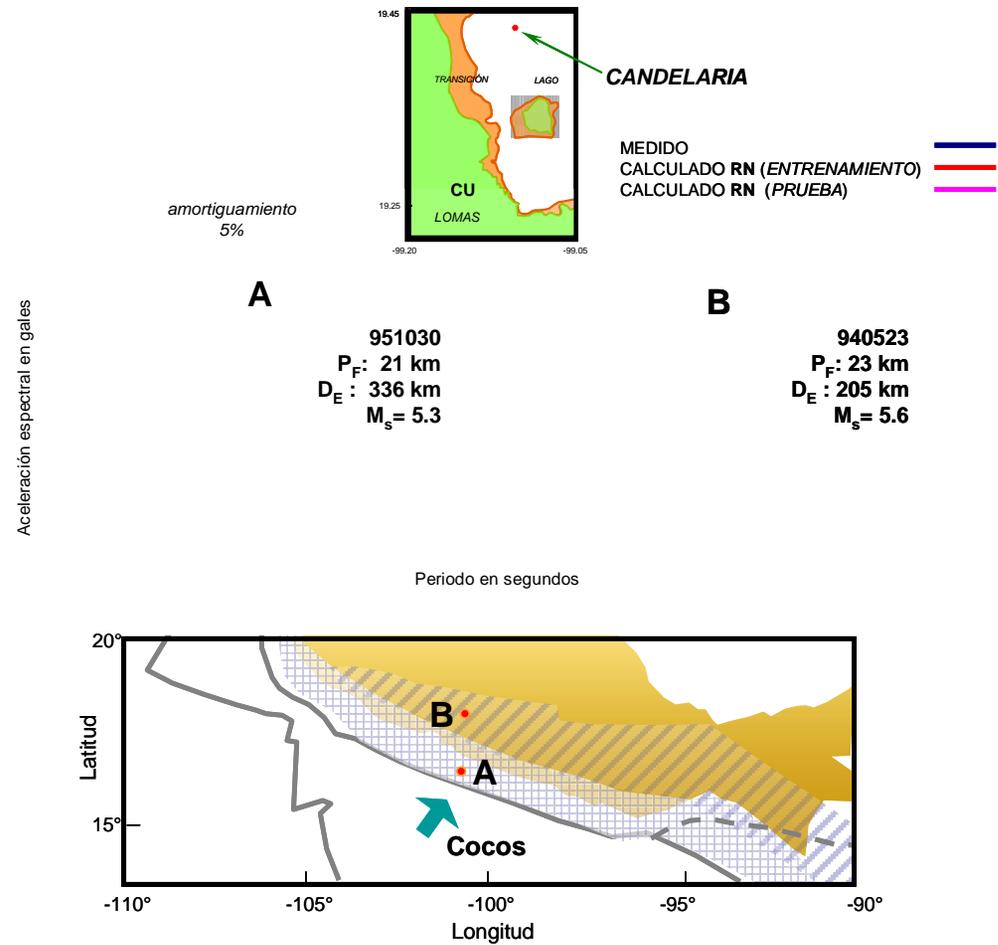


Figura 5.118 Predicción neuronal para Candelaria sismos *débiles*

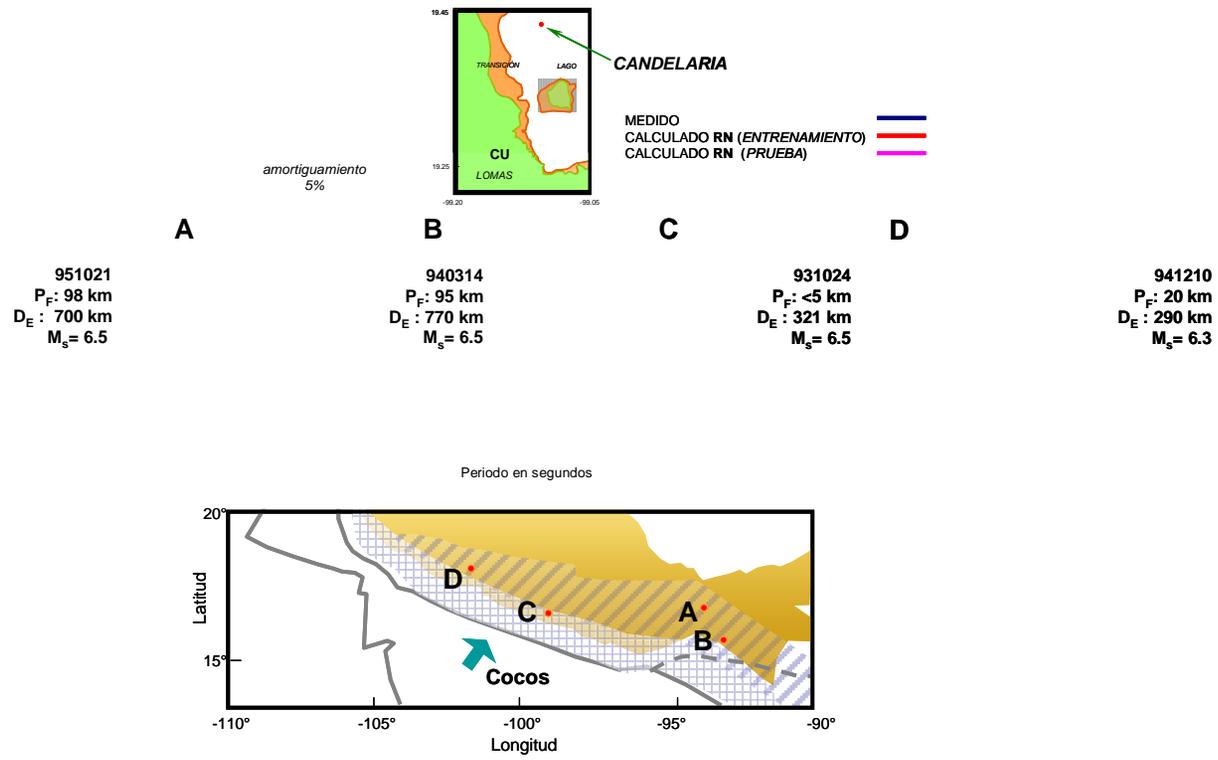


Figura 5.119 Predicción neuronal para Candelaria, sismos moderados

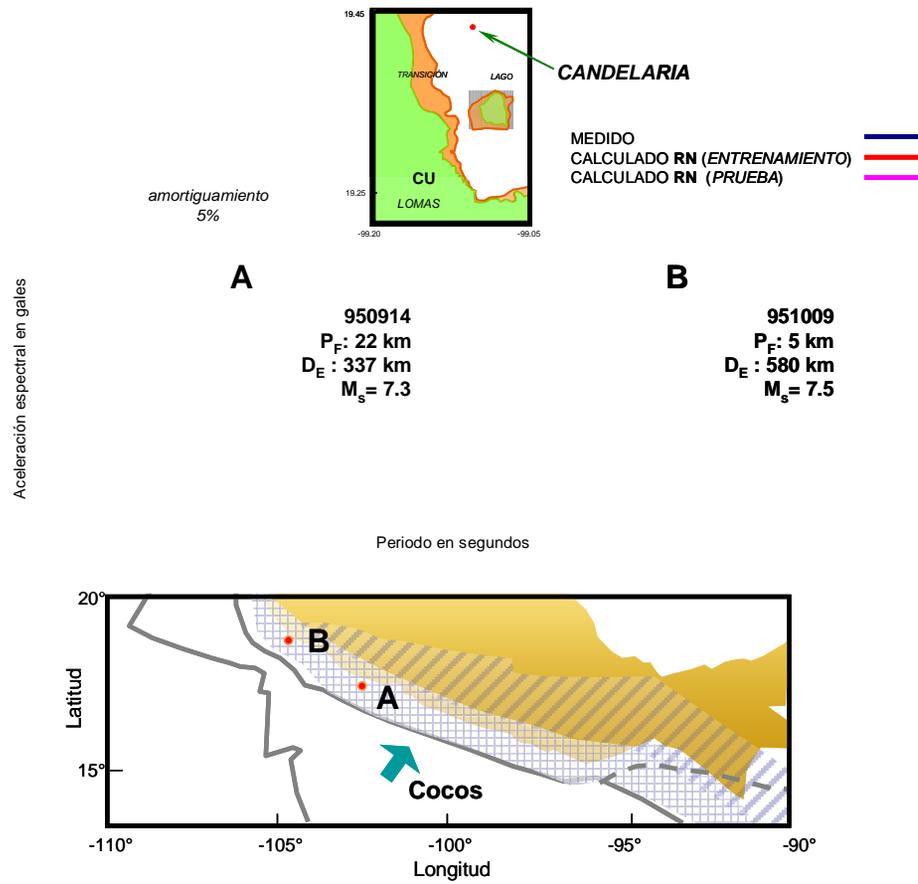


Figura 5.12o Predicción neuronal para Candelaria, sismos *severos*

- Sitio: Central de Abasto Oficinas CDAO

T_3 : 3.5 s

Este depósito ejemplifica la existencia de una frontera de comportamiento entre sismos *débiles* y *severos*. En las Figs. 5.121, 5.122 y 5.123 se muestran ambas tendencias de comportamiento. Si bien la información sobre el sitio es algo escasa, por lo menos se logra ubicar puntos sobre toda la base de la variable M y no es imprudente argumentar sobre la activación y desactivación de estados de acuerdo con la intensidad de entrada.

En la Fig. 5.121 se muestran las excelentes predicciones para las sacudidas menores durante el entrenamiento y la prueba de la RN. En la Fig. 5.122 se presenta el MR recuperado para el sismo de prueba (*débil*). Los detalles geométricos son reproducidos fielmente y no se observa ninguna desviación en la ubicación de las OEs máximas. Contrario a lo que se espera si pocos sismos débiles fueron presentados a la red durante el entrenamiento, las estimaciones neuronales alcanzan el agudo máximo en el segundo modo de vibrar y dibujan correctamente las zonas blancas de nula activación. ¿Por qué si no hay información al respecto, la RN ajusta asombrosamente los ERAs?, la respuesta puede ir de la mano con el argumento de un patrón único de respuesta en todo el valle para sismos menores. Este aspecto se tratará a detalle más adelante.

Cuando la demanda sísmica crece en intensidad, la meseta de máximos típica de este sitio ($3 < T < 4$) es bien reconocida por la RN y las relaciones que guardan estos valores con las ordenadas que se presentan en T_2 (segundo modo de vibrar) prácticamente son las mismas que las obtenidas en ERAs "reales". Es muy interesante el despliegue geométrico del depósito y cómo la RN es capaz de identificar, a través del parámetro de clase T , el cambio en el ancho de las bandas *frías*.

La respuesta de la RN en modo de trabajo directo para el sismo de Oaxaca de 1999 (Fig. 5.124) permite puntualizar el *pensamiento* del modelo propuesto: la entrada es *similar* (cercana en el espacio de fase) a la del sismo 95/09/14 por lo que, para un mismo T (el mismo punto sobre la superficie del valle) la respuesta a esta nueva demanda debe ser muy *parecida* a la anteriormente generada (observe que el estado de $OE_{máxima}$ durante el evento del '99 es el mismo que en el sismo del '95).

Entra la condición XY (T) y el modelo reconoce el sitio, lee la demanda sísmica (eigenvector CU y parámetros E) y la relaciona con la historia del depósito. A través de las formulaciones construidas en entrenamiento la RN modifica el eigenvector histórico de acuerdo con los nuevos requerimientos y ofrece un eigenvector *transfigurado* de salida. En post-proceso este vector se proyecta en el espacio y se obtiene el MR y ERA correspondientes. Siguiendo este procedimiento y para decirlo de manera muy simplista, el resultado nomotético para el ejemplo 99/09/30 es la salida *transfigurada* del sismo del '95 (cambio sutil referido a la intensidad del sismo).

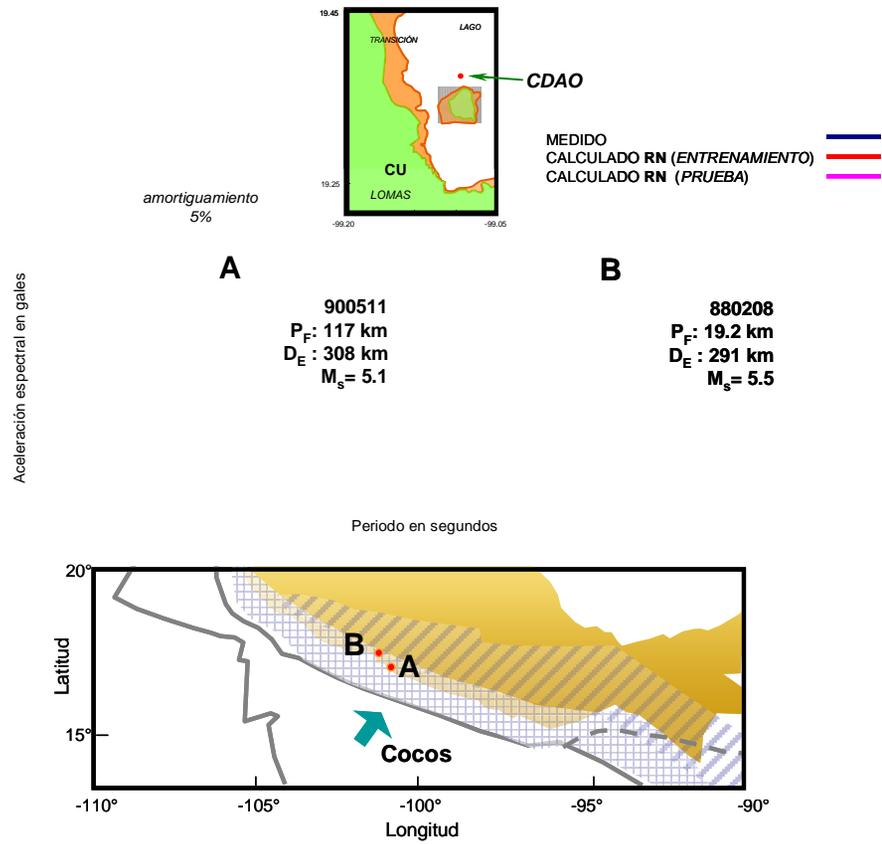


Figura 5.121 Predicción neuronal para Central de Abasto Oficinas, sismos débiles

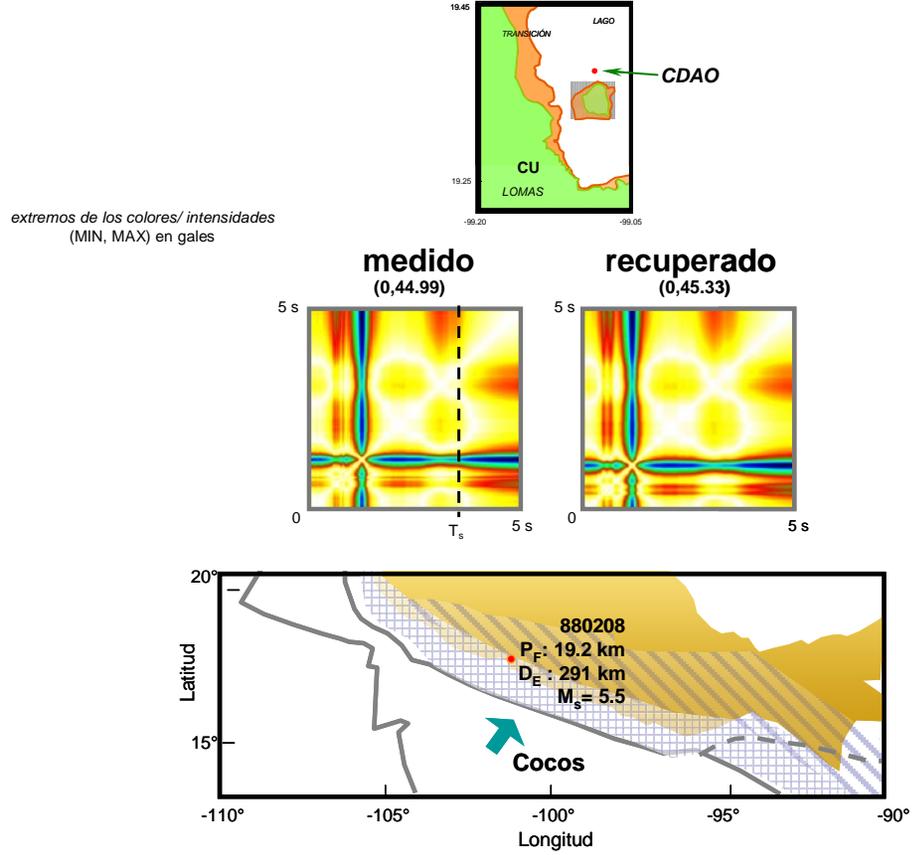


Figura 5.122 MR obtenido del eigenvector calculado por la RN para un sismo *débil*

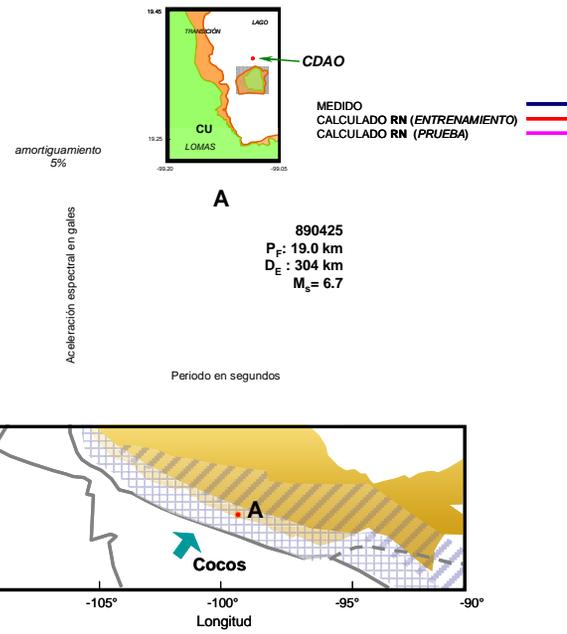


Figura 5.123 Predicción neuronal para Central de Abasto Oficinas, sismos *moderados*

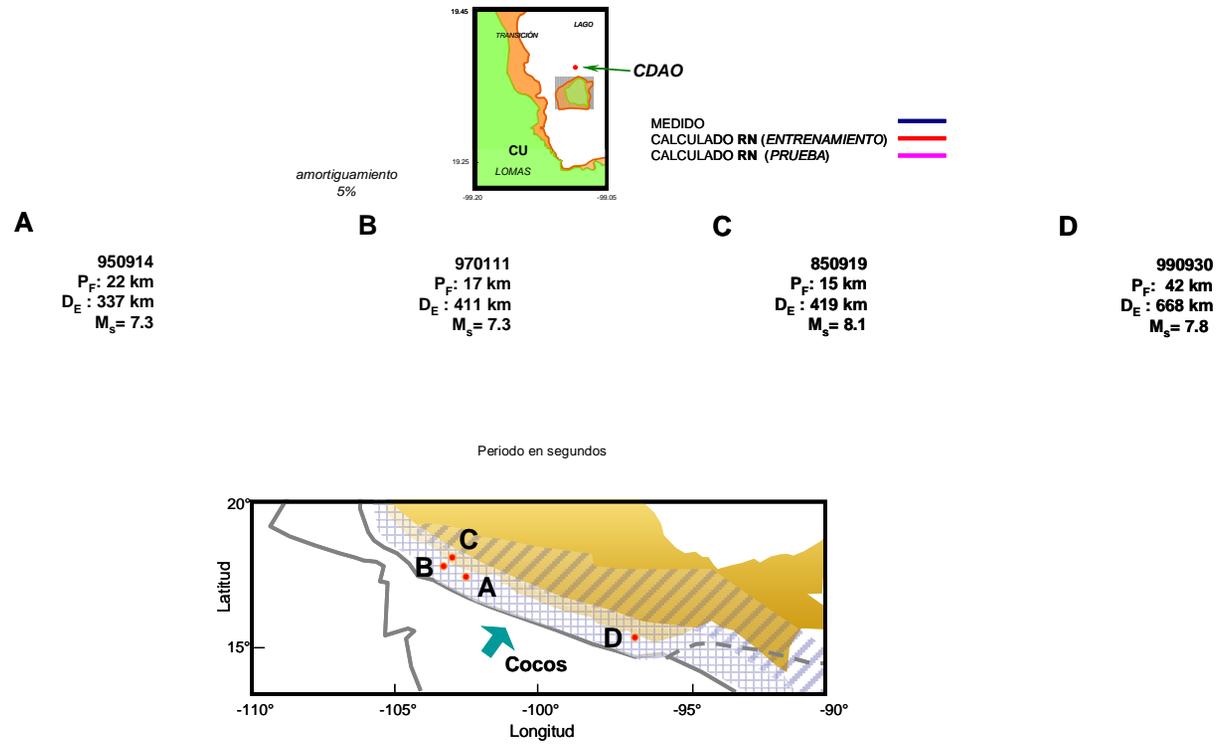


Figura 5.124 Predicción neuronal para Central de Abasto Oficinas, sismos severos

- Sitio: **Hangares**

T_s : 4.05 s

El argumento de que existe un patrón de respuesta común a todos los sitios para intensidades menores, se verifica con los resultados obtenidos para este sitio. Como se observa en la Fig. 5.125 el ajuste y la localización de máximas ordenadas, para sismos *débiles*, son bastante convenientes. La activación más importante vuelve a ser en estados por debajo de 1.0 s o alrededor de 1.6 s y más allá de esta localizada franja de respuestas máximas las OEs son mínimas.

De entre los sitios elegidos para mostrar las capacidades de la RN, este último es el que menor ajuste presenta entre los datos objetivo y los calculados. Si observa la Fig. 5.126 podrá verificar que el modelo sigue la tendencia marcada por el ERA "real" pero no logra alcanzar la eficiencia *estado a estado* logrado en los otros depósitos. A pesar de que los MR originales no parecen tan desestructurados, el modelo neuronal no alcanzó a otorgarle individualidad por lo que no fue capaz de revelar las leyes contenidas en los datos registrados.

Para los sismos más fuertes (Fig. 5.127) las predicciones se alejan más de las mediciones. En el MR construido a partir del eigenvector del caso prueba (Fig. 5.128) las diferencias geométricas son notables y eso se traduce como: i) no existe o la información recopilada no permite detectar la geometría característica del depósito ante sismos fuertes y ii) las oscilaciones entre estados (máximos y mínimos en el ERA) son demasiado pronunciadas y el modelo no reconoce este tipo de cambios.

Observe los detalles de los MR de la Fig. 5.128. El MR objetivo (medido) presenta bandas *frías* al igual que los otros sitios ejemplo, sin embargo es el único que tiene "zonas *frías*" ($1 < T < 3.5$) con cortes *cálidos* muy evidentes (oscilaciones fuertes, verdes y azules atravesados por delgados amarillos y naranjas). El MR calculado simula adecuadamente las zonas azules y verdes, pero no consigue cortar esta tendencia con líneas cálidas.

Bajo esta condición es necesario resolver si los ERAs son: *reales* (que expresan comportamiento *natural*) o *contaminados* (señales de baja calidad exhiben en el ERA aspectos *antinaturales*). Si resulta que el ERA es *real*, el patrón se mantiene como miembro del espacio y se debe re-entrenar a la RN con reproducciones del ejemplo estudiado.

En el caso de que los ERAs presentados estén *contaminados*, las estimaciones en predicción serán calificadas como adecuadas aunque los ERAs de respuesta luzcan más *suaves* que los medidos.

En el caso del sitio Hangares los resultados fueron conceptuados como *contaminados*. No forma parte del objetivo de este trabajo de tesis evaluar las incertidumbres adheridas a las señales sísmicas, pero ligando el significado de un ERA con los términos dinámicos de un MR, un depósito que active un oscilador con una amplitud considerable y a los inmediatos anterior y posterior (diferencia de 0.1 s en T_s) con amplitudes casi despreciables, es difícil de ubicar en el entorno de comportamiento de materiales "reales".

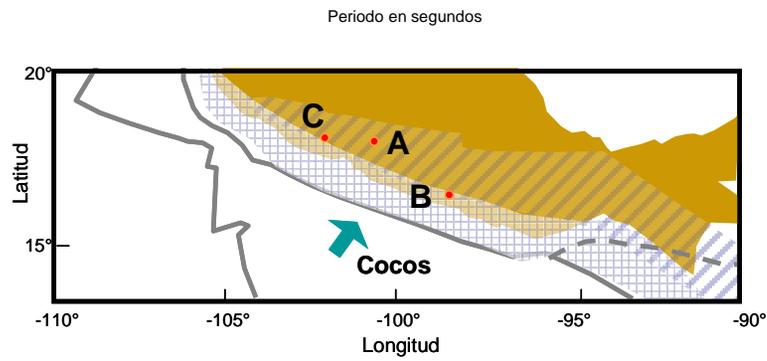
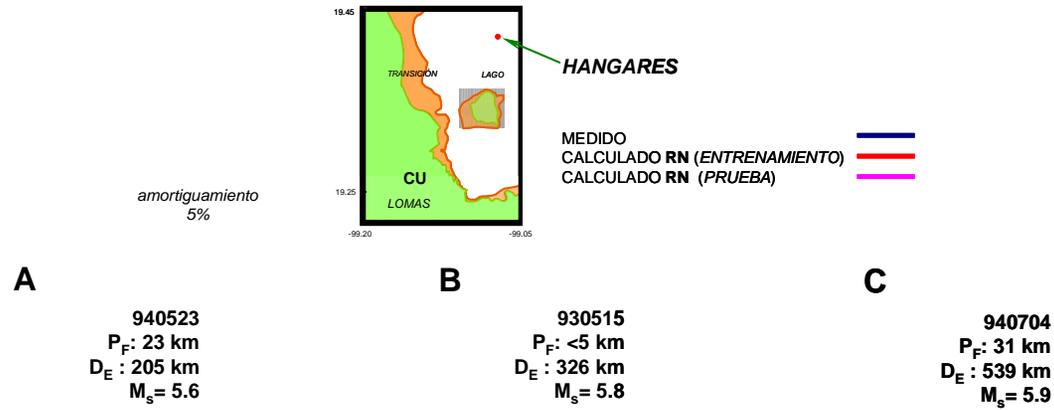


Figura 5.125 Predicción neuronal para Hangares, sismos débiles

Aceleración espectral en gales

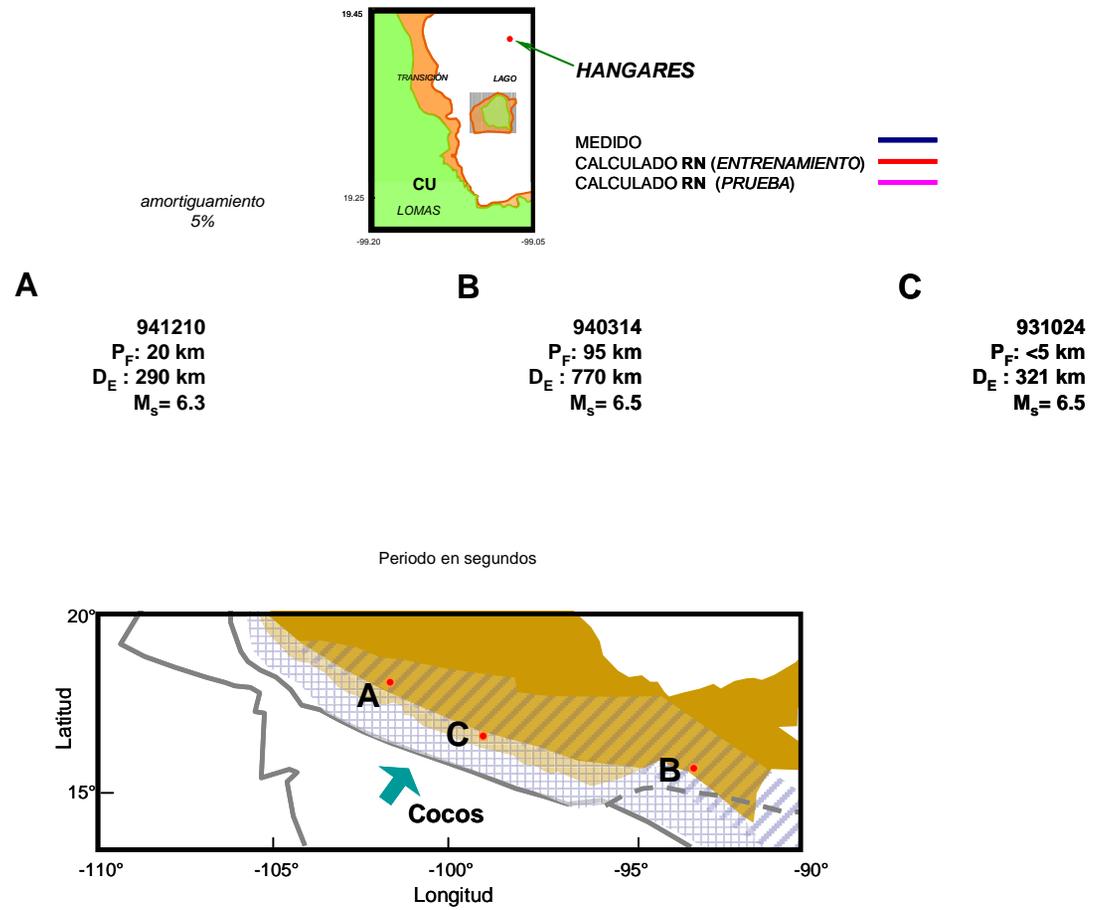


Figura 5.126 Predicción neuronal para Hangares, sismos moderados

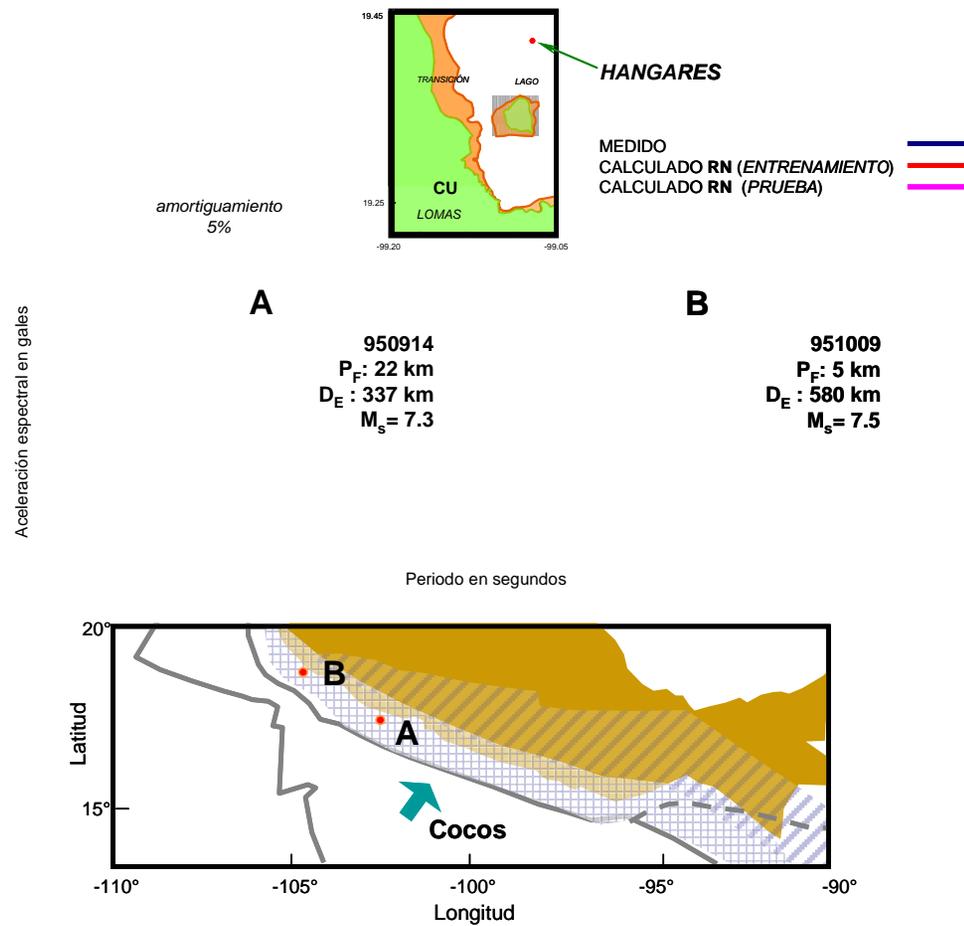


Figura 5.127 Predicción neuronal para Hangares, sismos *severos*

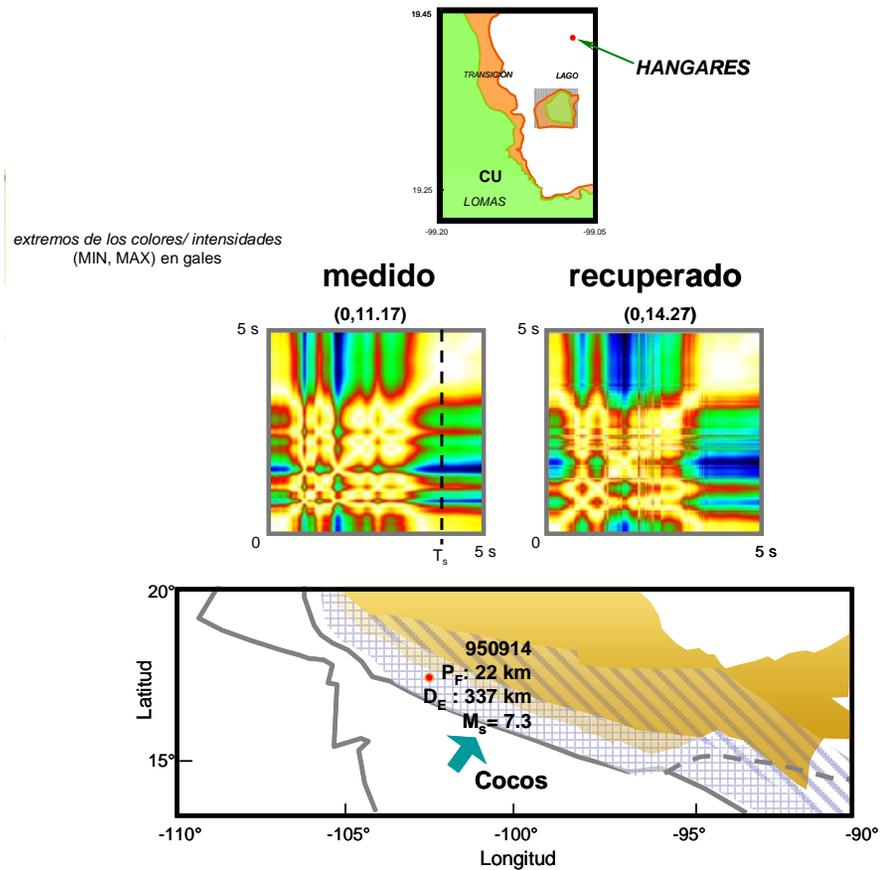


Figura 5.128 MR obtenido del eigenvector calculado por la RN para un sismo *severo*

Si hemos calificado anteriormente a la RN y al espacio de fase como una dupla de herramientas eficaces, estos resultados no deberían ser tomados como una deficiencia del modelo neuronal sino como una de las muchas *grietas* en nuestro entendimiento y representación del fenómeno sísmico.

A pesar de lo asombroso de estos primeros resultados, no se puede asumir que todo en el esquema funcionará bien. A la pregunta ¿éste es el modelo correcto para estimar las respuestas de los depósitos del valle?, la RN contesta con excelentes predicciones, sin embargo, el punto que define el valor del modelado se concentra en el equilibrio entre *ajuste* y *memorización*.

La *memorización* ocurre cuando al modelo se le orienta hacia ajustes *demasiado* cercanos sobre un cierto grupo de datos. Si sabemos que la mayoría de los datos contienen cierta cantidad de ruido o inherente aleatoriedad, desarrollar una función que ajuste *demasiado* bien, conduce a modelar no sólo la tendencia detrás de los datos sino también el ruido.

La cercanía de los ERAs calculados con los ERAs medidos podría ser tomada como *memorización* de la RN sobre este conjunto de datos. Para evitar juicios parciales sobre el comportamiento del modelo, a continuación se muestran

ejemplos que completan la idea de las predicciones neuronales, lejanas a la *memorización* y con elementos útiles en la evolución del conocimiento sobre sismos y suelos.

Los sitios elegidos en esta oportunidad responden a diversas condiciones típicas en análisis de respuestas en superficie. Las ubicaciones de los depósitos permiten cubrir un área mayor de la zona del Lago y la zona de Transición (Fig. 5.129).

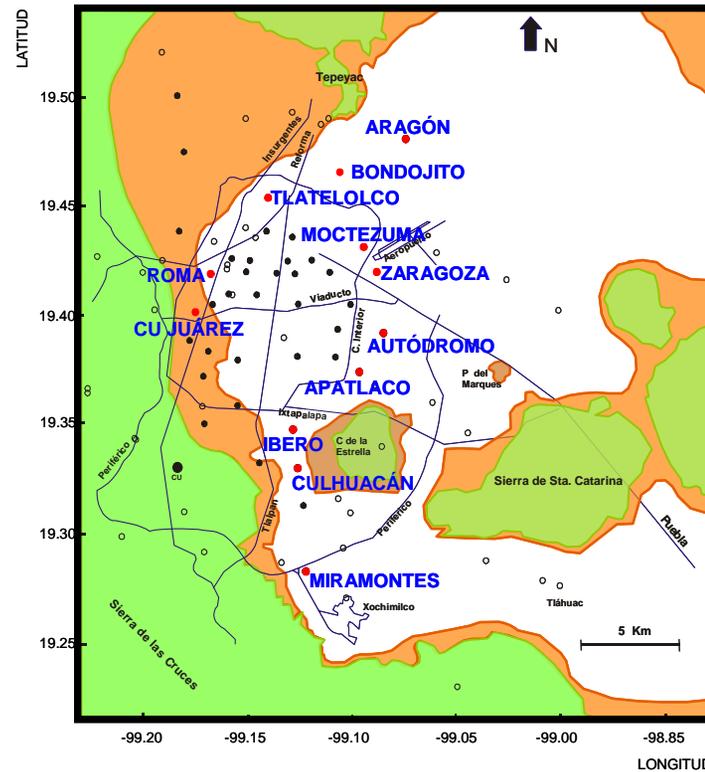


Figura 5.129 Localización de algunos sitios en zona de Lago y Transición

Los resultados indican ventajas prácticas pero advierten de carencias técnicas, ambas posiciones útiles para mejorar el propio modelo y dirigir futuras líneas de investigación.

La zona sur del valle, con un menor número de estaciones acelerográficas, se describe a través de los resultados en operación directa para los sitios Miramontes, Ibero y Culhuacán (Fig. 5.130). Su ubicación y por ende T_g , permite verificar la habilidad de la RN de reproducir las relaciones *naturales* observadas durante las sacudidas.

Si bien los periodos fundamentales en los tres sitios son muy cercanos, se verifica distinta geometría para el sitio más cercano a la zona de Lomas (Figs. 5.131-5.133). La respuesta de los sitios Ibero y Culhuacán, en términos de intensidad y osciladores activados es muy cercana y en intensidades severas las diferencias llegan a ser despreciables. La RN reproduce fielmente la aguda banda *fría* (máximos puntuales y descenso fuerte de las OEs en los otros periodos). El sitio Miramontes responde con menor intensidad, comparado con los sitios más cercanos al centro del Lago, y la RN no presenta problemas en el ajuste de los máximos pero genera formas espectrales con la tendencia de los ejemplos del Lago (bandas *frías* agudas) por lo que en varios eventos llega a equivocar la posición de la $OE_{máxima}$.

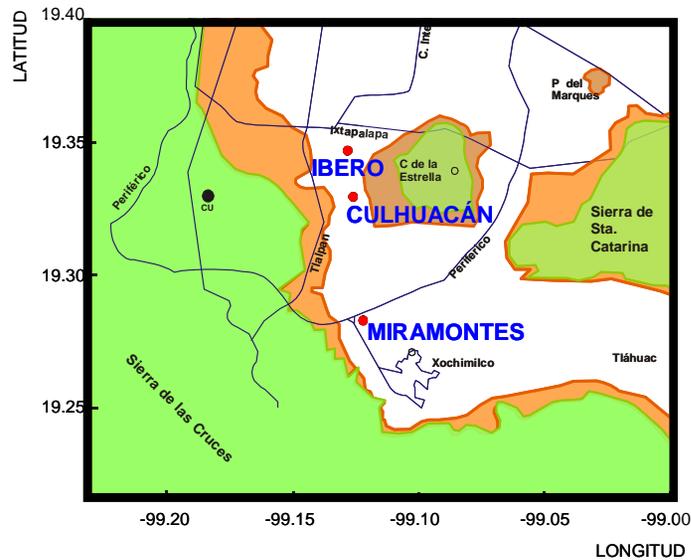


Figura 5.130 Sitios *lejos* del centro, periodos fundamentales alrededor de 1 segundo

Sitio : **Miramontes**
 $T_s : 1.3$ s

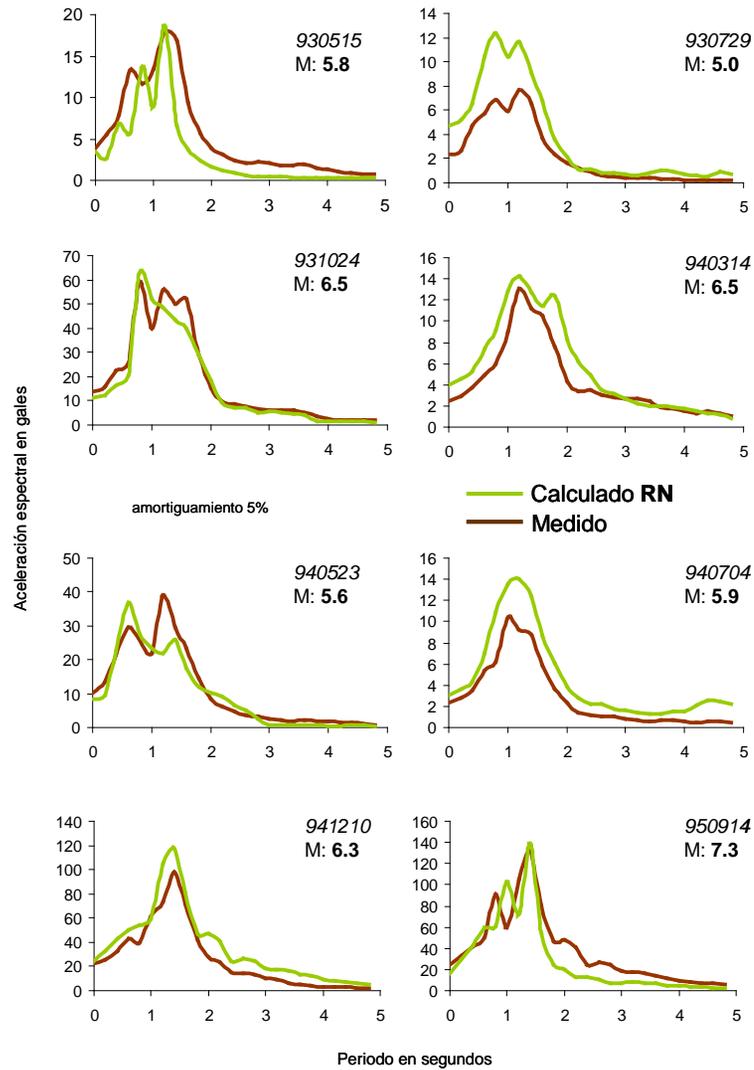


Figura 5.131 Sitio: Miramontes, predicciones en modo directo

Sitio : Ibero
 $T_s : 1.4 \text{ s}$

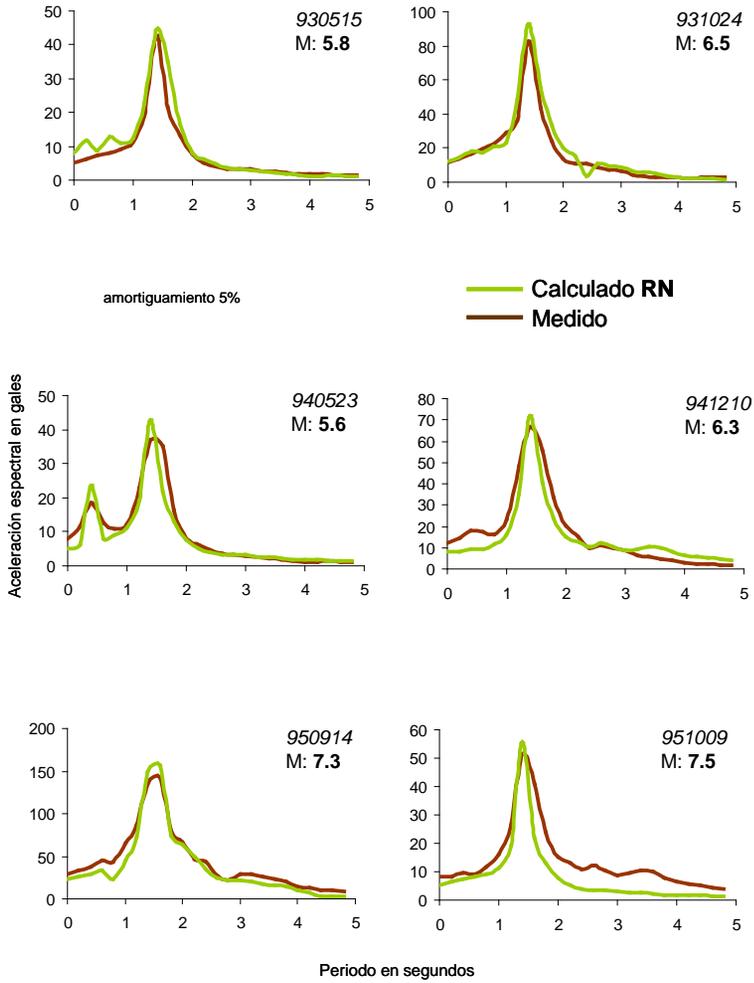


Figura 5.132 Sitio: Ibero, predicciones en modo directo

Sitio : Culhuacán
 $T_s : 1.44$ s

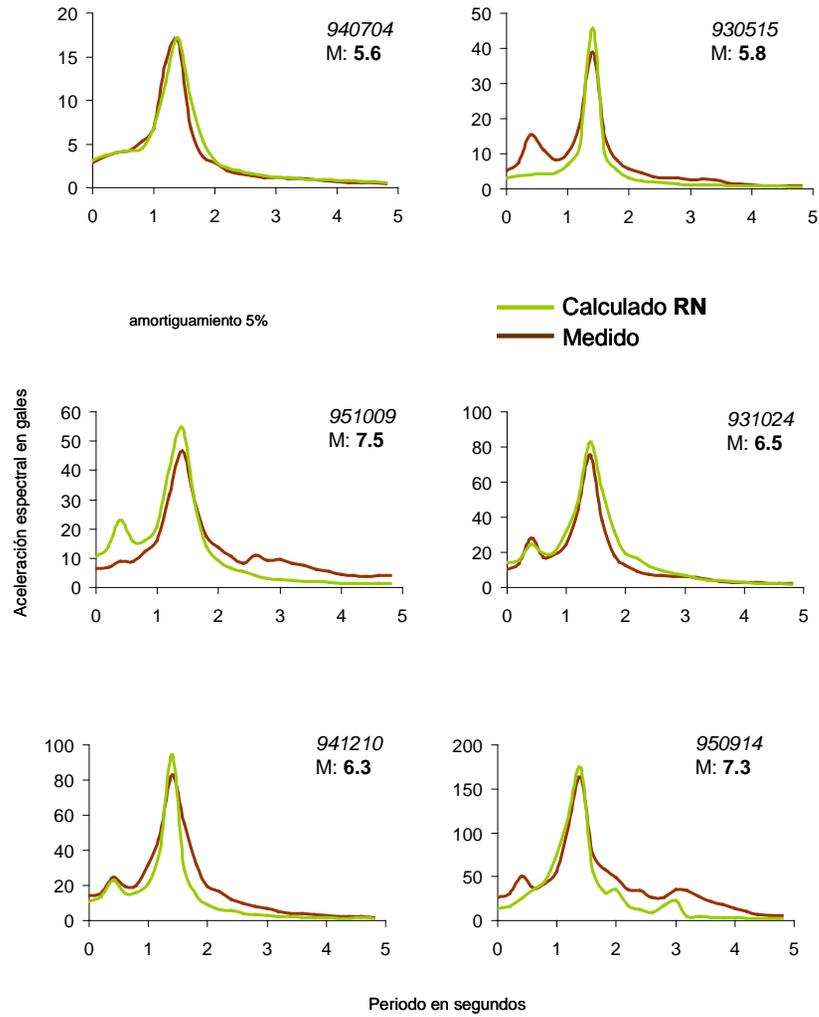


Figura 5.133 Sitio: Culhuacán, predicciones en modo directo

Conforme nos movemos hacia el norte (zona del aeropuerto de la Ciudad) y de acuerdo a lo expuesto por los sitios Apatlaco y Autódromo (Fig. 5.134) el número de estados que se activan durante los sismos de cualquier intensidad es mayor y comienzan a aparecer importantes OE en más de un periodo.

La presencia de dos bandas con máximas diferencias es bien *entendida* por la RN a pesar de no presentar el asombroso ajuste de los sitios anteriormente expuestos. Se reconoce la mayor capacidad de amplificación del sitio Apatlaco pero no se logra ajustar el máximo en el sismo de mayor respuesta, parece que la RN completa la tendencia de la zona de presentar las OEs máximas sobre el periodo (o la zona de periodos) fundamental(es) (Figs. 5.135 y 5.136). En Autódromo se observa la tendencia de los sitios con $T_s \geq 2.0$ s de clarificar la posición de las $OE_{máximas}$ conforme la intensidad de la sacudida crece. La RN lo reconoce y ofrece mejores predicciones conforme la magnitud del sismo es mayor.

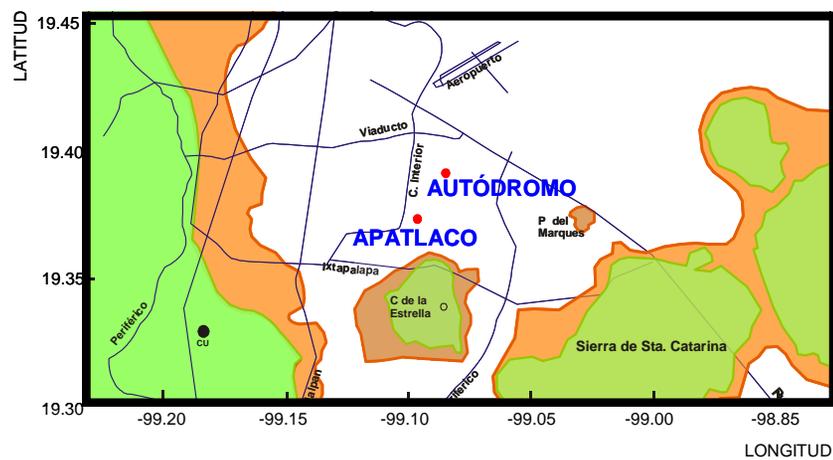


Figura 5.134 Sitios más cercanos al centro, periodos fundamentales alrededor de los 4 segundos

Sitio : Apatlaco
 $T_s : 3.1$ s

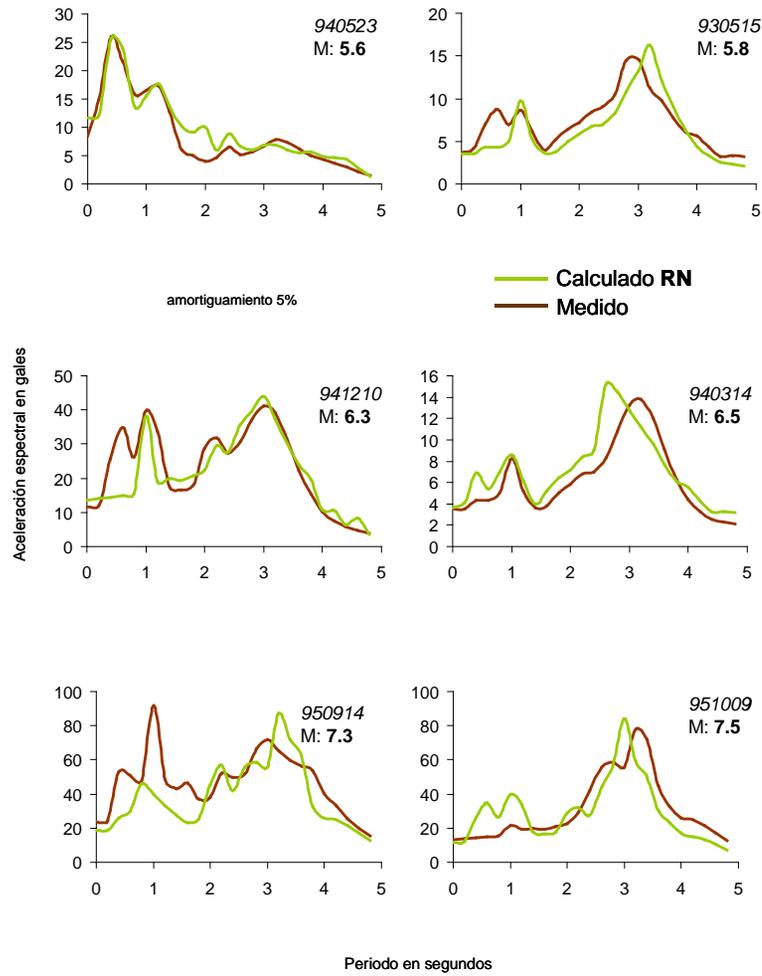


Figura 5.135 Sitio: Apatlaco, predicciones en modo directo

Sitio : Autódromo
 $T_s : 4.2$ s

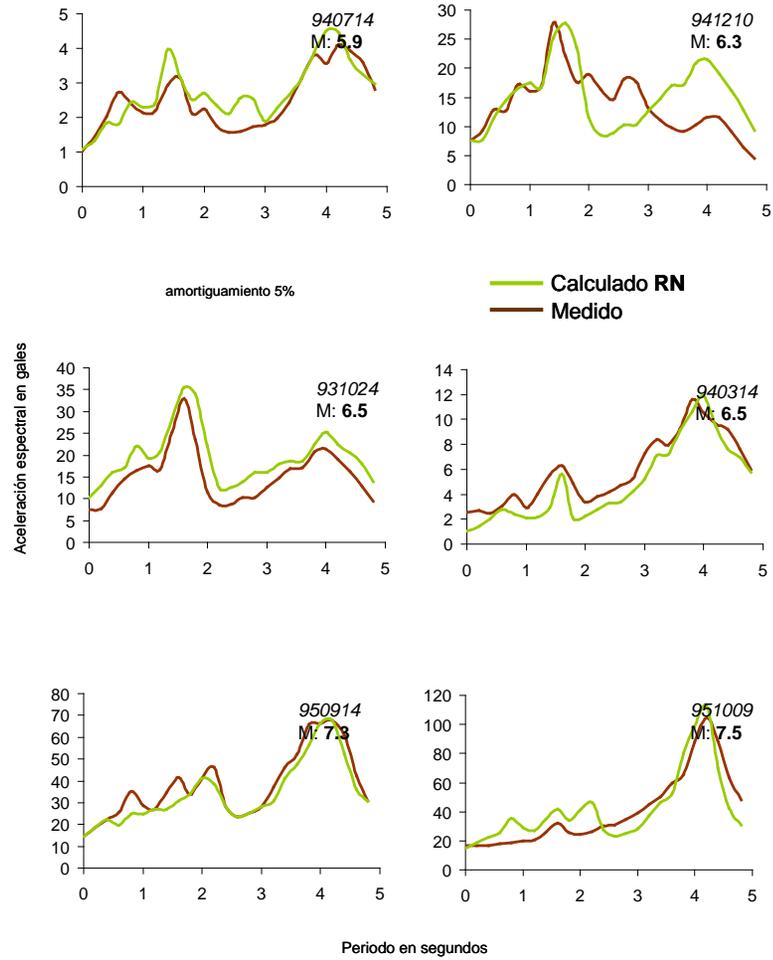


Figura 5.136 Sitio: Autódromo, predicciones en modo directo

Sitio : **Deportivo Moctezuma**
 $T_s : 3.65 \text{ s}$

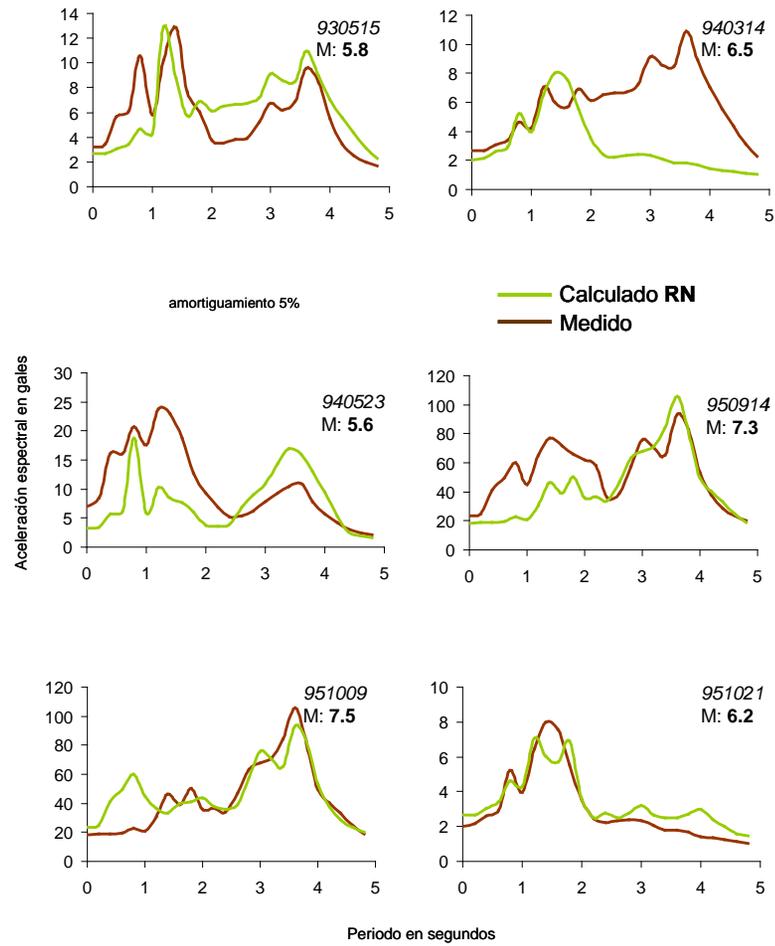


Figura 5.138 Sitio: Deportivo Moctezuma, predicciones en modo directo

Sitio : Zaragoza Superficie
 T_s : 4.0 s

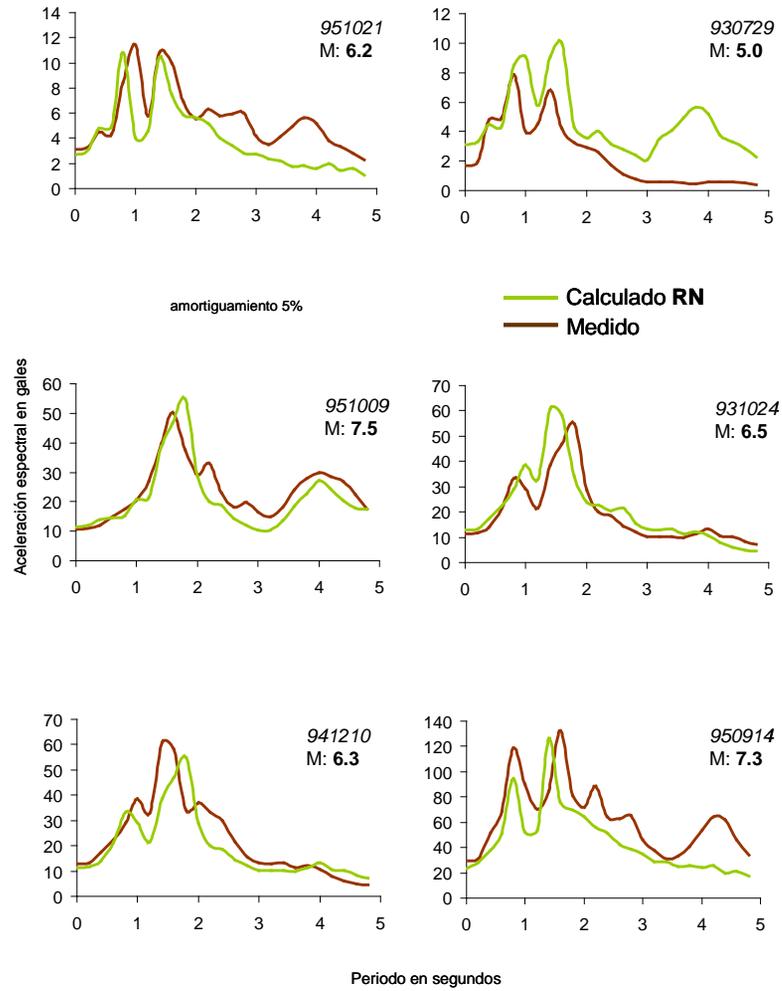


Figura 5.139 Sitio: Zaragoza superficie, predicciones en modo directo

A pesar de haber solucionado el efecto de las bandas *frías* con intercalaciones *cálidas* del sitio Zaragoza, la RN parece no haber encontrado un patrón de respuesta. Los máximos no se encuentran en la zona del T_s durante ningún evento aunque en algunos de ellos llega a haber una cierta activación alrededor de los 4 s. La RN no es capaz de captar este comportamiento.

En búsqueda de la respuesta a esta deficiencia en el modelo se analizaron los sitios Aragón, Bondojito y Tlatelolco, más hacia el norte de la Ciudad (Fig. 5.140). Los resultados obtenidos (Figs. 5.141-5.143) muestran que la capacidad de predicción de la RN es mejor en sitios más cercanos al Lago, en términos geográficos y estratigráficos.

El sitio Aragón, cerca de los límites con el Estado de México es el que presenta mayores diferencias entre lo *medido* y lo *calculado* y ninguna de las formas espectrales estimadas logra seguir a las observadas. Por otro lado, los

comportamientos en Bondojito y Tlatelolco son mejor *entendidos* por el modelo y los resultados comienzan a ser mejores. Las formas espectrales neuronales, aunque suavizadas, son congruentes con las *naturales* y las máximas ordenadas coinciden en intensidad y oscilador activado.

Los sitios con mayor capacidad de amplificación, los que se acercan al centro del Lago, generan geometrías de menor complejidad si se comparan con las del sitio Aragón el cual amplifica menos las ordenadas de entrada.

Este efecto está incluido en las relaciones generadas por la red, sin embargo no se puede abundar sobre esta capacidad neuronal debido a las fuertes discrepancias entre los $ERAS_{medidos}$ y $ERAS_{calculados}$, quizá esta observación se relacione más con las deficiencias del modelo que con una virtud en términos de predicción.

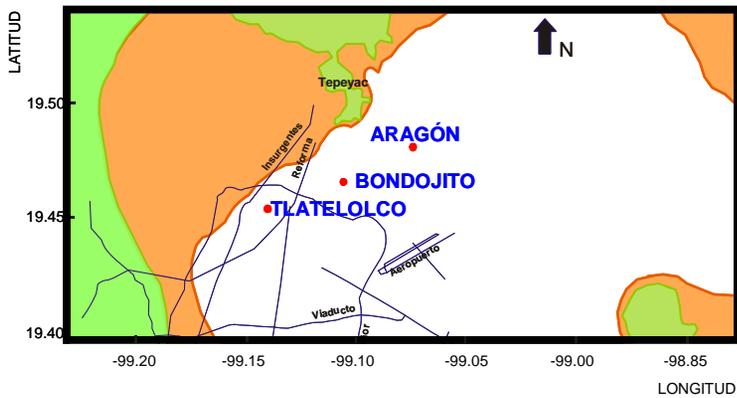


Figura 5.140 Sitios *hacia* el aeropuerto, periodos fundamentales entre 2 y 3,5 segundos aproximadamente

Sitio : Aragón
 $T_s : 3.4$ s

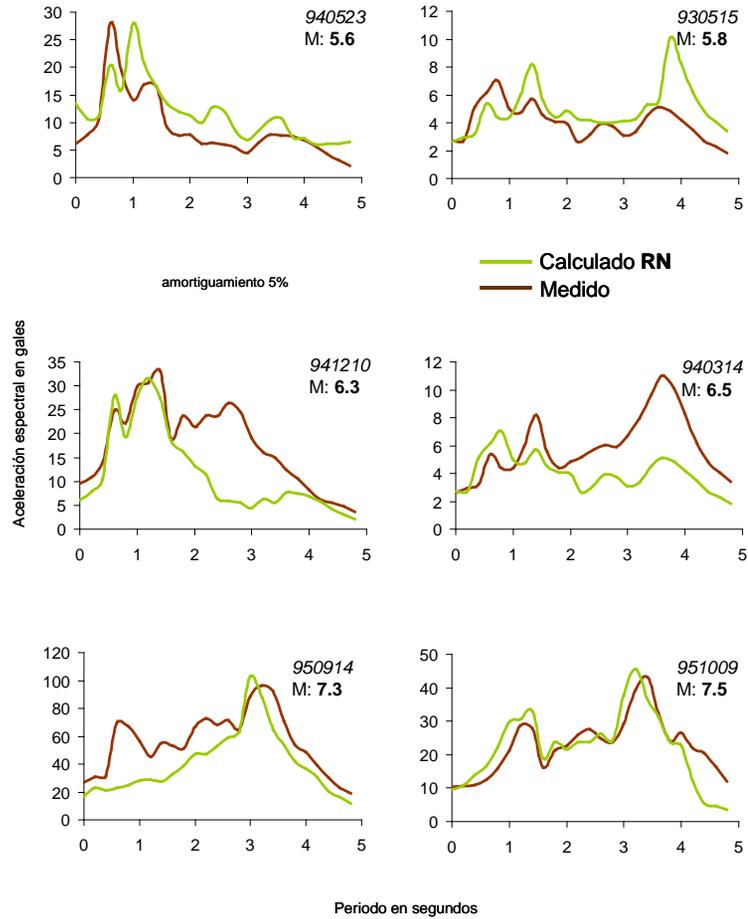


Figura 5.14I Sitio: Aragón, predicciones en modo directo

Sitio : **Bondojito**
 $T_s : 2.7$ s

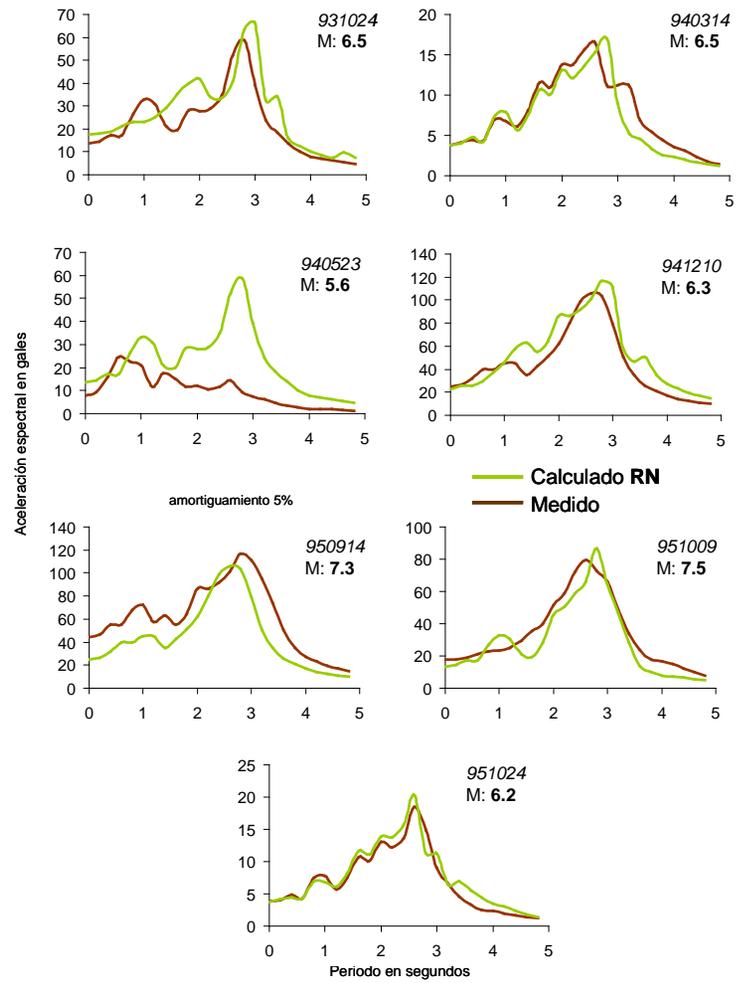


Figura 5.142 Sitio: Bondojito, predicciones en modo directo

Sitio : Tlatelolco
 $T_s : 2.1$ s

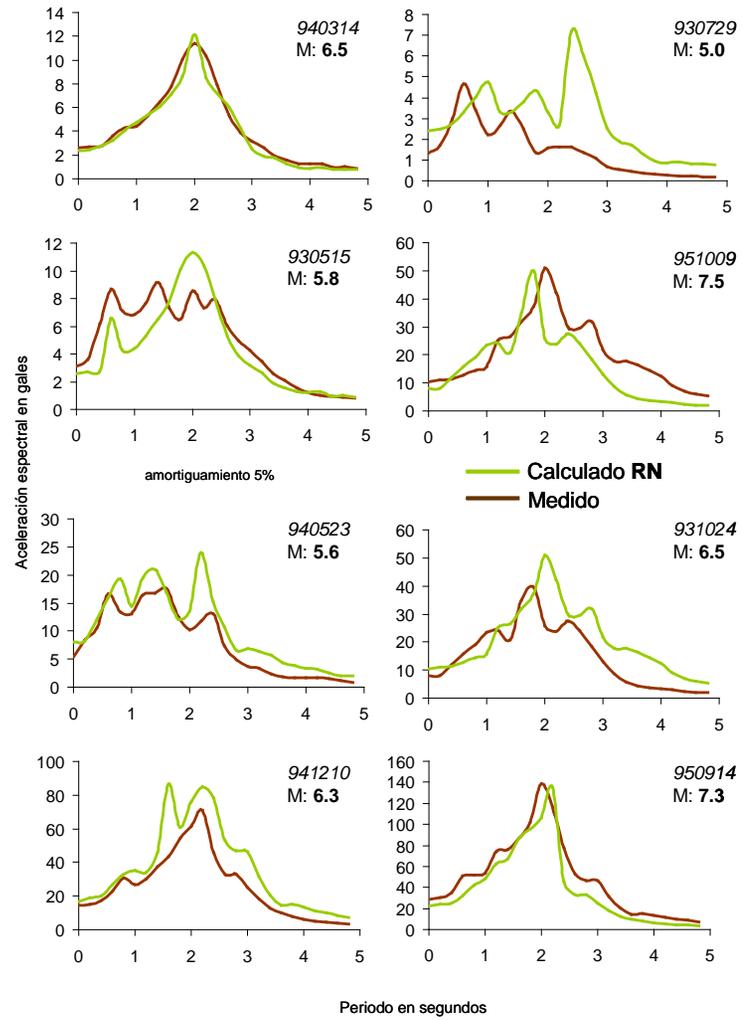


Figura 5.143 Sitio: Tlatelolco, predicciones en modo directo

Por último, se presentan los sitios Roma A Superficie y CU Juárez (Figs. 5.144-5.146), cercanos y dentro de la zona de Transición. Contrario a lo que se espera las predicciones en el sitio de Transición (CU Juárez) son más cercanas (tendencias y máximas ordenas correctamente dispuestas) que en el sitio en Lago (Roma A) donde son evidentes las diferencias entre las predicciones y las mediciones durante sismos menores. Los niveles de amplificación durante sacudidas ligeras son muy similares y sólo se presentan diferencias entre las respuestas de los depósitos cuando las amplitudes de entrada rebasan la etiqueta de *moderadas*. La hipótesis de un comportamiento único en el Lago durante las sacudidas menores parece abarcar también la zona de Transición.

Es importante señalar que en estos sitios, como en la mayoría de los cercanos a la Transición, no se puede hablar de un periodo donde se concentren las $OE_{máximas}$. Lo que se observa es la activación de estados en una zona de T (desde 1 y hasta 3 s) sin que sea posible (por lo menos a simple vista) decidir sobre el parámetro que dirige la ubicación de las máximas amplitudes.

Modelar esta condición con herramientas convencionales es una tarea muy difícil si no hay certeza del peso y la cualidad que debe otorgarse a cada parámetro de entrada para separar una serie de comportamientos que difícilmente podemos distinguir. Para la RN fue suficiente declarar como propios de un mismo depósito estos complejos patrones de respuesta para que se generara la *habilidad* y quedara implícita la ley que gobierna esta actuación.

Bajo una crítica parcial la característica neuronal de “caja oscura” puede acuñarse como deficiencia del modelo pues no es posible extraer una estructura numérica simple que sostenga los resultados. A favor de la actuación de la RN, se debe decir que no siempre obtener una estructura numérica que se *entienda* significa que *entendemos* los sucesos y somos capaces de explicarlos correctamente.

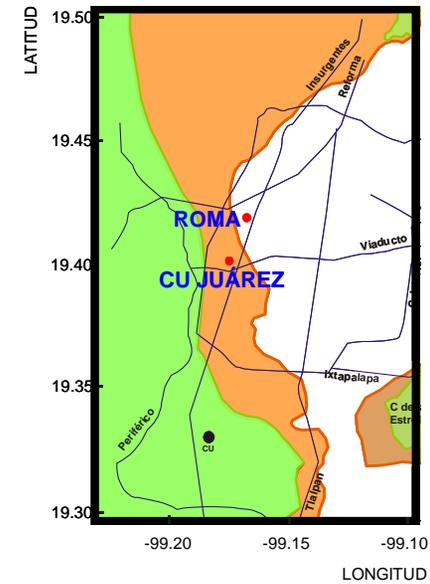


Figura 5.144 Sitios *hacia* la Transición, periodos fundamentales alrededor de los 2 segundos

Sitio : Roma A Superficie
 $T_s : 2.2$ s

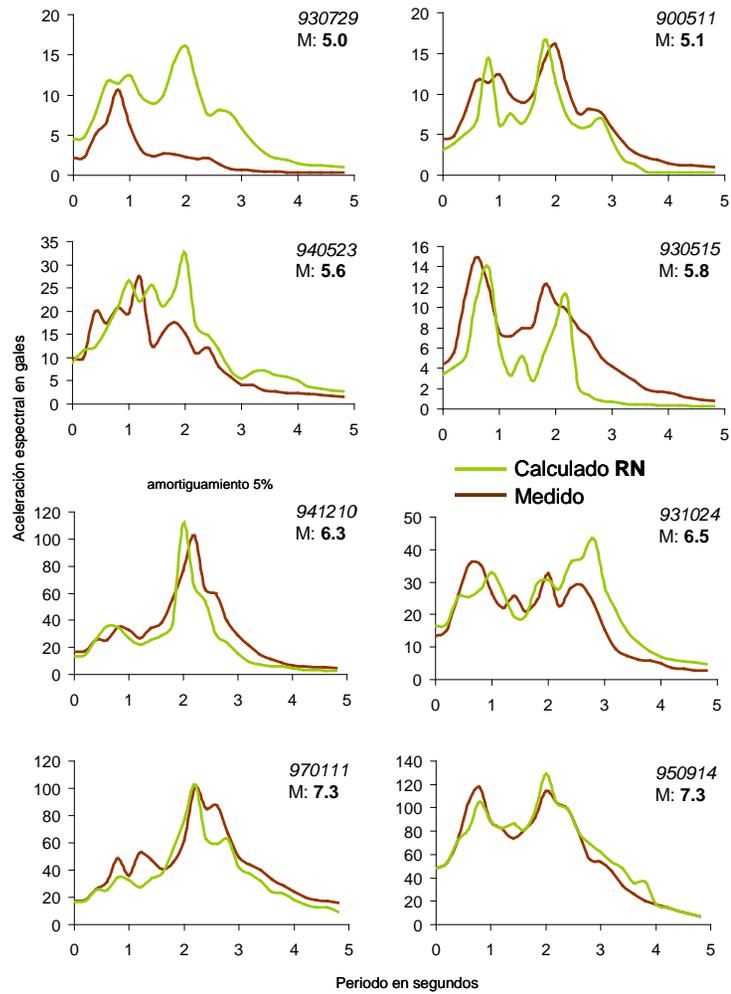


Figura 5.145 Sitio: Roma A superficie, predicciones en modo directo

Sitio : CU Juárez
 $T_s : 2.05 \text{ s}$

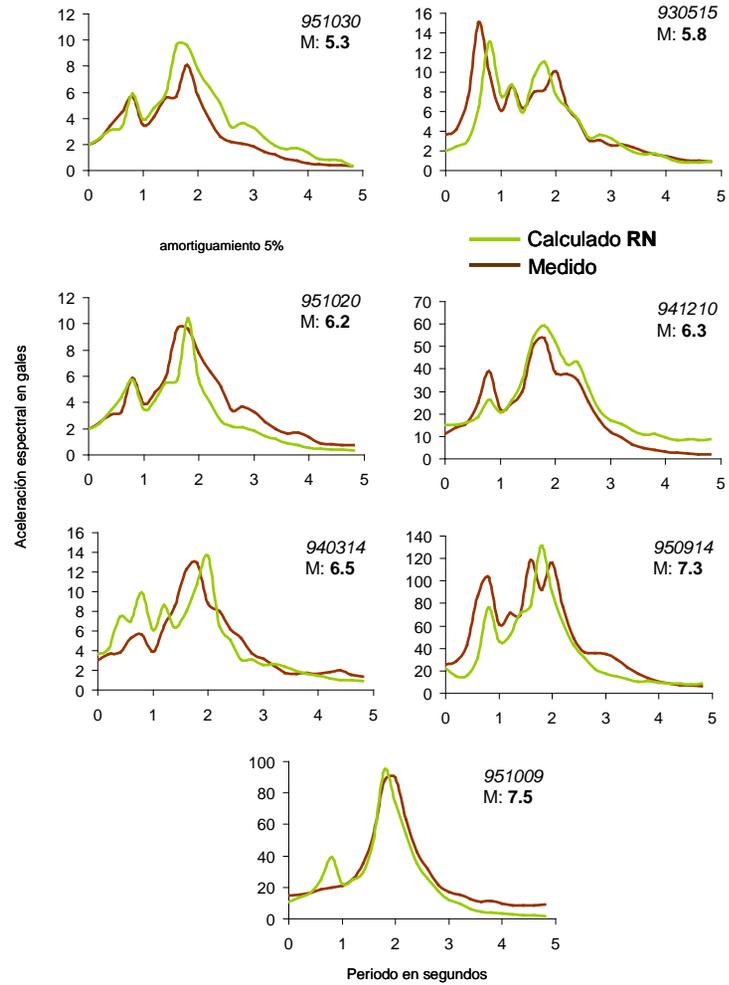


Figura 5.146 Sitio: CU Juárez (Transición), predicciones en modo directo

Operación del Modelo

Hasta este punto ha sido detallada la teoría detrás de: i) el procesamiento de señales (MR-EFs) y ii) el modelo neuronal. Resulta evidente que no es común en análisis o diseño sísmico el manejo de este tipo de esquemas conexionistas ni la visión dinámica no lineal con la que se construyó el modelo de estimación de respuesta de los depósitos del valle.

Al principio de este trabajo se argumentó sobre la necesidad de generar marcos de operación donde el ingeniero de la práctica pueda trabajar cómodamente a sabiendas de que el oportuno desarrollo científico le permite ese confort. A pesar de lo lejano que parece un esquema computacionalmente *avanzado* de las asignaturas básicas aprendidas por los graduados en el área, el producto final de esta propuesta (software) contiene una secuencia operativa muy cercana al pensamiento más básico (*natural*) en el planteamiento de la estimación de la respuesta sísmica (Fig. 5.147).

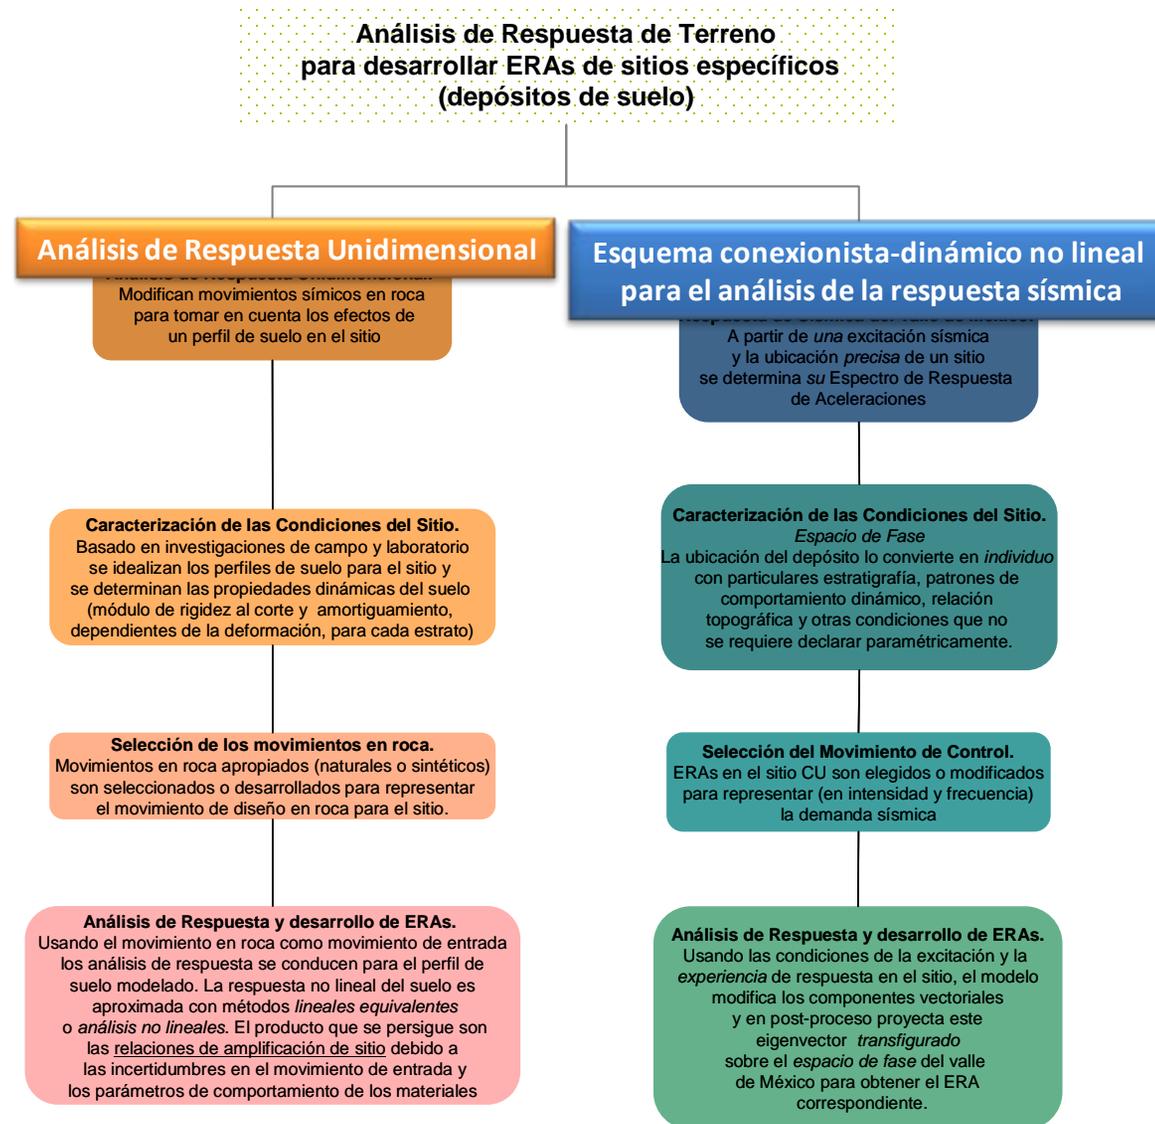


Figura 5.147 Comparación conceptual entre el ampliamente usado modelo 1D y el esquema conexionista propuesto en este trabajo de tesis

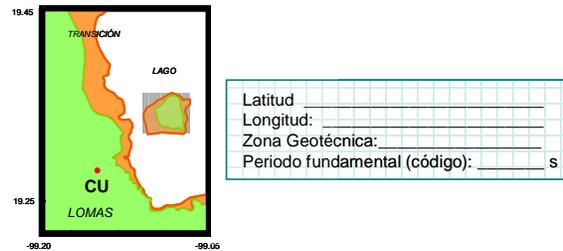
En el modelo MR-EFs/RN *cerrado* (la etapa de entrenamiento se declara *no-abierta*), sobre un mapa referenciado geográficamente se permite al usuario situar el punto que desea estudiar sobre la superficie del valle de México (Fig. 5.148). En esta tesis se presenta la parte del sistema que trabaja sobre sitios XY (caracterizados con T_s) específicos.

Señalar un punto distinto a los incluidos en el archivo de entrenamiento llama a una rutina adicional de interpolación de respuestas. El desarrollo y descripción de esta *conexión* paralela van más allá del alcance de esta

investigación y no serán presentados a detalle, pero se considera necesario aclarar que esta formulación forma parte del software final.

Cuando el usuario califica como válida su elección, el modelo despliega: i) las coordenadas geográficas del punto, ii) el periodo fundamental del sitio (de acuerdo con el RCDF y el criterio de modificación presentado al inicio de este apartado de **Resultados**) y iii) la zona geotécnica a la que pertenece el sitio.

UBICA EL SITIO :



SELECCIONA UNA OPERACIÓN :

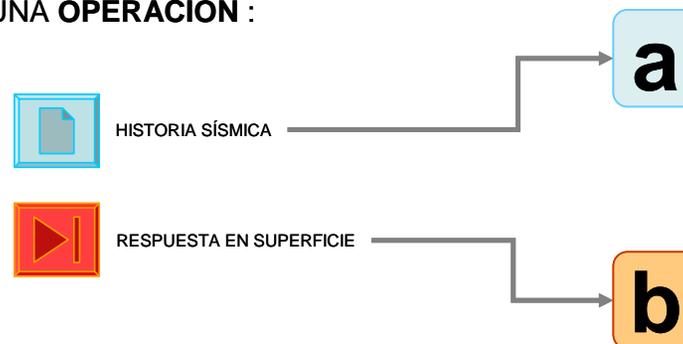


Figura 5.148 Primera etapa operativa del modelo

Posteriormente el sistema ofrece dos posibles operaciones. Se permite a) una revisión gráfica de la Historia Sísmica del sitio expresada en ERAs y MR con el evento de control adherido a cada respuesta (Figs. 5.149 y 5.150). Cualquiera de los eventos de control puede ser seleccionado como la alimentación de la segunda opción de operación: b) Respuesta en Superficie (Figs. 5.151 y 5.152).

Cuando un usuario pulsa la opción que calcula la Respuesta en el sitio de interés se le pregunta únicamente sobre los Parámetros E ya que el Parámetro S es determinado a través de la memoria codificada del propio sistema. El movimiento de control puede seleccionarse de alguno descrito en la Historia Sísmica aunque se permite la carga de un archivo de datos con las dos primeras columnas ocupadas por el vector de periodos y de OEs, respectivamente.

Existe la opción gráfica de modificar el ERA histórico con el arrastre del cursor para guardarlo como nuevo ERA y usarlo como demanda sísmica. Es importante recordar que si dentro de la relación entrada→salida, la *entrada* resulta demasiado ajena a la historia con la que se entrenó el modelo, la *salida* podría contener incongruencias numéricas.

Antes de presionar *Calcular* el usuario debe indicar los sub-productos que desea *guardar*: 1) Entrada (en ERA o en MR), 2) Eigenvector de entrada, 3) Salida (en ERA o en MR) y 4) Eigenvector de salida.

El resultado de la operación Respuesta en Superficie se despliega en pantalla y queda abierta la opción de más cálculos sobre el mismo sitio. Un cambio de posición implica cambio en la estratigrafía (mínimo o sustancial dependiendo de la distancia entre los puntos y la zona geotécnica donde se encuentren) y por tanto distintos patrones de comportamiento, por lo que cálculos en otro depósito requieren *restablecer* el sistema hacia el punto de arranque y una nueva selección XY sobre la superficie del valle.

Resumiendo, el usuario solamente: A) indica la posición del depósito, B) indica la demanda sísmica y C) indica los productos que desea que se *muestren o guarden*.



movimiento de control

respuesta monitoreada (ERA)

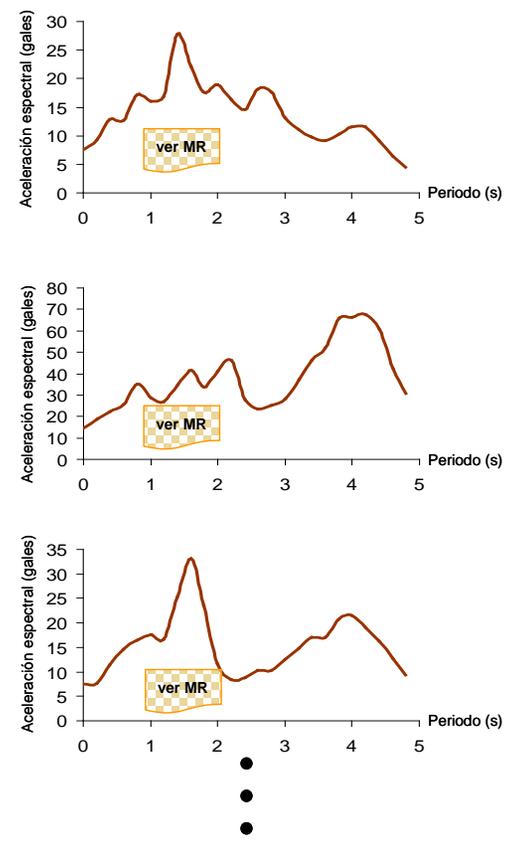
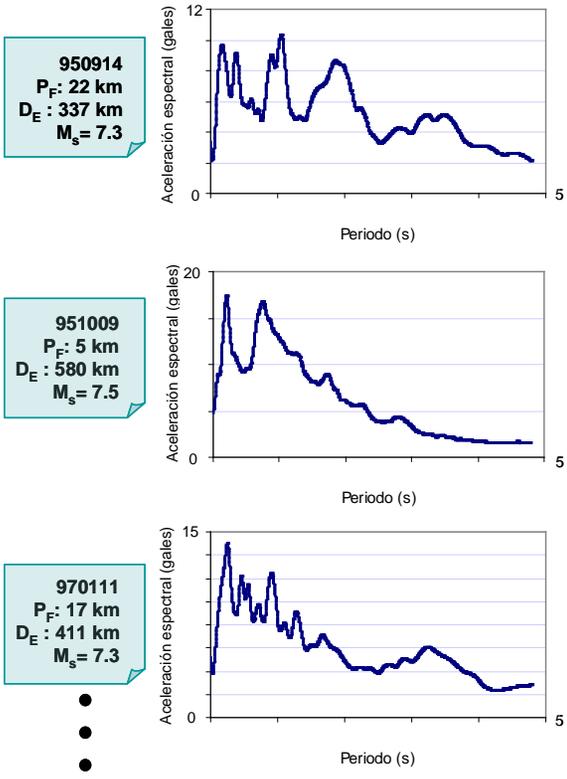


Figura 5.149 Primera opción operativa del modelo, opción *Historia Sísmica*



movimiento de control

respuesta monitoreada (ERA)

MR

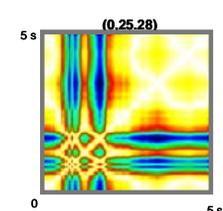
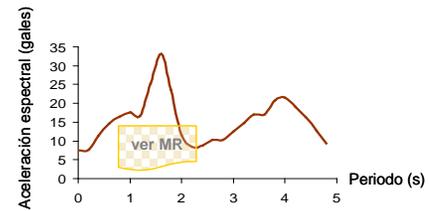
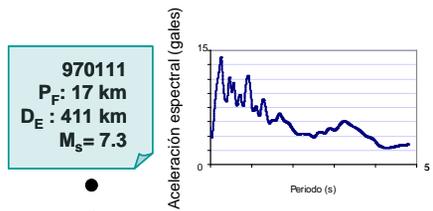
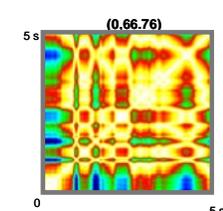
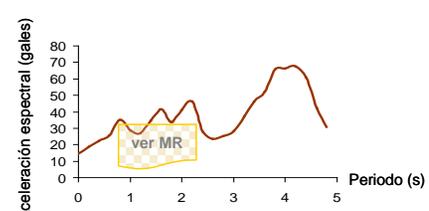
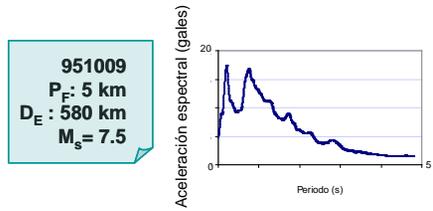
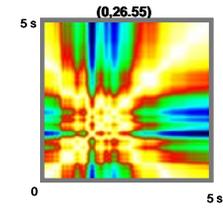
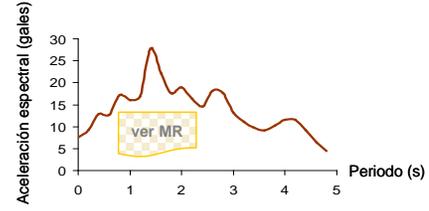
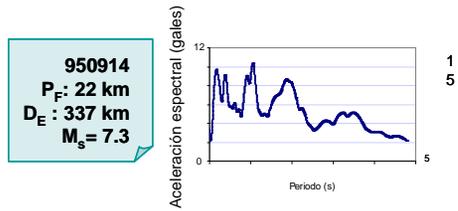


Figura 5.150 Primera opción operativa del modelo, opción Historia Sísmica

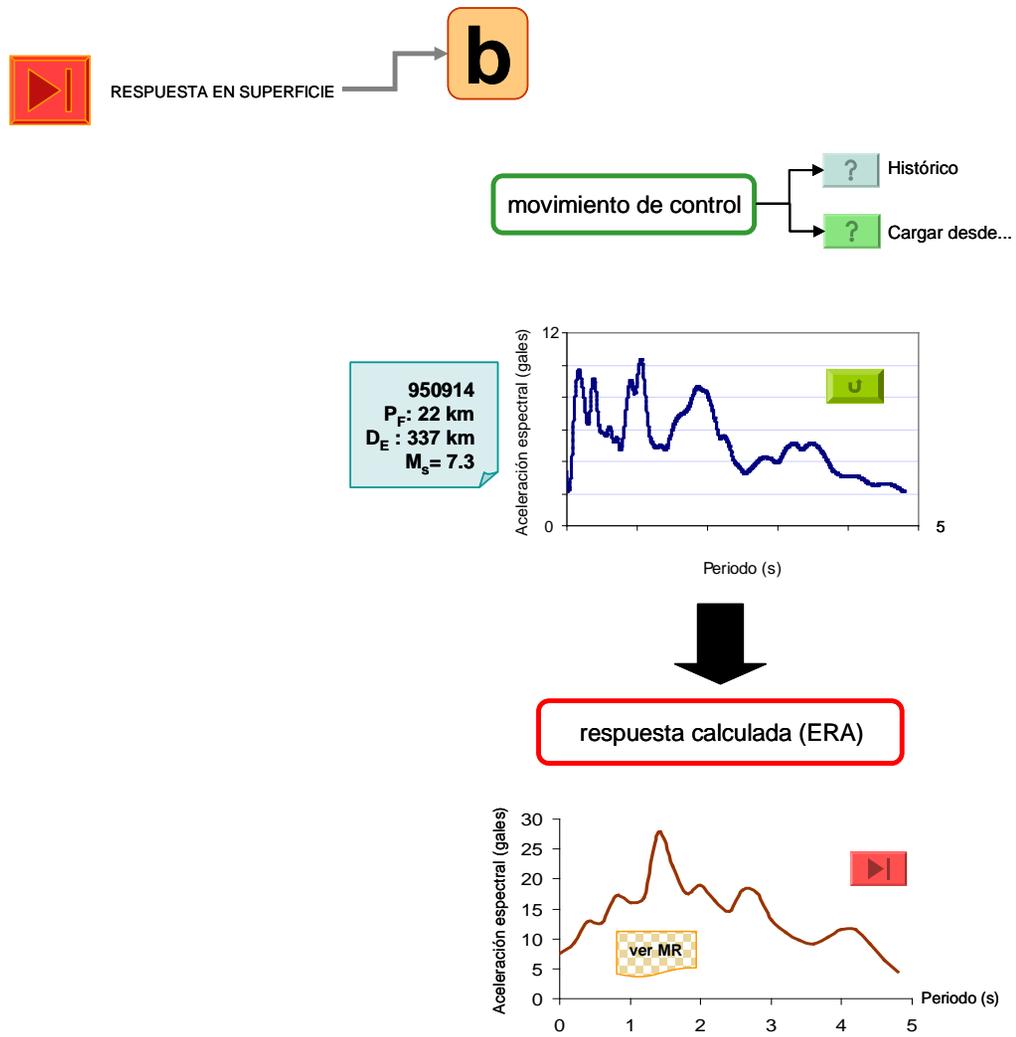


Figura 5.151 Segunda opción operativa del modelo, opción Respuesta en Superficie

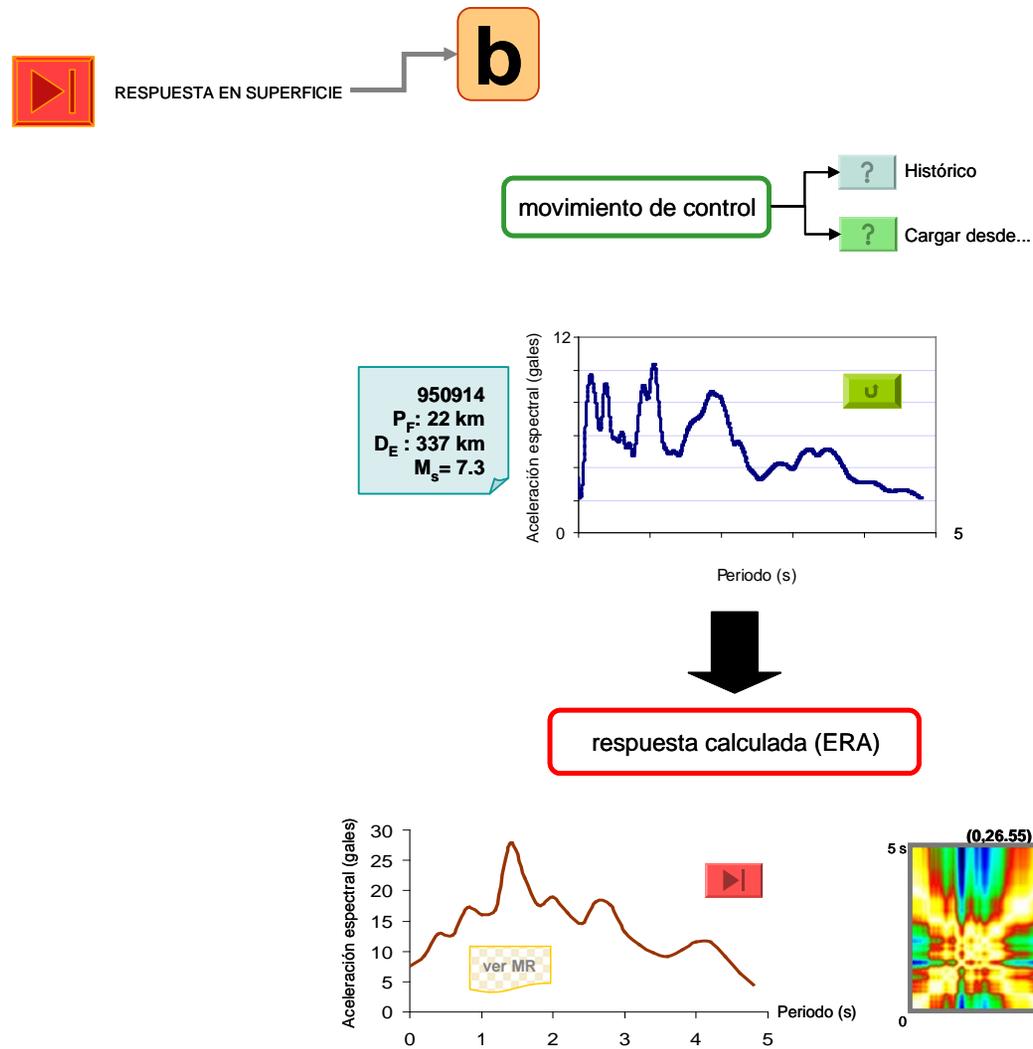


Figura 5.152 Segunda opción operativa del modelo, opción *Respuesta en Superficie*

Hacia la evolución del conocimiento

Algunos de los resultados presentados pueden significar evidencias útiles en la transformación de los actuales programas de análisis o, por lo menos, ideas sustancialmente poderosas para comprender el fenómeno sísmico explotando su manifestación en la superficie de los depósitos.

A continuación se presenta un condensado de estas observaciones.

- Sobre el movimiento de entrada

Si se dejan a un lado las hipótesis acerca de los movimientos en el afloramiento y el lecho rocoso, debemos reconocer que los acelerogramas que se colectan en el sitio en roca blanda (CU) contienen, de alguna manera, la propagación de las ondas sísmicas (génesis y viaje a través de cientos de kilómetros de roca) y el efecto de las condiciones del propio sitio.

Las estructuras generadas en CU, para los sismos incluidos en esta base de datos, van desde geometrías propias de funciones logarítmicas hasta, aunque parezca absurdo, bandas en periodos y amplitudes muy similares a las que se generan en sitios del Lago. Son claras las incongruencias entre magnitudes e intensidades espectrales.

La característica de respuesta más evidente es casi pulsos ($O_{E_{máxima}}$ alrededor de los 0.5 s) para sismos *débiles* y un gran número de osciladores activados (zona con $O_{E_{máximas}}$ entre 0.5 y 2.7 s) para la mayoría de los sismos de magnitud *moderada a severa* (aspecto importante para obtener relaciones de amplificación “convenientes”).

Esta condición podría ser la responsable de la recomendación de separar, de acuerdo con la intensidad sísmica, los modelos de análisis y de alguna manera podría estar ligada a la discusión obcecada sobre la linealidad de la respuesta de los suelos blandos.

Sin pretender descalificar los estudios que usan CU como entrada sísmica, conviene señalar que los MR de CU tienen una compleja activación de estados y que esto debería ser suficiente para que se apliquen con cautela las relaciones espectrales que deriven de sus ERAs.

El uso de los espectros, como *individuos*, para expresar la demanda sísmica es una restricción del marco teórico tradicional y, considerando las geometrías descubiertas para el sitio en roca blanda (CU), podría ser la responsable de algunas amplificaciones espurias entre sitios en terreno firme y depósitos de suelos blandos.

El sistema conexionista *flexibiliza* la definición de la sacudida a través de la ventajosa adición de los *Parámetros E* y el concepto *espacio de fase*, lo que al mismo tiempo *robustece* la estimación del eigenvector de salida *transfigurado*.

-

Sobre la respuesta de los depósitos

Las ubicaciones estudiadas permiten argumentar sobre el comportamiento de los depósitos del valle, un medio de arcillas plásticas, anisótropas y heterogéneas, en términos de sus trayectorias de respuesta.

Para eventos de intensidad *débil* se reconoce una misma estructura en el Lago y en la Transición, disímil a la mostrada por el sitio en roca (CU) en esos mismos eventos. Esto significa que, en términos muy simples, para M *menores* (< 6 grados) sería suficiente con un mapa *inteligente* de contornos de amplificación para definir los MR-ERAs escalados (si se parte de un MR *típico* con [0,1] en la barra de intensidades), mostrando un ligero aumento en la intensidad de las respuestas conforme se avanza hacia la zona central del viejo Lago y un notable decremento en el valor de las $O_{E_{máximas}}$ hacia el sureste de la Ciudad.

Es importante señalar que la ubicación del sitio es la variable explícita con más peso en el modelo mientras que la ubicación del epicentro y la P_F (mecanismo de falla) parecen no ser parámetros directores de este patrón de respuesta.

Estudiando los MR de sismos *moderados a severos* en los sitios en Lago y refiriéndoles a los correspondientes para el sitio de control se puede concluir que el nivel de energía contenida en el mapa de CU (el área total de los colores *fríos*) dirige la intensidad de la respuesta en los depósitos de suelos blandos.

Si se observan las ubicaciones de las máximas diferencias en CU (bandas o líneas azules/negras) y los periodos fundamentales en cada sitio no se pueden encontrar evidencias contundentes sobre el fenómeno de resonancia. Esto no indica su inexistencia, lo que hace es señalar la incapacidad del sitio de control para expresar completa y correctamente el contenido frecuencial de la sacudida.

Resulta una simplificación arriesgada y alejada de las *observaciones* tomar relaciones de amplificación (periodo a periodo) como válidas si se estudia el comportamiento de la superficie del valle. Esta posición de análisis resultaría válida sólo en modelos desarrollados para cada sitio, siempre y cuando sus trayectorias de respuesta sean *constantes* (vea las respuestas del sitio SCT, por ejemplo).

Durante los sismos de intensidad *mayor* se observan diferencias zonificadas entre las geometrías desplegadas en superficie. A pesar de la reconocida heterogeneidad en los depósitos que conforman el valle, en términos generales, los suelos parecen actuar como *filtros* de actividad bien delimitada.

Se encontró una separación *difusa* ($T_s \approx 2.5$ s) entre patrones de respuesta. Sitios cuyas máximas diferencias ($OE_{m\acute{a}xima}$) (bandas o líneas azules/negras) se localicen antes de esta frontera presentan ERAs agudos, bien definidos, y con máximas respuestas localizadas debajo de este T, incluso para sismos tan severos como el sismo del '85. Los depósitos con colores *fríos* máximos por encima de la frontera *difusa* presentan zonas de activación (espectros *anchos*) de entre 2 a 3 s que arrancan en $T_s \approx 2$ s. La aparición de importantes respuestas en un segundo modo de vibrar es característica de estas geometrías. Parece que es únicamente la ubicación del sitio (T_s) el parámetro director de esta separación de comportamientos.

6. Conclusiones

Sobre las aplicaciones

Han sido considerados dos importantes y complejos problemas geosísmicos. Se ha mostrado que las técnicas del cómputo aproximado ayudan a resolverlos exitosamente. La lógica difusa, la teoría del caos, el reconocimiento de imágenes, y las redes neuronales (en disposición híbrida) pueden ser considerados como herramientas convenientes en planteamientos geotécnicos e interpretaciones sísmicas. La consistencia y fusión computacional incrementaron la robustez y la utilidad práctica de conocidos planteamientos ingenieriles evolucionándoles hacia funcionales predictivos escalables, transparentes, interpretables, rápidos y económicos.

Estimación de la Velocidad de Ondas de Corte a partir de la Resistencia a la Penetración del Cono Eléctrico

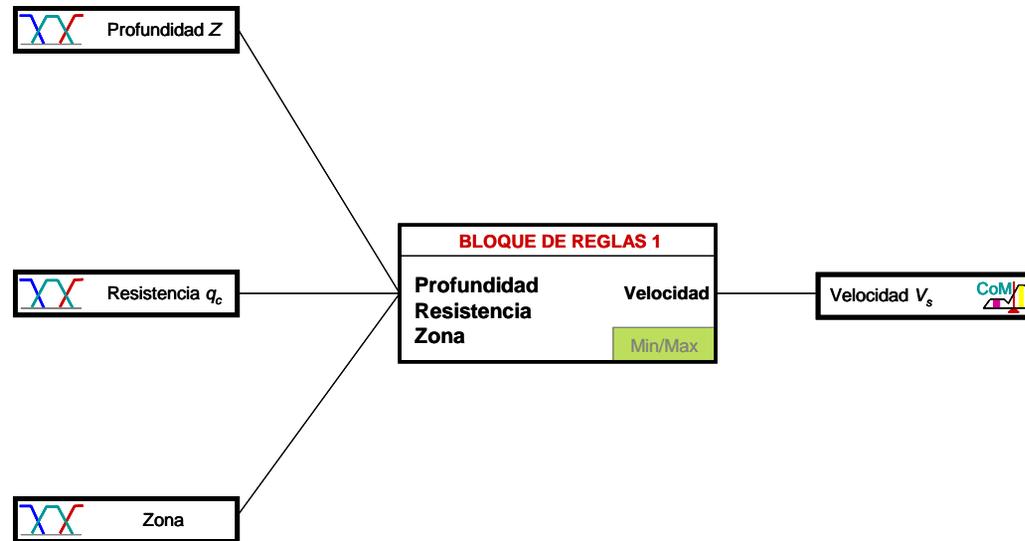


Figura 5.15 Estructura del Sistema de Lógica Difusa (viene del Capítulo 5)

- El modelo es *completo*, es decir, permite elaborar juicios y dictar sentencias sobre el comportamiento de la variable dependiente V_s . Se cubre un amplio rango de resistencias, profundidades y zonas geotécnicas para determinar velocidades desde *bajas* (suelos muy blandos) hasta *muy altas* (material considerado firme).
- Es posible identificar los parámetros de entrada del modelo por medio de un número pequeño de pruebas estándar realizadas sobre los materiales.
- El modelo está fundamentado en interpretaciones físicas de los comportamientos, no se decide *a priori* sobre las relaciones paramétricas ni las trayectorias de respuesta. Las predicciones, además de ser confiables, contienen *conocimiento* sobre los materiales y las propiedades.

Determinación del Módulo de Resistencia al Corte y el Amortiguamiento de acuerdo con la Plasticidad de los Suelos

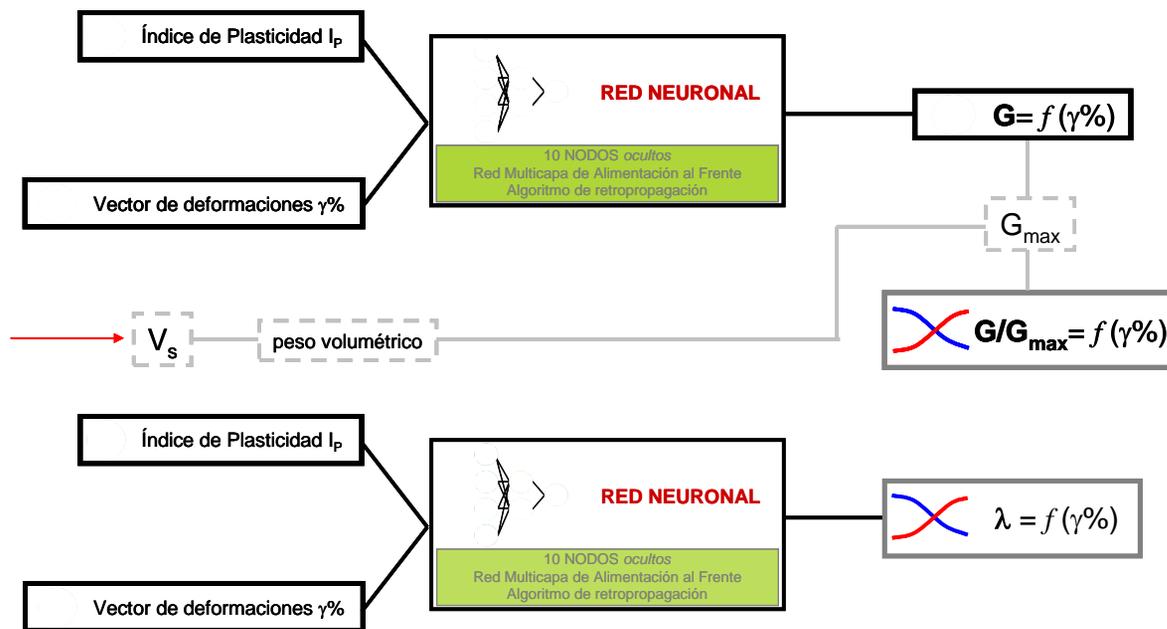


Figura 5.42 Topología más exitosa para modelar: $(G/G_{max}, \lambda) = f(I_p, \gamma\%)$ (viene del Capítulo 5)

- Esta relación neuronal es capaz de estimar los valores de G, λ por medio de una propiedad índice (I_p) obtenida de ensayos de laboratorio económicos y sencillos.
- Se encontró que, efectivamente, existe una relación *simple* entre la plasticidad y los parámetros dinámicos requeridos, lo que permitió la construcción de un módulo neuronal eficiente.
- La mayoría de las relaciones empíricas para obtener G, λ están muy lejos de la perfección y las incertidumbres asociadas difícilmente pueden ser cuantificadas. Esta herramienta *inteligente* -estándar, asequible y práctica- permite trabajar en los marcos de indeterminación paramétrica con suficiente confianza sobre el método y los resultados.

Estimación de Movimientos de Terreno en la Ciudad de México

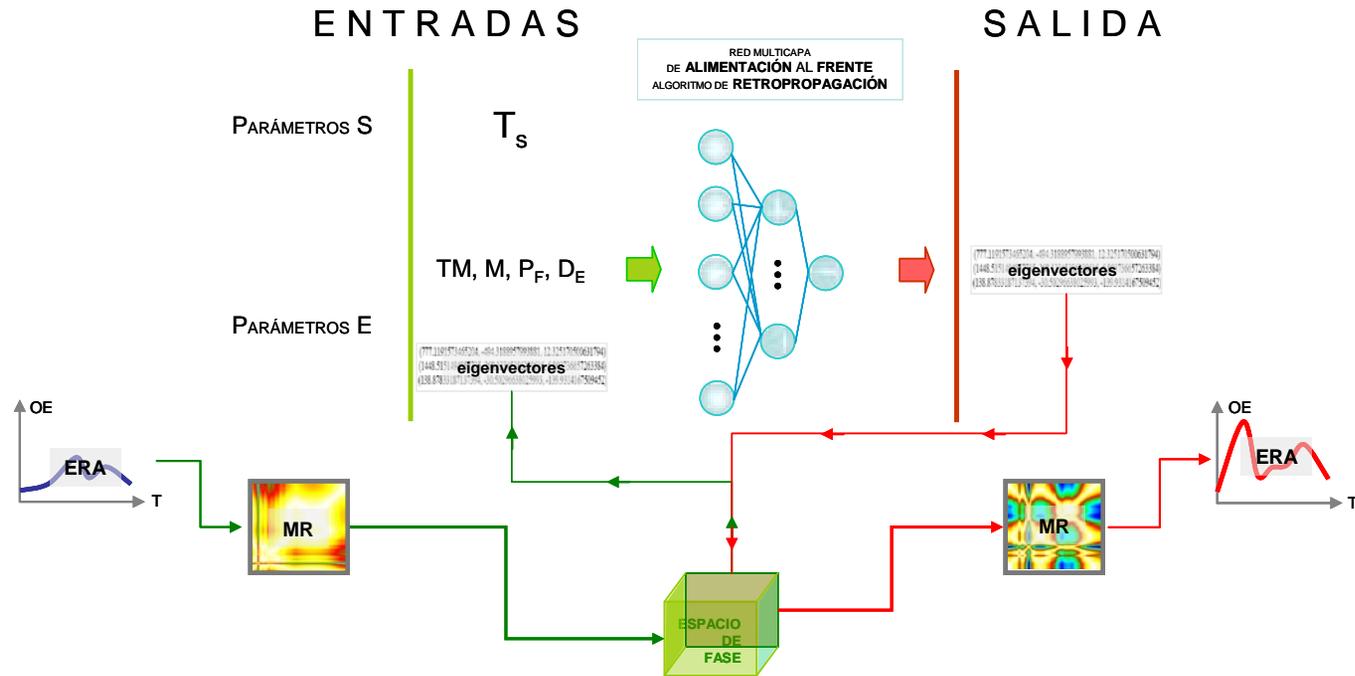


Figura 5.103 Señales recuperadas usando la dupla MR-EFs (viene del Capítulo 5)

- La poca practicidad de análisis *completos* de respuesta de terreno (aquellos que modelen el mecanismo de ruptura en la fuente, la propagación de las ondas de esfuerzo a través de la corteza terrestre hasta la parte superior del manto rocoso y la modificación de este movimiento en roca por efecto de los suelos depositados) dirige la tendencia del funcional RN-RPs/EFs de ser *muy simple*: únicamente se propone el movimiento que excita y se cuantifica su transformación de acuerdo con la situación geográfica y características de los materiales que conforman un depósito de suelo.
- Se evitan decisiones subjetivas (basadas en información *incierto* o *incompleta*) en la especificación de los movimientos de terreno. Se eliminan las afirmaciones poco científicas sobre el **Sistema** (depósitos del valle) y no se recurre a simplificaciones sobre la naturaleza del **Proceso** (propagación de ondas sísmicas).

- El *movimiento de control* facilita las decisiones de diseño y genera un procedimiento neuronal más robusto; la exclusión de propiedades dinámicas, índice y geométricas permite *dibujar* un espacio de respuestas de suelo (geo-referenciadas) sin incongruencias ni restricciones.
- La consistencia de los resultados dan confianza en los hallazgos sobre los comportamientos y los patrones que los rigen. Se avanza en *entender* el fenómeno a través de lo que observamos sin ajustar las observaciones a funciones matemáticas que *entendemos*.

Sobre el planteamiento

...Teoría es el lenguaje por medio del cual las lecciones de la experiencia pueden ser claramente expresadas. Cuando no hay teoría no existe una sabiduría colectiva, sino fragmentos meramente incompresibles...

[Fragmento del diario personal del Dr. K. Terzaghi, marzo 17, 1919]

...la Teoría es requerida para entrenar y desarrollar nuestra capacidad para interpretar correctamente lo que observamos; pero, al mismo tiempo, únicamente con *teorías* no podríamos entender casi nada en todo el campo de la ingeniería que trabaja con la tierra...

...yo siempre pierdo la paciencia con la gente que piensa que ha llegado a la *verdad* de los comportamientos¹ después de que han tenido cierto éxito en representar alguna fase de ellos², simplificada artificialmente, por medio de complicadas triples integrales, mientras al mismo tiempo, han olvidado cómo se manifiesta el suelo...

[Fragmento de una carta escrita por el Dr. K. Terzaghi, enero 21, 1926]

...nuestra experiencia práctica puede ser muy confusa a menos que se combine con una concepción razonablemente precisa de la mecánica del fenómeno bajo consideración...

[Fragmento de un reporte escrito por el Dr. K. Terzaghi, abril 9, 1939]

^(1,2) se refiere, dentro del texto en su idioma original, al comportamiento de los suelos

Ninguno de los planteamientos descritos en este trabajo desprecian las teorías ni postulados geotécnicos/sísmicos difundidos hasta el momento, al contrario, el desarrollo de los modelos requirieron de un profundo conocimiento acerca del significado de hipótesis, simplificaciones, parámetros y funcionales y de la interpretación de resultados provenientes de metodologías tradicionales. Las alternativas de análisis aglutinan de forma ventajosa las experiencias, los conceptos básicos y el cómputo aproximado para construir un ambiente que eventualmente contenga la *historia* y genere la *evolución* de la ingeniería geosísmica.

En esta tesis se intenta la expresión *correcta* de las manifestaciones del suelo a las acciones sísmicas para generar conocimiento ingenieril útil. Las novedosas tecnologías del CA evitan las simplificaciones y ayudan a entender *mejor* a través de lo que somos capaces de observar y expresar numérica y lingüísticamente. No se trata sólo de progresos computacionales a planteamientos rutinarios ni a juicios geosísmicos tradicionales. Se trata de establecer nuestra incapacidad para reconocer, analizar y modelar algunos aspectos del fenómeno geosísmico y nuestra invaluable experiencia y aciertos de interpretación del fenómeno, para dirigir lo más acertadamente posible la intuición del ingeniero sin alardear sobre los procedimientos matemáticos ni la tecnología que los sustentan.

Con la solución de los dos retos prácticos se puntualiza sobre algunos aspectos que podrían derivar en una nueva forma de pensamiento. Los modelos aquí propuestos requieren de hechos y conceptos *simples* (no de simplificaciones) para *aprender*. Conforme el ingeniero o especialista desarrolle observaciones más críticas, astutas e inteligentes podrá aprovechar, en la misma medida, las posibilidades que le brindan estas técnicas y metodologías.

Las formulaciones de esta investigación buscan la belleza, la armonía y la simpleza que, en sí mismas, puedan ser la dirección hacia la *verdad*. Los modelos hechos *visibles*, casi palpables, pierden su opacidad y acercan a la *realidad*. El soporte computacional posibilita visualizar los problemas, comprender cómo resolverles y, a veces, el descubrimiento (o la invención) de técnicas, métodos y algoritmos de formas inéditas.

7. Apéndices

7.1. Apéndice 2.3.A

Se presenta una lista de lecturas recomendadas para profundizar en aspectos importantes cuando se estudia el Análisis de Respuesta de Sitio.

Referencias Seleccionadas

- Efectos topográficos
- Aki, K. (1988), "Local Site Effects on Strong Ground Motion", *Earthquake Engineering and Soil Dynamics II; Recent Advances in Ground Motion Evaluation, Geotechnical Special, Publication No. 20*, June, pp 103-155.
- Aki, K. (1993), "Local site effects on weak and strong ground motions", *Tectonophysics*, 218, 1-3, pp93-111.
- Athanasopoulos, G.A., Pelekis P.C. y Leonidou E.A. (1999), "Effects of surface topography on Seismic Ground Response in the Egion, Greece, 15 June 1995 earthquake", *Soil Dynamics and Earthquake Engineering*, Vol. 18, No.1, ISSN 0267-7261, pp. 135-149.
- Deng, N. (1993), "FLUSHPLUSH: A computer program for approximate 3D analysis of soil -structure interaction problems", An enhanced PC version of the original FLUSH program published in 1975 by Lysmer, Udaka, Tsai y Seed, (program conversion and modification), University of California, Berkeley.
- Faccioli, E. (1991), "Seismic Amplification in the presence of geological and topographic irregularities", *Proc. of the 2nd. Int. Conf. on Recent Advances in Geotechnical Engineering and Soil Dynamics*, St. Louis Missouri, Vol. 2, pp-1779-1797.
- Geli, L., Bard P.Y., y Jullien B.(1988), "The effect of topography on earthquake ground: motion : a review and new results", *Bulletin of Seismological Society of America*, Vo. 78, No. 1, pp 42-63.
- Reinoso, E., Wrobel, L.C. y Power H, (1997), "Three Dimensional Scattering of Seismic waves from Topographical Structures", *Soil Dynamics and Earthquake Engineering*, Vol. 16, pp. 41-61.
- Sánchez-Sesma, F.J. (1983), "Diffraction of elastic waves by three-dimensional surface irregularities", *Bulletin of the Seismological Society of America*, 73, pp1621-1636.
- Sánchez-Sesma, F. (1990), "Elementary solutions for response of a wedge-shaped médium to incident SH- and SV-waves", *Bulletin of the Seismological Society of America*, Vol. 80, pp. 737-742.
- Sánchez-Sesma F. y Campillo M., (1993). "Topografic effects for incident P, SV and Rayleigh waves". *Tectonophysics*, Vol. 218, No.1-3, pp 113-125.
- Sánchez-Sesma, F., Chávez-Pérez S., Aviles, J. (1994), "Scattering of elastic waves by three dimensional topographies", *Proc. of the 8th World Conference on Earthquake Engineering*, Sn. Francisco, Vol. II, pp. 639-646.
- Trifunac, M.D. (1971), "Surface motion of a semi-cylindrical alluvial valley for incident plane SH waves", *Bulletin of the Seismological Society of America*, 61, pp1661-1667.
- Trifunac, M.D: (1973), "Scattering of plane SH waves by a semi-cylindrical canyon", *Earthquake Engineering Structural Dynamics*, 1: 267-281.
- Wong, H.L. y Trifunac, M.D. (1974), "Scattering of plane SH waves by a semi-elliptical canyon", *Earthquake Engineering Structural Dynamics*, 3: 157-169.
- Todorovska M.I. y Lee, V.W. (1991), "A note on scattering of Rayleigh waves by shallow circular canyons: analytical approach", *Bull. Indian Soc. Earthquake Tech.*, 20:1-16.
- *Cuencas Aluviales:*
- Bard, P.Y. y Gariel, J.C. (1986), "The seismic response of two dimensional sedimentary desopits with large vertical velocity gradients", *Bulletin of the Seismological Society of America*, Vol. 76, pp. 346-356.
- Chávez-García, F.J., Ramos-Martínez J., y Romero-Jiménez E., (1995), "Surface Wave Dispersión Análisis in Mexico City", *Bulletin of the Seismological Society of America*, Vol. 85, pp. 1116-1126.
- Graves,R.W. (1993), "Modeling three dimensional site response effects in Marina District Basin, San Francisco , California", *Bulletin of the Seismological Society of America*, Vol. 78, No.1, pp. 42-63.
- Rial J.A., Saltzman, N.G. y Lingh, H. (1992), "Earthquake-induced resonance in sedimentary basin", *American Scientist*, Vol. 80, No. 6, pp. 565-578.
- Somerville, P. (1998), "Emerging art: earthquake ground motion", *Geotechnical Earthquake Engineering and Soil Mechanics III*, Vol. I, ASCE, *Proc. of speciality conference*.
- *Geometría del valle y las no-homogeneidades del suelo*
- Alterman, Z.S. and Karal, F.C. (1968), "Propagation of elastic waves in layered media by finite difference methods", *Bulletin of the Seismological Society of America*, 58, pp367-398.
- Bielak, J., MacCamy, R.C., McGhee, D.S. and Barry, A. (1991), "Unified symmetric BEM-FEM of site effects on ground motions - SH waves", *Journal of Engineering Mechanics*, ASCE, 117 (10), pp2265-2285.
- Lysmer, J. and Drake, L.A. (1971), "The propagation of Love waves across non horizontally layered structures", *Bulletin of the Seismological Society of America*, 61, pp1233-1252.

Sánchez-Sesma, F.J. (1983), "Diffraction of elastic waves by three-dimensional surface irregularities", *Bulletin of the Seismological Society of America*, 73, pp1621-1636.

TRISEE (1999), "3D site effects and soil-foundation interaction in earthquake and vibration risk evaluation", edited by Faccioli, E., Paolucci, R. And Vanini, M., European Commission, Directorate General XII for Science, Research and Development.

Romo , M.P.,(1977) "Soil-Structure Interaction in a Random Seismic Environment", Tesis Doctoral, Universidad de California , Berkeley.

Bárcena A. y Romo M., (1994), "RADSH: Un programa de computadora para analizar depósitos de suelo estratificados horizontalmente sujetos a excitaciones dinámicas aleatorias", Reporte Interno del Instituto de Ingeniería, UNAM.

Seed H.B. e Idriss I. (1969), "The Influence of Soil Conditions on Ground Motions during Earthquakes", *Journal of Soil Mechanics and Foundations Division, ASCE*, Vol. 94, No. SM1, pp. 120-137.

Martin, P.P. (1975), "Non-Linear Methods for Dynamic Analysis of Ground Response", PhD dissertation, University of California, Berkeley.

Lee, M.K.W. and Finn, W.D.L. (1991), "DESRA-2C: Dynamic effective stress response analysis of soil deposits with energy transmitting boundary including assessment of liquefaction potential", University of British Columbia, Faculty of Applied Science, p. 34.

Li, X.S., Wang, Z.L. and Shen, C.K. (1992), "SUMDES: A nonlinear procedure for response analysis of horizontally-layered sites subjected to multi-directional earthquake shaking", Dept. University of California, Davis, p. 81.

7.2.Apéndice 3.1.A

Breve historia del Conexionismo

La revolución conexionista

La investigación conexionista está firmemente establecida entre la comunidad científica [inteligencia artificial (Aizawa, 1992; Gallant,1993), neurociencia cognitiva (Mozer et al., 1997), economía (Zapranis y Refenes, 1994), lingüística (Plunkett, 1995), filosofía (Horgan y Tienson, 1996), y física (Hopfield, 1982), por nombrar algunos] especialmente en el campo multidisciplinario de la ciencia cognitiva (Thorndike , 1932; Bechtel y Abrahamsen, 1991; Dawson, 1988; Rumelhart et al., 1986; McClelland et al., 1986; Thagard, 1996).

El conexionismo tiene un pasado muy largo, el origen de las ideas conexionistas pueden atribuirse al gran filósofo griego Aristóteles y sus ideas sobre asociaciones mentales. Estas ideas fueron retomadas por los empíricos británicos y naturalmente extendidas por los fundadores de la psicología, siendo los neuropsicólogos quienes relacionan el proceso de aprendizaje y memoria a las propiedades cerebrales. Pero esto es sólo la mitad de la fotografía, la otra mitad la conforman los investigadores que alimentaron la investigación matemática y la temprana ciencia computacional y contribuyeron a la comprensión de los sistemas conexionistas.

La perspectiva ingenieril sobre los sistemas conexionistas dirige el diseño hacia redes tan eficientes como sean posibles (en términos de topología de red, respuestas correctas, y generalización) y el concepto general sobre estos mecanismos se ligó al cómputo neuronal, inspirado en la física e ingeniería y alejado de la biología (George et al., 1988).

Bajo la visión de la ciencia cognitiva, el conexionismo es usado para contestar preguntas concernientes al conocimiento humano desde la *percepción* hasta el más alto nivel llamado *atención* y *razonamiento*. Los científicos cognitivos-conexionistas se basan en la biología y no en la tecnología. Consecuentemente, los objetivos de la aproximación ingenieril no necesariamente aproximan a la ciencia cognitiva hacia el conexionismo.

Ciencia Cognitiva y Conexionismo

Raíces filosóficas

A pesar del considerable crecimiento de la investigación conexionista a partir de la década de los 80, éste no es un fenómeno nuevo. Aristóteles (ca. 400 B.C.) ha sido citado [Anderson et al., 1990] como el primer científico en proponer el concepto básico del conexionismo: "la memoria se compone de elementos individuales ligados o conectados entre sí a través de diferentes mecanismos como sucesión temporal, similitud de objetos, y proximidad espacial".

Mattie y Hobbes así como la escuela empírica británica encabezada por Berkeley, Locke y Hume extienden estas ideas y declaran que: i) los elementos mentales o ideas se asocian unas con otras a través de la experiencia, ii) que la experiencia consiste de contigüidad espacial, contigüidad temporal, similitud y disimilitud de ideas y iii) que estas ideas son muy complejas pero pueden ser reducidas a un conjunto de elementos simples (sensaciones) los cuales a través de sencillas reglas aditivas pueden ser convertidas en sujetos de predicción

Manifestaciones Psicológicas

Con el nacimiento de la psicología como un campo diferente de la filosofía, las ideas detrás del conexionismo se refinaron y concretaron su bases neurofisiológicas. Los trabajos de psicólogos como Spencer (1910) y James (1950) son ejemplos tempranos de redes conexionistas –redes que combinaron principios básicos de asociativismo con neurología.

a) Conexiones de Spencer

En *The Principles of Psychology*, Herbert Spencer (1910a,1910b) estableció que existe una conexión fundamental (básica) entre cambios nerviosos y estados físicos.

b) Memoria asociativa de James

William James (1950a, 1950b) postula que no existe modificación mental que no esté acompañada o seguida de un cambio en el cuerpo (primera referencia a los pesos entre neuronas).

c) Conexionismo de Thorndike

Edward Lee Thorndike trató a profundidad los estados de la mente (a partir del trabajo de Watson, 1913) y cómo cambian con la experiencia por lo que se le considera uno de los primeros conexionistas formales. En su libro, *The Fundamentals of Learning* (Thorndike, 1932) diferenció los principios del asociativismo británico del *nuevo conexionismo*. El conexionismo de Thorndike es un punto de giro donde las teorías de la asociación neuronal se hacen sub-simbólicas y graduadas en arquitecturas funcionales (Walter, 1990). En otras palabras, las conexiones neuronales se convierten en sustitutos para, en lugar de mecanismos de, procesos de ideas. Son sus leyes del *ejercicio* o *uso frecuente* y la del *efecto* los principios que subyacen a las actuales técnicas de entrenamiento supervisado (retropropagación, por ejemplo).

d) La regla de aprendizaje de Hull

Clark L. Hull (1943) describe varias propiedades funcionales de actividad neuronal que consideró importantes en los organismos vivos y fue el primero en desarrollar ecuaciones empíricas para describir el proceso de aprendizaje.

La influencia neurofisiológica

Siguiendo los trabajos pioneros de Sherrington y Cajal los esfuerzos en investigación se dirigieron al establecimiento de correlaciones entre el aprendizaje y la memoria. A partir de este paradigma dos grandes figuras en el conexionismo emergieron: Karl Lashley y Donald Hebb.

Aprendizaje Hebbiano

Quizá el trabajo más influyente en la historia del conexionismo es la contribución del neurofisiólogo Donald O. Hebb (estudiante de Lashley). En su libro, *The Organization of Behaviour* (Hebb, 1949) se describen (i) la existencia de propiedades de actividad cerebral continua y (ii) la naturaleza de la transmisión sináptica en el sistema nervioso central.

El concepto más importante que se desprende del trabajo de Hebb es su hipótesis formal de cómo ocurre el aprendizaje (postulado de Hebb),

“Cuando el axón de célula A está lo suficientemente cerca para excitar a la célula B y repetidamente o persistentemente toma parte en excitarla, algún tipo de crecimiento o cambio metabólico toma lugar en una o ambas células tal que la eficiencia de A, como una de las células excitadoras de B, sea incrementada”

La influencia matemática

La siguiente gran formulación de las teorías conexionistas puede atribuirse a McCulloch y Pitts (McCulloch y Pitts, 1943). En su trabajo *A logical calculus of the ideas immanent in nervous activity*, ellos simplificaron la actividad de las neuronas dentro de cinco estados funcionales:

1. La actividad de la neurona es un proceso “todo o nada”
2. Un número fijo de sinapsis debe ser excitado dentro del periodo de adición latente de manera que excite una neurona, este número es independiente de la actividad previa y la posición de la neurona.
3. El único retraso significativo entre el sistema nervioso es el retraso sináptico.
4. La actividad de una sinapsis inhibitoria previene completamente la excitación de la neurona en ese tiempo.
5. La estructura de la red no cambia con el tiempo.

Definición de Conexionismo

El Conexionismo es una teoría de procesamiento de información. A diferencia de los sistemas clásicos los cuales usan reglas explícitas, comúnmente lógicas, arregladas de manera jerárquica para manipular símbolos de manera serial, los sistemas conexionistas usan procesamiento paralelo de sub-símbolos con propiedades estadísticas en lugar de reglas lógicas para transformar la información.

La visión conexionista establece que los bloques de construcción básicos del cerebro son las neuronas y seis de sus propiedades funcionales (Dudai, 1989) son transportadas a las unidades artificiales:

- Es un dispositivo que recibe señales del ambiente o de otras neuronas.
- Es un dispositivo integrador y manipulador de entradas.
- Es un dispositivo conductor de la información integrada a distancia.
- Es un dispositivo de salida que envía información a otras neuronas o células.
- Es un dispositivo computacional que mapea un tipo de información a otro.
- Es un dispositivo que sub-ofrece la formación de representaciones internas.

Siguiendo estos puntos, Rumelhart, Hinton, y McClelland (Rumelhart et al., 1986) enlistan los 8 aspectos esenciales en los modelos neuronales, llamados PDP (Procesamiento Distribuido en Paralelo).

- Un conjunto de unidades de procesamiento
- Un estado de activación
- Una función de salida para cada unidad
- Un patrón de conectividad entre unidades
- Una regla de propagación para patrones de actividades propagándose a través de las conexiones de la red
- Una regla de activación para combinar las entradas con el estado actual de una unidad y producir un nuevo nivel de activación
- Una regla de aprendizaje por medio de la cual los patrones de conectividad son modificados por la experiencia.
- Un ambiente dentro del cual el sistema pueda operar.

Estas ocho propiedades de los modelos PDP se relacionan fácilmente en las seis propiedades funcionales de la neurona. La unidad de procesamiento es la neurona en sí. El estado de activación y la regla de activación son parte de la entrada y del dispositivo integrador de la neurona y la función de salida es simplemente la salida de la neurona. El patrón de conectividad y la regla de propagación se relacionan con la función conductiva de la neurona y la regla de aprendizaje y el ambiente operativo son parte de las funciones de representación y cómputo de la neurona (Fig. A.3.1.1).

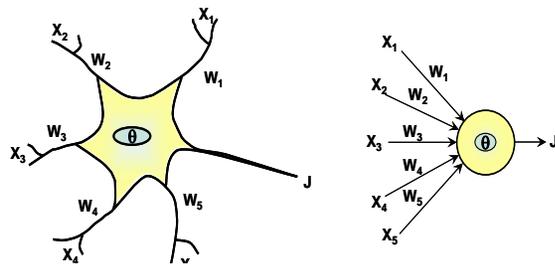


Figura A.3.1.1. Esquemas de una neurona biológica y una artificial

Primeros modelos computacionales de conexionismo

La influencia de la computadora en las teorías de aprendizaje puede verse como positiva y negativa cuando se trata del conexionismo. El *Pandemonium* de Selfridge (1959) y el *Perceptron* de Rosenblatt (1958, 1962) constituyen el esqueleto del conexionismo, pero las pruebas de las limitaciones de los perceptrones simples (Minsky y Papert, 1969), sin embargo, causaron el casi total abandono de este tipo de herramientas.

Pandemonium

Pandemonium (Selfridge, 1959) fue introducido como un modelo de aprendizaje que se auto-adaptaba para manejar problemas de clasificación de patrones sin especificaciones *a priori* a través de procesamiento en paralelo. El cambio hacia este tipo de procesamiento no fue arbitrario sino motivado por dos prominentes ventajas: (1) es más sencillo y *natural* manejar datos de forma paralela, y (2) es más fácil modificar un ensamble de módulos casi-independientes que una máquina cuyas partes interactúan secuencialmente de manera muy compleja.

Pandemonium consta de 4 capas o estratos cada una compuesta de *demonios* especializados en tareas específicas (Fig. A.3.1.2). El estrato del fondo contiene *demonios* de datos o imágenes que las almacenan y transmiten. El tercer estrato está compuesto de *demonios* computacionales que desarrollan cálculos complicados sobre los datos y después pasan los resultados al siguiente nivel. El segundo estrato está compuesto de *demonios* cognitivos quienes pesan la evidencia desde los *demonios* computacionales y "gritan" la evidencia hacia el estrato más alto de la red. Entre más evidencia se acumule, más fuerte será el grito. En el estrato más alto de la red está el *demonio* de decisión, quien simplemente escucha el grito más alto de los *demonios* cognitivos y decide qué fue presentado a la red.

La estructura de red inicial se determina *a priori* (de acuerdo con la tarea) excepto para el nivel computacional que se modifica por medio de dos diferentes mecanismos de aprendizaje. El primer mecanismo cambia los pesos de conexión entre los *demonios* cognitivos y los *demonios*

computacionales a través de aprendizaje supervisado (todas las otras conexiones entre la red permanecen fijas). Los pesos son entrenados usando un procedimiento de *gradiente ascendente* para optimizar el comportamiento de la red.

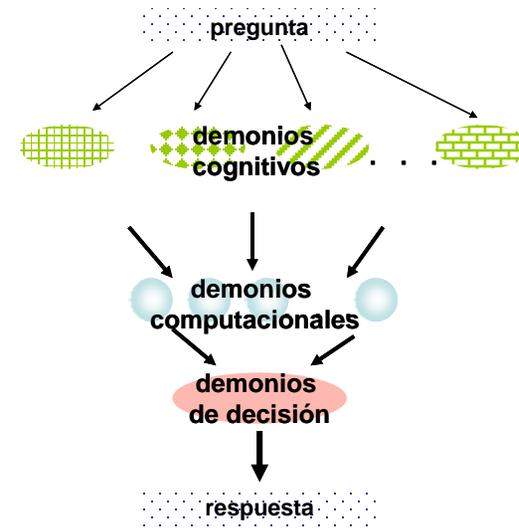


Figura A.3.1.2 *Pandemonium*

Después de que el aprendizaje supervisado se considera exitoso, un segundo mecanismo de aprendizaje es empleado. En este caso se seleccionan aquellos *demonios* computacionales importantes (basados en qué tanto influyen en la decisión), se eliminan aquellos con baja importancia y se generan nuevos *demonios* a partir de las características de los exitosos. Este segundo mecanismo es uno de los primeros algoritmos genéticos aplicados al aprendizaje-máquina.

Perceptrón

El *Perceptrón* (Rosenblatt, 1958) (o la teoría de la separabilidad estadística) alcanza más de los requerimientos funcionales del sistema nervioso que ningún otro sistema propuesto antes que él.

A pesar de que originalmente se intentó un modelo genotípico del funcionamiento de cerebro (Rosenblatt, 1958; Rosenblatt, 1962), el perceptrón representa la génesis de las máquinas de reconocimiento de patrones.

Básicamente se trata de un artefacto computacional en paralelo compuesto de (i) una capa de unidades sensoriales (S-unidades) las cuales transducen energía física (e.g. luz, sonido, etc.) a una señal, (ii) cualquier número de capas de unidades de asociación (A-unidades) las cuales tienen conexiones de entrada y de salida, y (iii) una capa final de unidades de respuesta (R-unidades) que emiten una señal para transmitir al mundo exterior (Fig. A.3.1.3).

En un perceptrón elemental las unidades-S están conectadas a las unidades A (no necesariamente masivamente conectadas) y todas las unidades-A están conectadas a una sola unidad-R, ninguna otra conexión es permitida. Debido a la importancia de este sistema, una exposición más detallada se presenta en una sección posterior de este mismo Apéndice.

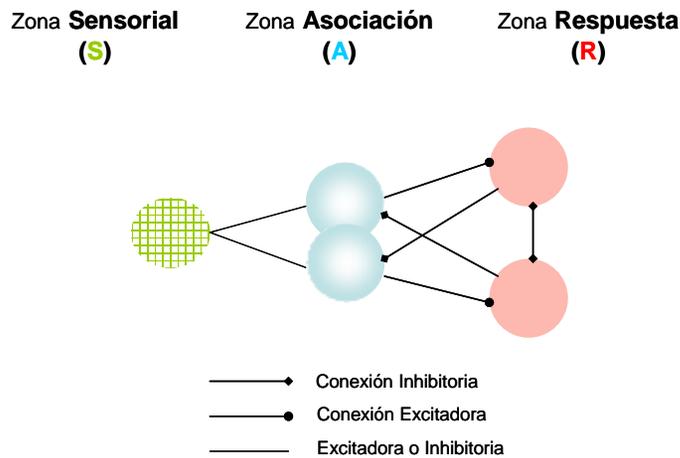


Figura A.3.1.3 *Perceptrón*

Adaline

La siguiente formulación en reglas de aprendizaje para redes se debe a Widrow y Hoff (Widrow y Hoff, 1960). Ellos desarrollaron *Adaline* (primero por *adaptive linear*, después *adaptive linear neuron* y posteriormente *adaptive linear element*) como una máquina de clasificación de patrones adaptativa. El procedimiento de aprendizaje se basó en un proceso iterativo de búsqueda que usa retroalimentación para guiar dicho proceso. El diseñador *entrena* al sistema por medio de ejemplos de entradas-salidas haciendo que la competencia de la red se relacione directa y cualitativamente con la cantidad de experiencia ofrecida al sistema.

La unidad *adaline* típica, también llamada “elemento neurona”, es un circuito lógico combinatorio que suma las señales a partir de las conexiones pesadas (ganancias), a_i , y luego envía una señal de salida si la señal interna excede algún umbral (una ganancia modificable, a_0). *Adaline* usa señales de entrada de -1 y $+1$ lo cual significa que una señal pasa siempre a lo largo de una conexión (a menos que la ganancia en la línea sea cero). Las ganancias en las conexiones se ajustan tal que las señales de salida sean exactamente -1 o $+1$; por lo tanto, la clasificación no puede ser *simplemente correcta*, sino *exactamente correcta*. Esta restricción en las salidas significa obligar al aprendizaje a continuar aún si la clasificación es *simplemente correcta* (resultado que no es *exactamente* -1 o $+1$).

Revisión de los Perceptrones

A pesar de que se sabía de las limitaciones de los perceptrones, no fue sino hasta el trabajo de Minsky y Papert, *Perceptrons* (1969), que estas dificultades fueron totalmente comprendidas. De hecho, fue con esta publicación que la ola conexionista se desaceleró (por lo menos durante algunos años). En lugar de preguntar si las redes neuronales eran buenas, Minsky y Papert se preguntaron “para qué son buenas las redes neuronales?”. Esto es claramente una pregunta a nivel computacional generada con el fin de identificar las limitaciones en las habilidades de representación de las redes tipo perceptrón.

Como Minsky y Papert apuntaron en su prólogo a la edición de 1988 de *Perceptrons*, “No hay máquina que pueda aprender a reconocer X a menos que ella posea, por lo menos potencialmente, algún esquema para representar X”. El estudio de las redes neuronales se basó en ejercicios prácticos de reconocimiento de patrones visuales que llevó a descubrir que algunos problemas (por ejemplo distinguir triángulos de cuadrados) fueron relativamente fáciles y podían ser calculados por redes simples (Papert, 1988). Algunos otros problemas (determinar si una cierta figura fue presentada o no, por ejemplo) resultaron extremadamente difíciles y requirieron redes muy grandes para resolverlos. La principal diferencia entre estos dos tipos de problemas no fue el tamaño del espacio de patrones, sino el orden (Minsky y Papert, 1969).

Las funciones que tienen un orden de 1, llamadas “linealmente separables”, pueden ser resueltas por medio de un perceptrón con una sola capa. Las tareas de reconocimiento que no pudieron ser resueltas por los perceptrones simples fueron aquellas cuyo orden fue mayor a 1. Este tipo de problemas, llamados “linealmente no-separables”, requieren de un estrato de unidades de procesamiento entre las unidades de entrada y las de salida y en aquel momento no existía un método formal para entrenar este nivel intermedio, así los perceptrones se limitaron a participar sólo en problemas linealmente separables.

A pesar de que los avances en la investigación sobre redes neuronales han producido métodos para entrenar múltiples capas de unidades (Rumelhart et al, 1986), muchas de las preocupaciones de Minsky y Papert continúan sin ser resueltas. Las redes que usan unidades de frontera lineales todavía violan la

restricción de orden límite cuando se enfrentan con problemas no separables linealmente. Más aún, el escalamiento de los pesos conforme el tamaño del espacio del problema se incrementa continúa siendo un punto a discutir (Feldman-Stewart y Mewhort, 1994).

Nuevo Conexionismo

Esta sección trata con la descripción de los sistemas conexionistas en la era post-perceptrón; esto es, redes del nuevo conexionismo. El nuevo conexionismo se caracteriza por redes poderosas computacionalmente que pueden ser entrenadas totalmente y han sido llamadas *mecanismos de aprendizaje universal* (Gallistel, 1995). Los algoritmos de aprendizaje involucrados en el nuevo conexionismo han generado procesadores de información muy poderosos –aproximadores funcionales universales (Cybenko, 1989) y clasificadores de patrones arbitrarios (Lippman, 1987).

Las *post-matemáticas* de la revolución de las redes neuronales han permitido que el número de arquitecturas conexionistas disponibles el día de hoy sea inmenso; la discusión de todas ellas está más allá del objetivo de este trabajo, pero es importante describir algunas arquitecturas básicas cuyos principios son comunes en la mayoría de las propuestas conexionistas actuales.

Arquitecturas Conexionistas Modernas

Interactive Activation and Competition (IAC) (McClelland, 1981), el primer ejemplo de conexionismo moderno, es un modelo de manejo de información a partir de conocimiento almacenado. Las primeras versiones de la arquitectura IAC no aprendían, pero desplegaban características del conocimiento humano que eran obviadas en los modelos simbólicos clásicos.

Siguiendo las bases de la red IAC surgieron las configuraciones de Grossberg (1974, 1976) (*instar* y *outstar*) y su red ART (de *Adaptive Resonance Theory*) y los mapas de auto-organización de Kohonen (1982) (redes Kohonen).

La **arquitectura genérica PDP** (procesamiento distribuido en paralelo) es una red multi-capas entrenada con el algoritmo de retropropagación (Rumelhart et al., 1986). La red PDP es probablemente la mejor conocida y más ampliamente usada arquitectura en la actualidad y se estima que cerca del 80% de las aplicaciones *reales* usan el algoritmo de retropropagación (Werbos, 1995) para tareas tanto de aproximación de funciones como de problemas de clasificación de patrones.

Una primera crítica a la arquitectura PDP fue su limitada capacidad de mapeo estático cuando el cerebro es un sistema dinámico no-lineal altamente dimensional (Doya, 1995). Para salvar esta desventaja, Hopfield (1982) presenta su arquitectura recurrente donde la activación de procesamiento (usualmente la salida) en el tiempo t es re-usada (usualmente como una entrada) en el tiempo $t+1$. Una red recurrente completamente conectada es potencialmente una arquitectura de procesamiento temporal; sin embargo, requiere de algoritmos muy poderosos para lograr un verdadero aprendizaje.

La red genérica PDP

Un perceptrón elemental tiene, en principio, el capacidad para resolver cualquier problema de clasificación de patrones expresado en notación binaria (separable linealmente), mientras que una red multicapa puede teóricamente cortar un espacio de patrones en un número arbitrario de regiones de decisión (Lippman, 1987). Se ha demostrado teóricamente que tales redes son aproximadores de funciones universales (esto es, capaces de resolver cualquier problema de aproximación de funciones de cualquier grado) (Cybenko, 1989; Hartman et al., 1990; Hornik et al., 1989).

Es fundamental entender que las pruebas de capacidad y eficiencia se concentran en arquitecturas, sin modificar las reglas de aprendizaje. Distinguir entre arquitectura y regla de aprendizaje permite (i) apuntar lo concerniente a “plausibilidad biológica” de ciertos algoritmos de aprendizaje sin comprometer la interpretación y resultados finales de una red entrenada y (ii) determinar si las diferencias en el desarrollo de las redes se deben a deficiencias de arquitectura o a modificaciones en el algoritmo de aprendizaje.

Referencias

- Aizawa, K. (1992). *Connectionism and artificial intelligence: History and philosophical interpretation*. *Journal of Experimental Artificial Intelligence*, 4:295-313.
- Anderson, J. A., Pellionisz, A. and Rosenfeld, E. editors. (1990). *Neurocomputing 2*. MIT Press, Cambridge, MA.
- Arbib, M. A. editor. (1995). *The Handbook of Brain Theory and Neural Networks*. MIT Press, Cambridge, MA.
- Bechtel, W. and Abrahamsen, A. (1991). *Connectionism and the Mind: An Introduction to Parallel Processing in Networks*. Blackwell, Cambridge, MA.
- Cybenko, G. (1989). *Approximation by superpositions of a sigmoidal function*. *Mathematics of Control, Signals, and Systems*, 2:303-314.
- Dawson, M.R.W. (1998). *Understanding Cognitive Science*. Blackwell, Oxford.
- Dawson, M.R.W., Medler, D.A. and I.S.N. Berkeley. (1997). *PDP networks can provide symbolic models that are not mere implementations of classical theories*. *Philosophical Psychology*, 10:25-40.
- Doya, K. *Recurrent networks: Supervised learning*. In Arbib, 1995, pages 796-800.
- Dudai, Y. (1989). *The Neurobiology of Memory*. Oxford University Press, Oxford.
- Feldman-Stewart, D. and Mewhort, D.J.K. (1994). *Learning in small connectionist networks does not generalize to large networks*. *Psychological Research*, 56:99-103.
- Gallant, S.I. (1993). *Neural Network Learning and Expert Systems*, MIT Press, Cambridge, MA.

- Gallistel, C.R. (1995). *The replacement of general-purpose theories with adaptive specializations*. In M. S. Gazzaniga, editor, *The Cognitive Neurosciences*, pages 1255-1267. MIT Press, Cambridge, MA.
- George, J., Reeke, N. and Edelman, G.M. (1988). *Real brains and artificial intelligence*. In S. R. Graubard, editor, *The Artificial Intelligence Debate*. MIT Press, Cambridge, MA.
- Grossberg, S. (1974). *Classical and instrumental learning by neural networks*. *Progress in Theoretical Biology*, 3:51-141.
- Grossberg, S. (1976). *Adaptive pattern classification and universal recoding: I. parallel development and coding of neural feature detectors*. *Biological Cybernetics*, 23:121-134.
- Hartman, E. J., Keeler, J. D. and J. Kowalski, M. (1990). *Layered neural networks with gaussian hidden units as universal approximations*. *Neural Computation*, 2:210-215.
- Hebb, D.O. (1949). *The Organization of Behaviour*. John Wiley & Sons, New York.
- Hinton, G.E. and Anderson, J.A. editors. (1981.) *Parallel Models of Associative Memory*. Lawrence Erlbaum Associates, Hillsdale, NJ.
- Hopfield, J.J. (1982). *Neural networks and physical systems with emergent collective computational abilities*. *Proceedings of the National Academy of Sciences*, 79:2554-2558.
- Horgan, T. and Tienson, J. (1996.) *Connectionism and the Philosophy of Psychology*. MIT Press, Cambridge, MA.
- Hornik, K., Stinchcombe, M. and White, H. (1989). *Multilayer feedforward networks are universal approximators*. *Neural Networks*, 2:359-366.
- Hull, C.L. (1943). *Principles of Behavior*. Appleton-Century-Crofts, New York.
- James, W. (1890/1950). *The Principles of Psychology*, volume 1. Dover, New York.
- James, W. (1890/1950). *The Principles of Psychology*, volume 2. Dover, New York.
- Kohonen, T. (1982). *Self-organized formation of topologically correct feature maps*. *Biological Cybernetics*, 43:59-69.
- Lippman, R.P. (1987). *An introduction of computing with neural nets*. *IEEE ASSP Magazine*, April:4-22.
- McClelland, J.L. (1981). *Retrieving general and specific information from stored knowledge of specifics*. In *Proceedings of the Third Annual Meeting of the Cognitive Science Society*, pages 170-172.
- McClelland, J.L., Rumelhart, D.E. and the PDP Research Group, editors. (1986). *Parallel Distributed Processing*, volume 2: *Psychological and Biological Models*. MIT Press, Cambridge, MA.
- McCulloch, W.S. and Pitts, W. (1943). *A logical calculus of the ideas immanent in nervous activity*. *Bulletin of Mathematical Biophysics*, 5:115-133.
- Minsky, M. and Papert, S.A. (1988/1969). *Perceptrons: An Introduction to Computational Geometry*. MIT Press, Cambridge, MA, expanded edition.
- Mozer, M.C., Halligan, P.W. and J. C. Marshall. (1997). *The end of the line for a brain-damaged model of unilateral neglect*. *Journal of Cognitive Neuroscience*, 9:171-190.
- Papert, S. (1988). *One AI or many?* *Daedalus*, 117:1-14.
- Plunkett, K. (1995). *Connectionist approaches to language acquisition*. In P. Fletcher and B. MacWhinney, editors, *The Handbook of Child Language*, pages 36-72. Blackwell, Oxford.
- Rosenblatt, F. (1958). *The perceptron: A probabilistic model for information storage and organization in the brain*. *Psychological Review*, 65:386-408.
- Rosenblatt, F. (1962). *Principles of Neurodynamics*. Spartan, Washington, DC.
- Rumelhart, D.E., Hinton, G.E. and McClelland, J.L. *A general framework for parallel distributed processing*. In Rumelhart et al. 1986 pages 45-76.
- Rumelhart, D.E., Hinton, G.E. and Williams, R. J. *Learning internal representations by error propagation*. In Rumelhart et al, 1986, pages 318-362.
- Rumelhart, D.E., Hinton, G.E. and Williams, R. J. (1986). *Learning representations by back-propagating errors*. *Nature*, 323:533-536.
- Rumelhart, D.E., McClelland, J.L. and the PDP Research Group, editors. (1986). *Parallel Distributed Processing*, volume 1: *Foundations*. MIT Press, Cambridge, MA.
- Rumelhart, D.E. and Norman, D.A. *Parallel associative models of memory: Where do they fit?* In Hinton and Anderson, 1981.
- Schneider, W. (1987). *Connectionism: Is it a paradigm shift for psychology?* *Behavior Research Methods, Instruments, and Computers*, 19:73-83.
- Selfridge, O.G. and Neisser, U. (1960). *Pattern recognition by machine*. *Scientific American*, 203:60-67.
- Selfridge, O.G. (1959). *Pandemonium: A paradigm for learning*. In D. V. Blake and A. M. Uttley, editors, *Proceedings of the Symposium on Mechanisation of Thought Processes*, pages 511-529, London. H. M. Stationary Office.
- Siegelmann, H.T. and Sontag, E.D. (1994). *Analog computation via neural networks*. *Theoretical Computing Science*, 131:331-360.

Skinner, B.F. (1938). *The Behavior of Organisms*. Appleton-Century-Crofts, New York.

Spencer, H. (1855/1910). *The Principles of Psychology, volume 1*. D. Appleton and Company, New York, 3rd edition.

Spencer, H. (1855/1910). *The Principles of Psychology, volume 2*. D. Appleton and Company, New York, 3rd edition.

Thagard, P. (1996). *Mind: Introduction to Cognitive Science*. MIT Press, Cambridge, MA.

Thorndike, E.L. (1932). *The Fundamentals of Learning*. Teachers College, Columbia University, New York.

Walker, S.F. (1990). A brief history of connectionism and its psychological implications. *AI & Society*, 4:17-38.

Watson, J. B. (1913). Psychology as the behaviorist views it. *Psychological Review*, 20:158-177.

Werbos, P.J. Backpropagation: Basics and new developments. In Arbib, 1995, pages 134-139.

White, H. (1988). Economic prediction using neural networks: The case of IBM daily stock returns. In *Proceedings of the IEEE International Conference on Neural Networks*, pages II-451-II-459, San Diego,

Widrow, B. and Hoff. (1960). M.E. Adaptive switching circuits. In *1960 IRE WESCON Convention Record*, pages 96-104, New York, IRE.

Zapranis, A.D. and Refenes, A.N. Investment management: Tactical asset allocation. In Arbib, 1995, pages 491-495.

7.3.Apéndice 3.1.B

Aprendizaje Neuronal – Teoría del Caos

Los paradigmas inspirados en la espontánea habilidad de los sistemas biológicos para adaptar su estructura y funciones a situaciones *problemáticas*, representan una ventajosa alternativa en el estudio y desarrollo de modelos sobre fenómenos naturales.

Las RNs son sistemas paralelos, dinámicos y adaptativos cuyo funcionamiento emula hechos generales propios de las redes biológicas. Una RN interactúa con los objetos y sus características estadísticas de formas similares a las que desarrollan los seres vivos.

Colectivamente las neuronas pueden llevar a cabo funciones tan complejas como identificación y corrección de errores, reconstrucción de información y análisis de patrones. Su fuerza paradigmática en aplicaciones prácticas (resolver problemas computacionales inflexibles o modelado adaptativo) reside en su habilidad para conseguir *síntesis funcional* (mapeo topológico) (Josin, 1988) y *abstracción espacial, funcional o temporal* de estos mapeos, a través del establecimiento de relaciones entrada→salida con base en ejemplos característicos.

Una vez que las invarianzas que están detrás de los datos presentados han sido aprendidas y codificadas en la topología y resistencias de las interconexiones sinápticas, la RN puede generalizar para resolver instancias de problemas arbitrarios. Además, las versiones operacionales de estas redes pueden ser “regularizadas” dinámicamente sin re-entrenamiento explícito (Barhen y Gulati, 1989) o reprogramación. Ya que los mapeos topológicos se alcanzan a partir de ejemplos *reales*, la funcionalidad de las redes no está limitada a hipótesis que observan la incertidumbre paramétrica o de ambiente, por lo que ofrecen una atractiva base para desarrollar algoritmos alternativos que resuelvan problemas con estrategias más poderosas que la tecnología existente.

Aprendizaje neuronal y la Teoría del Caos

Una red neuronal constituye un sistema dinámico no lineal disipativo cuyo flujo de información generalmente converge hacia un conector múltiple de baja dimensión en el espacio de fase. Tal sistema neuromórfico puede almacenar estados de memoria (o patrones) en puntos fijos de la dinámica de red, es decir, configuraciones de neuronas en alguna vecindad o cuenca de atracción hacia las que el estado de memoria será atraído. Para sustentar la competencia de las redes es muy importante conocer qué tan estables son estos atractores y, comenzando desde una configuración de red arbitraria, qué tan rápido pueden ser alcanzados. Sobre esta línea de análisis, un concepto de la teoría de sistemas dinámicos, los *atractores terminales*, permite formalizar la eficiencia de los algoritmos neuronales en términos de *aprendizaje*.

Atractores Terminales. Los atractores estáticos considerados en las simulaciones de sistemas dinámicos no lineales (como las redes neuronales) representan soluciones regulares a ecuaciones diferenciales de movimiento que nunca intersecan los estados transitorios (Fig. 1a). Teóricamente el tiempo de relajación del sistema a estos atractores “regulares” puede ser infinito y sufren de convergencia a mínimos locales o estados falsos. El concepto de atractor terminal en redes neuronales fue introducido por Zak (1988) para obviar algunas de las anteriores limitaciones y mejorar significativamente las características de comportamiento de los modelos neuronales de memoria asociativa.

La existencia de los atractores terminales fue establecida con el siguiente argumento: en equilibrio, los puntos fijos de un sistema dinámico disipativo

$$\text{N-dimensional } \dot{u}_n - f_n(u_1, u_2, \dots, u_N) = 0, \text{ para } n = 1, 2, \dots, N, \text{ se definen como sus soluciones constantes } u_n(\infty).$$

Si las partes reales de los eigenvalores μ_ξ de la matriz Jacobiana $M_{nm} = [\partial f_n / \partial u_m]$ en un punto fijo son todos negativos $\text{Re}\{\mu_\xi\} < 0$, entonces estos puntos son estables asintóticamente de manera local. Estos puntos son llamados atractores estáticos porque cada movimiento a lo largo

de la curva de fase consigue acercarse lo suficiente a $\bar{u}(\infty)$ (entra a la cuenca de atracción) y se aproxima al valor constante que corresponde a un cierto límite cuando t tiende a infinito.

Un punto de equilibrio representa un repulsor si por lo menos uno de los eigenvalores de la matriz M tiene una parte real positiva. Comúnmente las redes neuronales no lineales sólo generan sistemas que satisfacen la

condición de Lipschitz $|\partial f_n / \partial u_m| < \infty$. Esta condición garantiza la existencia de la solución única para cada configuración de espacio de fase inicial y explica porqué una solución transitoria no puede intersecar la solución constante correspondiente a la cual tiende, y por lo tanto, el tiempo teórico de aproximación a los atractores es siempre infinito. La evolución temporal del atractor se muestra en la Fig. B.3.1.1a.

En contraste, la noción del atractor terminal se basa en la violación de la condición de Lipschitz. Ahora un punto fijo se convierte en una solución singular (única) que cubre la familia de las soluciones regulares, mientras que cada solución regular se aproxima al atractor terminal en tiempo finito (Fig. B.3.1.1b).

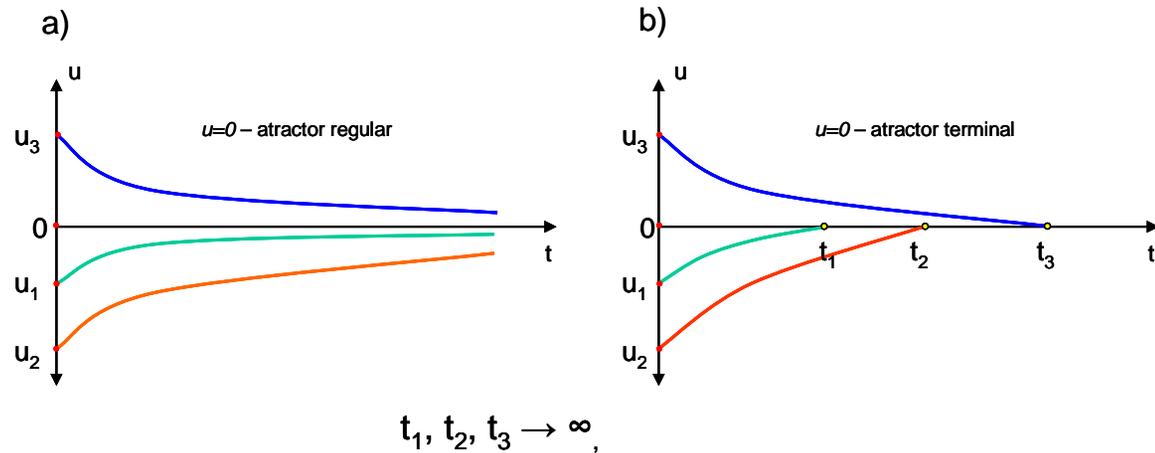


Figura B.3.1.1. a) Relajación asintótica de atractores regulares, b)atractor Terminal como solución única a un sistema dinámico

Para mostrar formalmente un atractor terminal considere el siguiente ejemplo unidimensional simple:

$$\dot{u} = -u^{1/3}$$

Esta ecuación tiene un punto de equilibrio $u = 0$ en el que la condición de Lipschitz no se cumple en

$$\frac{d\dot{u}}{du} = -\frac{1}{3}u^{-2/3}$$

$$\rightarrow -\infty \text{ en } u \rightarrow 0$$

Cuando $\text{Re}\{\mu\} \rightarrow -\infty$, este punto es un atractor con estabilidad local "infinita". Como una consecuencia, el sistema dinámico contiene "poder de atracción infinita". En una red neuronal codificada para mapeo, el fenómeno anterior implica inmediatamente relajación a las coordenadas del atractor deseadas, x_n y q_n .

De acuerdo con el ejemplo ilustrativo, el tiempo de relajación de la solución correspondiente a las condiciones iniciales $u = u_0$ hacia el atractor es finito y está dado por

$$t_u = - \int_{u_0}^{u \rightarrow 0} \frac{du}{u^{1/3}}$$

$$= \frac{3}{2} u_0^{2/3} < \infty$$

por lo que este atractor se convierte en atractor terminal y representa una solución singular (única) intersecada por todos los transeúntes atraídos.

Por lo tanto, si uno considera el caso más general $\dot{u} = \pm u^\beta, \beta > 0$ los atractores terminales estáticos ocurren para $\beta = (2i + 1)^{-1}$ y $i \geq 1$, mientras que en caso contrario todos los atractores son regulares. De esta manera ha sido demostrado que incorporar atractores terminales en las dinámicas neuronales pueden eliminar estados falsos (mínimos locales) (Zak, 1988).

Asegurar esta propiedad es un aspecto crítico para ofrecer confianza en la capacidad de generalización en operación de las redes propuestas en esta investigación. De esta manera se asegura que las interpolaciones (o extrapolaciones) de las configuraciones no están basadas en atractores falsos y sobre todo, en un marco neuromórfico, la dinámica de un atractor terminal ofrece el mecanismo para, implícitamente, explotar en tiempo restringido la “terminalidad” de las trayectorias de fase y la estabilidad infinita (localmente) permitiendo soluciones exactas y eficientes.

Aproximación universal y sus límites en SC

En 1900, en su memorable conferencia durante el Segundo Congreso Internacional de Matemáticas en París, Hilbert enlistó 23 hipótesis sobre problemas que él consideraba como los más importantes a resolver por los matemáticos del siglo XX. De acuerdo con la conjetura no. 13 existen funciones multivariadas continuas que no pueden ser descompuestas como una superposición finita de funciones continuas de pocas variables:

“existe por lo menos una función continua de tres variables, ejemplificada por $f^7 + xf^3 + yf^2 + zf + 1 = 0$ la cual podría no ser descompuesta como una superposición finita de una función continua bi-variable”

En 1957 Arnold desaprobó esta hipótesis (Arnold, 1957) y en el mismo año, Kolmogorov (1957) mostró un teorema de representación general con una prueba constructiva donde las funciones en la descomposición fueron unidimensionales.

El teorema de representación de Kolmogorov fue mejorado por varios autores como Sprecher (1965) y Lorentz (1966) siendo De Figueiredo (1980) quien mostró que este teorema puede ser generalizado para una red neuronal multicapa de propagación al frente y por lo tanto éstas podrían ser consideradas aproximadores universales (De Figueiredo, 1980; Blum y Li, 1991; Hornik et al., 1989; Kurkova, 1992).

Resultados similares fueron establecidos desde el comienzo de los 90 sobre lógica difusa (Castro, 1995; Kosko, 1992; Wang, 1992, por ejemplo) mostrando la capacidad de diferentes métodos de razonamiento difuso para aproximar cualquier función continua en un dominio compacto con cualquier exactitud específica.

Sin embargo, se ha demostrado que los modelos neuronales y difusos tienen una complejidad exponencial en términos del número de variables de la función original, esto significa que, (en el contexto de redes neuronales) el número de unidades en los estratos ocultos, o (en el contexto de lo difuso) el número de reglas o bloques de reglas, crece exponencialmente conforme el error de aproximación tiende a cero. Esta exponencialidad no puede ser eliminada por lo que la propiedad de aproximación universal de estos sistemas basados en la incertidumbre no puede ser explotada directamente para propósitos prácticos.

Además, para algunos sistemas difusos especiales, por ejemplo controladores del tipo Takagi-Sugeno, (Moser, 1999; Tikk, 1999) se ha probado que si se limita el número de bloques de construcción (reglas), el conjunto de funciones resultante no puede ser “denso” en el espacio de las funciones aproximadas, es decir, se convierte en un *quasi*-conjunto discreto (Klement et al., 1999).

Estos resultados mutuamente contradictorios hacen surgir la pregunta: ¿en qué extensión la *aproximación* se cataloga como exacta?. Desde el punto de vista práctico es suficiente tener una “buena” aproximación y, de acuerdo con el problema por resolver, el modelador determine la aceptación en términos de exactitud. La tarea es encontrar un posible intercambio (equilibrio) entre la exactitud especificada y el número de unidades de construcción que permitan que sea factible (en términos de tiempo) dicha aproximación.

Pocos resultados han sido publicados en los campos teóricos de las RNs y la LD acerca de la determinación del número de bloques de construcción como función de la exactitud. En RNs, Blum y Li (1991) determinaron un límite superior para el número de unidades Mc-P (McCulloch-Pitts) para redes de tres capas (sólo una oculta). En el caso de redes de propagación al frente multicapa, Kurková (1995) fijó el límite superior para el número de unidades en capa ocultas con funciones de activación sigmoidales. Por su parte, en teoría difusa y para algunas aplicaciones prácticas de funciones de membresía específicas, Kóczy y Zorat (1997) determinaron el error de aproximación (el peor caso) y el costo parametrizado de la inexactitud en las funciones de aproximación. Para los controladores del tipo Takagi-Sugeno, Ding et al., (2000), Ying et al., (1998) y Zeng et al., (2000) determinaron las condiciones mínimas necesarias para la configuración del sistema en exactitud específica.

Es importante remarcar que el formalismo en topología es conveniente para probar sólo la existencia de la aproximación y no ofrece los medios para construir el aproximador por sí mismo. Para que el lector interesado en el proceso de construcción y su repercusión sobre la actuación final del sistema se recomienda (Haykin, 1999; Hellendoom et al., 1993; Jang et al., 1997).

Resultados positivos en aproximación universal.

Aproximación universal en RN

Los primeros resultados sobre RNs se basan en el teorema de representación de Kolmogorov (De Figueredo, 1980). Hecht-Nielsen (1987) reformularon el teorema de Sprecher estableciendo que cualquier función continua definida en I^n podría ser implementada (de manera exacta) por una red de tres estratos con $2n+1$ unidades en el estrato oculto y con funciones de transferencia $\lambda^{ps} \psi_q$ ($p=1, \dots, n; q=1, \dots, 2n+1$) -de la entrada a las unidades ocultas- y ϕ -desde las ocultas a la salida-. Con esto quedó demostrada la universalidad ya que ψ_q podría ser explotada para aproximar funciones de dimensión más alta usando el teorema de representación de Kolmogorov, esto es, cualquier función que satisfaga completamente las condiciones anteriores puede ser aproximada por medio de una red neuronal teniendo funciones Kolmogorov como funciones de activación.

Sin embargo, las funciones ϕ y ψ_q ($q=1, \dots, 2n+1$) pueden tener incluso gráficas fractales y están lejos de ser funciones de activación típicas. De acuerdo con Poggio y Girosi (1989) el resultado de Kolmogorov no es relevante para RN porque las unidades de red Kolmogorov tienen funciones complejas.

Los primeros resultados sobre una clase general de redes neuronales con funciones de activación "normales" y capacidad de aproximación universal fueron publicados por Hornik et al., (1989). Ellos probaron que cualquier

función continua $f \in C(I^n)$ puede ser aproximada (con exactitud arbitraria) en la norma suprema por una red de alimentación al frente de tres estratos (entrada-oculto-salida) con unidades ocultas semi-lineales con función límite y una unidad de salida lineal, lo que se expresa formalmente como:

$$\left| f(x) - \sum_{i=1}^m w_i g \left(\sum_{j=1}^n a_{ij} x_j + c_i \right) \right| < \varepsilon$$

donde los número reales w_i y a_{ij} son los pesos y c_i los límites. Las unidades semi-lineales tienen la forma $g(L(x) - b)$ donde $L(x)$ es

lineal en x , y la función g es una función real monotónica con los límites $\lim_{x \rightarrow -\infty} g(x) = 0$ y $\lim_{x \rightarrow \infty} g(x) = 1$ usualmente llamada

limitante cerrado y g puede ser una función sigmoideal, por ejemplo $\sigma(z) = 1/(1 + e^{-z})$ o la función escalón

$$H(z) = \begin{cases} 1 & \text{si } z > 0 \\ 0 & \text{si } z \leq 0 \end{cases}$$

Adicionalmente, en (Hornik et al., 1989) se prueba que cualquier función $f \in L_2(I^n)$ (en el espacio de L_2 -funciones integrables) puede ser

aproximada (con exactitud arbitraria) respecto a la norma L_2 por redes de tres estratos.

Resultados similares se han presentado en redes de retro-propagación (Cybenko, 1989; Funahashi, 1989; Castro et al., 2000) pero estos trabajos no fueron construidos de forma simple y las pruebas dependen de teoremas existenciales (revisar el de Stone-Weierstrass o el de Hahn-Banach en (Cybenko, 1989) por lo que no se presentarán en este trabajo de investigación.

Aproximación Universal en Sistemas Difusos.

Los primeros trabajos concernientes a las capacidades de los sistemas difusos tienen un planteamiento práctico y muestran experimentalmente cómo cualquier función no lineal continua, expresada dentro de un universo de discurso compacto, es posible aproximarla (con exactitud arbitraria) por medio de un sistema de control difuso (Kawamoto, 1992). Es a partir de estos lineamientos que se producen los postulados matemáticos que validaron los anteriores planteamientos y resultados.

Kosko (1992) probó que los controladores del tipo Mamdani (sistemas difusos aditivos que en términos de estructura y parámetros son similares al método Mamdani) podían aproximar uniformemente $f \in C(X)$ donde X es compacta. Aquí debe puntualizarse que a pesar de que el teorema es

presentado como válido para cualquier compacta $X \subset \mathfrak{R}^n$ la prueba fue aplicada sólo en espacios de entrada unidimensional.

El número de reglas puede estimarse por medio de la distancia mínima entre los centros de dos conjuntos adyacentes. Si estos conjuntos son denotados

por y_i y $y_i + 1$ entonces para ε -aproximación:

$$|y_i - y_{i+1}| < \frac{\varepsilon}{2p-1}$$

donde P es el número máximo de los antecedentes traslapados sobre X (2 para entrada unidimensional). A partir de esto, si la exactitud pre-establecida es ε , el número de reglas en la base debería ser

$$|\mathfrak{R}| \geq \frac{|X|}{\varepsilon}$$

A partir de la ecuación anterior se desprende que para una aproximación arbitraria el número de reglas es ilimitado, sin embargo, para una pre-escrita ε el número de reglas puede ser estimado usando dicha desigualdad.

Al mismo tiempo, los resultados de Wang (Wang y Mendel, 1991; Wang, 1992) mostraron que un tipo diferente de sistemas basados en reglas difusas tiene propiedades similares. En (Wang, 1992) investigó los sistemas con múltiples entradas y reglas de salida únicas, donde sea que se usaran funciones de membresía exponenciales positivas sobre todo el dominio de las entradas y por lo tanto de las reglas consecuentes, con el algoritmo de inferencia de Larsen y con el proceso difuso inverso del Centroide. Probó que un conjunto de estos controladores difusos podría aproximar cualquier función continua con exactitud arbitraria respecto a la norma suprema. También aplicó el teorema de Stone-Weierstrass, como lo hicieron Hornik et al. (1989) para mostrar que el conjunto de funciones entrada-salida de los

controladores anteriores es denso en $C(I^n)$. Desafortunadamente la misma dificultad técnica se mantiene como en el caso del teorema de Kosko: el número y los términos de las reglas en la base no están limitados.

Numerosos autores han contribuido en este tema mostrando que la propiedad de aproximación universal se mantiene para varios tipos de sistemas difusos (por ejemplo, Buckley, 1993; 1995; Nguyen y Kreinovich, 1992). El trabajo más general fue publicado por Castro et al. (2000) y en él se ofrece una prueba para cada clase de lógicas difusas y por cada tipo fijo de función de membresía perteneciente a un amplio grupo de funciones de membresía. Las pruebas muestran que un sistema de control de lógica difusa es capaz de aproximar cualquier función real continua sobre un conjunto compacto con exactitud arbitraria. A pesar de esto, como se aclara en las conclusiones de Castro et al. (2000), ni el proceso de construcción ni el número de reglas requeridas se pre-definen y éstas últimas permanecen sin límite.

Recientemente ha sido demostrado que sistemas difusos más generales y que no están incluidos en el trabajo de Castro (por ejemplo los que usan inferencia t-norma y t-co-norma) poseen la propiedad de aproximación universal (Yager y Kreinovich, 2003).

En (Bauer et al., 1995; Ying, 1998a, 1988b; 1988c, Zeng et al., 2000) se trata con los controladores Takagi-Sugeno y concluyen que con sólo dos reglas y teniendo conjuntos difusos normalizados como antecedentes, cualquier función continua puede ser representada (en el caso multidimensional un número considerablemente más grande de reglas es requerido). A pesar de que esta sorprendente hipótesis usa sólo dos funciones de membresía el resultado tiene un punto débil: no se garantiza que los términos sean convexos a pesar de que la convexidad juega un papel central en el razonamiento natural (como la lingüística). Por lo tanto no se demuestra que con este método la reducción de la complejidad computacional, como la no

linealidad de f , es simplemente transferida a las funciones de membresía. Además, la función de membresía de los antecedentes debe ser construida

por medio de una transformación directa de la función f lo que significa que si no hay transformación exacta disponible en la función entrada-salida del sistema bajo control, como en la mayoría de los casos prácticos, estos postulados no ayudan en el diseño paramétrico de los controladores difusos

que aproximan una función desconocida f .

Referencias

Arnold, V.I. (1957). *On functions of three variables, Doklady Akademii Nauk USSR, 114:679-681.*

Bauer, P., Klement, E.P., Leikermoser, A. and Moser, B. (1995). "Modeling of control functions by fuzzy controllers". In H. Nguyen, M. Sugeno, R. Tong, and R.R. Yager Editors, *Theoretical Aspects of Fuzzy Control, 91-116, Wiley, New York.*

Barhen, J. y Gulati, S. (1989). "Theory for Neural Learning of Nonlinear Mappings". *Neural Networks.*

Blum, E.K. y Li, L.K. (1991). "Approximation Theory and Feedforward networks". *Neural Networks, 4(4):511-515.*

Buckley, J.J. (1993). "Sugeno type controllers are universal controllers". *Fuzzy Sets and Systems, 53:299-304.*

Buckley, J.J. (1995). "System stability and the fuzzy controller". In H. Nguyen, M. Sugeno, R. Tong, and R.R. Yager Editors, *Theoretical Aspects of Fuzzy Control, 51-63, Wiley, New York.*

Castro, J.L. (1995). "Fuzzy logic controllers are universal approximators". *IEEE Trans. On SMC, 25:629-635.*

Castro, J.L., Mantas, C.J. and Benitez, J.M. (2000). "Neural networks with a continuous squashing function in the output are universal approximators". *Neural Networks, 13:561-563.*

Cybenko, G. (1989). "Approximation by superposition of sigmoidal functions". *Mathematics of Control, Signal and Systems, 2:303-314.*

- De Figueiredo, R.J.P. (1980). *Implications and Applications of Kolmogorov's superposition theorem*. IEEE, Tr. Autom. Control, 1227-1230.
- Ding, Y.S., Ying, H. and Shao, S.H. (2000). "Necessary conditions on minimal system configuration for general miso mamdam fuzzy systems as universal approximators". IEEE Tr. Systems, Man and Cybernetics, Part B, 30(6):857-864.
- Funanashi, K.I. (1989). "On the approximate realization of continuous mapping by neural networks". Neural Networks, 2:183-192.
- Haykin, S. (1999). *Neural Networks: A Comprehensive Foundation*, Prentice Hall, Upper Saddle River, New Jersey, 2nd edition.
- Hecht-Nielsen, R., Kolmogorov's mapping neural network existence theorem. In Proc. Of the International Conference on Neural Networks, Vol. III, 11-14, New York, 1987.
- Hellendoorn, H., Driankov, D. and Reinfrank, M. (1993). *An introduction to fuzzy control*, Springer, Berlin.
- Hornik, K., Stinchcombe, M. and White, H. (1989). "Multilayer feed forward networks are universal approximators". Neural Networks, 6:359-366.
- Jang, J.S.R., Sun, C.T. and Mizutani, E. (1997). *Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence*. Prentice Hall, Upper Saddle River, New Jersey.
- Josin, G. (1988). "Neural-Space Generalization of a Topological Transformation". Biological Cybernetics, Vol. 59, pp. 283-290.
- Kawamoto, S., Tada, K., Onoe, N., Ishigame, A. and Taniguchi, T. (1992). "Construction of exact fuzzy systems for nonlinear systems and its stability analysis". In Proc. Of the 8th Fuzzy System Symposium, 517-520, Hiroshima.
- Klement, E.P., Kóczy, L.T. and Moser B. (1999). "Are fuzzy systems universal approximators?". Int. J. General Systems, 28 (2-3):259-282.
- Kóczy, L.T. and Zorat A. (1997). "Fuzzy systems and approximation". Fuzzy sets and Systems, 85:203-222.
- Kolmogorov, A.N. (1957). "On the representation of continuous functions of many variables by superpositions of continuous functions of one variable and addition". Dokl. Akad. USSR, 114:953-956. (In russian)
- Kosko, B. (1992). Fuzzy systems as universal approximators. In Proc. Of the IEEE Int. Conf. On Fuzzy Systems, 1153-1162, San Diego.
- Kurková, V. (1992). "Kolmogorov's theorem and multilayer neural networks". Neural Networks, 5, 501-506.
- Kurková, V. (1995). "Approximation of functions by perceptrons networks with bounded number of hidden units". Neural Networks, 8(5): 745-750.
- Lorentz, G.G. (1966). *Approximation of functions*. Holt. Reinhard and Winston, New York.
- Moser, B. (1999). Sugeno controllers with a bounded number of rules are nowhere dense. Fuzzy sets and Systems, 104(2),269-277.
- Nguyen, H.T. and Kreinovich, V. (1992). *On approximation of controls by fuzzy systems*. Technical Report TR 92-93/302, LIFE Chair of Fuzzy Theory, Tokyo Institute of Technology, Tokyo.
- Poggio, T. and Girosi, F. (1989). "Representation properties of networks: Kolmogorov's theorem is irrelevant". Neural Computation, 1(4):465-469.
- Sprecher, D.A. (1965). "On the structure of continuous functions of several variables". Trans. Amer. Math. Soc. 115:340-355.
- Tikk, D. (1999). "On nowhere denseness of certain fuzzy controllers containing prerestricted number of rules". Tatra Mountains Math. Publ. 16:369-377.
- Wang, L.X. (1992). "Fuzzy systems are universal approximators". In Proc. Of the IEEE Int. Conf. On Fuzzy Systems, 1163-1169, San Diego.
- Wang, L.X. and Mendel, J. (1991). "Generating fuzzy rules from numerical data with suplications". Technical Report TR USC-SIPI #169. Signal and Image Processing Institute, University of Southern California,
- Yager, R.R. and Kreinovich, V. (2003). "Universal approximation theorem for uninorm-based fuzzy systems modeling". FUZZY SETS AND SYSTEMS 140 (2): 331-339.
- Ying, H. (1998). "Sufficient conditions on uniform approximation of multivariable functions". by general Takagi-Sugeno fuzzy systems with linear rule consequents. IEEE Trans. On SMC, Part A, 28(4):515-520.
- Ying, H. (1998). fuzzy systems with linear rule consequents are universal approximators. General SISO Takagi-Sugeno IEEE Trans on FS, 6(4): 582-587.
- Ying H. (1998). "fuzzy systems with simplified linear rule consequents are universal approximators". General Takagi-Sugeno. Models and filters, J Inform. Sci., 108:91-107.
- Ying H., Sufficient conditions on uniform approximation of multivariate functions by general Takagi-Sugeno fuzzy systems with linear rule consequents. IEEE Trans. on SMC, Part A, 28(4):515-520, 1998.
- Zeng, K., Zhang N.Y. and Xu, W.L. (2000). A comparative study on sufficient conditions for Takagi-Sugeno fuzzy systems as universal approximators. IEEE Trans. On FS. 8(6):773-780.
- Zak, M., "Terminal attractors for adressable memory in neural networks", Physics Letters A, Vol. 133, 1988, pp. 218-222.

7.4. Apéndice 4.1.A

Lista de lecturas recomendadas para profundizar en la teoría, construcción e interpretación de los Mapas de Recurrencia.

Referencias Seleccionadas

A. Babloyantz, "Some remarks on nonlinear data analysis of physiological time series", (1989), In: *Measures of Complexity and Chaos*, Neal A. Abraham, Alsonso M. Albano, Anthony Passamante and Paul E. Rapp (eds.), pp. 51-62, Plenum Press, NATO ASI Series B: Physics Vol. 208, New York and London

A. Babloyantz, "Evidence for slow brain waves: a dynamical approach", (1991), *Electroencephalogr. Clin. Neurophysiol.*, vol. 78, pp. 402-405

M.C. Casdagli, "Recurrence plots revisited", *Physica D* 108 (199) 12-44

J.P. Eckmann, S. Oliffson Kamphorst and D. Ruelle, "Recurrence plots of dynamical systems", (1987), *Europhys. Lett.*, Vol. 4, No. 9, pp. 973-977

Claire G. Gilmore, "A new test for chaos", (1993), *J. Econ. Behav. Organ.*, Vol. 22, pp. 209-237

Claire G. Gilmore, "A new approach to testing for chaos, with applications in finance and economics", (1993), *Int. J. Bifurcation Chaos*, Vol. 3, No. 3, 583-587.

Pawel Kaluzny and Remigiusz Tarnecki, "Recurrence plots of neuronal spike trains", (1993), *Biol. Cybern.*, vol. 68, pp. 527-534

Keegan AP, Zbilut JP, Merritt SL, Mercer PJ, "Use of recurrence plots in the analysis of pupil diameter dynamics in narcoleptics", (1993) *SPIE Proceedings: Chaos in Biology and Medicine*, Vol 2036, pp 206-213.

M.C.K. Khoo (ed), "Approaches to Pulmonary Physiology and Medicine", Plenum Press, New York, 1996., Chapter 8, pp 137-148.

Matthew Koebbe and Gottfried Mayer-Kress, "Use of recurrence plots in the analysis of time-series data" (1992), In: *Nonlinear Modeling and Forecasting*, M. Casdagli and S. Eubank (eds.), pp. 163-188, *SFI Studies in the sciences of complexity*, Proc. Vol. XII, Addison-Wesley

Gottfried Mayer-Kress and Alfred Huebler, "Time evolution of local complexity measures and aperiodic perturbations of nonlinear dynamical systems", (1989), In: *Measures of Complexity and Chaos*, Neal A. Abraham, Alsonso M. Albano, Anthony Passamante and Paul E. Rapp (eds.), pp. 155-171, Plenum Press, NATO ASI Series B: Physics Vol. 208, New York and London

F. Takens, "Detecting strange attractors in turbulence", (1981), In: *Dynamical Systems and Turbulence* (Warwick 1980), *Lecture Notes in Mathematics*, No. 898, Springer-Verlag, Berlin

Trulla, L.L, A. Giuliani, J.P. Zbilut, and C.L. Webber, Jr., "Recurrence quantification analysis of the logistic equation with transients", *Phys. Lett. A* 223: pp 255-260, (1996).

M. Vihinen, "An algorithm for simultaneous comparison of several sequences", (1988), *CABIOS*, Vol. 4, No. 1, pp. 89-92.

C.L. Webber, Jr. and J.P. Zbilut, "The application of chaos theory to rhythmic breathing patterns", (1991), In: *Cardiorespiratory and motor coordination*, H.-P. Koepchen and T. Huopaniemi (eds.), pp. 239-247, Springer-Verlag, Berlin, Heidelberg, New York

C.L. Webber, Jr., "Rhythmogenesis of deterministic breathing patterns", (1991), In: *Rhythms in Physiological Systems*, H. Haken and H.P. Koepchen (eds.), pp. 177-191, Springer-Verlag, Springer Series in Synergetics, Berlin, Heidelberg, New York

Webber, C.L., Jr. and J.P. Zbilut, "Assessing deterministic structures in physiological systems using recurrence plot strategies. In: *Bioengineering*", Charles L Webber and Joseph P. Zbilut. *Dynamical assessment of physiological systems and states using recurrence plot strategies.* (1994), *J. Appl. Physiol.*, vol. 76, no. 2, pp. 965-973

Webber, C.L., Jr. and J.P. Zbilut, "Recurrent structuring of dynamical and spatial systems", In: *Complexity in the Living: A Modelistic Approach. A.*

J.P. Zbilut, M. Koebbe, H. Loeb and G. Mayer-Kress, "Use of recurrence plots in the analysis of heart beat intervals", (1991), In: *Proceedings IEEE Computers in Cardiology*, pp. 263-265, IEEE Computer Society Press, Washington, Brussels, Tokyo

J.P. Zbilut, "Power laws, transients, attractors, and entropy: possible implications for cardiovascular dynamics" (1991), In: *Rhythms in Physiological Systems*, H. Haken and H.P. Koepchen (eds.) pp. 139-151 Springer-Verlag Springer Series in Synergetics Berlin, Heidelberg, New York

Joseph P. Zbilut and Charles L Webber Jr., "Embeddings and delays as derived from quantification of recurrence plots", (1992), *Phys. Lett. A*, vol. 171, pp. 199-203

Webber, C.L., Jr. and J.P. Zbilut, "The applicability of methods from nonlinear dynamics in assessing physiological states of the respiratory system", *Proc. Eng. Med. Biol. Soc. 12*: 1863-1864, 1990.

Webber, C.L., Jr. and J.P. Zbilut, "The applicability of chaos theory to rhythmic breathing patterns." In: *Cardiorespiratory and Motor Coordination*. H.-P. Koepchen and T. Huopaniemi (eds.). Springer-Verlag, Berlin, Heidelberg, New York, pp 239-247, 1991.

Webber, C.L., Jr., "Rhythmogenesis of deterministic breathing patterns" In: *Rhythms in Physiological Systems*. H. Haken and H.P. Koepchen (eds.). Springer-Verlag, Berlin, Heidelberg, New York, pp 177-191, 1991.

Zbilut, J.P. and C.L. Webber, Jr., "Embeddings and delays as derived from quantification of recurrence plots", *Physics Letters A* 171: 199-203, 1992.

Webber, C.L., Jr. and J.P. Zbilut, "Dynamical assessment of physiological systems and states using recurrence plot strategies" *J. Appl. Physiol.* 76: 965-973, 1994.

Webber, C.L., Jr., Schmidt, M.A., and J.M. Walsh, "Influence of isometric loading on biceps EMG dynamics as assessed by linear and nonlinear tools." *J. Appl. Physiol.* 78: 814-822, 1995

Webber, C.L., Jr. and J.P. Zbilut, "Assessing deterministic structures in physiological systems using recurrence plot strategies", In: *Bioengineering Approaches to Pulmonary Physiology and Medicine*. M.C.K. Khoo (ed.). Plenum Press, New York, Chapter 8, pp 137-148, 1996.

Trulla, L.L., A. Giuliani, J.P. Zbilut, and C.L. Webber, Jr., "Recurrence quantification analysis of the logistic equation with transients", *Physics Lett. A* 223: 255-260, 1996.

Zbilut, J.P., A. Giuliani, C.L. Webber, Jr., "Recurrence quantification analysis and principle components in the detection of short complex signals", *Physics Lett. A* 237: 131-135, 1998.

Zbilut, J.P. and C.L. Webber, Jr., "Quantification of heart rate variability using methods derived from nonlinear dynamics", In: *Analysis and Assessment of Cardiovascular Function*. G. Drzewiecki and J.K.-J. Li (eds.). Springer Verlag, New York.

Webber, C.L., Jr. and J.P. Zbilut, "Recurrent structuring of dynamical and spatial systems", In: *Complexity in the Living: A Modelistic Approach*. Interdisciplinary Science Rev. Oxford Press, A. Colosimo and A. Lesk (eds.). (in press).

7. Referencias

Capítulo 2 Problemática Geosísmica

- Anderson, J. G. (2001). "Precautionary principle: Applications to seismic hazard analysis", *Seism. Res. Lett.* 72, 319- 322.
- Bendat, J.S. y Piersol, A.G. (1986). "*Random Data, Analysis and Measurement Procedures*". Wiley-Interscience, New York, 2nd edition, J. Soil Mech. Found. Div., ASCE, 98, 603-624.
- Campanella, R.G. y Kokan, M.A. (1993). "A new approach to measuring dilatancy in saturated sands". *Geotechnical Testing Journal, ASTM GTJODJ*, 16(4):485-495.
- Campanella, R.G., Stewart, W.P., Roy, D. y Davies, M.P. (1994). "Low strain characteristics of soils with the downhole seismic piezocone penetrometer". En *Proc. Symp. on Dynamic Geotechnical Testing II*, 73-87, San Francisco, CA.
- Campanella, R.G. (1994). "Field methods for dynamic geotechnical testing: An overview of capabilities and needs". En *Proc. Symp. on Dynamic Geotechnical Testing II*, 3-23, San Francisco, CA.
- Davis, P.M., Rubinstein, J.L., Liu, K.H., Gao, S. S. y Knopoff, L. (2000). "Northridge earthquake damage caused by geologic focusing of seismic waves", *Science* 289, 1746-1750.
- Day, S.M. (1998). "Efficient simulation of constant Q using coarse-grained memory variables", *Bull. Seism. Soc. Am.* 88, 1051-1062.
- Dobry, R. Ladd, R.S., Yokel, F.Y., Chung, R.M. y Powell, D. (1982). "Prediction of Pore Water Pressure Buildup and Liquefaction of Sands during Earthquakes by the Cyclic Strain Method", Report NBS Building Science Series 138, U.S. Department of Commerce, Washington.
- Dobry, R. y Vucetic, M., (1987). "Dynamic properties and seismic response of soft clay deposits", *Proc. International Symposium on Geotechnical Engineering of Soft Soils*, Mexico City, Vol. 2, pp. 51-87.
- Douglas, B.J. y Olsen, R.S. (1981). "Soil Classification Using the Electric Cone Penetrometer", *Proceedings of the Cone Penetration Testing and Experience Session*, ASCE National Convention, St. Louis, Oct 1981, American Society of Civil Engineers, New York, NY.
- Erdik, M., (1987). "Site response analysis", *Strong Ground Motion Seismology*, edited by M. Erdik and M. Toksoz, D. Reidel Publishing Company, Dordrecht, 479-543.
- FUGRO Ltd, (1996). "Cone Penetration Testing CPT: Simplified Description of the Use and Design Methods for CPTs in Ground Engineering", *HANDBOOK*, United Kingdom.
- Harder, H. y von Bloh, G. (1988)., "Determination of representative CPT-parameters", En *Proc. Geotechn. Conf. Penetration Testing in the UK*, 237-240, Birmingham, Inst. of Civil Engineers.
- Hardin, B. O. y Drnevich, V. P. (1972a)., "Shear modulus and damping in soils, Design equation and curves measurement and parameter effects", *J. Soil Mech. Found. Div., ASCE*, 98, 667-692.
- Hardin, B. O. y Drnevich, V. P. (1972b). "Shear modulus and damping in soils: Measurement, *J. Soil Mech. Found. Div., ASCE*, 98, 667-692.
- Harris, R.A. y Day, S.M. (1993). "Dynamics of fault interaction: Parallel strike-slip faults", *J. Geophys. Res.* 98, 4461-4472.
- Harris, R.A. y Day, S.M. (1999). "Dynamic 3D simulations of earthquakes on echelon faults", *Geophys.Res. Lett.* 26, 2089-2092.
- Hegazy, Y.A. y Mayne, P.W. (1995). "Statistical correlations between Vs and cone penetration data for different soil types". En *Proceedings of the International Symposium on Cone Penetration Testing (CPT'95)*, Linkoping, Sweden, 4-5 October 1995. Swedish Geotechnical Society, Linkoping, Sweden, Report 3-95, Vol. 2, 173-178.
- Jaime, A. y Romo, M.P. (1988). "Correlations between dynamic and static properties of Mexico City clay", *Earthquake Spectra*, EERI, Vol. 4, No. 4, 787-804, November.
- Jefferies, M.G. y Davies, M.P. (1993). "Use of CPTu to estimate equivalent SPT N_{60} ". *Geotechnical Testing Journal*, 16(4):458-468.
- Kokusho, T., Yoshida, Y. y Esashi, Y. (1982). "Dynamic properties of soft clay for wide strain range", *Soils and Foundations*, Vol. 22, No.4, 1-18.

- Magistrale, H. y Day, S. (1999). "3D simulations of multi-segment thrust fault rupture", *Geophys. Res. Lett.* 26, 2093-2096.
- Martin, P.P. y Seed, H.B. (1982). "One-dimensional dynamic ground response analyses." *Journal of Geotechnical Engineering Division, ASCE*, 108(7), 935-952.
- O'Connell, D. R. H. y Ake, J.P. (2000), *Earthquake Ground Motion Estimation*, "Hazards and Disasters" series, to commemorate the International Decade of Natural Disaster Reduction, published by Routledge, Ltd.
- Oreskes, N., Shrader-Frechette, K. y Belitz, K. (1994). "Verification, validation, and confirmation of numerical models in the Earth sciences", *Science*, 264, 641-646.
- Ovando, E. y Romo, M.P. (1991). "Shear wave velocity estimation of Mexico City clay from cone tests", *Sismodinámica*, Vol. 2, No. 2-3, 107-123, June-September
- Popescu, R. y Prévost, J.H. (1995). "Reliability assessment of centrifuge soil test results", *Soil Dynamics and Earthquake Eng.*, 14(2):93-101.
- Prévost, J.H. y Popescu, R. (1996). "Constitutive Relations for Soil Materials", *EJGE*, Paper no. 9609.
- Romo, M.P. y Ovando, E. (1996). "Modelling the dynamic behaviour of Mexican clays", 11th World Conference on Earthquake Engineering, Acapulco, Mexico, Paper # 1028, Proceedings in CD ROM, June. NOTA: SUSTITUIR POR ROMO (1990)
- Silva, W., Li, S., Darragh, B. y Gregor, N. (1999). "Surface geology based motion amplification factors for the San Francisco Bay and Los Angeles areas", PEARL report to PG&E/CEC/Caltrans.
- Stewart, W.P. y Campanella, R.G. (1993). "Practical aspects of in-situ measurements of material damping with the SCPT". *Canadian Geotechnical Journal*, 30(2):211-219.
- Sun, J.I., Galesorkhi, R. y Seed, H.B. (1988). "Dynamic moduli and damping ratios for cohesive soils", Report No. EERC-88/15, Earthquake Engineering Research Center, University of California, Berkeley.
- Terzaghi, K., (1925), „Erdbaumechanik auf bodenphysikalischer Grundlage“: Franz Deuticke, Leipzig und Wein, 399.
- Terzaghi, K. (1943). "*Theoretical Soil Mechanics*"; John Wiley and Sons, N.Y.
- Toro, G.R., Abrahamson, N.A. y Schneider, J.F. (1997). "Model of strong ground motions from earthquakes in Central and Eastern North America: Best estimates of uncertainties", *Seism. Res. Lett.* 68, 41-57.
- Vucetic, M. y Dobry, R. (1991). "Effect of soil plasticity on cyclic response", *J. Geotech. Eng.* 117, 89-107.
- Yung-Mook, Na., Victor, Choa., Cee-Ing, Teh. y Ming-Fang, Chang. (2005). "Geotechnical parameters of reclaimed sandfill from the cone penetration test". *Can. Geotech. J.* 42: 91-109
- Zen, K., Umehara, Y. y Hamada, K. (1978). "Laboratory tests and in-situ seismic survey on vibratory shear modulus of clayey soils with different plasticities", *Proceedings, 5th Japan Earthquake Engineering Symposium, Tokyo*, 721-728.

Capítulo 3 Cómputo Aproximado

Bonissone, P.P. (1997). "Soft Computing: The convergence of emerging reasoning technologies", *Soft Computing*, 1:6-18

Hajek, P. (1995). "Fuzzy logic as logic". En: *Mathematical Model for Handling Partial Knowledge in Artificial Intelligence*, G. Coletti, D. Dubois, R. Scozzafava, eds., Plenum Press, New York, 21-30

Holland, J.H. (1975). "Adaptation in Natural and Artificial Systems", MIT Press, Cambridge, MA.

Mendel, J. (1995). "Fuzzy logic systems for engineering: A tutorial", *Proc IEEE* 83:345-377

Novak, V. (1996). "Paradigm, formal properties and limits of fuzzy logic". *Int J of General Systems*, 24:377-406

Rosenbaltt, F. (1959). "Two theorems of statistical separability in the perceptron", En: *Mechanization of Thought Processes*, 421-456, Symposium held at the National Physical Laboratory, HM Stationary Office, London, England.

Vopenka, P. (1989). Introduction to the mathematics in the alternative set theory. Alfa Bratislava (in Slovak).

Vopenka, P. (1979). *Mathematics in the alternative set theory*. Teubner, Leipzig.

Widrow, B. and Hoff, M.E. (1960). "Adaptive switching circuits", En: *IRE Western Electric Show and Convention Record*, Part 4. 96-104.

Zadeh, L.A. (1965). "Fuzzy Sets", *Inf. Control* 8, 338-353.

Zadeh, L.A. (1994). "Fuzzy Logic and Soft Computing: Issues", *Contentions and Perspectives*. En *IIZUKA'94: 3rd International Conference on Fuzzy Logic, Neural Nets and Soft Computing*, 1-2, Iizuka, Japan.

Zadeh, L.A. (1997). "What is soft computing?", *Soft Computing*, 1(1):1

Redes Neuronales

Ahmad, R. y Salam, F. (1992). "Error back propagation learning using the polynomial energy function," en *Proceedings of the International Joint Conference on Neural Networks*, Iizuka, Japan.

Anand, R., Mehrotra, K., Mohan, C. y Ranka S. (1993). "An improved algorithm for neural network classification of imbalanced training sets," *IEEE Transactions on Neural Networks*, vol. 4, no. 6, 962-969.

Blum, M. (1962). "Properties of a neuron with many inputs". In *Principles of Self-organization*, H. von Foerster and G.W. Zopf, eds., 95-120; Pergamon Press: Oxford.

Cajal, S.R. (1904). "Histologie du système nerveux de l'homme et des vertébrés", Dunod, Paris.

Carpenter, G.A. y Grossberg, S. (1988). "The ART of adaptive pattern recognition by a self-organizing neural network". *Computer*, 21, 77-88.

Chen X.H., (1997). "Efficient backpropagation learning using optimal learning rate and momentum," *Neural Networks*, vol. 10, no. 3, 517-527.

Cherkassky, V. y Shepherd, R. (1998). "Regularization effect of weight initialisation in back propagation networks," en *1998 IEEE International Joint Conference of Neural Networks (IJCNN'98)*, (Anchorage, Alaska), 2258-2261, IEEE.

Denoeux, T. y Lengelle, R. (1993). "Initialising back propagation networks using prototypes," *Neural Networks*, vol. 6, no. 3, 351-363.

Eaton, H. y Oliver, T. (1992). "Improving the convergence of the back propagation algorithm," *Neural Networks*, vol. 5, 283-288,

Fahlman, S.E. y Hinton, G.E. (1987). "Connectionist Architectures for Artificial Intelligence". *IEEE Computer* 20(1):100-109.

Fukushima, K. (1975). "Cognitron: A self-organizing multi-layered neural network". *Biological Cybernetics*, 20:121-136.

Fukushima, K. y Miyake, S. (1982). "Neocognitron: A new algorithm for pattern recognition tolerant of deformations and shifts in position," *Pattern Recognition* 15(6), 455-469.

Gori M. y Tesi, A. (1992). "On the problem of local minima in backpropagation," *IEEE Transactions on PAMI*, vol. 14, no. 1, 76-86.

Holt, M. y Semnani, S. (1990). "Convergence of back-propagation in neural networks using a log-likelihood cost function," *Electronics Letters*, vol. 26, no. 23, 1964-1965.

Haykin, S. (1994). "Neural Networks: A Comprehensive Foundation", New York 10022: IEEE Society Press, Macmillan College Publishing.

- Hirose, Y., Yamashita, K. y Hijiya, S. (1991). "Back propagation algorithm which varies the number of hidden units," *Neural Networks*, vol. 4, no. 1, 61-66.
- Hopfield, J.J. y Tank, D.W. (1986). "Computing with neural circuits", *Model Science*, v.233, 3088-3092.
- Hopfield, J.J. y Tank, D.W. (1988). "Computación conjunta en circuitos neuromorfos". *Investigación y Ciencia*, 137:44-52.
- Jacobs, R. (1989). "Increased rates of convergence through learning rate adaptation," *Neural Networks*, vol. 1, no. 1, 295-307.
- Joost, M. y Schiffmann, W. (1998). "Speeding up backpropagation algorithms by using crossentropy combined with pattern normalization," *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems (IJUFKS)*, vol. 6, no. 2, 117-126.
- Kohonen, T. (1988). *Self-Organization and Associative Memory*. Springer, second edition.
- Kruschke, J. y Movellan, J. (1991). "Benefits of gain: Speeded learning and minimal hidden layers in back propagation networks," *IEEE Transactions on Systems, Man and Cybernetics.*, vol. 21, no. 1, 273-280.
- Kwon, T. M. y Cheng, H. (1996). "Contrast enhancement for backpropagation," *IEEE Transactions on Neural Networks*, vol. 7, no. 1, 515-524.
- Linsker, R. (1988). "Self-organization in a perceptual network". *En Computer*, 21.
- McCulloch, W.S. y Pitts, W. (1943). "A Logical Calculus of the Ideas Immanent in Nervous Activity" *Bulletin of Mathematical Biophysics*, vol. 5, 115-133.
- Minsky, M.L. y Papert, S.A. (1969). "Perceptrons: An Introduction to Computational Geometry" ,Cambridge, Massachusetts:MIT Press.
- Ooyen, A. y Nienhuis, B. (1992). "Improving the convergence of the back propagation algorithm," *Neural Networks*, vol. 5, 465-471,
- Riedmiller, M. y Braun, H. (1993). "A direct method for faster backpropagation learning: The RPROP Algorithm," *En IEEE International Conference on Neural Networks 1993(ICNN93)*, San Francisco, 586-591.
- Riedmiller, M. (1994). "Advanced supervised learning in multi-layer perceptrons from backpropagation to adaptive learning algorithms," *Computer Standards and Interfaces Special Issue on Neural Networks*, vol. 16, no. 3, 265-275.
- Rumelhart, D.E. y McClelland, J.L. (1986). "Parallel Distributed Processing: Explorations in the Microstructure of Cognition", MIT Press, Cambridge, MA, London, England.
- Sarkar, D. (1995). "Methods to speed up error back propagation learning algorithm," *ACM Computing Surveys*, vol. 27, no. 4, 519-542.
- Schiffmann, W., Joost, M. y Werner, R. (1993). "Application of genetic algorithms to the construction of topologies for multilayer perceptrons," *en Proceedings of International Conference on Neural Networks and Genetic Algorithms (ICNNGA)*, (University of Innsbruck, Austria), 675-682.
- Schittenkopf, C., Deco, G. y Brauer, W. (1997). "Two strategies to avoid overfitting in feedforward neural networks," *Neural Networks*, vol. 10, no. 3, 505-516.
- Shannon, C.E. y McCarthy, J. (Eds). (1956). "Automata Studies", Princeton U. Press, Princeton, N. J.
- Silva, F. y Almeida, L. (1990). "Speeding up back-propagation," *in Advanced Neural Computers (R. Eckmiller, ed.)*, (Amsterdam), 151-158, Elsevier Science Publishers,
- Solla, S., Levin, E. y Fleisher, M. (1988). "Accelerated learning in layered neural networks," *Complex System*, vol. 2, 625-640.
- Steinbuch, K. (1963). "Die Lernmatrix", *Kibernetik Vol. 1*, 1961, Versión ampliada de este trabajo por el mismo autor en "Automat und Mensch", Springer Verlag
- Tollenaere, T. (1990). "Super SUB: Fast adaptive back propagation with good scaling properties," *Neural Networks*, vol. 3, no. 5, 561-573.
- Vitthal, R. P. Rao, Sunthar, y Durgaprasada, C. (1995). "The generalized proportional-integral-derivative (PID) gradient descent back propagation algorithm," *Neural Networks*, vol. 8, no. 4, 563-569.

Vogl, T., Mangis, J., Rigler, A., Zink, W. y Alkon, D. (1988). "Accelerating the convergence of the backpropagation method," *Biological Cybernetics*, vol. 59, 257-263, September.

Weir, M. (1991). "A method for self determination of adaptive learning rate in back propagation," *Neural Networks*, vol. 4, 371-379.

Wessels, L. y Barnard, E. (1992). "Avoiding false local minima by proper initialisation of connections," *IEEE Transactions on Neural Networks*, vol. 3, no. 6, 899-905.

Wiener, N. y Schade J.P. (1969). "Sobre modelos de los nervios, el cerebro y la memoria". Ed. Tecnos, Madrid,

Widrow, B. (1962). "Generalization and Information Storage in Networks of Adaline Neurons".

Yovits, M.C., Jacobi, G.T. y Goldstein, G.D. (1962). "Principles of Neurodynamics" (New York:Spartan) Washington, Spartan, 435. Rosenblatt, F.

Zhang, B.-T. (1994). "Accelerated learning by active example selection," *International Journal of Neural Systems*, vol. 5, no. 1, 67-75.

Lógica Difusa

Abraham, A. y Nath, B. (2000). "Evolutionary Design of Neuro-Fuzzy Systems - A Generic Framework", en *Proceedings of the 4th Japan - Australia joint Workshop on Intelligent and Evolutionary Systems*, Japan.

Abraham, A. (2001). "Neurofuzzy systems: State-of-the-Art modeling techniques", in *Proceedings of the Sixth International Conference on Artificial and Natural Neural Networks*, IWANN 2001, Granada, Springer-Verlag, June, <http://ajith.softcomputing.net>

Agrawal, G. Chaneau, J.L.A. y Bordeau, P.L. (1997). "Assessing the liquefaction susceptibility at a site based on information from penetration testing", In *Artificial Neural Networks for Civil Engineers: Fundamentals and Applications*, New York, ASCE, 185-214

Bezdek, J.C. (1981). "Pattern recognition with fuzzy objective function algorithm", Plenum Press

Bherenji, H.R. y Khedkar, P. (1992). "Learning and Tuning Fuzzy Logic Controllers through Reinforcements", *IEEE Transactions on Neural Networks*, Vol (3), 724-740,

García, S., Romo, M.P. y Figueroa-Nazuno, J. (2006). "Soil dynamic properties determination: A neurofuzzy system approach", *Control and Intelligent Systems*, Volume 34, Issue 1, 1-11, ISSN:1480-1752

Ghaboussi, J., Garret, J.H. y Wu, X. (1991). "Knowledge based modeling of material behavior with neural networks", *Journal of the Engineering Mechanics Division, ASCE*, Vol. 117, No. 2, 132-153

Hoppner, F., Klawonn, F., Kruse, R. y Runkler, T. (1999). "Fuzzy cluster analysis", John Wiley and Sons, New York, ISBN 0-471-98864-2

Jang et al. Jang, J.S., Sun, C.T. y Mizutani, E. (1997). "Neuro-Fuzzy and Soft Computing". Prentice-Hall, Englewood Cliffs, NJ

Kandel, A. (editor). (1992). "Fuzzy expert systems", CRC Press, Inc. Boca Ratón, FL

Kasabov, N. y Qun, Song. (1999). "Dynamic Evolving Fuzzy Neural Networks with 'm-out-of-n' Activation Nodes for On-line Adaptive Systems", Technical Report TR99/04, Department of information science, University of Otago,

Kosko N, (1992), "Neural networks, Fuzzy systems: Dynamical systems approach to machine intelligence", Englewood Cliffs, N.J., Prentice Hall

Kosko, B. (1992). "Neural networks and fuzzy systems: A dynamical systems approach to machine intelligence", Prentice-Hall, London, ISBN 0-13-611435-0

Jang, R. (1992). "Neuro-Fuzzy Modeling: Architectures, Analyses and Applications", PhD Thesis, University of California, Berkeley.

Juang Chia, Feng. y Lin Chin, Teng. (1998). "An Online Self Constructing Neural Fuzzy Inference Network and its Applications", *IEEE Transactions on Fuzzy Systems*, Vol 6, No.1, 12-32,.

Lin, C.T. y Lee, C.S.G. (1991). "Neural Network based Fuzzy Logic Control and Decision System", *IEEE Transactions on Comput.* (40(12): 1320-1336,

Menger, K. "Statistical metrics", *Proc. Nat. Acad. of Sci., U.S.A.*, 28 (1942), 535-537.

Munukata, T. y Jani, Y. (1994). "Fuzzy Sets: An Overview", *Communications of the ACM*, 7(3), pp. 69-76.

Nauck, D. y Kruse, R. (1996a). "Designing neuro-fuzzy systems through backpropagation", en W Pedrycz (ed): *Fuzzy modeling: Paradigms and Practice*, 203-228, Kluwer, Boston

Nauck, D. y Kruse, R. (1996b). "Neuro-fuzzy classification with NEFCLASS", en P. Kleinshmidt, A. Backem, U. Derigs, D. Fisher, U. Leopold-Wildburger y R. Möhring (eds): *Operations Research Proceedings 1995*, 294-299, Springer-Verlag, Berlin

Nauck, D. y Kruse, R. (1997). "Neuro-Fuzzy Systems for Function Approximation", 4th International Workshop Fuzzy-Neuro Systems,

Reiter, R. (1980). "A logic for default reasoning. *Artificial Intelligence*", vol. 13, 81-132.

Romo, M.P. y García, S.R. (2003). "Neurofuzzy mapping of CPT values into soil dynamics properties", *International Journal of Soil Dynamics and Earthquake Engineering*, Vol. 23, Num. 6, August, 473-482

Romo, M.P. (2004). "System-identification: From analytic to neurogenetic methods", Keynote Lecture, 3er Congreso Internacional de Computación, Instituto Politécnico Nacional, Mexico City, October.

Sulzberger, S.M., Tschicholg-Gurman, N.N. y Vestli, S.J. (1993). "FUN: Optimization of Fuzzy RuleBased Systems Using Neural Networks", en *Proceedings of IEEE Conference on Neural Networks*, San Francisco, 312-316.

Takagi, T. y Sugeno, M. (1985). "Fuzzy Identification of Systems and its applications to Modeling and Control", *IEEE Transactions on Systems, Man and Cybernetics*, SMC-15 (1), 116-132.

Tano, S., Oyama, T. y Arnould, T. (1996). "Deep combination of Fuzzy Inference and Neural Network in Fuzzy Inference", *Fuzzy Sets and Systems*, 82(2), 151-160,

Yager, S., Ovchinnikov, R.M. y Tong, H.T. Nguyen (eds), *Fuzzy Sets and Applications*, Wiley, New York, 293-329.

Yager, R.R. (1982). "Measuring tranquillity and anxiety in decision making: An application of fuzzy sets", *Inter. Journal of General Systems* 8, 139-146

Yager, R.R. y Filev, D.P. (1993). "SLIDE: A simple adaptive defuzzification method", *IEEE Transactions on Fuzzy Systems*, Vol. 1, No. 1, 69-78

Zadeh, L.A. (1965). *Fuzzy sets*, *Information and Control*, 8, 338-353

Zadeh, L.A., (1987), "A theory of approximate reasoning", en: R.R. Yager, S. Ovchinnikov, R.M. Tong, H.T. Nguyen (Eds.), *Fuzzy Sets and Applications: The selected papers by L.A. Zadeh*, Wiley, New York, 1987, 367-411.

Capítulo 4 Análisis de Series de Tiempo

Bendat, J. S., (1990) "Nonlinear System Analysis and Identification from Random Data". Wiley Interscience, 267.

Davis, P.J. (1994), "Chaos and the New Understanding". SIAM NEWS 27: 6.

De Jong, A.J. (1990), "Reclaiming a Mission; New Direction for the Church-Related College". Grand Rapids, MI: William B. Erdmans.

Earman, J. (1986), "A Primer on Determinism". Dordrecht: D. Reidel,

Kantz, H., y T. Schreiber, (1999), "Nonlinear Time Series Analysis". Cambridge University Press, 304.

Kellert, S. H. (1993), "In the Wake of Chaos". Chicago, IL: University of Chicago Press.

May, R. M. y Oster, G. F. (1976), "Bifurcations and Dynamic Complexity in Simple Ecological Models." American Naturalist 110: 573-599.

Priestley, M. B., (1988), "Nonlinear and Nonstationary Time Series Analysis". Academic Press, 237.

Stewart, I. (1989), "Does God Play Dice? The Mathematics of Chaos". Cambridge, MA: Basil Blackwell.

Tong, H., (1990), "Nonlinear Time Series Analysis". Oxford University Press, 564.

Mapas de Recurrencia

H. D. I. Abarbanel, (1995), "Analysis of Observed Chaotic Data". Springer.

J.-P. Eckman, O.S. Kamphorst, y D. Ruelle, (1987), "Recurrence Plots of Dynamical Systems". Europhysics Letters 5, 973-977.

U. Feudel y C. Grebogi, (1997), "Multistability and the control of complexity", CHAOS. V.7, 597.

Fraser A. M. y Swinney H. L., (1986), "Independent coordinates for strange attractors from mutual information", Phys. Rev. A 33, 1134.

García S.R., Botero E. y Romo M., (2003), "Chaotic Analysis and Neural Modeling of Seismic Time Series", International Conference

on Adaptive Modeling and Simulation ADMOS 2003, N.-E Wiberg and P. Díez, Eds, CIMNE, Barcelona,.

Hegger R., Kantz H. y Schreiber T., (1999), "Practical implementation of nonlinear time series methods: The TISEAN package", CHAOS 9, 413.

J. Huang y D.L. Turcotte, (1990a), "Are Earthquakes an Example of Deterministic Chaos?", Geophys.Res.Lett.,17, 223-226.

J. Huang y D.L.Turcotte, (1990b), "Evidence for Chaotic Fault Interactions in the Seismicity of the San Andreas Fault and Nakai Trough", Nature, 348, 234- 236.

Kennel M. B., Brown R. y Abarbanel H. D. I., (1992), "Determining embedding dimension for phase-space reconstruction using a geometrical construction", Phys. Rev. A 45, 3403.

D.G. Luchinsky, P.V.E. McClintock y M.I. Dykman. (1998), "Analogue studies of nonlinear systems". Reports on Progress in Physics, V.61. 889.

N. Packard, J. Crutchfield, J. Farmer, y R. Shaw, (1980), "Geometry from a time series". Physical Review Letters, 45:712.

Paluš M., (1995), "Testing for nonlinearity using redundancies: Quantitative and qualitative aspects", Physica D 80, 186.

Sauer, T.; Yorke J. y Casdagli M., (1991), "Embedology", J. Stat. Phys. 65, 579.

Takens, F. (1981), "Detecting strange attractors in fluid turbulence". En D. Rand and L- S. Young, editors, Dynamical Systems and Turbulence, Springer, Berlin, 366-381.

Eigenfaces

González, R. C., y Tou, J. T., (1974), "Pattern recognition principles", Addison-Wesley Publishing Company.

Kirby, M., and Sirovich, L., (1990), "Application of the Karhunen-Loeve procedure for the characterization of human faces", IEEE PAMI, Vol. 12, 103-108.

Lau Technologies. (1999). "Facial recognition technology". Retrieved September 25, 1999, from the World Wide Web: <http://www.lautechnologies.com/Pages/FacialRecognition.htm>.

Press, W. H., Flannery, B. P., Teukolsky, S. A., y Vetterling, W. T., (1988), "Numerical recipes in C", Cambridge University Press,353-380.

Sirovich, L., y Kirby, M., (1987), "Low-dimensional procedure for the characterization of human faces", J. Opt. Soc. Am. A, 4, 3, 519-524.

Turk, M. y Pentland, A. (1991). "Eigenfaces for recognition". Journal of Cognitive Neuroscience, 3, 71-86.

Velasco, J. (1998). "Teaching a computer to recognize a friendly face", The New York Times, G7.

Yuille, A. L., Cohen, D. S., y Hallinan, P. W., (1989), "Feature extraction from faces using deformable templates", Proc. of CVPR.

Capítulo 5 Resultados

Díaz-Rodríguez, J. A., Lozano-Santa Cruz, R., Dávila-Alcocer, V.M., Vallejo, E. y Girón, P. (1998). "Physical, chemical, and mineralogical properties of Mexico City: a geotechnical perspective", *Canadian Geotechnical Journal*, Vol. 35, No. 4, 600-610.

Gomez-Looh, B. (1987). "Análisis por difracción de rayos X de las arcillas del subsuelo de la Ciudad de México". Tesis de licenciatura, Facultad de Química, UNAM, México.

Lo, K.Y. (1962). "Shear strength properties of a sample of volcanic material of the valley of Mexico". *Géotechnique*, Vol. 12, No. 4, 303-318.

Marsal, R.J. y Mazari, M. (1959). "The Subsoil of Mexico City". Contribution to the First Panamerican Conference on Soil Mechanics and Foundation Engineering, Ciudad de México, México.

Mesri, G. Rokhsar, A., y Bohor, B.F. (1975). "Composition and compressibility of typical samples of Mexico City clay", *Geotechnique*, Vol. 25, No. 3, 527-554.

Peralta y Fabi, R. (1989). "Sobre el origen de algunas propiedades mecánicas de la formación arcillosa superior del valle de México". Simposio Tópicos Geológicos de la cuenca del valle de México, SMMS, México.

Zeevaert, L. (1949). "An investigation of the engineering characteristics of the volcanic lacustrine clay deposit beneath Mexico City". *Ph.D. Thesis*, University of Illinois, Urbana, Illinois.

Índice

	Página		Página
1. Introducción	1	5. Modelos aproximados: aplicaciones geosísmicas	62
2. Problemática Geosísmica	3	5.1 Estimación de la velocidad de ondas de corte V_s a partir de la resistencia a la penetración del cono q_c	62
2.1 Variabilidad e Incertidumbre	3	Estimación de propiedades dinámicas (G, λ)	116
2.2 Propiedades Dinámicas de los Suelos	4	5.2 Estimación de movimientos de terreno en la Ciudad de México	136
2.3 Respuesta de Sitio	8	6. Conclusiones	284
3. Cómputo Aproximado	11	7. Apéndices	291
3.1 Redes Neuronales	15	7.1 Apéndice 2.1.A	291
3.2 Lógica Difusa	29	7.2 Apéndice 3.1.A	293
4. Técnicas de Análisis de Series de Tiempo	45	7.3 Apéndice 3.1.B	300
4.1 Mapas de Recurrencia	49	7.4 Apéndice 4.1.A	306
4.2 Eigenfaces	55	8. Referencias	308

máximas capacidades siendo cada día más evidente el desequilibrio entre la complejidad de los comportamientos observados y las técnicas usadas para modelarlos. En la búsqueda de nuevas hipótesis, códigos y metodologías de estudio, deben tomarse en cuenta aspectos centrales en este tipo de sistemas: i) la presencia de una amplia gama de comportamientos, en su mayoría no lineales, ii) la imposibilidad para medir algunas variables de estado o peor aún, el desconocimiento de las *verdaderas* variables de estado y iii) la condición simultánea de abundancia y escasez de datos: megabytes de información registrada sobre un parámetro y la dificultad para medir otros igualmente importantes en la representación de los hechos.

Por lo general, si el sistema bajo estudio es lineal, los datos producto de la observación de los comportamientos pueden ser caracterizados usando estadística (media, desviación estándar, etc.), ajustando curvas a ellos (aproximación de funciones) y generando gráficas para visualizar su comportamiento. La experiencia en el modelado de fenómenos geosísmicos ha demostrado que estas operaciones de procesamiento resultan poco eficaces cuando lo que se necesita es *aprender* (abstraer y comprender) y no sólo *imitar*. La integración a la ingeniería geosísmica de herramientas de procesamiento numérico y lógico, dominio del cómputo aproximado CA - Redes Neuronales RNs y Lógica Difusa LD-, figura como una alternativa *natural* para el análisis de fenómenos relacionados con los suelos y los sismos.

Sabiendo que las RNs permiten el estudio y manejo de sistemas cuya definición es parcial, difíciles de modelar, con espacios de solución a gran escala y en donde la información relevante disponible se representa por medio de datos entrada→salida y que la LD, por su parte, es el marco teórico formal para aproximaciones graduadas de lo difuso y desarrollos que modelan la deducción natural humana; en este trabajo de investigación se describe y respalda el uso de estas técnicas para desarrollar algoritmos, verificar teorías y establecer modelos geosísmicos eficientes.

A través de los resultados y conclusiones de: a) la evaluación de las velocidades de ondas de corte a partir de los resultados de una prueba de penetración de cono y b) el análisis de la respuesta sísmica del Valle de México, se demuestra la conveniencia de utilizar RNs y sistemas de LD en la construcción de modelos *aproximados* (opuestos a los *precisos* obtenidos con métodos numéricos clásicos). Como subproducto de esta disertación se presenta una alternativa en el análisis de bases de datos masivas (series de tiempo o vectores unidimensionales) que parte de conceptos básicos de la Teoría del Caos -Mapas de Recurrencia, MR- y de técnicas de reconocimiento de imágenes -Eigenfaces, EF-. Esta original herramienta (MR-EF) facilita y optimiza la construcción y el desempeño de estructuras de CA, llamadas también estructuras conexionistas.

La intención de esta tesis doctoral es el desarrollo y la disseminación de tecnologías complementarias para su establecimiento, a través de guías prácticas, como piezas estándar en procesos y procedimientos en el ámbito de la ingeniería geosísmica sin que esto signifique reemplazar los análisis convencionales ni el juicio ingenieril.

1. Introducción

En la incorporación de la dimensión ambiental a la planificación y desarrollo de comunidades, la condicionante sísmica es un importante factor de riesgo cuando se procuran asentamientos humanos menos vulnerables. Es imposible evitar su ocurrencia, pero las consecuencias económicas, sociales y ambientales de las grandes sacudidas pueden disminuir a través de los avances en la ciencia apoyada en la práctica de la ingeniería.

El principal objetivo de la Ingeniería Geosísmica es mitigar el riesgo sísmico desde el punto de vista geotécnico. Esta rama de la ingeniería ha evolucionado desde la dinámica de suelos hacia los modelos que permiten anticipar el comportamiento del suelo o de la roca a través del juicio de expertos y de las aproximaciones teórico-empíricas.

Para el análisis de sistemas geotécnicos complejos (naturales y construidos por el hombre) se cuenta con herramientas analíticas que permiten establecer relaciones causa→efecto con fines de estimación y predicción. Sin embargo, muchos de estos procedimientos están cerca de alcanzar sus

El proceso empírico de creación de modelos

De acuerdo con el proceso empírico de creación de modelos una condición necesaria para que M sea un buen modelo del proceso P , para un conjunto preestablecido de secuencias de entrada S , es que:

$$M(u) \cong P(u), \forall u \in S \quad 1.1$$

$M(u)$ y $P(u)$ representan las respuestas del modelo y del proceso ante una determinada secuencia de entrada, u . Esta condición se compone de varios elementos que la hacen altamente flexible: i) la interpretación del símbolo \cong , ii) el conjunto de entradas S y iii) la clase de modelos C , entre la que se busca el mejor de ellos (M).

Es fundamental, en primer lugar, aclarar el significado que se adopta del símbolo \cong . ¿Qué quiere decir que un modelo *aproxima* correctamente la salida de un sistema? Esta pregunta nos lleva a cuantificar, de alguna manera, la diferencia entre las respuestas del modelo y las del proceso, es decir, a medir la *error*. Existen diversos criterios para establecer estas diferencias y cada uno de ellos puede tener justificación en un ámbito científico particular. Las medidas usuales en ingeniería son la suma cuadrática y la suma absoluta de errores. Resulta particularmente interesante, aunque es un aspecto no tratado en esta tesis, que ahora es obligación del científico relacionar esta capacidad aproximativa con la complejidad computacional (número de parámetros y costo tiempo-recursos-máquina de las operaciones), la competencia en transmisión de conocimiento, y la eficiencia interpretativa de los modelos para calificar el desempeño de sus proyectos.

En este trabajo se presentarán los modelos que fueron marcados como exitosos y no se aborda el proceso de competencia que condujo a ellos. Es suficiente tener en cuenta que en ambos incisos de análisis el error se mide con dos tipos de criterios, en resultados experimentales se utilizan las medidas estándar para determinar la distancia entre lo que se calcula y lo que se plantea como *cierto*; esto permite acotar y penalizar el error máximo de una aproximación y, por otro lado, se comparan modelos con similares niveles de error y se jerarquizan de acuerdo con su i) complejidad, ii) operabilidad (aplicables, prácticos) y iii) vinculación con los conocimientos naturales.

La aplicación del criterio de error puede, en general, realizarse *a priori* sobre cualquier patrón o entrada al modelo, pero resulta más comprometido seleccionar el conjunto de zonas de trabajo o señales de entrada S para los que el modelo M (desconocido) será válido en su operación normal. Los sistemas no lineales (como los estudiados en este trabajo) se comportan de modo cualitativamente diferente según el régimen de operación en que se encuentren. No existe una forma sistemática de saber cuántos de estos regímenes de operación hay y, sobre todo, cómo llegar a ellos (qué entradas llevarán el proceso a tales estados).

Debido a esta ambigüedad, aquí se utiliza el conjunto de señales de entrada formado por todas las secuencias originales (refiriéndose a los datos

medidos, obtenidos o calculados directamente de algún ensayo geotécnico o sísmico) y se consideran como los patrones que llevan al sistema a gran parte de sus estados alcanzables. Para minimizar esta incertidumbre sobre lo que se presenta como ejemplos de estados, se divide el conjunto total en tres subconjuntos: señales de entrenamiento o identificación, de prueba y de validación (modo directo), respectivamente, de forma que la evaluación de las capacidades de los modelos se realizarán únicamente con las señales de validación, entradas no utilizadas en el proceso de creación del modelo y consideradas más oportunas.

Finalmente, la clase de modelos C en que se basa este trabajo se refiere al cómputo aproximado y algunas otras herramientas avanzadas de análisis de señales. La caracterización y justificación del uso de estas teorías y metodologías se ofrece en los capítulos donde se presentan los resultados de cada inciso de análisis.

Organización del escrito

Esta tesis está ordenada en unidades de información. Para el lector familiarizado con la geotecnia y la sismología se ofrecen los módulos de **Cómputo Aproximado** y de **Técnicas de Análisis de Series de Tiempo** como una breve introducción a las herramientas de modelado, mientras que los expertos en cómputo y matemáticas avanzadas pueden recurrir a la sección **Problemática Geosísmica** para conocer los aspectos medulares de los fenómenos estudiados.

El núcleo del documento es el capítulo de **Resultados** el cual pretende i) dar una visión particular de las metodologías computacionales y ii) establecer la filosofía, el criterio de aplicación y la certidumbre en los modelos.

Prefacio

Esta tesis intenta ser una amplia introducción al cómputo aproximado para los ingenieros involucrados en la solución de problemas geotécnicos y sísmicos. Se pretende resaltar especialmente los principios que dirigen el modelado con redes neuronales, lógica difusa y teoría del caos y establecer las condiciones en que pueden aplicarse para estudiar fenómenos relacionados con los suelos. Se relega a un segundo término el panorama histórico y el tratamiento matemático formal de cada técnica.

Una de las características de este trabajo es el énfasis en las aplicaciones. Cada solución es desarrollada sistemáticamente comenzando con el planteamiento de la física del problema seguido de su interpretación desde un enfoque "aproximado" (construcción del ambiente de cálculo) y culminando con la interpretación de los resultados. Sobre los ejemplos se discuten los métodos y su integración con la intuición y juicio ingenieril.

Sin aspirar a ser un libro de texto, este documento se conduce como una guía para el desarrollo de análisis alternativos que clarifiquen y/o corrijan nuestro ejercicio teórico y práctico.

2.1. Variabilidad e Incertidumbre

La variabilidad aleatoria VA y la incertidumbre epistémica IE son de tomarse en cuenta cuando se jerarquiza y selecciona un método de análisis. VA es la aleatoriedad natural del proceso estudiado, mientras que IE es la incertidumbre propia del modelo debida a datos y conocimiento limitados.

La interpretación de la VA y la IE concierne a los límites futuros del conocimiento. Existe una escuela de pensamiento donde no se contempla VA en los procesos sísmicos. En un principio los sismos son respuestas a esfuerzos y deformaciones en la corteza terrestre que se transmiten hacia capas más superficiales. Eventualmente, transcurrido el tiempo, se habrán recopilado suficientes datos para desarrollar modelos detallados del proceso sísmico con los que se pronosticarán localizaciones, intensidades y respuestas a futuros terremotos. Si el proceso sísmico es en teoría *comprendible* (puede llegar a conocerse en su totalidad) contiene sólo IE y ésta debería reducirse con el paso del tiempo.

La idea de distinguir entre VA e IE suena simple pero en la práctica esta separación puede volverse confusa. Como un ejemplo considérese una falla con un punto de segmentación postulado. Un modelo consideraría que el punto de segmentación es una barrera impenetrable y un modelo alternativo podría considerar que el punto de segmentación no existe. En este caso, la existencia del punto de segmentación es IE. Otro modelo de segmentación de la falla podría considerar que el punto de segmentación existe pero que sólo detiene un poco la ruptura, aceptando VA en el modo en que rompe pues algunas veces la ruptura es detenida en el punto de segmentación y otras rompe a través de él.

Tomemos ahora el ejemplo de las leyes de atenuación de movimientos de terreno. La estructura detallada 3D de la corteza es potencialmente explicable, con lo que sería posible desarrollar un modelo de propagación de ondas para cada fuente y sitio específicos. Se puede argumentar entonces, que la variabilidad entre las relaciones de atenuación de movimientos de terreno se debe a la falta de conocimiento para explicar el complejo proceso de propagación de ondas (hablamos de IE) y ésta pudiera ser eliminada (teóricamente) una vez que estén disponibles datos adicionales sobre este tipo de fenómenos.

Relacionando estos conceptos con el análisis de la respuesta de sitio y la caracterización dinámica de los suelos, se deben distinguir como restricciones de modelado: i) la incertidumbre relacionada con la forma del modelo -función matemática y parámetros físicos asociados- y ii) la variabilidad en las observaciones de entrada. Advirtiendo que ambos aspectos limitan la flexibilidad y la robustez de los esquemas de estudio, en esta investigación, a través de los postulados conexionistas, se ofrece una vertiente que significa la simplificación de los estándares geosísmicos y la construcción de buenos modelos científicos: menor número de variables básicas para predecir las variables derivadas con suficiente aproximación y confiabilidad.

2. Problemática Geosísmica

Desde los primeros intentos por desarrollar marcos de referencia para catalogar la observación y la experiencia en el comportamiento de suelos y rocas a través de conceptos básicos de la mecánica (origen en el trabajo de Terzaghi, 1925), la difícil empresa de tratar con materiales cuyas características son producto de acciones de la naturaleza marcó el lento avance -si se compara con otros campos de la ingeniería- en el establecimiento de métodos geotécnicos racionales.

A diferencia de la ingeniería estructural y mecánica cuyas incertidumbres son deductivas (a partir de condiciones razonablemente bien conocidas se emplean modelos para deducir el comportamiento de un universo específico), la ingeniería geotécnica trata con incertidumbres puramente inductivas (con base en observaciones limitadas, conocimiento geológico parcial y razonamiento estadístico ambiguo, se infiere el comportamiento de un universo pobremente definido). Debido a lo anterior, es importante tener en cuenta el riesgo de manejar el razonamiento puro en geotecnia (aproximaciones deductivas a condiciones inciertas del mundo geológico) y aplicar literalmente los resultados cualitativos y cuantitativos producto de este tipo de análisis.

Por otro lado, las técnicas de análisis deductivo abarcan campos del conocimiento cuyas características -y limitaciones- se reflejan en los modelos obtenidos a través de ellas. Los métodos prácticos de evaluación y diseño carecen en cierta medida de rigor científico y análisis directo. Por ejemplo, la respuesta de un sistema suelo-estructura ante eventos sísmicos severos se espera que, en la mayoría de los casos, sea no lineal (particularmente en terrenos blandos), sin embargo, la evaluación del comportamiento se representa por medio de mapas y cuantificadores simples procurando, sistemáticamente, involucrar un mínimo de variables. Los cálculos, desarrollados con funcionales lineales, son sensibles a factores de ajuste que se establecen con base en la experiencia, las observaciones (casi siempre muy reducidas) y las restricciones que impone el conocimiento sobre los materiales involucrados.

Estas aproximaciones empíricas e indirectas a menudo arrojan importantes discrepancias entre los comportamientos registrados y los que los modelos pronostican, como lo han demostrado sismos recientes. Un modelo geosísmico que intente mejorar esta tendencia debería usar i) el conocimiento empírico y ii) los recursos que ofrecen la sismología, la geotecnia, la geología, la mecánica aplicada, las matemáticas y la computación para interpretar, caracterizar y predecir más efectivamente los fenómenos analizados.

2.2. Propiedades Dinámicas de los Suelos

Los suelos son materiales 4D (x, y, z, t) extremadamente complejos en su comportamiento constitutivo y cuyos elementos mineralógicos y geológicos, presencia de los tres estados de la materia y distribuciones logarítmicas del tamaño de sus partículas, los hacen elementos naturales únicos (Terzaghi, 1943). Además, el estado inicial de esfuerzos, la rigidez no lineal, la resistencia, la anisotropía, la permeabilidad, las características de drenaje, y el comportamiento reológico hacen de la investigación de los suelos con fines de caracterización (in situ y/o laboratorio) una formidable tarea.

Contemplar la diversidad de partículas, mineralogías, agentes cementantes, y arreglos estructurales en un modelo numérico global sería difícil e ineficiente (Prévost y Popescu, 1996). La articulación de un modelo del suelo está contaminada de la incertidumbre inherente a la determinación de cualquier propiedad y ella no podrá ser eliminada sin importar cuántas pruebas sean dirigidas para conocer las condiciones de los materiales (Bendat y Piersol, 1986; Popescu y Prévost, 1995). La mejor práctica de estudio para emitir conclusiones útiles en el diseño geotécnico es la combinación de la exploración (perforación, muestreo, pruebas de campo y laboratorio), juicios calificados y teorías básicas bien fundamentadas.

Propagación de ondas, vibración de maquinaria, respuesta sísmica e índices de licuación, son algunos ejemplos de las aplicaciones donde es indispensable el conocimiento de las propiedades mecánicas del suelo asociadas con la carga dinámica: velocidad de ondas de corte V_s , módulo de rigidez al corte G , relación de amortiguamiento λ y relación de Poisson μ . Las metodologías y programas de computadora en Ingeniería Geosísmica orientados a estimar la respuesta dinámica de los depósitos (método lineal equivalente, método característico y método de elementos finitos, entre otros) dependen de la adecuada determinación del módulo de rigidez al corte para bajas deformaciones G_{max} y la atenuación del módulo G y el incremento de la relación de amortiguamiento λ respecto a la deformación angular $\gamma\%$ (G versus $\gamma\%$; λ versus $\gamma\%$) para caracterizar el comportamiento dinámico de los materiales (Martin y Seed, 1982) y generar evaluaciones de movimientos particulares (Fig. 2.1).

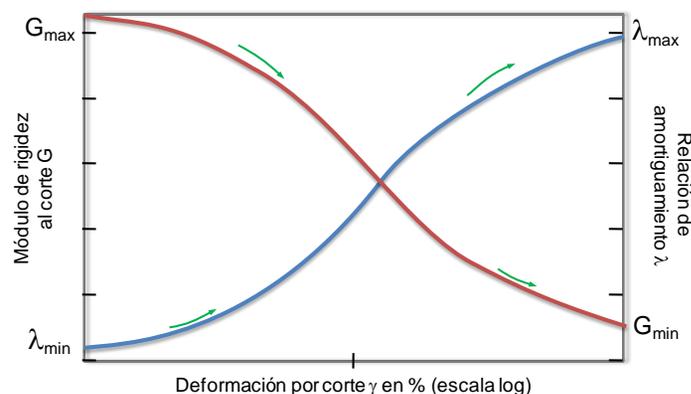


Figura 2.1 Propiedades dinámicas en función de la deformación por corte

Estimación de propiedades

Las acciones de exploración en el suelo pueden dividirse en tres categorías generales: pruebas in situ, pruebas de laboratorio y clasificación de materiales. Las pruebas in situ esencialmente evalúan las propiedades ingenieriles geotécnicas en su ambiente natural. Algunas de las ventajas de usar mediciones de campo sobre las obtenidas de pruebas de laboratorio son: i) las alteraciones sobre el material se minimizan, ii) los efectos de la estructura y de la edad se preservan y, iii) el suelo es ensayado en su estado natural (in situ) de esfuerzos (Campanella, 1994). Además, en la extrapolación de propiedades medidas en un punto (probeta de laboratorio) hacia características atribuibles a capas de suelo, los tan comúnmente llamados estratos "homogéneos" son en realidad sólo "estocásticamente homogéneos", es decir, existen importantes variaciones espaciales en las propiedades, identificables sólo a través de pruebas de campo.

La obtención directa de la resistencia y deformabilidad de los suelos así como datos suplementarios (estratigrafía, distribución granular, propiedades de amortiguamiento, etc.) a partir de pruebas de campo y un mínimo de ensayos de laboratorio, elimina algunas fuentes de incertidumbre y economiza los análisis preliminares a estudios formales de peligro sísmico (Harder y von Bloh (1988), Jefferies y Davies (1993) Stewart y Campanella (1993), Campanella et al (1994), Campanella y Kokan (1993)).

Prueba de Penetración del Cono

La prueba de penetración del cono CPT (por sus siglas en inglés Cone Penetration Test) consiste en empujar una punta cónica para hacer una perforación cilíndrica en el terreno a una velocidad muy lenta (FUGRO, 1996). La prueba es instrumentada para medir la fuerza resistente al avance de la punta (q_c) y la fricción sobre la superficie del dispositivo, generando lecturas que constituyen un registro casi continuo de las características del subsuelo (Fig. 2.2). El hecho de que esta prueba sea de avance lento (carga cuasi-estática) hace que sus estimaciones se prefieran sobre las obtenidas de una prueba de penetración estándar SPT (por sus siglas en inglés Standar Penetration Test) que se realiza con carga dinámica y las fuerzas de amortiguamiento (desconocidas) podrían influenciar los resultados en suelos de baja permeabilidad (Jefferies y Davies, 1993).

Adicionalmente, pueden hacerse mediciones geofísicas en el mismo pozo para medir la velocidad de onda de corte (V_s) del suelo a varias profundidades (Fig. 2.2). Esta información es muy efectiva en la evaluación del potencial de daño en eventos sísmicos y su uso, a través de correlaciones entre V_s y la rigidez del suelo, es rutinario cuando se evalúa la respuesta de sitio.

CPT: correlaciones empíricas.

Además del valor de resistencia no drenada (para suelos cohesivos) y la construcción de cartas para identificación de suelos (Douglas y Olsen, 1981) el valor de q_c puede asociarse al valor de G_{max} relacionando las bases de datos de la prueba CPT y los resultados de la prueba realizada en ese mismo sitio para obtener V_s .

V_s puede ser usada para determinar el módulo G del suelo a través de

$$G = \rho \cdot V_s^2 \quad 2.1$$

donde $\rho = \gamma_t / g_a$, ρ = densidad de masa, γ_t = peso volumétrico total, y g_a = aceleración de la gravedad, 9.8 m/s². Para ondas planas, la deformación por corte, γ_s ($\gamma\%$), se define como la relación entre la velocidad máxima de partícula, \dot{u} , y la velocidad de onda de corte:

$$\gamma_s = \frac{\dot{u}}{V_s} \quad 2.2$$

A pequeñas deformaciones, el movimiento de partícula resultante de la propagación de las ondas de corte es no destructivo. Conforme γ_s se incrementa más allá del límite de deformación elástica $\gamma_{iésimo}^e$, el módulo cortante decrece a partir de su máximo valor G_{max} . (Dobry et al., 1982).

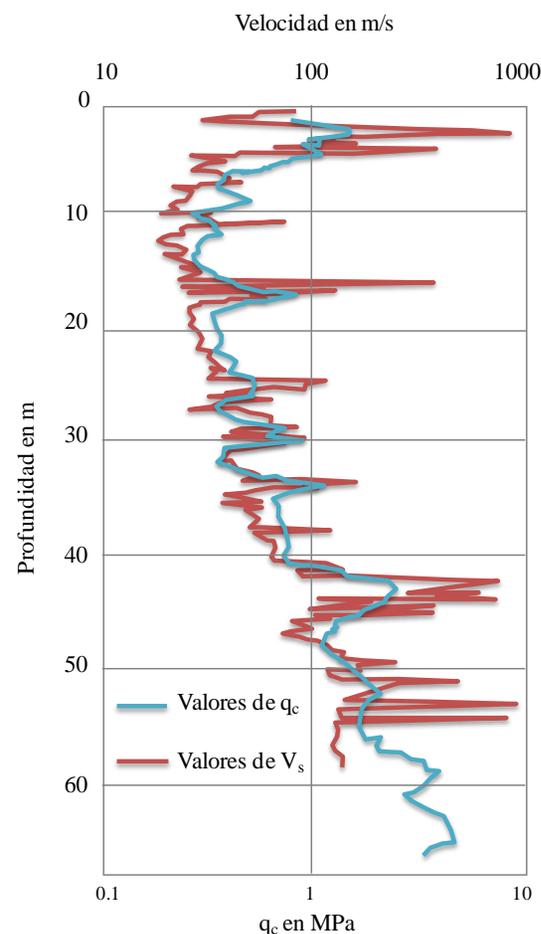


Figura 2.2 Ejemplos de perfiles de velocidad de onda de corte y resistencia a la penetración de la punta (modificado de Ovando y Romo, 1991)

Las pruebas in situ se asumen comúnmente como representativas de pequeñas deformaciones ($\gamma_s > \gamma_{s\text{ íesimo}}^{\text{íesimo}}$), y la medida de la velocidad de ondas de corte puede relacionarse directamente al valor máximo del módulo G .

Existen diferentes tipos de funciones matemáticas que intentan relacionar los valores de q_c y V_s a través de hipótesis particulares a cada material y evitan el costoso y especializado ensaye geofísico para determinar el perfil de caracterización dinámica. Lamentablemente, la mayoría de estas aproximaciones centran su eficiencia en el ambiente definido por la base de datos estudiada y carecen de capacidad de generalización (Na et al., 2005; Hegazy y Mayne, 1995).

En el caso de las arcillas de la Ciudad de México, existen las correlaciones semi-empíricas propuestas por Ovando y Romo (1991) y Jaime y Romo (1988) para estimar V_s a partir de q_c . En la primera aproximación se usa la teoría de expansión de cavidades acoplada con un modelo hiperbólico para definir el comportamiento esfuerzo-deformación de la arcilla, mientras que en la segunda se trata con un análisis de aproximación con mínimos cuadrados (Tabla 2.1). Debido a su sustento matemático, la primera es más confiable y consecuentemente es la que se usa en la práctica profesional.

Tabla 2.1 Correlaciones semi-empíricas para las arcillas de la Ciudad de México

<i>Ovando y Romo , 1991</i>	<i>Jaime y Romo , 1988</i>
HIPERBÓLICO	MÍNIMOS CUADRADOS
$V_s = \eta \sqrt{\frac{q_c}{N_{kh} \gamma_s}}$ <p>γ_s : Peso volumétrico del suelo, t/m³</p> <p>N_{kh}: para las arcillas del lago de Texcoco preconsolidado y virgen su valor medio es de 9.5 y para las del lago de Xochimilco-Chalco es de 9.9</p> <p>η :Es una constante que depende del tipo de suelo, $\eta = \sqrt{\frac{g}{\gamma_r}}$</p> <p>$g$: Aceleración de la gravedad, m/s²</p> <p>γ_r : Deformación de referencia, para las arcillas del lago de Texcoco preconsolidado se considera 1.5%, mientras que 1.17% para las arcillas del lago Xochimilco-Chalco</p>	$V_s = 10.03 + 0.0789q_c \rightarrow \text{a)}$ $V_s = 6 + 0.1211q_c \rightarrow \text{b)}$ <p>a) Lago de Texcoco precargado</p> <p>b) Lago de Texcoco virgen</p>
<p>q_c en kPa y V_s m/s.</p>	

Comportamiento de los parámetros dinámicos G y λ

En general, la relación esfuerzo-deformación de un suelo se torna no lineal e histerética para excitaciones de gran amplitud. Esta no linealidad e histerisidad corresponde a una reducción de la resistencia del suelo, incremento del amortiguamiento, y deformación de ondas si se comparan con la forma de las ondas a bajas deformaciones (Hardin y Drnevich 1972a, b; Erdik 1987; Vucetic y Dobry 1991; Silva et al. 1999, entre otros).

El valor del módulo de rigidez depende fuertemente del nivel de deformación cíclica inducida. Las aproximaciones para modelar las curvas G/G_{max} versus $\gamma\%$ y λ versus $\gamma\%$ precisan del módulo de rigidez máximo y algunos otros parámetros para incluir las diferencias por tipo de suelo (Zen et al., 1978; Kokusho et al., 1982). En el caso de materiales cohesivos, un gran número de estudios experimentales (Kokusho et al., 1982; Dobry y Vucetic, 1987; Sun et al., 1988; Romo, 1990; entre otros) han demostrado que el índice de plasticidad I_p tiene un efecto significativo sobre la forma de las curvas de degradación, mientras que el nivel de esfuerzos efectivos (incluido en el peso volumétrico, γ_t) está relacionado directamente con el rango de G_{max} (Dobry y Vucetic, 1987; Sun et al. 1988).

Para las arcillas de la Ciudad de México, Romo (1990) desarrolló relaciones hiperbólicas esfuerzo-deformación con las cuales los aspectos más relevantes del comportamiento (incluso a grandes deformaciones) de las arcillas pueden ser modelados con cierta eficiencia:

$$G = G_{max} (1 - H(\gamma\%)), \quad H(\gamma) = \left[\frac{(\gamma\% / \gamma_r)^{2B}}{1 + (\gamma\% / \gamma_r)^{2B}} \right]^A \quad 2.3$$

donde γ_r es una deformación de referencia (en por ciento), A depende del índice de plasticidad I_p y B es otra función experimental derivada de A . El modelo se construyó con base en resultados de pruebas triaxiales y de columna resonante desarrolladas para obtener el valor de G dependiente de la deformación por corte. Hardin y Drnevich (1972) mostraron que el amortiguamiento λ de materiales viscoelásticos (materiales que obedecen las reglas Masing durante la carga cíclica) puede relacionarse con el módulo G a través de una simple expresión ($\lambda = \lambda_{max} (1 - G/G_{max})$) y junto con la ecuación anterior se usa para construir la dupla de curvas G y λ dependientes de $\gamma\%$.

En cualquier análisis que haga uso de propiedades dinámicas del suelo debe reconocerse i) la inevitable incertidumbre en la determinación de las variables básicas (en este caso q_c y la caracterización puntual del material por medio del I_p y el peso volumétrico) y su efecto sobre las dependientes (V_s y las curvas G versus $\gamma\%$ y λ versus $\gamma\%$), ii) la restricción adherida a las hipótesis y teorías empleadas (que no necesariamente simulan el comportamiento del suelo bajo condiciones "reales") y iii) el significado *no físico* de los parámetros asociados con el fin de mejorar la identificación de los comportamientos modelados.

2.3. Respuesta de sitio: aspectos básicos

Este apartado no contiene metodologías ni abunda sobre los conocidos pasos para determinar la respuesta de un sitio ante un evento sísmico. Se recomienda al lector interesado la revisión del Apéndice: 2.3.A. El objetivo de esta sección es analizar los puntos débiles de los planteamientos convencionales que sirven como base en la estructuración de los modelos conexionistas (cómputo aproximado) propuestos en secciones posteriores.

La atención en los últimos años sobre los análisis de riesgo sísmico ha generado una gran cantidad de modelos para describir fuentes sísmicas, evaluar la recurrencia de los eventos y establecer el efecto que sobre los movimientos tiene la estratigrafía de sitios específicos. Los ingenieros que trabajan en este tema algunas veces consideran negativas las consecuencias del rápido crecimiento en este campo de investigación, pues los enfrenta al problema de comprender distintas metodologías numéricas, manipular apropiadamente los datos para la selección de parámetros asociados a cada modelo y relacionar e interpretar los resultados de acuerdo con su experiencia en estos fenómenos.

Ya que no todos los profesionales involucrados con este tipo de estudios cuentan con los recursos para desarrollar análisis de riesgo sísmico de una manera consistente (en particular la respuesta de sitio RS), una herramienta simple y auto-documentada a este respecto sería muy útil en la comprensión y el razonamiento correctos de los resultados.

Para decidir sobre la aplicación de cierto modelo bajo condiciones específicas in situ y/o la validez de las respuestas calculadas, es fundamental aclarar las limitantes y desventajas de cada herramienta de análisis, lo que al mismo tiempo representa la dirección que deben seguir las mejoras en futuros desarrollos.

Validación de las Estimaciones

La confianza puesta en cualquier estimación sobre movimientos de terreno es proporcional al realismo físico del modelo y el soporte que éste tenga en observaciones del fenómeno. El nivel de la investigación sobre la dinámica de la ruptura en fallas tectónicas, propagación de ondas, y respuesta no lineal de los suelos sugiere que nuestro conocimiento sobre la física asociada con estos procesos es incompleto (O'Connell y Ake, 2000).

La IE en la evaluación de la RS se refiere al entendimiento parcial sobre procesos sísmicos (generación, propagación y respuesta) mientras que la VA se relaciona con los aspectos inherentemente impredecibles de los sismos, por ejemplo, el patrón de esfuerzos específico que desarrollará un evento futuro (Toro et al., 1997).

La identificación de las incertidumbres en la estimación de movimientos de terreno en términos epistémicos y aleatorios es útil, pero la experiencia reciente sugiere que es probable que existan IE que ni siquiera han sido descubiertas. En principio, datos adicionales y mejoras en el conocimiento

podrían reducir la IE pero, en general, existe una fusión entre IE y VA que hace muy difícil determinar qué beneficio reportan sobre nuestro conocimiento los modernos y voluminosos bancos de datos y/o las inclusiones multiparamétricas a las que tienden las mejoras hechas a modelos convencionales.

Además, el hecho de que muchas fuentes sísmicas, factores de propagación de ondas y comportamientos de materiales naturales quizá nunca sean conocidos (no totalmente) caracteriza a los modelos de RS como *sistemas abiertos*, es decir, cualquier modelo de movimientos de terreno es necesariamente no-único (Oreskes, et al., 1994) y por esto, las cuantificaciones precisas de movimientos para sitios específicos, no son posibles.

Debido a que los modelos sísmicos se construyen para que confirmen experiencias pasadas, su habilidad para predecir comportamientos futuros es necesariamente limitada, pero al mismo tiempo estos estudios son el único medio para establecer la susceptibilidad de un sitio a ciertos sesgos en intensidades y duraciones máximas relativas a la historia de movimientos. Si la validación de la simulación de movimientos de terreno se refiere exclusivamente a los resultados y a su consistencia cuando se comparan con las observaciones, esta imposición es una condición explícita de que la información de movimientos a la fecha contiene todos los comportamientos físicos posibles.

Las comparaciones no son validaciones, se trata de simples confirmaciones de la capacidad del modelo para reproducir la experiencia y dan una idea de que tan correcto, desde el punto de vista físico, es el planteamiento (Oreskes et al., 1994) y por ello no deben tomarse como único recurso para establecer la capacidad de las herramientas o métodos de análisis. Cuando se jerarquizan los modelos la mayoría juegan el papel de esquemas de interpolación de experiencia, descuidando el aspecto crítico de descubrir comportamientos potencialmente significativos más allá de los límites de nuestra experiencia actual (Anderson, 2001). Los modelos que tienden a usar exclusivamente información empírica para evaluar sus capacidades, son propuestas que restringen sus propios límites de operación o representan una espectacular aseveración de que en el futuro no caben las sorpresas. ¿Qué se requiere para ponderar el uso de alguna aproximación sobre las conocidas hasta la fecha?. Bajo la perspectiva expuesta en este capítulo, sólo las bases físicas que eliminen hipótesis contradictorias (premisas ajenas al comportamiento *natural* o registrado) y mejoren el conocimiento (llevando a conclusiones simples e *inteligentes*) elevará el nivel de confianza en las estimaciones hechas sobre comportamientos futuros.

Marco de desarrollo para estimar RS

Las simulaciones de movimientos de terreno se sustentan en simplificaciones y descripciones estadísticas de los procesos de propagación de ondas y las fuentes generadoras en lugar de tratar de modelar la física de la ruptura o la propagación de las ondas elásticas.

Esta representación ha sido necesaria porque el conocimiento para formular (apropiadamente) ecuaciones diferenciales es vago, las observaciones de movimientos severos de terreno son escasas, el conocimiento 3D de la estructura y velocidad de propagación de las ondas en la corteza es limitado, y la demanda computacional para construir un esquema que incluya todos estos aspectos sería extrema. Las investigaciones que intentan cubrir cada ángulo de esta compleja perspectiva han sido catalogadas como *raras*, *exóticas*, y *caras* (computacionalmente) dejando a las aproximaciones estadísticas simplificadas como *buenas* y la mayoría de las veces únicas alternativas de análisis.

El proceso en la estimación de movimientos fuertes de terreno debe mejorarse a través del reemplazo (con conocimiento y monitoreo adecuado) de los parámetros estadísticos y puramente matemáticos por parámetros físicos basados en datos y experiencia disponible, y la exclusión de la actividad, bien conocida y poco fundamentada, de especificar *a priori* las relaciones entradas→salidas de los sistemas. Desde el enfoque Bayesiano, un progreso significativo en la estimación de movimientos de terreno será representado por una evolución de las hipótesis *a priori* a declaraciones *a posteriori*.

Son los avances recientes en tecnología computacional (microprocesadores rápidos y económicos, memorias eficientes y procesamiento paralelo) los que hacen posible los cálculos complejos y las opciones de modelado avanzadas, aunque hay que reconocer que desafortunadamente la geosismología es escasa respecto a datos y conocimiento si se compara con las modernas capacidades computacionales. Es tarea del investigador equilibrar el uso de las emergentes herramientas computacionales con los progresos en la caracterización de la fuente, dinámica de la ruptura, propagación de ondas y respuestas no lineales del suelo, sin esperar a que nuestras deficiencias de análisis y cálculo sean evidenciadas conforme la naturaleza nos demuestra su poder.

Algunos de los aspectos en RS que requieren mayor profundidad en su interpretación y modelado para lograr un avance en el conocimiento y hacer de las nuevas propuestas *verdaderas* alternativas, son (O'Connell y Ake, 2000):

Tema 1: Caracterización de la fuente

Modelación de la tectónica, cinemática, distribución de esfuerzos, y localización de deformaciones para cuantificar las propiedades de las fallas. Comprensión física de los factores que promueven e inhiben la ruptura a lo largo de los segmentos de falla y las interacciones dinámicas entre ellos para estimar magnitudes sísmicas y comportamientos recurrentes (Harris y Day, 1993,1999; Magistrale y Day, 1999). Una necesidad muy poco abordada es mejorar los métodos para detectar fallas *ocultas*.

Tema 2: Restricciones dinámicas en la ruptura

Ya que las correlaciones espaciales entre los factores de fuente son *pobrementemente* comprendidas es necesario reestructurar las metodologías que asumen relaciones paramétricas donde no necesariamente existen. Investigaciones teóricas de ruptura para examinar influencias dinámicas de las velocidades, heterogeneidades en esfuerzos, y geometrías de segmentación asociadas con fallas son necesarias para reducir errores y sesgos potencialmente peligrosos en la estimación de movimientos de terreno (Harris y Day, 1983; Magistrale y Day, 1999).

Tema 3: Propagación de ondas

Un importante tema de investigación es la determinación de la influencia de la estructura 3D en respuestas de movimientos de terreno (Davis et al., 2000). Esto requiere incorporar esquemas realistas de atenuación (Day, 1998) y manejar la influencia de las topografías y anisotropías en movimientos severos, así como generar mayor conocimiento sobre ondas atrapadas en cuencas-cuña y efectos espaciales en regiones densamente pobladas.

Tema 4: Respuestas de sitio no lineales

Es importante i) determinar los límites de aplicación de los métodos lineales equivalentes con parámetros de suelo lineales independientes del tiempo; en particular, el efecto de la intensidad y tiempo de duración para alcanzar degradación significativa del módulo de rigidez; ii) definir *directividad* y su repercusión en la producción de máximas amplitudes en los estados iniciales de la sacudida antes de que una degradación significativa del módulo G ocurra; y iii) conceder la importancia debida a la no linealidad del suelo, respaldo más científico en la determinación de los parámetros que expresan este aspecto.

Tema 5: Monitoreo

Perfeccionamiento de las técnicas geológicas, geodésicas, geotécnicas y geofísicas de observación, exploración y prueba (in situ y/o laboratorio).

La solución a los 5 planteamientos anteriores mejorará la habilidad de los profesionales en la conducción de investigaciones de movimientos en sitios específicos y podrá convertirse en la motivación de inversión en monitoreo sísmico, investigaciones regionales geológicas y geofísicas, así como en el desarrollo de modernas y mejor constituidas aplicaciones geosísmicas.

3. Cómputo Aproximado

En el horizonte de los descubrimientos relacionados con la informática surgen no sólo ideas nuevas para mejorar las técnicas existentes, sino también paradigmas radicalmente diferentes de los actuales procedimientos. Uno de ellos, actualmente aplicado en casi todas las ramas de la ciencia, es el Cómputo Aproximado CA (Soft Computing en su idioma nativo). Su objetivo es bien concreto: aumentar el "coeficiente intelectual" de las máquinas a través de la *flexibilidad, adaptación e inteligencia*. En palabras de Lotfi Zadeh (1994), reconocido experto mundial en la materia, "el CA es la antítesis de la computación actual (asociada con la rigidez, la fragilidad y la simpleza) la cual no es suficientemente capaz de desarrollar y ejecutar sistemas *inteligentes*" (Fig. 3.1).

En lugar de sostenerse únicamente en las habilidades del modelador, un programa de CA aprende de su experiencia por generalización y abstracción, adquiriendo la facultad de razonamiento y aprendizaje en un ambiente incompleto, incierto, impreciso y con verdad parcial, aspectos propios de la realidad. El CA, capaz de modelar y controlar una gran variedad de sistemas, se constituye como una herramienta efectiva en problemas de toma de decisiones, control, clasificación y comprensión, reconocimiento y predicción.

En el CA se combinan diferentes técnicas de la Inteligencia Artificial IA como Lógica Difusa LD, Redes Neuronales RNs, Algoritmos Genéticos AGs y Razonamiento Probabilístico; esta última comprende Algoritmos Evolutivos, Sistemas Caóticos, Redes de Opinión y, parcialmente, Teoría del Aprendizaje (Zadeh, 1997, Bonissone, 1997). Conviene aclarar que el CA no es una mezcla de ingredientes sino una disciplina en la que cada componente contribuye con una metodología específica para manejar problemas en su dominio de aplicación que, de otra forma, se tornarían irresolubles.

La LD, en su más popular concepción, se liga a los cálculos numéricos basados en reglas difusas que tienen el propósito de modelar una función numérica para describir sistemas de ingeniería (Mendel, 1995). Sin embargo, en la literatura orientada hacia las matemáticas modernas, se le califica como una lógica multi-valuada cuyo propósito es modelar valores de verdad parcial e incertidumbres (Novak, 1996; Hajek, 1995). El desarrollo de la LD está ligado con la investigación en IA pero sobre todo con los análisis de sistemas de ingeniería por lo que las aplicaciones a problemas reales tratan en las primeras etapas de su desarrollo con la representación del conocimiento y una vez terminadas se convierten en una interfaz numérica/simbólica.



Figura 3.1 Cómputo Aproximado (soft) y Preciso (hard)

Las RNs se originaron en un intento por construir modelos matemáticos de unidades de procesamiento elementales anidadas en un *cerebro* que permitieran el flujo de señales a través de ellas. Después de un periodo de estancamiento, los modelos formales de RNs incrementaron su popularidad con el descubrimiento de eficientes algoritmos capaces de ajustarse a complicadas y masivas bases de datos. Las aplicaciones neuronales más exitosas se concentran en la construcción de arquitecturas computarizadas capaces de aproximar funciones no lineales con un gran número de variables y clasificar objetos inmersos en espacios multidimensionales. Básicamente, una red neuronal es una sofisticada función no lineal, tipo caja negra, que puede ser entrenada con datos numéricos para satisfacer tareas objetivo.

Los AGs son procedimientos de aproximación combinatoria estocástica desarrollados con base en la analogía biológica de la mutación y el intercambio de cromosomas en Genética (Holland, 1975). Pertenecen a los procesos meta-heurísticos que se usan para evitar mínimos locales en búsquedas siendo una sobresaliente particularidad su capacidad para mejorar -en paralelo- soluciones propuestas a un problema a través de saltos y fusiones aleatorias.

A la luz de las definiciones anteriores, es claro que la LD, las RNs y los AGs pertenecen a diferentes campos de investigación y el obvio punto en común es su inspiración en los seres vivos: la imprecisión del lenguaje humano y su eficiencia en la expresión y transmisión de información en el caso de la LD, la insuperable perfección de la arquitectura cerebral para las RNs y la reproducción y adaptación exitosa de los seres vivos en los AGs. De una forma complementaria y sinérgica -en lugar de competitiva- su estudio como herramientas de análisis conduce generalmente a lo que se denomina sistemas inteligentes híbridos, siendo los más destacados los neuro-difusos, los difuso-genéticos, los neuro-genéticos y los neuro-difuso-genéticos (Fig. 3.2).

El problema del sentido común

La computadora convencional "razona" utilizando una lógica estricta. El hombre no analiza las situaciones minuciosamente y basa mayormente sus reacciones en la experiencia. El cerebro trata de relacionar partes de su problema actual con algo ya solucionado en el pasado y aprovecha su amplio conocimiento acerca del modo en que funciona el mundo para razonar por aproximación antes de hacer uso de acciones precisas y rigurosas.

En ese sentido, Marvin Minsky, uno de los fundadores de la Inteligencia Artificial, postuló que, para avanzar en el campo de las máquinas inteligentes, es necesario dotarlas de sentido común. Pero, ¿qué se entiende por sentido común? Muchos lo definen como el caudal de conocimientos tácitos o de trasfondo, estrechamente interrelacionados, que facilita nuestra comprensión inmediata del entorno en el que nos desenvolvemos. El CA se perfila como una buena plataforma para dotar a las máquinas de sentido común, aunque debe aclararse que esta capacidad se ve restringida por la tarea (fenómeno) y la experiencia específicas (registro o monitoreo de los hechos estudiados).

Modelar contra Explicar

Formalizar la conexión entre datos y conocimiento es sin duda una de las más desafiantes actividades en la era de la computación. La producción de conocimiento a partir de datos se puede plantear desde dos antagónicos puntos de vista:

- **Modelación.** Se construye una función que imite los datos con suficiente precisión y que se comporte adecuadamente cuando se aplique a nuevos conjuntos de datos.
- **Abstracción:** Se construye un sistema que produzca conocimiento articulado, posiblemente en lenguaje natural, a partir de datos.

En el primer punto, el esfuerzo se concentra en desarrollar la habilidad para reproducir lo que se ha observado. Las RNs se adaptan bien a este problema. En el caso de la abstracción se busca desarrollar la destreza para comprender y explicar datos numéricos tal que se obtengan conclusiones útiles en el desarrollo del conocimiento humano. La LD ofrece los elementos teóricos para lograrlo.

Imprecisión e Incertidumbre constituyen la Indeterminación

El CA se presenta como un paradigma computacional para resolver problemas que se estudian bajo cierto grado de imprecisión e incertidumbre, características comunes en los fenómenos con los que reconocemos el mundo a nuestro alrededor. Estos fenómenos pueden dividirse en dos grandes grupos: *objetos* y *propiedades*. Un *objeto* es un fenómeno que puede ser separado del mundo, es decir, un fenómeno al que se le puede conceder individualidad (Vopenka, 1989). Los *objetos* se acompañan usualmente por lo que llamamos *propiedades*. Una misma *propiedad* puede ser aplicada a más de un *objeto*.

La *imprecisión* básicamente concierne a grupos de objetos, por ejemplo, nosotros agrupamos objetos que comparten alguna propiedad $f(x)$:

$$X = \{x \mid f(x)\} \quad 3.1$$

Donde x es la variable que declara *objetos*. Si $f(x)$ es demasiado compleja (y en la realidad así sucede en la mayoría de los casos) no es posible caracterizar el grupo X de manera precisa pues sus límites no están definidos.

Técnicas de Razonamiento Aproximado

Técnicas Optimización / Búsqueda

Mecanismo: **Condicionante**

Mecanismo: **Modus Ponens**

Búsqueda local: **gránulo fino**

Búsqueda global: **gránulo grande**

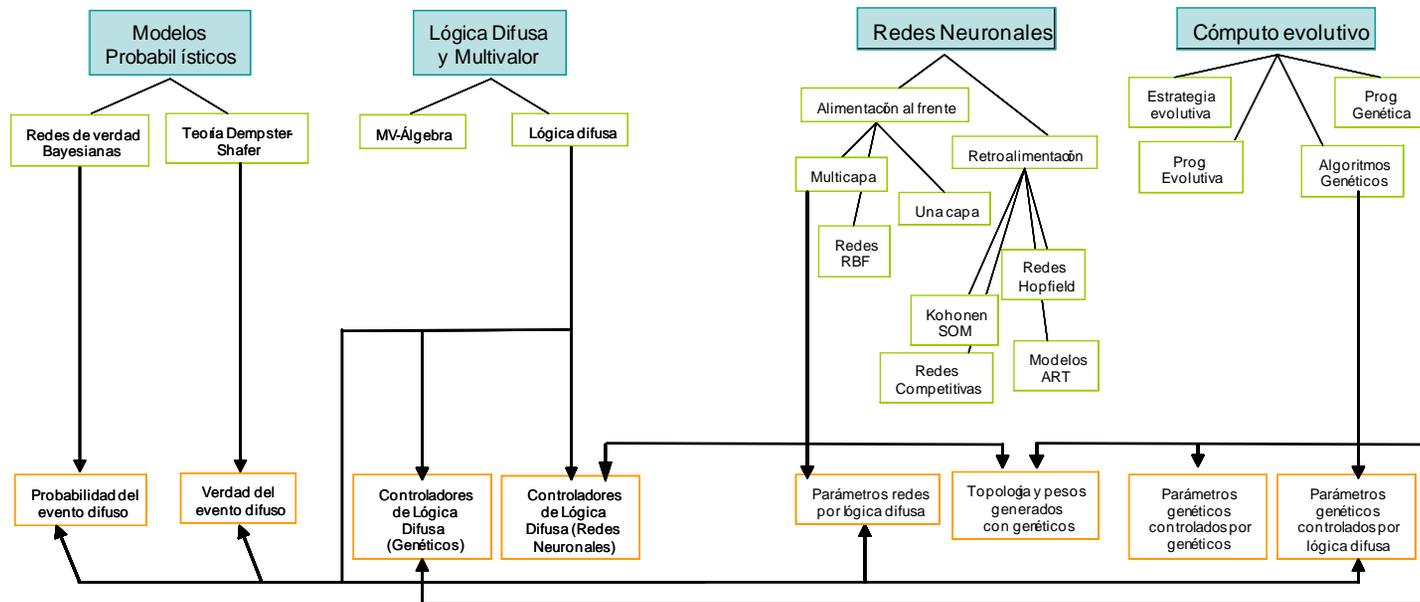


Figura 3.2 Técnicas SC

La incertidumbre, por otro lado, se caracteriza por la falta de información acerca de la ocurrencia de algún fenómeno. La palabra “ocurrencia” contiene la variable tiempo, el fenómeno de incertidumbre está siempre conectado con la posibilidad de monitorear el fenómeno en un lapso de tiempo (si éste llega a ocurrir). En la caracterización imprecisa de los grupos, el tiempo no siempre interviene; por ejemplo, en el fenómeno “árbol pequeño” sólo se busca el significado de “pequeño” ligado al elemento “árbol” sin considerar si se puede observar o no dicho objeto. La incertidumbre responde al cuestionamiento de ocurrencia mientras que la *imprecisión* se relaciona con la pregunta de qué es lo que ha ocurrido (Vopenka 1979, 1989).

Reconociendo las características básicas de los incisos planteados en esta investigación, se elige a la LD (Zadeh,1965) para la traducción numérica del conocimiento ingenieril cualitativo por medio de sus robustos mecanismos de razonamiento por interpolación; y a las RNs (Rosenbaltt,1959; Widrow y Hoff, 1960), para la determinación y aprendizaje de las relaciones numéricas entradas→salidas producto del monitoreo y ensaye geosísmicos. A continuación se presenta una breve descripción de los aspectos teóricos más relevantes de estas dos herramientas para justificar su aplicación en este trabajo de tesis.

3.1.Redes Neuronales

Una de las primeras líneas de búsqueda en la aspiración humana de diseñar y construir máquinas capaces de desarrollar procesos inteligentes de tratamiento de información fueron los autómatas. Estos artefactos mecánicos son los antecesores de las actuales computadoras que, de acuerdo con la filosofía de funcionamiento Von Neumann, se apoyan en descripciones secuenciales para llevar a cabo todos sus procesos.

A pesar del elevado nivel y competitividad de las computadoras modernas, el reto en su crecimiento sigue siendo el desarrollo de máquinas tecnológicamente avanzadas a partir de las condiciones que establece la inteligencia del silicio (artificial) frente al conocimiento que tenemos de la inteligencia del carbono (natural).

En este sentido, una de las ramas de mayor crecimiento en la inteligencia artificial es la de las redes de autoproceso. Estas redes están formadas por nodos procesadores de información de cuyas interacciones locales depende el comportamiento del sistema y pueden operar bajo el esquema de: i) procesamiento numérico y/o ii) procesamiento simbólico (Fig. 3.3). En el primero se recibe directamente la señal de entrada desde el mundo exterior y se trabaja sobre ella, mientras que en el segundo se establecen “conceptos” en los nodos y las reglas sintácticas constituyen los lazos de interconexión.

El procesamiento numérico trabaja con sistemas constituidos por nodos interconectados entre sí formando una red en el sistema intuitivo clásico, por lo que también suelen llamarse conectivistas (o conexionismo). Las raíces cognitivas (biológicas) de los sistemas conexionistas y su asociación con las ideas modernas computacionales se detallan en el Apéndice 3.1.A.

La conexión entre los nodos puede hacerse de forma global indiscriminada (aunque existen ciertas reglas de composición) o agrupada en subredes. En el primer caso estamos ante sistemas distribuidos, mientras que en el segundo

se trata de “redes de redes” o sistemas asociativos. Dentro de los sistemas distribuidos existen sub-clasificaciones: si existen agrupaciones locales de nodos que manejan “conceptos” se trata de las denominadas redes sub-simbólicas, mientras que si admitimos que todos los elementos del sistema funcionan corporativamente, se habla de una red neuronal o neurocomputador.

Los neurocomputadores, perspectiva renovada por el crecimiento de la microelectrónica, tienen su punto de partida en la constitución y ordenamiento del sistema nervioso SN de los animales y en particular de los seres humanos. Dejando aparte cualquier disquisición de tipo biológico, desde los trabajos originales de Cajal (1904) se reconocen en el SN dos aspectos fundamentales:

- Las redes nerviosas cerebrales se componen de neuronas densamente interconectadas organizadas en capas. La información circula de atrás hacia delante (camino directo), de adelante hacia atrás (realimentación entre capas) y dentro de la propia capa (interacciones laterales) (Fig. 3.4).
- Las neuronas poseen numerosas entradas y generan una única salida. Las entradas se reciben en los contactos (sinapsis) de su árbol dendrítico, mientras que la salida aparece en el axón desde donde se distribuye a otras neuronas (Fig. 3.5).

La organización indicada en el primer punto ha sugerido otro nombre para estos dispositivos: redes neuronales artificiales RNAs o por reducción, redes neuronales RNs. Es evidente que muchos aspectos puramente biológicos no son utilizados en estos modelos y del mismo modo es cierto que, por razones eminentemente prácticas, ha debido renunciarse *a priori* a muchos otros planteamientos de inteligencia aún a riesgo de perder buena parte de capacidad informática, ya que el punto básico en la aplicación de estas tecnologías en problemas del mundo *real* es conseguir, no la mejor solución, sino la más eficiente, factible y simple.

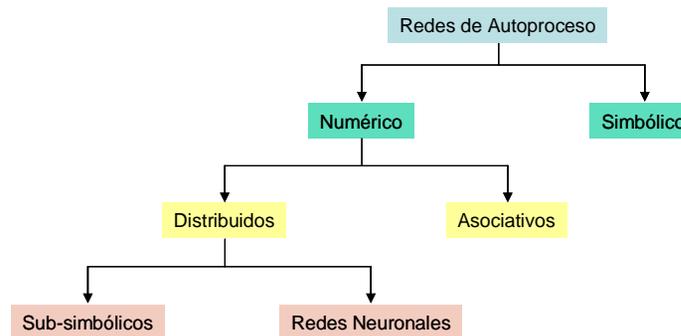


Figura 3.3 Esquema operativo de las redes de autoproceso

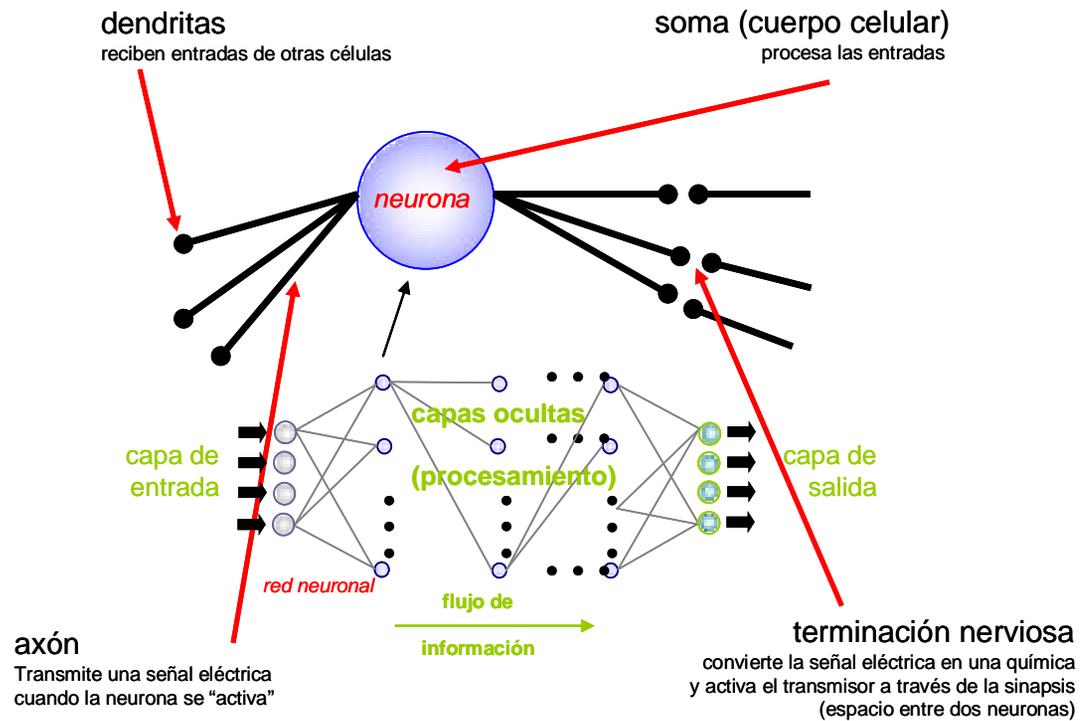


Figura 3.4 Sistema nervioso artificial

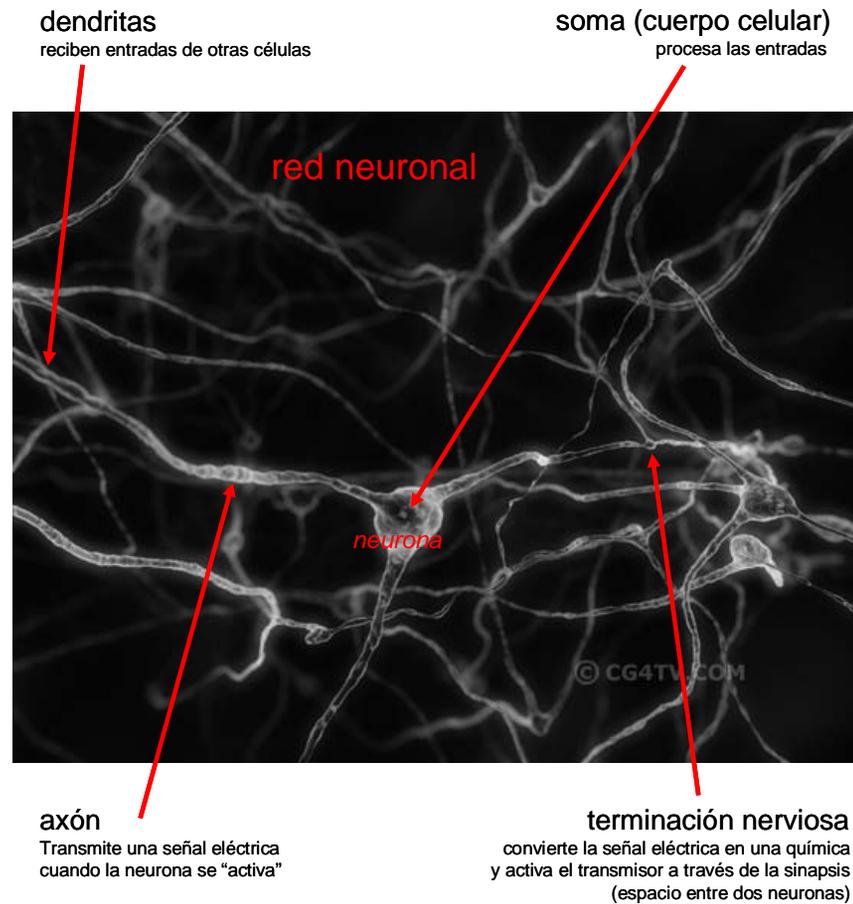


Figura 3.5 Sistema nervioso biológico

Objetivos de los Neurocomputadores

Las RNs no deben ser empleadas para realizar las tareas que las computadoras convencionales ya desarrollan a la perfección (o casi). El objetivo de un neurocomputador debe dirigirse hacia el tratamiento de estrategias de aprendizaje. Partiendo de una versión simplificada de una red biológica, la forma natural en que se *aprende* es por medio de la experiencia. Salvando las distancias, se *enseña* a la red mediante la presentación repetitiva y sistemática de una serie de entradas típicas con las que se definen, por asociación, los conceptos que deberán ser asimilados para interpretar futuras entradas.

Para lograr que este esquema funcione se requiere de: a) una riqueza másica semejante o superior a la de las entradas; un número reducido de neuronas sólo podrá aprender de un número reducido de entradas y b) de algún mecanismo que le permita a las neuronas adaptarse a los objetivos que se esperan de ellas; un elevado número de neuronas absolutamente rígidas, funcionalmente hablando, sería absolutamente incapaz de aprender nada; y si las neuronas no están densamente interconectadas, se trabaja con un conjunto numeroso de nodos muy flexibles pero desconectados unos de otros, con lo que la información apenas será procesada.

Entonces, los ejes fundamentales en las redes neuronales son: el *número de nodos*, que depende directamente de los avances tecnológicos (estructura y capacidad computacional) y las *interconexiones*, cuya complejidad reside en las características de los lenguajes de simulación y la capacidad de autoadaptación (relacionada con la flexibilidad de los algoritmos de síntesis).

Modelos Básicos

El primer modelo de neurona se debe al trabajo de McCulloch y Pitts (1943). No se trata de un modelo fisiológico de una célula nerviosa real sino de la representación lógica de los puntos más significativos del funcionamiento de ésta a través de 5 suposiciones fundamentales. Estos puntos constituyen un cuerpo de doctrina profundo y matemáticamente riguroso y a partir de él parten la gran mayoría de los modelos neuronales actuales (Fig. 3.6):

- La actividad de la neurona es un proceso “todo o nada”
- Para provocar la excitación de la neurona deben excitarse previamente (durante el tiempo de integración) un número mínimo de sinapsis (entradas) siendo este número independiente de la actividad anterior o de la posición de la neurona
- El retraso sináptico es el único significativo
- Las sinapsis inhibitoras impiden el disparo de la neurona
- La estructura de la red no cambia a lo largo del tiempo.

Básicamente para *disparar* a una neurona (hacer que genere un nivel “alto” de actividad en la salida) es preciso que:

- Ninguna entrada inhibitora, I , esté activa, y
- El número de entradas excitadoras activas iguale o supere el umbral U ,

$$\sum E_i \geq U \quad 3.2$$

$$I_j = 0 \quad 3.3$$

Una interesante propiedad de estas neuronas (llamadas *formales*) es la posibilidad de sintetizar circuitos lógicos mediante la adaptación de los umbrales. Como ejemplo, la Fig.3.7 muestra la síntesis de una función AND (Y) y de una OR (O). Este modelo inicial admite i) asignar un peso -1 a las entradas inhibitoras de forma que la condición de disparo ahora se convierte en $\sum(E_i - I_j) \geq U$ y ii) incorporar el retardo propio de las neuronas reales. De esta forma se establecen verdaderos elementos de memoria (Fig. 3.8).

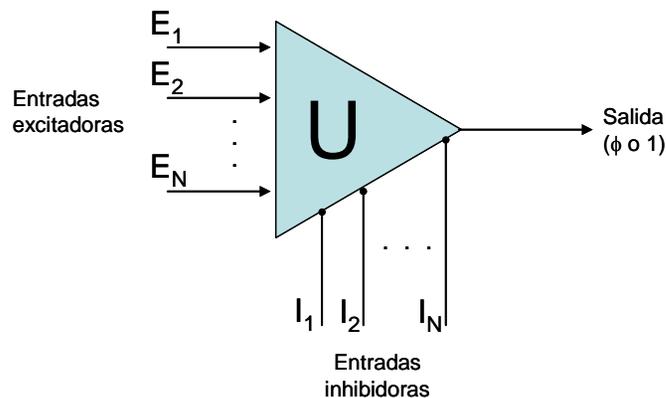


Figura 3.6 Modelo neuronal básico

Estas neuronas fueron modificadas posteriormente por M. Blum (1962) permitiendo la síntesis de funciones no separables linealmente. El punto clave en su propuesta consistió en la postulación de la inhibición presináptica: cuando una entrada está activa evita que otra, a la que inhibe antes de tocar la sinapsis, llegue hasta esta neurona (Fig. 3.9 inciso a). Un sencillo esquema (Fig. 3.9 inciso b) mediante el cual queda sintetizada la función paridad ("O exclusivo") de las variables X_1 y X_2 es:

$$Y(X_1, X_2) = \bar{X}_1 X_2 + X_1 \bar{X}_2 \quad 3.4$$

aplicable a la síntesis de funciones de cualquier número de variables. La extensión natural de este modelo consistió en la alteración del valor de las entradas de forma que la ecuación que describe el comportamiento de la neurona sería:

$$f(X) = 1 \quad \text{si} \quad \sum_{i=1}^N m_i x_i \geq U \quad 3.5$$

$$f(X) = 0 \quad \text{si} \quad \sum_{i=1}^N m_i x_i < U \quad 3.6$$

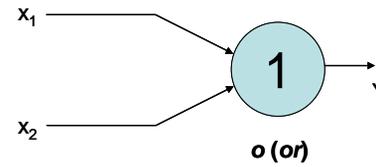
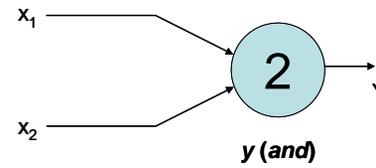


Figura 3.7 Neurona formal: funciones Y/O

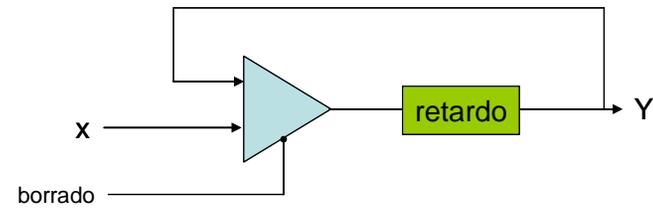


Figura 3.8 Esquema de memoria

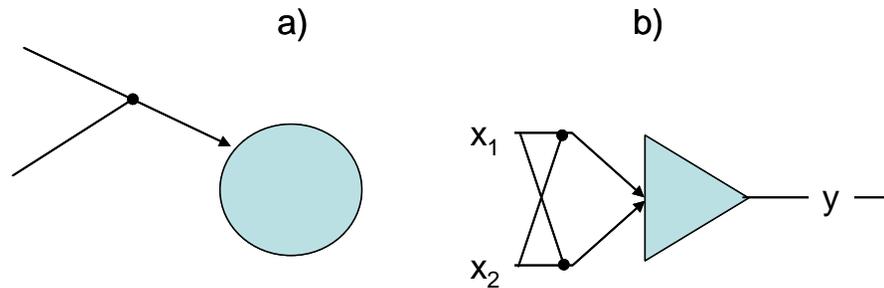


Figura 3.9 Propuesta de inhibición presináptica

donde X representa el conjunto de todas las entradas, mientras que los valores m_i son los pesos asociados a cada una de ellas (Fig.3.10). Si partimos de (X) como el conjunto de todas las entradas, X_i es la configuración correspondiente a un patrón que hay que asociar a una clase de entre dos posibles categorías. Suponiendo que, por construcción, una de las entradas está definida (rígidamente) con valor "1", la función $g(X)$ se define como:

$$g(X) = \sum_{i=1}^N m_i x \quad 3.7$$

entonces la función que realiza la neurona es:

$$f(X) = 1 \quad \text{si } g(X) \geq U \quad 3.8$$

$$f(X) = 0 \quad \text{si } g(X) < U \quad 3.9$$

Con lo que $g(X)$ no es más que la ecuación de un plano en el espacio de las coordenadas X_i que se denomina "hiperespacio". En este punto puede tomarse cada entrada como una variable binaria independiente o en otras palabras, podría construirse un generador de funciones lógicas combinatorias o con lógica de umbral.

Por otro lado, una visión diferente, con resultados más interesantes desde el punto de vista ingenieril, es considerar las entradas del elemento de umbral como las componentes de un patrón presentado al sistema. Cambiando adecuadamente los valores de los pesos, incluido el del término independiente, se puede modificar la "hipersuperficie" que separa el conjunto de los patrones para los que $f(X)$ toma el valor 1 de los que corresponden al valor 0. De esta forma, si se conecta la salida del circuito de umbral a un elemento de decisión, éste indicará qué patrones de entrada pertenecen a la clase o categoría A ($f(X) = 1$) y cuáles a la clase B ($f(X) = 0$), lo que representa un primer dispositivo de reconocimiento y clasificación de caracteres, llamado "función discriminante lineal" ($f(X)$ en este caso es lineal).

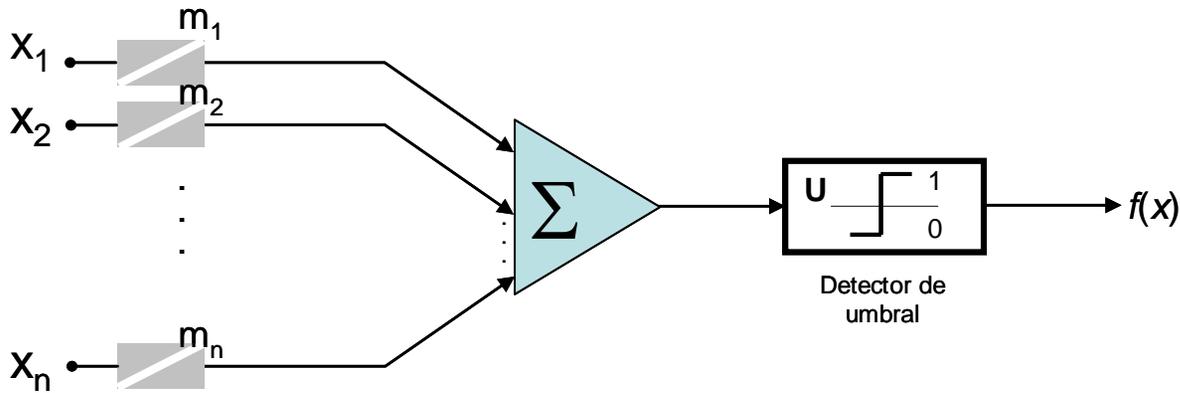


Figura 3.10 Esquema con entradas, pesos y función de activación

Este caso puede extenderse para clasificar un número superior de clases eliminando la parte de umbral y reduciendo la función a $g(X)$. Para establecer N categorías entre los caracteres se recurre a la disposición esquematizada en la Fig.3.11 En ella se establecen M discriminadores lineales

$g_k(X)$ cada uno de ellos ofreciendo el máximo valor de su salida para aquellas entradas que correspondan a la clase k . Todas las salidas son enviadas a un circuito selector de máximos que, en última instancia, decide la clase definitiva a la que pertenece la entrada concreta. Este dispositivo recibe el nombre de “máquina lineal de clasificación”.

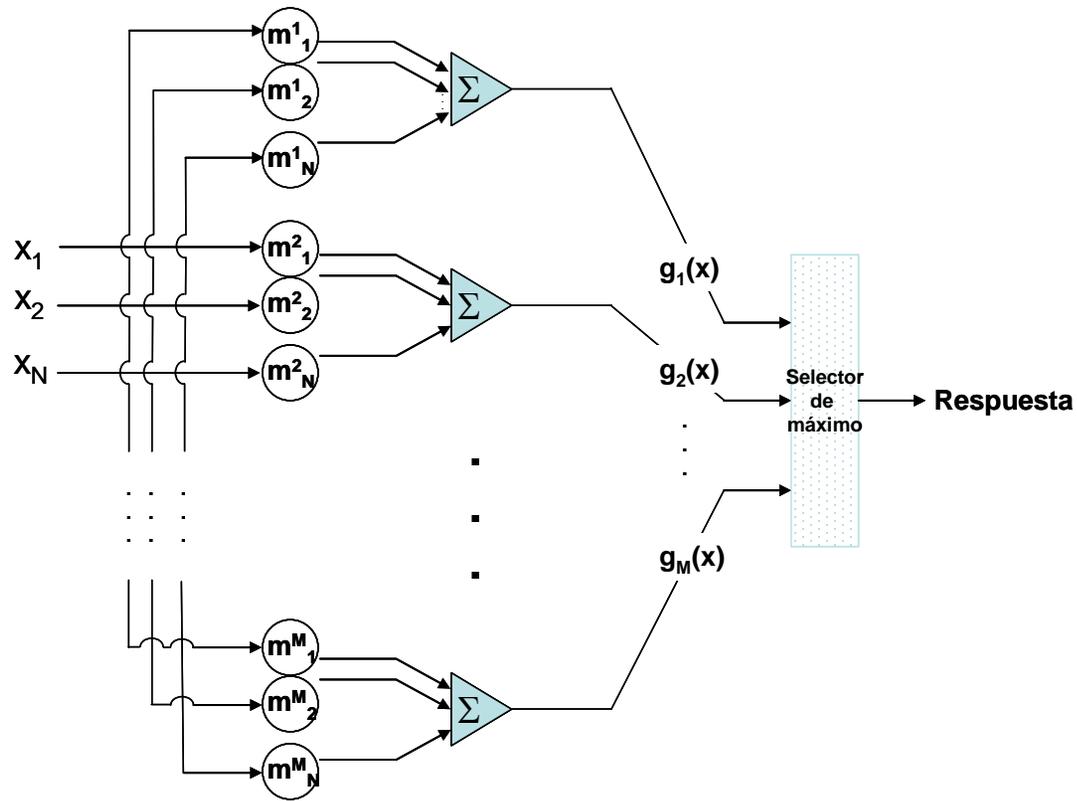


Figura 3.11 Esquema neuronal para clasificación

Mediante este tipo de dispositivos se pueden establecer asignaciones a distintas clases de pertenencia entre entradas definidas por prototipos a través de un esquema de decisión de distancias mínimas. Reuniendo R máquinas lineales es posible establecer discriminaciones no lineales establecidas en otras tantas superficies (Fig. 3.12).

Tras este modelo aparecieron, casi simultáneamente, dos aproximaciones muy semejantes enfocadas a la síntesis de elementos clasificadores lineales: la Adaline (Widrow, 1962) y el Perceptrón (Rosenblatt, 1962).

Adaline (Widrow, 1962) está constituido por dos elementos (Fig.3.13), un dispositivo de combinación lineal adaptativa (*adaptive linear combiner* ALC) donde se realiza la suma ponderada de los componentes del vector entrada para generar la salida. Esta salida Y se confronta con la correcta (esperada) a través de un elemento *comparador*. La diferencia "Δ" es realimentada a un bloque de corrección de pesos de forma que se disminuya su magnitud hasta anularse a lo largo de las sucesivas aproximaciones. La otra parte lo conforma un clasificador lineal conectado a un disparador de umbral. La función que describe el circuito completo es:

$$f(X) = -1 \quad \text{si} \quad \sum_{i=1}^N m_i x_i < 0 \quad 3.10$$

$$f(X) = +1 \quad \text{si} \quad \sum_{i=1}^N m_i x_i > 0 \quad 3.11$$

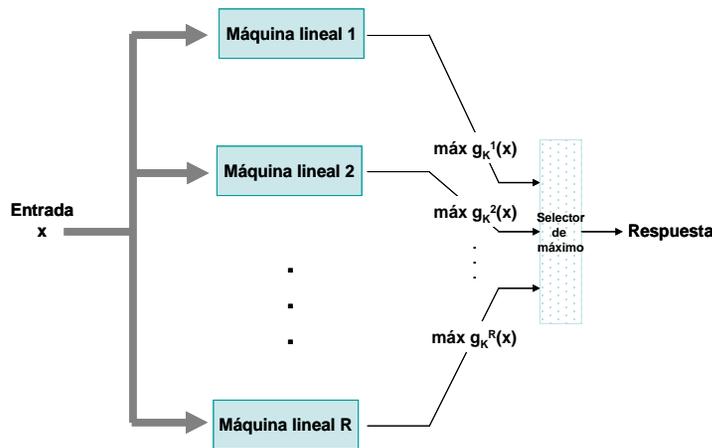


Figura 3.12 Máquinas lineales discriminantes

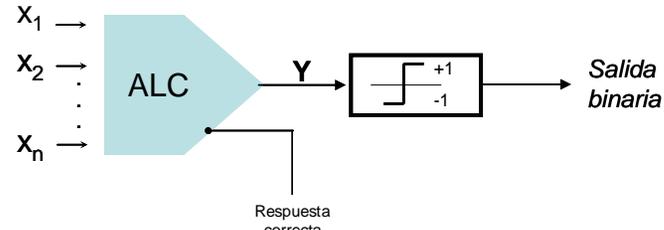


Figura 3.13 Dispositivo de combinación lineal adaptativa (ALC)

El resultado final constituye lo que el propio Widrow denominó Adaline (*adaptive threshold element*). Evidentemente también puede incluirse un umbral en el circuito de salida, además de que la combinación de varias adalinas permite la generación de superficies dicotomizantes de diversas formas (hiperplanos discriminantes).

Un aspecto muy interesante de las adalinas lo constituye la regla adaptativa, que es la ecuación que define la manera en que cambian los pesos asociados a las distintas entradas en dos instantes sucesivos cualesquiera (indicado por t y t+1):

$$m_i(t+1) = m_i(t) + x_i(t) \Delta(t) \quad 3.12$$

A la vez que Widrow presentó sus *adalinas*, Rosenblatt hizo lo propio con los *Perceptrones*, descritos posteriormente -con más detalle- por Minsky y Papert (1969). El principio de funcionamiento, muy similar al de las *adalinas*, se muestra en la Fig.3.14.

Un perceptrón está formado por tres tipos distintos de elementos constitutivos: los sensores "S", los asociativos "A" y los de respuesta "R". Los primeros constituyen la capa receptora/transformadora de los estímulos externos en señales. Las salidas de éstos se dirigen a las entradas de la siguiente capa formada exclusivamente por elementos de asociación en los que se realiza la combinación de las señales de entrada; por ejemplo, si se trata de señales digitales, los elementos de asociación podrán estar configurados como simples funciones booleanas. En principio, todos los elementos de asociación reciben señales desde todos los elementos sensores, pero pueden diseñarse distribuciones más restrictivas (en conexión y complejidad).

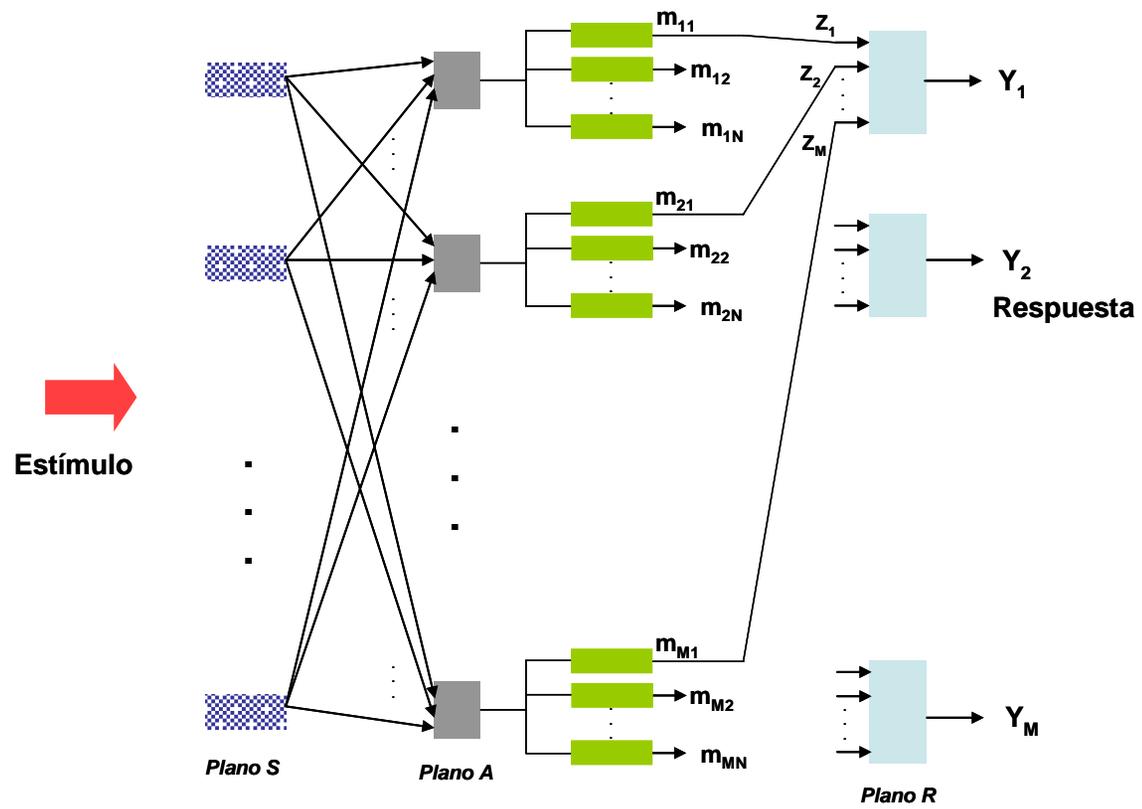


Figura 3.14 Perceptrón multicapa

El último nivel está integrado por las auténticas neuronas del sistema (elementos de respuesta) donde se ejecutan las funciones elementales:

$$y_k = 0 \quad \text{si} \quad \sum_{i=1}^N m_{ik} z_i < \text{Umbral} \quad 3.13$$

$$y_k = 1 \quad \text{si} \quad \sum_{i=1}^N m_{ik} z_i \geq \text{Umbral} \quad 3.14$$

El proceso de aprendizaje o de ajuste de los pesos m_{ik} está referido siempre a la adecuación ente la respuesta dada y la deseada, lo que se denomina *aprendizaje supervisado* y cuya forma genérica se describe en dos puntos:

- si la entrada z_i es un "1" y la salida del elemento no coincide con la deseada, entonces se aumenta el valor del peso asociado a dicha entrada si la salida es cero y debía ser 1, y se disminuye en caso contrario

- si la entrada z_i es un 0 o la salida coincide con la deseada no se altera el valor de m_{ik} .

Esta estructura, originalmente construida con elementos electromecánicos, presentaba un problema fundamental: no siempre existe una superficie discriminadora sintetizable mediante un *perceptrón*, y en caso de que exista, no siempre puede asegurarse que la aplicación reiterada del algoritmo de aprendizaje lleve a una solución estable, pudiendo caer en lazos interminables de valores oscilantes alrededor del correcto.

Otro sistema capaz de implantar ciertas propiedades inteligentes fue la llamada *matriz adaptativa* (learning matrix) propuesta por Steinbuch (1963). En su forma original se trataba de un método para simular los procesos de condicionamiento clásico (tipo Pavlov) (Figura 3.15).

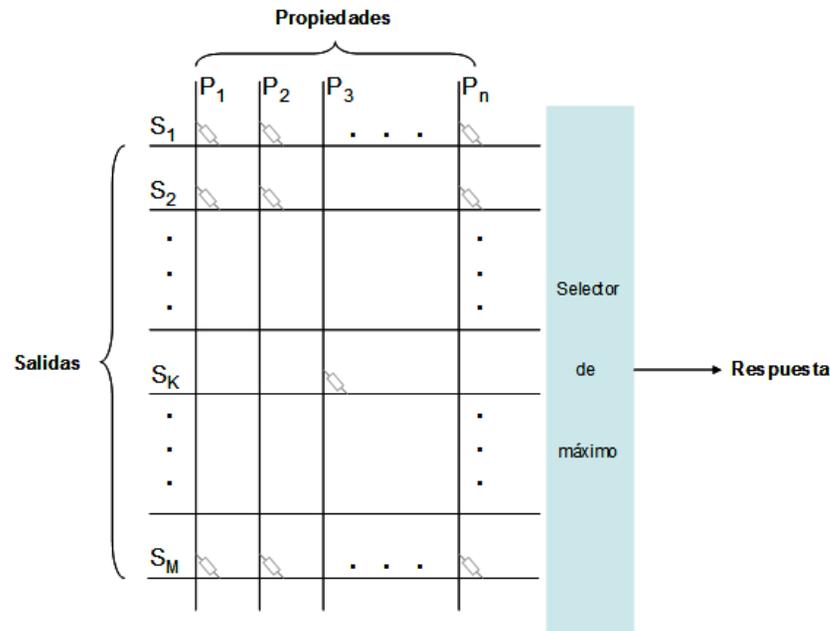


Figura 3.15 Matriz adaptativa

Las columnas constituyen las entradas al sistema y a éstas se conectan las propiedades p_1, p_2, \dots, p_n que definen el vector (P) del elemento a reconocer o asociar. Las filas representan las posibles salidas conectadas a un detector de máximos. En la fase de aprendizaje se escoge una determinada entrada $\{P_i\}$ correspondiente a un evento en particular y una fila de salida cualquiera S_k . Suponiendo que las entradas son binarias, mediante un esquema de refuerzo convencional del tipo

$$\Delta m_{hk} = +x, \quad \text{si } p_h = 1 \quad 3.15$$

$$\Delta m_{hk} = -x, \quad \text{si } p_h = 0 \quad 3.16$$

donde m_{hk} es el peso asociado a la conexión de la línea de entrada p_h con la salida s_k , al cabo de un cierto número de repeticiones, cada vez que se repita la entrada anterior sobre las líneas p, en la salida k se obtendrá

$$y_k = \sum_{h=1}^N m_{hk} p_k \quad 3.17$$

Este proceso debe repetirse para todas las líneas de salida (filas de la matriz) de forma que cada vez que haya una entrada presente, cada fila responderá con un determinado valor de salida. En ese momento se habrá terminado la fase de aprendizaje y se pasa a la de funcionamiento normal. La conexión de todas las salidas a un selector de máximos permite escoger aquella característica $\{p_i\}$ que más se parezca (su salida sea mayor) a la entrada que se presenta.

Además de los descritos anteriormente, existe una serie de modelos neuronales primigenios donde resultan especialmente interesantes los estudios teóricos de Minsky, Kleene, von Neumann, Ashby o Uttley. El lector interesado puede encontrar una revisión completa de éstos en la recopilación de Shannon y Mc Carthy (1956) y en la de Wiener y Schadé (1969).

Modelos Actuales

A partir de los fundamentos antes expuestos Fukushima (1975) desarrolló el cognitrón, una versión de la adalina aplicada a procesos de reconocimiento de formas. Este sistema evolucionó hacia las estrategias de aprendizaje sin supervisión en lo que se conoce como neocognitrón y cuyas características principales son (Figura 3.16):

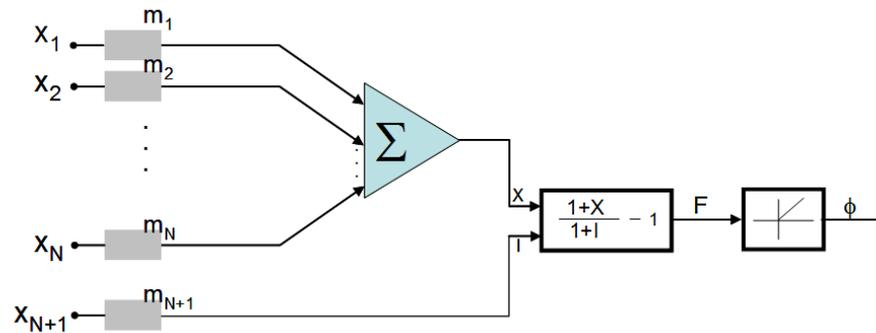


Figura 3.16 Neocognitrón

1. Sólo hay una entrada inhibidora

2. A diferencia de la neurona formal, el efecto de la entrada inhibidora no es absoluto, sino que se define por la función:

$$F(X, I) = \frac{1 + X}{1 + I} - 1 \quad 3.18$$

donde X e I corresponden al valor total de excitación e inhibición respectivamente:

$$X = \sum_{k=1}^N m_k x_k \quad 3.19$$

$$I = m_{N+1} z \quad 3.20$$

siendo z evidentemente el valor de la entrada inhibidora. $F(X, I)$ contiene un elemento no lineal cuya salida (la definitiva del modelo) es cero si la inhibición supera la excitación, o $F(X, I)$ en caso contrario, es decir:

$$\Phi(F) = F(X, I) \quad \text{si} \quad F(X, I) \geq 0 \quad 3.21$$

$$\Phi(F) = 0 \quad \text{si} \quad F(X, I) < 0 \quad 3.22$$

Estos elementos, dispuestos en capas de procesamiento, pueden eliminar las deformaciones geométricas (tamaño, giros, etc.) o físicas (ruido principalmente) que presenten los patrones de entrada una vez finalizado el proceso adaptativo. El esquema de aprendizaje sin supervisión significa que dada una entrada correspondiente a un prototipo, la excitación continua de las líneas x_j correspondientes al valor lógico 1 (suponiendo entradas binarias) hará que se incrementen los pesos asociados a ellas a la vez que se disminuyen los demás.

Volviendo a la estructuración en capas, estas células (como las llama Fukushima) se disponen en planos superpuestos de manera que cada capa recibe sus entradas desde las salidas de la anterior a la vez que envía sus propias salidas a las entradas de la siguiente (posible en ambos sentidos).

La limitante computacional en los 60 permitió sólo avances en niveles teóricos que no pudieron ser concretados en realizaciones prácticas significativas, pero que constituyen la base conceptual de los más modernos y avanzados modelos neuronales. El surgimiento de modelos tan exitosos como el trabajo de Hopfield (1986, 1988), la propuesta evolutiva de Linsker (1988), la llamada teoría de *resonancia adaptativa* (ART) de Carpenter y Grossberg (1988) y la formulación analítica de T. Kohonen (1988) representan el inicio de la etapa moderna de esta clase de estructuras inteligentes.

Redes de alimentación al frente RAF y algoritmo estándar de Retropropagación RP

El modelo neuronal más prominente y ampliamente empleado (presente en cerca del 80% de las aplicaciones prácticas) es el de red multicapa RNM con aprendizaje por retropropagación RP (Rumelhart et al., 1986). La importancia del algoritmo RP, el cual permitió generalizar a los perceptrones hacia arquitecturas con estratos ocultos, en el progreso del neurocómputo se describe detalladamente en Sarkar (1995) y Riedmiller y Braun (1993).

No es intención de este apartado revisar a fondo las ideas del conexionismo (cómputo neuronal) o del aprendizaje por RP, sino describir de forma general el proceso de aprendizaje-máquina y se da por hecho que el lector está familiarizado con los principios básicos sobre sistemas conexionistas. Lecturas recomendadas a este respecto son: Fahlman y Hinton (1987) y Rumelhart et al. (1986) además del Apéndice 3.1.A, contenido en este trabajo de tesis.

Una RNM (llamada en lo sucesivo RN) es una red neuronal de alimentación al frente en la cual un vector de entrada arbitrario es propagado hacia el frente a través de la red, originando un vector de activación que será la producción del estrato de salida (Haykin, 1994). La red se comporta como una función (aproximador universal) que mapea el vector de entrada hacia el vector de salida y esta función es determinada por la estructura (nodos) y las conexiones (pesos) de red. El objetivo de la RP es modificar los pesos de la red de tal forma que ésta consiga mapear la(s) entrada(s)-salida(s) de manera eficiente. Una interesante interpretación sobre la justificación como aproximador universal de las estructuras neuronales se detalla en el Apéndice 3.1.B.

RP estándar

Permita a u_i^l ser la i ésima neurona en el l ésimo estrato (el estrato de entrada es el o ésimo estrato y el estrato de salida es el k ésimo estrato) y a n_l ser el número de neuronas en el estrato l ésimo.

El peso de la conexión entre la neurona u_i^l y la neurona u_i^{l+1} se denota por w_{ij}^l . Ahora $\{x_1, x_2, \dots, x_m\}$, es el conjunto de patrones de entrada que la red debe aprender y $\{t_1, t_2, \dots, t_m\}$ es el conjunto de patrones objetivo (de salida) correspondiente a las entradas específicas. Los pares (x_p, t_p) $p = 1, \dots, m$ son llamados patrones de entrenamiento. Cada x_p es un vector n_0 -dimensional con componentes x_{ip} . Cada t_p es un vector n_k -dimensional con componentes t_{ip} .

La salida o_{ip}^0 de una neurona u_i^0 en el estrato de entrada, cuando el patrón x_p es presentado a la red, coincide con su entrada neta net_{ip}^0 , es decir, con el i ésimo elemento de x_p, x_{ip} . Para los otros estratos, la entrada neta net_{ip}^l de la neurona u_i^{l+1} (cuando el patrón de entrada x_p es presentado a la red) se calcula como sigue:

$$net_{ip}^{l+1} = \sum_{j=1}^{n_l} w_{ij}^l o_{jp}^l - \theta_i^{l+1}, \quad 3.23$$

donde o_{jp}^l es la entrada de la neurona u_j^l (usualmente $o_{jp}^l = f(net_{jp}^l)$ con f siendo una función de activación no lineal) y θ_i^{l+1} es el sesgo de la neurona u_i^{l+1} . Para mantener una representación homogénea, en lo sucesivo, los sesgos serán interpretados como los pesos de una conexión a una "unidad de sesgo" con un valor constante de salida de 1.

El error ε_{ip}^k de la neurona u_i^k del estrato de salida para el par de entrenamiento (x_p, t_p) se calcula con:

$$\varepsilon_{ip}^k = t_{ip} - o_{ip}^k \quad 3.24$$

Para los estratos ocultos el error ε_{ip}^l es calculado de manera recursiva a partir de los errores en otros estratos. La regla estándar de RP usa estos errores para ajustar los pesos (establecido aleatoriamente en el inicio) de tal forma que los errores gradualmente se reducen.

El comportamiento de la red puede ser ajustado usando la suma total de los errores al cuadrado (STEC):

$$E = \frac{1}{2} \sum_{p=1}^m \sum_{i=1}^{n_k} (\varepsilon_{ip}^k)^2 \quad 3.25$$

El proceso de entrenamiento se detiene cuando el error E se reduce a un nivel aceptable, o cuando no se obtienen mejoras posteriores.

En esta investigación se usa la variante del algoritmo estándar de RP donde la actualización de w_{ij}^l en el paso de aprendizaje s ésimo (llamado "época") se realiza de acuerdo con las siguientes ecuaciones:

$$w_{ij+\Delta w_{ij}^l(s)}^l(s+1) = w_{ij}^l(s) \quad 3.26$$

$$\Delta w_{ij}^l(s) = \eta \frac{\partial E}{\partial w_{ij}^l(s)} = \eta \delta_{ip}^{l+1}(s) o_{jp}^l(s) \quad 3.27$$

con $\delta_{ip}^{l+1}(s)$ refiriéndose a la señal de error de la neurona i en el estrato $l+1$ para el patrón p en la época S , la cual es el producto de la primera derivada de la función de activación y el error $\varepsilon_{ip}^{l+1}(s)$, y η es un parámetro llamado tasa de aprendizaje.

Mejoras al algoritmo estándar de RP

Varios métodos han sido explorados para mejorar el comportamiento en generalización y el tiempo de convergencia de la RP. La investigación en este campo se concentra principalmente en: i) el establecimiento óptimo de las tasas de aprendizaje y momento (Momentum y Rprop) (Chen, 1997; Eaton y Oliver, 1992; Jacobs, 1989; Riedmiller, 1994; Silva y Almeida, 1990; Tollenaere, 1990; Vogl et al., 1988; Weir, 1991); ii) el establecimiento óptimo de los pesos iniciales (Cherkassky y Shepherd, 1998; Denooux y Lengelle, 1993; Wessels y Barnard, 1992); iii) la mejora en la representación de contrastes en los patrones de entrada (Kruschke y Movellan, 1991; Anand et al., 1993; Kwon y Cheng, 1996; Vital et al., 1995; Zhang, 1994); iv) modificaciones a la función de error (Ahmad y Salam, 1992; Holt y Semnani, 1990; Ooyen y Nienhuis, 1992; Joost y Schiffmann, 1998; Solla et al., 1988); y v) técnicas para encontrar las arquitecturas óptimas ("podado") (Schittenkopf et al., 1997; Hirose et al., 1991). En este trabajo de tesis se hace uso de las modificaciones indicadas en el inciso i.

Momentum. En el método Momentum se implementa un coeficiente variable de tasa de aprendizaje al adicionar una fracción del último cambio de pesos al ajuste de los pesos de la siguiente iteración, de acuerdo con:

$$\Delta w_{ij}^l(s) = \eta \frac{\partial E(s)}{\partial w_{ij}^l(s)} + \mu \frac{dE(s-1)}{dw_{ij}^l(s-1)} \quad 3.28$$

donde μ es el parámetro momentum. Con este método decrece la oscilación de búsqueda (que ocurre comúnmente con tasas de aprendizaje muy altas) y acelera la convergencia. Para una discusión más detallada ver (Eaton y Oliver, 1992; Jacobs, 1989; Tollenaere, 1990).

Rprop (retropropagación resistente). Es una de las variaciones más veloces del algoritmo RP (Riedmiller, 1994; Schiffmann et al., 1993). Es un esquema adaptativo de aprendizaje local (aprendizaje supervisado) cuyo principio básico es eliminar la influencia negativa de la magnitud de la derivada parcial $\partial E / \partial w_{ij}^l$ sobre el cambio en los pesos. El signo de la derivada se usa para indicar la dirección de la actualización mientras que la magnitud del cambio en descensos se determina exclusivamente por medio de un valor de actualización específico para pesos $\Delta_{ij}^l(S)$ como sigue:

$$\Delta w_{ij}^l(s) = \begin{cases} -\Delta_{ij}^l(s) & \text{si } \frac{\partial E(s)}{\partial w_{ij}^l(s)} > 0, \\ +\Delta_{ij}^l(s) & \text{si } \frac{\partial E(s)}{\partial w_{ij}^l(s)} < 0, \\ 0 & \text{cualquier otro caso} \end{cases}$$

3.29

La actualización de valores $\Delta_{ij}^l(s)$ se modifica de acuerdo con la siguiente ecuación:

$$\Delta_{ij}^l(s) = \begin{cases} \eta^+ \Delta_{ij}^l(s-1) & \text{si } \frac{\partial E(s-1)}{\partial w_{ij}^l(s-1)} \bullet \frac{\partial E(s)}{\partial w_{ij}^l(s)} > 0, \\ \eta^- \Delta_{ij}^l(s-1) & \text{si } \frac{\partial E(s-1)}{\partial w_{ij}^l(s-1)} \bullet \frac{\partial E(s)}{\partial w_{ij}^l(s)} < 0, \\ \Delta_{ij}^l(s-1) & \text{cualquier otro caso} \end{cases}$$

3.30

donde η^+ y η^- son constantes que cumplen con $0 < \eta^- < 1 < \eta^+$.

En Rprop se definen a priori tres parámetros de ejecución: el valor de actualización inicial $\Delta_{ij}^l(0)$, el cual directamente determina el tamaño del primer paso de pesos (comúnmente establecido como $\Delta_{ij}^l(0) = 0.1$), y los límites para la actualización de valores Δ_{max} y Δ_{min} , las cuales previenen a los pesos de hacerse demasiado grandes o demasiado pequeños. Típicamente $\Delta_{max} = 50.0$ y $\Delta_{min} = 0.0000001$ para bases de datos normalizadas a la unidad, la convergencia es poco sensible a la diferencia numérica de estos parámetros. En algunos problemas prácticos puede ser ventajoso permitir sólo pasos muy cautelosos (pequeños) para prevenir que el algoritmo se atasque rápidamente en un mínimo local. Para un análisis detallado de los criterios de selección y su efecto sobre el desarrollo de la red ver (Riedmiller, 1994; Schiffmann et al., 1993).

A pesar de que la adición de estas dos mejoras (Momentum y Rprop) hace que el RP estándar sea considerablemente más rápido, todavía se sufre de algunos problemas operacionales durante la evolución de las redes. Se recomienda al lector interesado en este tema la revisión de (Gori y Tesi, 1992; Riedmiller, 1994).

3.2.Lógica Difusa

Las ideas básicas que subyacen a la Lógica Difusa LD y la Teoría de Conjuntos Difusos (Zadeh, 1965) fueron bien acogidas por algunos teóricos (especialmente los matemáticos) pero de forma mayoritaria la comunidad científica mostró escepticismo e incluso una hostilidad manifiesta. La tradición Cartesiana que promueve el respeto a lo cuantitativo y preciso y el desdén por lo cualitativo e impreciso está arraigada tan profundamente en nuestro pensamiento que es difícil desprenderse de ella sin presentar resistencia. Lord Kelvin –uno de los intelectos más excepcionales del siglo XIX– dictó en 1883 el dogma básico: “En la Física, un paso esencial hacia el aprendizaje de cualquier tema es encontrar principios y métodos para calcular y medir cualidades conectadas con él. Cuando se puede medir aquello sobre lo que se habla y es posible expresarlo mediante números se dice que se le conoce, en caso contrario el conocimiento es pobre e insatisfactorio, incluso nulo”.

Actualmente, la controversia que rodea a la LD continúa aunque no en el mismo grado. El éxito de numerosas aplicaciones es demasiado visible como para ignorarlas y varias ramas de la ciencia y la ingeniería se han visto obligadas a explorar esta metodología y han aprovechado los beneficios de adoptar una visión aproximada del mundo.

La representación difusa del conocimiento

En lenguaje natural se describe a los objetos o situaciones en términos imprecisos: grande, joven, tímido, etc. El razonamiento basado en estos términos no puede ser exacto pues normalmente representan impresiones subjetivas, quizá probables pero no exactas. La Teoría de Conjuntos Difusos resulta adecuada para representar el conocimiento humano y dotar a los fenómenos y observaciones de más de dos estados lógicos. En la construcción de Conjuntos Difusos para su implementación en Sistemas Inteligentes son necesarias técnicas específicas de Adquisición de Conocimiento que permitan manipular la información de manera eficiente.

La representación habitual del conocimiento en términos difusos se realiza por medio de reglas, del tipo:

$$\text{Si } x_1 \text{ es } A_{1,1}$$

$$\text{y/o } x_2 \text{ es } A_{2,1}$$

$$\text{y/o } x_n \text{ es } A_{1,n}$$

$$\text{Entonces } y \text{ es } B_1$$

Cada variable que interviene como hipótesis en una regla tiene asociado un dominio que puede estar dividido en tantos Conjuntos Difusos como el experto considere oportuno y a cada una de estas particiones se le asocia una etiqueta lingüística.

Un conjunto de términos (como el ejemplo de la Fig. 3.17) es un conjunto finito comúnmente con 7 ± 2 elementos que son restricciones de una variable lingüística difusa. El número de elementos debe ser tal que describa cualquier situación relativa al contexto en el que se sitúa el problema.

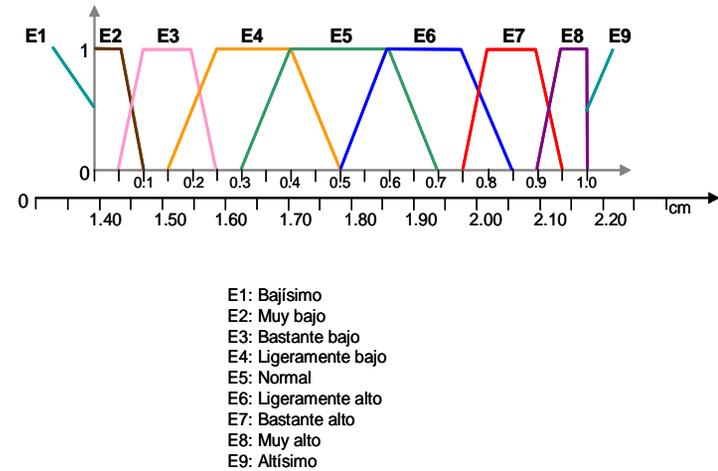


Figura 3.17. Tabla de términos para la variable lingüística “altura” (referida a personas)

El Razonamiento Aproximado

Zadeh introdujo la teoría del razonamiento aproximado (Zadeh, 1987) y a partir de sus trabajos diversas contribuciones en este campo han sido reportadas en todo el mundo. Aunque superficialmente pueda parecer que la teoría del razonamiento aproximado y la lógica clásica se diferencian considerablemente, la lógica clásica puede ser vista como un caso especial de la primera. En ambos sistemas, las premisas son inductoras de subconjuntos de mundos posibles que las satisfacen, aunque en el caso de la teoría del razonamiento aproximado esos conjuntos serán subconjuntos difusos. La inferencia en ambos sistemas está basada en una regla de inclusión: una hipótesis se infiere de una colección de premisas si el subconjunto de mundos posibles que satisfacen la conjunción de las premisas está contenido en el subconjunto de mundos posibles que satisfacen la hipótesis.

El fundamento del razonamiento aproximado es el uso de las variables y la representación de las proposiciones en términos lingüísticos (subconjuntos difusos) como valores de esas variables. La lógica clásica sólo usa de modo implícito la idea de *variable*, en el sentido de valor de verdad asociado a una proposición. Sin embargo, su naturaleza binaria le permite ocultar este hecho, ya que nos podemos referir a una proposición que es verdadera por su denotación, p , y a una que es falsa simplemente por su negación, $\neg p$, evitando así la introducción de una variable V_p cuyo valor sea la valoración de la proposición p .

El uso del concepto de variable en la teoría del razonamiento aproximado conduce a dominios que no están en el ámbito de aplicación de la lógica clásica, como es el caso de los problemas que tratan la toma de decisiones, el control y el reconocimiento de patrones. La teoría del razonamiento aproximado permite representar cuantificadores lingüísticos situados entre el “para todo” y el “existe” clásicos. Estos cuantificadores se usan para incorporar conocimiento por sentido común (Reiter, 1980; Yager, 1982) y resultan una extensión muy ventajosa cuando se modelan fenómenos naturales por su capacidad de tratar con el conocimiento ingenieril prototípico.

La lógica binaria puede ser vista como un caso especial de la teoría del razonamiento aproximado en el cual los conjuntos base tienen dos elementos $\{T, F\}$ y los grados de pertenencia se restringen a 1 ó 0. La lógica posibilista puede ser vista como una extensión de ésta, en tanto que, aunque se restringen los valores de los conjuntos base a dos, T y F, se permite que los grados de pertenencia sean números en el intervalo unidad.

La LD extiende la lógica binaria permitiendo su formalización en términos de la teoría del razonamiento aproximado. Así, “ p es verdadero”, se representa: V_p es $\{1/T, 0/F\}$, p es falso se representa: V_p es $\{0/T, 1/F\}$, mientras que V_p es $\{1/T, 1/F\}$ indica que el valor de verdad de la proposición es desconocido. En cualquiera de los casos, el conjunto base asociado a la variable valor de verdad de la proposición p es $\{T, F\}$.

La regla principal de inferencia en lógica clásica, modo de razonamiento ya introducido por los megáricos y estoicos en tiempos de Aristóteles, es el Modus Ponens (nombre asignado en la Edad Media), que establece: si se tiene la regla $A \rightarrow B$ y se da el hecho A se puede concluir B . En lógica difusa se puede generalizar esta regla, quedando su esquema de la siguiente forma:

Regla: Si x es A , entonces y es B .

Hecho: x es A'

Conclusión: y es B'

Por ejemplo, la regla podría ser “Si la ciudad es grande (x es A) entonces el tráfico es muy denso (y es B)”, el hecho podría ser “la ciudad no es muy grande (x es A')”, ¿Qué se podría decir del tráfico ($B'(x)$)?

Supongamos que las variables están relacionadas no necesariamente por una función, sino por cualquier relación. Supongamos que R es una relación

binaria difusa en el universo $X \times Y$ y que A' y B' son conjuntos difusos en X y Y , respectivamente. Si conocemos R y A' podríamos conocer B' mediante la denominada Regla de Composición de Inferencia:

$$B' = A'(x) \circ R(x, y) \tag{3.31}$$

$$B'(y) = \sup_{x \in X} \min[A'(x), R(x, y)] \tag{3.32}$$

donde $R(x,y) = I(A(x), B(y))$ (Función de Implicación).

Conceptos Básicos

La Teoría de Conjuntos Difusos fue introducida por Lotfi A. Zadeh a mediados de los años 60. Previamente, en 1922 Lukasiewicz cuestionaba la lógica clásica bivaluada (valores cierto y falso) y adelantaba una lógica de valores ciertos en el intervalo unidad como generalización de una lógica trivaluada. Max Black en un artículo de 1937 titulado "Vagueness: An exercise in Logical Analysis" y Karl Menger con el artículo de 1942 "Statistical Metrics" y los de los años 50 sobre relaciones difusas de no-distinción, sentaron las bases de lo que hoy se conoce como LD, inscrita en el contexto de la lógica multivaluada.

¿Qué son los conjuntos difusos?

En un conjunto clásico se asigna el valor 0 ó 1 a cada elemento para indicar la pertenencia a dicho conjunto, esta idea puede generalizarse de forma que se asignen valores a los elementos del conjunto que señalen el grado de pertenencia de dichos elementos al conjunto en cuestión. Esta función se llama función de pertenencia o membresía y el conjunto por ella definida conjunto difuso (ejemplo en la Fig. 3.18).

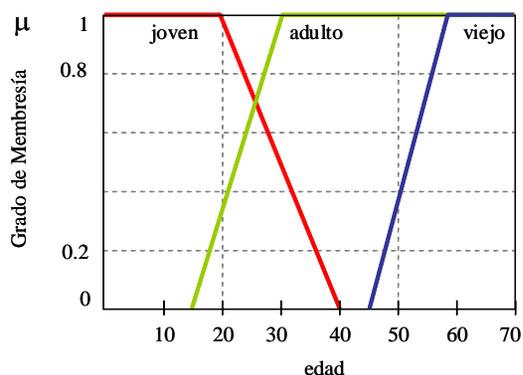


Figura 3.18. Funciones de membresía para los conceptos joven, adulto y viejo de la variable edad

La función de pertenencia μ_A con la que un conjunto difuso A se define, siendo $[0,1]$ el intervalo de números reales que incluye los extremos, tiene la forma: $\mu_A = X \rightarrow [0,1]$, es decir, mientras que en un conjunto clásico los elementos pertenecen o no pertenecen a él totalmente (por ejemplo un número puede pertenecer o no al conjunto de los pares, pero no pertenecer parcialmente) en los conjuntos difusos hay grados de pertenencia referidos a un universo local.

Definición

Siendo X un conjunto universal clásico, una función real $\mu_A: X \rightarrow [0,1]$ se denomina de membresía de A y define el conjunto difuso A de X. Esto es el conjunto de todos los pares $(x, \mu_A(x))$ con $x \in X$.

Por ejemplo, considerando la Fig. 3.18 en el contexto de la sociedad actual una persona de 50 años pertenecerá al conjunto difuso "viejo" con un grado supongamos de 0.4. Si en vez de usar de referencia esta sociedad aludimos a una cuya esperanza de vida fueran 40 años, este grado cambiaría radicalmente.

Operaciones con Conjunto Difusos

Unión, intersección y negación son las operaciones básicas de conjuntos clásicos. Con base en estas tres operaciones pueden ser establecidas un cierto número de identidades difusas.

Unión. La función de membresía de la unión de dos conjuntos difusos A y B con funciones de membresía μ_A y μ_B , respectivamente, se define como el valor máximo de dos funciones de membresía individuales, llamado el criterio del máximo.

$$\mu_{A \cup B} = \max(\mu_A, \mu_B) = \mu_A \vee \mu_B \quad 3.33$$

La operación unión en teoría de conjuntos difusos es el equivalente al O del álgebra booleana.

Intersección. La función de membresía de la intersección de dos conjuntos difusos A y B con funciones de membresía μ_A y μ_B , respectivamente, se define como el mínimo de dos funciones de membresía individuales, llamado el criterio del mínimo.

$$\mu_{A \cap B} = \min(\mu_A, \mu_B) = \mu_A \wedge \mu_B \quad 3.34$$

La intersección en teoría de conjuntos difusos es el equivalente al Y en álgebra booleana.

Complemento. La función de membresía del complemento de un conjunto difuso A con función de membresía μ_A es definida como la negación de la función de membresía especificada, llamado el criterio de negación.

$$\mu_{\bar{A}} = 1 - \mu_A \quad 3.35$$

La operación complemento en teoría de conjuntos difusos es el equivalente de la operación NO en álgebra booleana.

Las reglas clásicas en teoría de conjuntos (como la de Morgan, Asociativa, Conmutativa, Distributiva, etc.) también aplican a la teoría de conjuntos difusos (Jang *et al.*,1997).

En la Fig. 3.19 se muestran estas tres operaciones básicas: Fig. 3.19a se muestran dos conjuntos difusos A y B; Fig. 3.19b presenta el complemento de A; Fig. 3.19c es la unión de A y B; y la Fig. 3.19d representa la intersección de A y B.

Posteriormente se definieron clases de funciones con propiedades

axiomáticas adecuadas al uso de cada operador, principalmente las T-normas y T-conormas, que sirven como modelos de la *intersección* y la *unión* respectivamente. Las T-normas y T-conormas se desarrollaron para establecer la desigualdad triangular (en un triángulo cualquiera la suma de dos lados siempre es mayor que el tercero, Menger, 1942). El concepto de norma triangular (T-norma) surge de la necesidad de *componer* (sumar probabilísticamente) los lados de un triángulo que no *midan* un número sino una función de distribución de probabilidad y posteriormente se reveló como una herramienta adecuada para formalizar la intersección difusa.

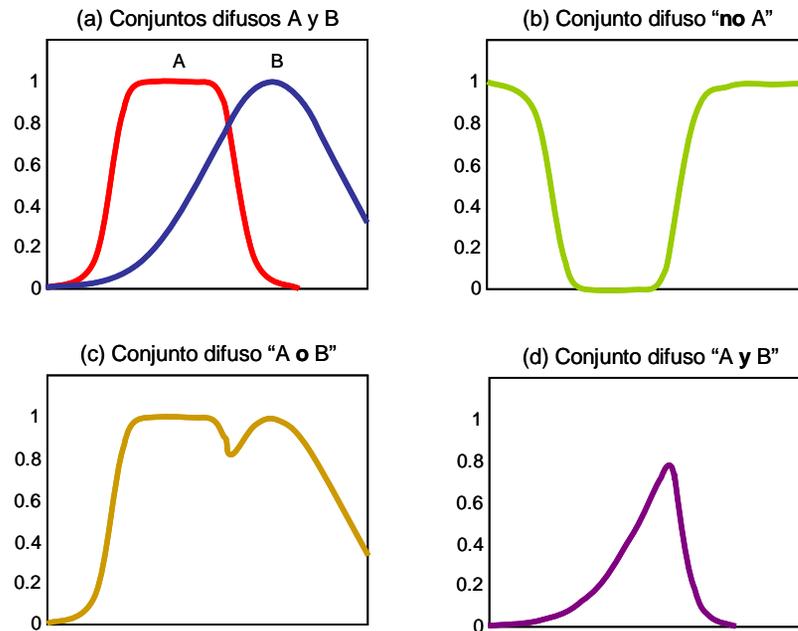


Figura 3.19. Operaciones en conjuntos difusos

Para completar un tipo de razonamiento análogo al que se realiza con lógica clásica es necesario definir el concepto de *implicación* o *inferencia*. Una implicación difusa I es, en general, una función de la forma:

$$I : [0,1] \times [0,1] \rightarrow [0,1] \quad 3.36$$

para cualesquiera dos valores ciertos a y b de proposiciones difusas p,q define el valor cierto I(a,b) de la proposición condicional “si p entonces q”, siendo una extensión de la implicación clásica $p \rightarrow q$ del dominio restringido {0,1} al dominio completo [0,1].

En lógica clásica una implicación se puede expresar de distintas formas y todas son equivalentes, sin embargo sus extensiones a lógica difusa no son directas y han dado lugar a diferentes clases de implicaciones difusas, como el llamado “Principio de Extensión” que permite la generalización de conceptos matemáticos *exactos* hacia la Teoría de Conjuntos Difusos: “cualquier función que asocie puntos x_1, x_2, \dots, x_n del conjunto *exacto* X al Y puede generalizarse de forma que asocie subconjuntos difusos de X en Y. Definiciones, terminología y operaciones teóricas entre conjuntos difusos pueden ser consultados en Jang *et al.*, (1997).

Inferencia desde Datos Imprecisos. ¿Dónde radica el éxito de las aplicaciones difusas?. El éxito radica en la simplicidad, tanto conceptual como de desarrollo. Las aplicaciones más notables se encuentran en el área del control y a estos ejercicios prácticos se deben los avances y la formalización de los métodos difusos. Los dos paradigmas clásicos del control difuso son el sistema de inferencia Mamdani (Munukata y Jani, 1994) y el Takagi-Sugeno (Takagi and Sugeno, 1985).

Las reglas de *Inferencia Difusa* tienen la misma estructura que las clásicas. Las reglas R₁ y R₂, por ejemplo, tienen la forma:

R₁ : Si X O Y Entonces Z

R₂ : Si X O Y Entonces W

La diferencia con las reglas de *inferencia* convencionales es la semántica de los operadores difusos. Estos (O,Y) son identificados con las funciones *máx* y *mín*, respectivamente. Esto es, por ejemplo, permita a los valores de X y Y ser 0.4 y 0.7, entonces

$$X (O) Y = \text{máx} (0.4, 0.7) = 0.7$$

$$X (Y) Y = \text{mín} (0.4, 0.7) = 0.4$$

El *mecanismo de inferencia difusa* (Kandel, 1992; Takagi and Sugeno, 1985; Kosko, 1992) permite a las reglas R₁ y R₂ ser aplicadas sólo parcialmente, esto es, la regla R₁ es aplicada al 70% y la regla R₂ al 40%. El resultado de la inferencia es una combinación de las proposiciones Z y W.

La estructura básica de un *sistema de inferencia difuso* consta de: a) base de reglas difusas; b) base de datos (incluye funciones de membresía) y c) un *mecanismo de razonamiento*, o procedimiento de inferencia sobre las reglas

para obtener una conclusión razonable de salida. Con entradas y salidas exactas, un *sistema de inferencia difusa* implementa un mapeo no lineal desde el espacio de entradas hacia el espacio de salida a través de un cierto número de reglas Si-Entonces que describen el comportamiento local del mapeo. El antecedente de una regla (oraciones antes de la conclusión Entonces) define una región difusa en el espacio de entrada mientras que la consecuencia (oración después de Entonces) es la salida en la región difusa.

Los sistemas básicos de *inferencia difusa* pueden emplear entradas exactas o difusas, pero las salidas son siempre difusas. Cuando, por la aplicación, se requiere una salida exacta (por ejemplo en un controlador) es necesario un método *inverso difuso* para extraer los valores exactos adecuados. Un sistema de inferencia difuso con salida exacta se describe en la Fig. 3.20.

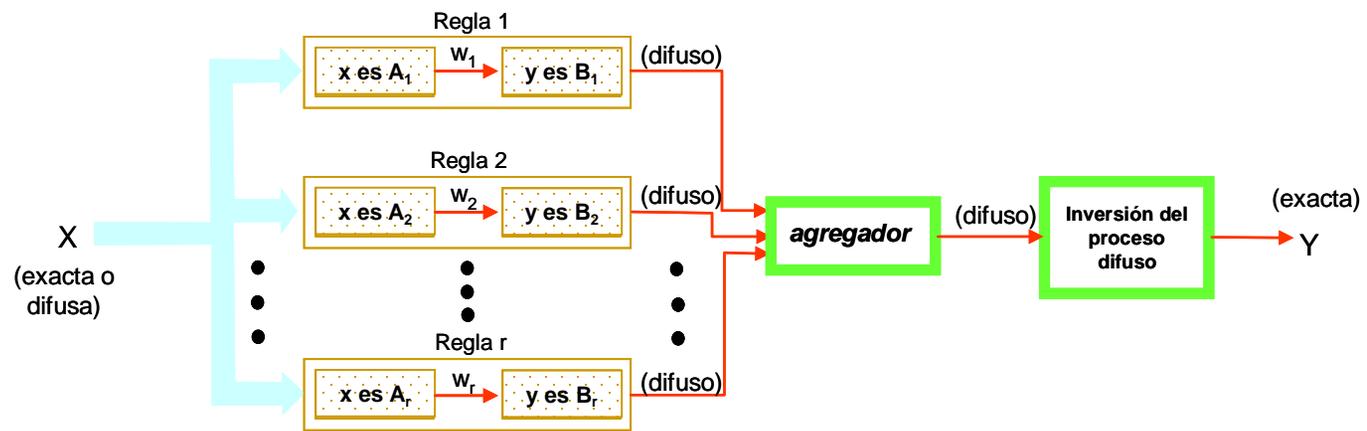


Figura 3.20 Diagrama de bloques para un sistema de inferencia difusa

Existen varios métodos para invertir el proceso difuso de un conjunto difuso A en un universo de discurso Z (Fig. 3.21):

1) Centroide

$$Z_{COA} = \frac{\int \mu_A(z)zdz}{\int \mu_A(z)dz} \quad 3.37$$

donde $\mu_A(Z)$ es la *función de membresía* de salida agregada. Éste es el método más ampliamente adoptado como estrategia *inversa difusa* y es similar al cálculo de valores esperados en distribuciones de probabilidad.

2) Bisector de área Z_{BOA} , la cual satisface

$$\int_{\alpha}^{z_{BOA}} \mu_A(z)dz = \int_{z_{BOA}}^{\beta} \mu_A(z)dz \quad 3.38$$

donde $\alpha = \min\{z|z \in Z\}$ y $\beta = \max\{z|z \in Z\}$. Esto es, la línea vertical $z = z_{BOA}$ parte la región entre $z = \alpha$, $z = \beta$, $y = 0$ y $y = \mu_A(z)$ en regiones con la misma área.

3) Promedio de máximos Z_{MOM} .

$$Z_{MOM} = \frac{\int z dz}{\int dz} \quad 3.39$$

donde $Z' = \{z|\mu_A(z) = \mu^*\}$. En particular, si $\mu_A(z)$ tiene un máximo único en $\mu = \mu^*$, entonces $Z_{MOM} = z^*$. Si $\mu_A(z)$ alcanza su máximo en cualquier $z \in [z_{izq}, z_{der}]$ (como en la Fig. 3.21) entonces $Z_{MOM} = (z_{izq} + z_{der})/2$.

4) El más pequeño de los máximos Z_{SOM} . Es el mínimo (en términos de magnitud) de la maximización de z .

5) El más grande máximo Z_{LOM} . Es el máximo (en términos de magnitud) de maximizar z .

Por sus obvios sesgos, Z_{SOM} y Z_{LOM} son raramente usados.

Es importante mencionar que estas operaciones *difusas inversas* no pueden ser fácilmente analizadas con rigor matemático y la mayoría de los estudios están basados en resultados experimentales (Yager y Filev, 1993).

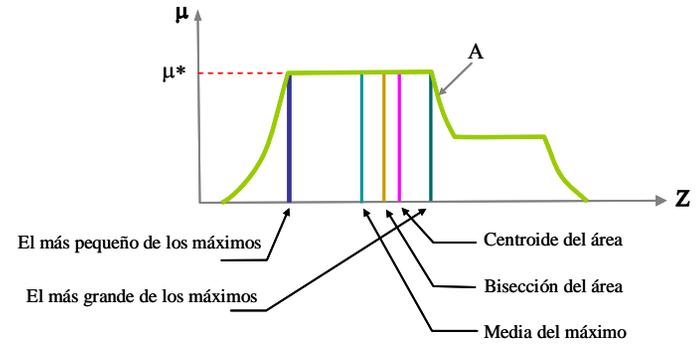


Figura 3.21 Esquemas de procesos inversos difusos

Sistema de Inferencia Mamdani

En el enfoque Mamdani un experto especifica su conocimiento en forma de reglas gramaticales y define las etiquetas lingüísticas que describen los estados de las variables. Para cada entrada (X_1, X_2, \dots, X_n) se especifica la correspondiente etiqueta lingüística que define la salida Y. Cada una de las n variables de entrada y la de salida se reparten en conjuntos difusos específicos. Así se definen P_1 conjuntos difusos distintos en la variable X_1 . Lo mismo se puede hacer con el resto de las variables y la salida. Cada conjunto difuso P_i lleva asociado una etiqueta lingüística.

En la Base de Conocimiento las reglas tienen la forma clásica:

Si h_1 es $A^{(1)}$ y h_2 es $A^{(2)}$, ..., y h_n es $A^{(n)}$ entonces η es B

$A^{(1)}$, ..., $A^{(n)}$ y B son etiquetas lingüísticas que corresponden a los conjuntos difusos μ_1, \dots, μ_n y μ , de acuerdo a las particiones de los conjuntos X_1, X_2, \dots, X_n y Y. La base (o bloque) de reglas constará de K reglas de control. En la lógica de control se comprueba separadamente cada regla de la base de reglas y se determina el grado de cumplimiento de cada hipótesis de la regla de acuerdo a la variable medida.

Si h_1 es $A^{(1)}$ y ... h_n es $A^{(n)}$ Entonces η es B. Para cada regla se observa el grado de compatibilidad de las variables medidas x_1, x_2, \dots, x_n con las etiquetas lingüísticas $A^{(1)}, \dots, A^{(n)}$ y después se hace la conjunción de grados de cumplimiento. Para cada regla R_r de las K de control se calcula: $\alpha_r = \min\{\mu_{1r}, \dots, \mu_{nr}\}$. La salida de R_r es un conjunto difuso de valores de salida obtenidos cortando el conjunto difuso μ_{ir} asociado con la conclusión de la regla R_r en el nivel de cumplimiento α_r .

Supongamos, por ejemplo, una base de reglas como la siguiente:

R_1 : Si ángulo A es positivo pequeño y ángulo B es aproximadamente cero

Entonces ángulo de salida es positivo pequeño

R_2 : Si ángulo A es positivo medio y es ángulo B aproximadamente cero

Entonces ángulo de salida es positivo medio

Las variables de entrada (ángulo A y ángulo B) y la de salida (ángulo de salida) tienen cada una asignada un conjunto de términos. Supongamos que

los datos reales medidos son los siguientes: ángulo A = 36° y ángulo B = -2.25° . ¿Cuál debe ser la salida (orden) que debe dar el controlador difuso?. La evaluación de la regla R_1 se presenta en la Fig. 3.22a Y la evaluación de la regla R_2 se muestra en la Fig. 3.22b. Tras la evaluación de cada regla, se combinan todos los conjuntos difusos obtenidos de la salida de las reglas mediante la operación máxima (unión), como se indica esquemáticamente en la Fig. 3.23.

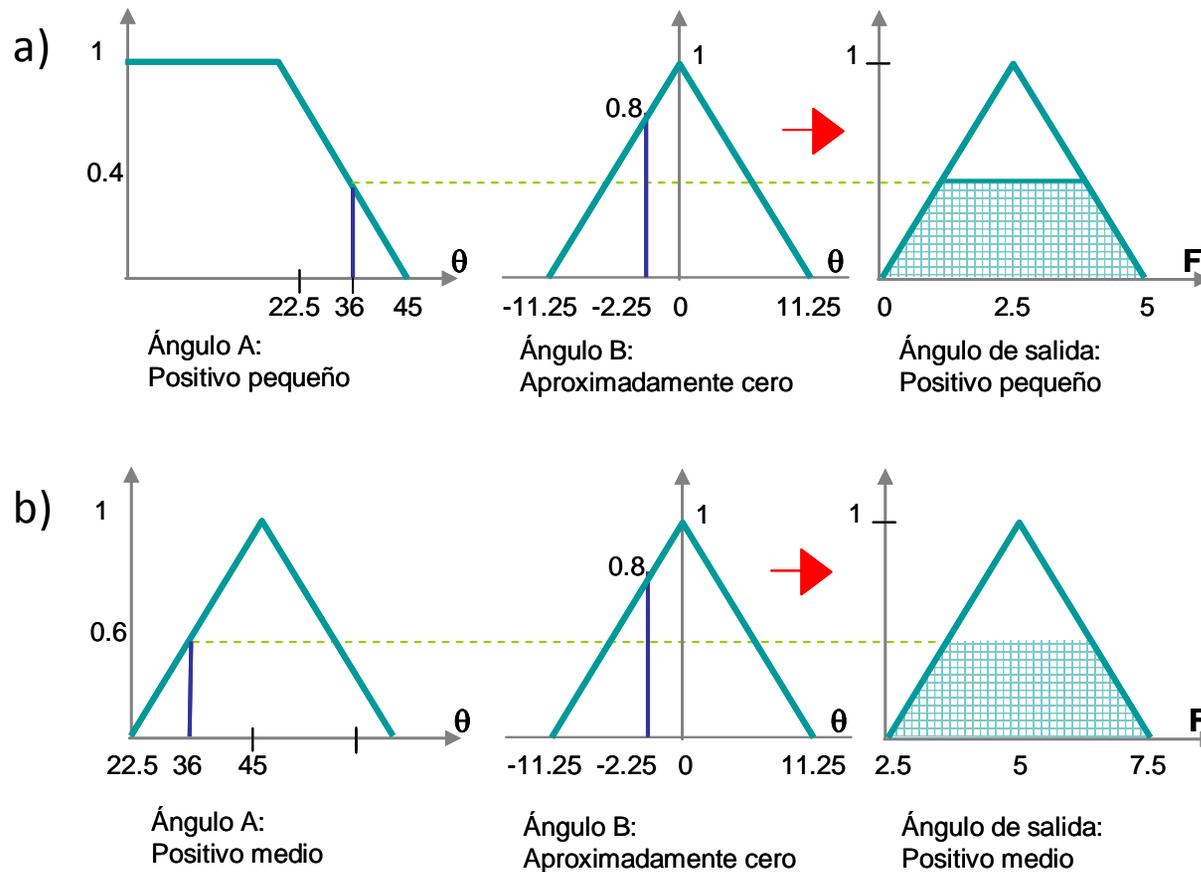


Figura 3.22 Evaluación de la Regla R_2

La salida es la asociación de cada dupla de entradas medidas $(x_1, \dots, x_n) \in X_1 \times \dots \times X_n$ con un conjunto difuso de salida para Y. Pero el sistema a controlar no entendería un conjunto difuso como orden, necesita un valor concreto para actuar, en nuestro ejemplo un ángulo de salida. Por ello es necesaria una interfaz de *proceso difuso inverso* que puede seguir varias estrategias: i) usar algún valor máximo del conjunto de salida (en el ejemplo cualquier valor en $[4^\circ, 6^\circ]$), ii) usar la media de los máximos (con este criterio en el ejemplo el valor de salida sería 5°) o iii) calcular la proyección sobre el eje X del centro de gravedad del conjunto difuso de salida (en el ejemplo el valor de salida con este método es 3.9°). Cada estrategia tiene ventajas e inconvenientes que deben ser revisados por el modelador para decidir sobre su aplicación en problemas particulares.

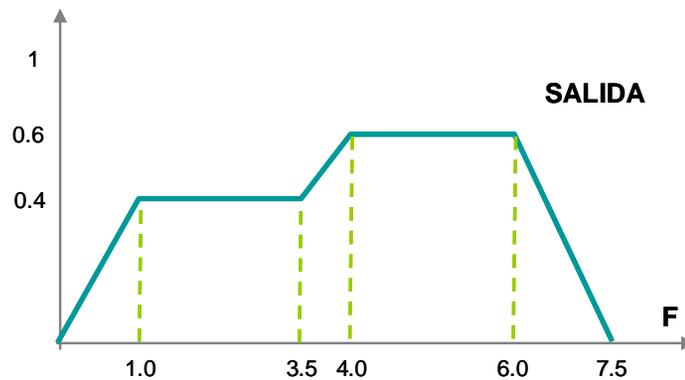


Figura 3.23 Combinación de conjuntos difusos

Sistema de Inferencia Takagi-Sugeno

Este modelo de inferencia fue propuesto por Takagi-Sugeno (1985) en un intento por desarrollar una aproximación sistemática para generar *reglas difusas* a partir de un conjunto de datos entrada-salida de la forma:

$$\text{Si } x \text{ es } A \text{ y } Y \text{ es } B, \text{ Entonces } z = f(x, y)$$

donde A y B son *conjuntos difusos* en el antecedente y $z = f(x, y)$ es una función exacta en la consecuencia. Comúnmente $f(x, y)$ es un polinomio sobre x y y pero puede ser cualquier función tal que sea capaz de describir la salida del modelo en la región difusa especificada por el antecedente de la regla. Si $f(x, y)$ es de primer orden el *sistema difuso* resultante es llamado TS-1, cuando $f(\cdot)$ es una constante resulta un TS de orden cero.

El procedimiento de razonamiento difuso para un TS-1er orden se ejemplifica en la Fig. 3.24 las reglas difusas tienen dos antecedentes y las salidas de cada regla son una combinación lineal de variables de entrada (p_1, q_1, p_2, q_2 , parámetros de la consecuencia) más un término constante del modelo lineal (r_1 y r_2). La salida final es el promedio pesado de cada salida parcial:

$$z = \frac{w_1 z_1 + w_2 z_2}{(w_1 + w_2)} \quad 3.40$$

Los pesos pueden ser calculados como

$$w_1 = A_1 x_1 + B_1 y_1 \quad 3.41$$

$$w_2 = A_2 x_1 + B_2 y_1 \quad 3.42$$

cuya forma general se escribe como

$$z = \frac{\sum_i^n w_i z_i}{\sum_i^n z_i} \quad 3.43$$

donde n es el número de implicaciones difusas, z_i es calculada para la entrada por la ecuación consecuente de la implicación i -ésima y el peso w_i implica el valor de verdad de la premisa de la implicación i -ésima para la entrada que se calcula

$$w_i = \prod_j A_j^i x_i \quad 3.44$$

Donde A_j^i es el grado de membresía de un conjunto difuso A , y x_i es el vector de variables de entrada.

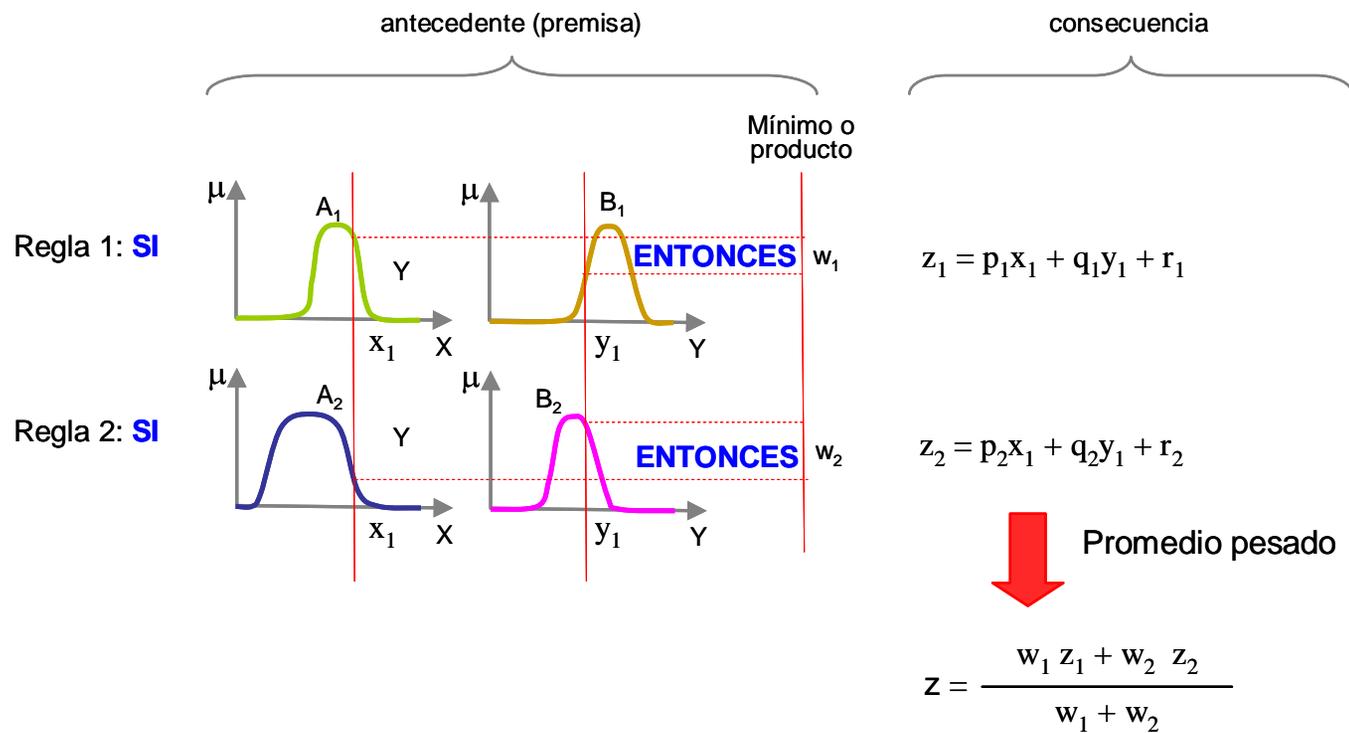


Figura 3.24 El modelo difuso Takagi-Sugeno

Reducción por métodos Difusos

El análisis de reducción es una técnica para agrupar datos y encontrar patrones en ellos para ser ordenados en grupos y clases. El pre-procesamiento remueve datos redundantes y resuelve conflictos entre patrones. La remoción de información superflua permite reducir el tamaño de la base de datos y un patrón característico (*típico*) puede sustituir a los miembros de los *grupos* formados. El resultado del análisis de reducción es un conjunto de *típicos* donde cada uno contiene las características de los patrones cercanos (vecinos próximos en el espacio de entradas y salidas).

Resolver conflictos entre datos implica identificar puntos de información incongruente en el conjunto de entrenamiento con lo que las reglas deducidas a partir de estos ejemplos son claras y simples (Bezdek, 1981; Höppner et al. (1999).

En la *reducción difusa* se calcula la similitud entre puntos de datos considerando condiciones diferentes para cada variable de acuerdo con el rango dinámico de los parámetros. La *reducción difusa* asocia a cada variable una función de membresía que establece la similitud entre dos puntos dependiendo de la diferencia entre sus valores referidos a la base asignada a cada parámetro. La distancia d_{xy} entre los dos puntos es calculada como el mínimo negativo de las similitudes:

$$d_{xy} = - \min v \{ \mu_{xy} \} \quad 3.45$$

Los dos puntos que tienen la d_{xy} menor son considerados los más cercanos (Fig.3.25). El parámetro ε es la diferencia más grande entre dos puntos para que se consideren completamente similares y δ es la diferencia más pequeña para que dos puntos se estudien como totalmente no similares.

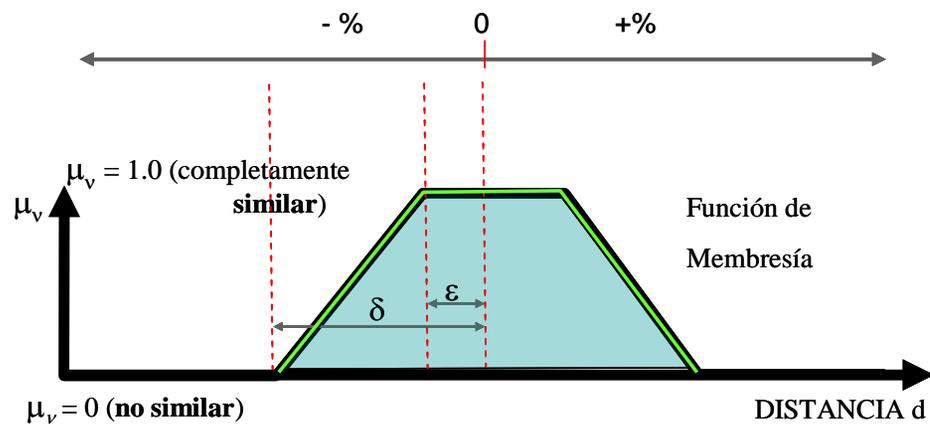


Figura 3.25 Distancias difusas

Sistemas Neurodifusos

La fusión entre RNs y Sistemas de Inferencia Difusa SID han atraído el interés de los investigadores en varias áreas de la ciencia y la ingeniería debido a la creciente necesidad de sistemas inteligentes adaptativos para resolver problemas *reales*. Las RNs aprenden, a partir de resultados, por medio del ajuste de las interconexiones entre estratos. Un SID es un marco computacional basado en conceptos de conjuntos difusos, reglas difusas Si-Entonces y razonamiento difuso. Las ventajas de la combinación de RNs y SID son obvias. Existen un gran número de aproximaciones que integran RNs y SID y la elección de la más adecuada depende totalmente de la aplicación. De manera muy general, la integración de estas dos herramientas arroja tres categorías: modelos concurrentes (Fig. 3.26), modelos cooperativos (Fig. 3.27), y modelos fusionados totalmente (Nauck y Kruse, 1996a, 1996b).

La mayoría de las aplicaciones difusas se encuentran en sistemas de control aunque en la última década el híbrido RNs-SID ha sido usado para resolver exitosamente problemas en ingeniería civil (Romo, 1999; Romo y García, 2003; Romo y García, 2004; Agrawal *et al.*, 1997; Ghaboussi *et al.*, 1991; García *et al.*, 2004, entre otros).

El cómputo neurodifuso es una estructura computacional capaz de resolver problemas complejos. Si tenemos conocimiento expresado en forma de reglas lingüísticas se puede construir un SID, si se tienen datos o se puede aprender a partir de una simulación (entrenamiento) entonces se pueden usar RNs. Para construir un SID se tienen que especificar los conjuntos difusos, los operadores difusos y la base de conocimiento. Similarmente, para construir una RN para una población el usuario necesita definir la arquitectura y un algoritmo de aprendizaje. Las desventajas de cada una de estas aproximaciones parecen complementarias y por lo tanto es natural considerar construir un sistema integrado que combine los conceptos. Mientras que la capacidad de aprendizaje es una ventaja desde la perspectiva de un SID, la formación de una base de reglas lingüísticas será ventajosa cuando se trata de RNs.

Las Figs. 3.26 y 3.27 muestran las arquitecturas neurodifusas más comunes: i) el *sistema neurodifuso cooperativo*, considerado un pre-procesador donde el mecanismo de aprendizaje neuronal determina el sistema de inferencia difuso (SID), funciones de membresía o reglas difusas a partir de datos de entrenamiento; y ii) el *sistema difuso concurrente*, donde una red neuronal y un sistema difuso trabajan juntos en algunas tareas, sin constituirse como un solo elemento de análisis.

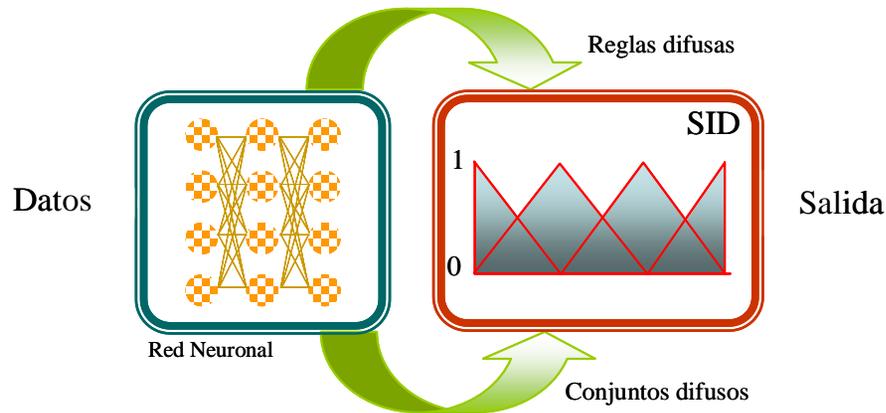


Figura 3.26. Modelo cooperativo (modificado de Abraham, 2001)

En el *sistema neurodifuso cooperativo*, una vez que los parámetros del SID son determinados (*fase de aprendizaje*) el sistema trabaja sin un esquema neuronal. La base de reglas, se obtiene generalmente por medio de una aproximación de agrupamiento que genera patrones *típicos* (*clustering* o algoritmos de *clusters*, Abraham, 2001). Las funciones de membresía iniciales se definen con base en el criterio de un grupo de expertos y son modificadas a través de un procedimiento iterativo neuronal sobre el conjunto de típicos que resulta del pre-procesamiento de los datos raíz. Esto se detiene una vez que la optimización de la solución (minimización de la función de error) alcanza un límite preestablecido.

Los *sistemas neurodifusos concurrentes* son aproximaciones en las cuales una red neuronal es usada como pre-procesamiento o como pos-procesamiento de un sistema difuso. Tales combinaciones no optimizan un *sistema difuso*, sólo tienden a mejorar el desarrollo de un sistema combinado. El *aprendizaje* toma lugar en la red neuronal y el *sistema difuso* permanece sin cambios. Este tipo de sistemas es especialmente útil si en las variables de entrada existen algunas que no puedan ser medidas directamente y resulten de una combinación entre otras variables.

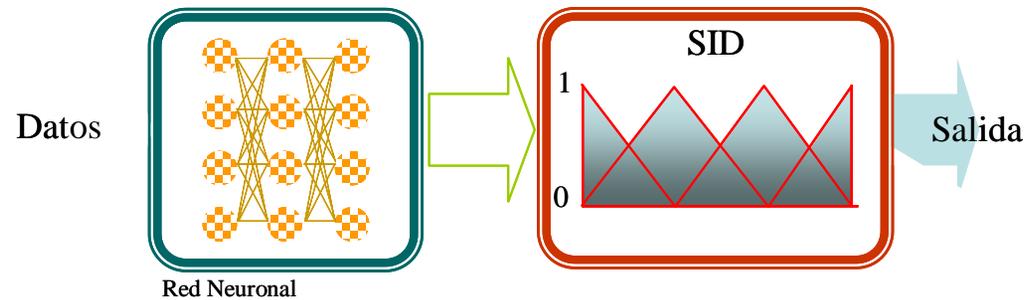


Figura 3.27 Modelo concurrente (modificado de Abraham, 2001)

Sistemas ND fusionados

En una arquitectura ND fusionada, los algoritmos de aprendizaje son usados para determinar los parámetros del SID. Los sistemas ND fusionados comparten estructuras de datos y representaciones de conocimiento.

Una manera común de aplicar un algoritmo de aprendizaje a un sistema difuso es representarlo en una arquitectura especial similar a la de RNs. Sin embargo, los algoritmos de aprendizaje convencionales de las RNs (gradiente descendiente, por ejemplo) no pueden ser aplicados directamente a tales sistemas porque las funciones usadas en los procesos de inferencia son comúnmente no diferenciables.

Este problema puede ser atacado usando funciones diferenciables en el sistema de inferencia o no usando el algoritmo estándar neuronal. Algunos de los trabajos en esta área son (siglas en su idioma nativo): GARIC (Bherenji y Khedkar, 1992), FALCON (Lin y Lee, 1991), ANFIS (Jang, 1992), NEFCON (Nauck y Kruse, 1997), FUN (Sulzberger et al., 1993), SONFIN (Juang et al., 1998), FINEST (Tano et al., 1996), EFuNN (Kasabov, 1999), dmEFuNN (Bherenji y Khedkar, 1992; Abraham y Khedkar, 2000), y muchos otros. A continuación se describe brevemente el sistema ANFIS, que será utilizado en la solución de la estimación de la velocidad de ondas de corte a partir del valor de la resistencia a la penetración del cono eléctrico.

Sistema de Inferencia Adaptativo Neurodifuso SIAN (Adaptive Neuro Fuzzy Inference System ANFIS)

SIAN es un SID Takagi-Sugeno y tiene una arquitectura de cinco estratos como se muestra en la Fig. 3.28. El primer estrato oculto se destina al proceso difuso de las variables de entrada y los operadores T-norma son desarrollados en el segundo estrato para calcular la parte del antecedente de la regla. El tercer estrato normaliza los pesos de las reglas seguido por el cuarto estrato donde se determinan los parámetros de la consecuencia de la regla.

El estrato de salida calcula la entrada total como la suma de todas las señales que llegan. SIAN usa el aprendizaje por retropropagación para determinar los parámetros de las premisas (para aprender los parámetros relacionados con las funciones de membresía) y el algoritmo de máxima pendiente para determinar los parámetros de la consecuencia. Uno de los pasos en el procedimiento de aprendizaje se divide en dos partes: i) la primera parte propaga los patrones de entrada y los parámetros óptimos de la consecuencia son estimados a través de iteraciones del proceso de máxima pendiente, mientras que los parámetros de las premisas se asumen fijos para el ciclo que ocurre a través del conjunto de entrenamiento; ii) en la segunda parte los patrones son propagados otra vez, y en esta época (o ciclo) la retropropagación se usa para modificar los parámetros de las premisas, mientras que los parámetros de las consecuencias permanecen fijos. Este procedimiento se repite hasta alcanzar un criterio de convergencia predeterminado.

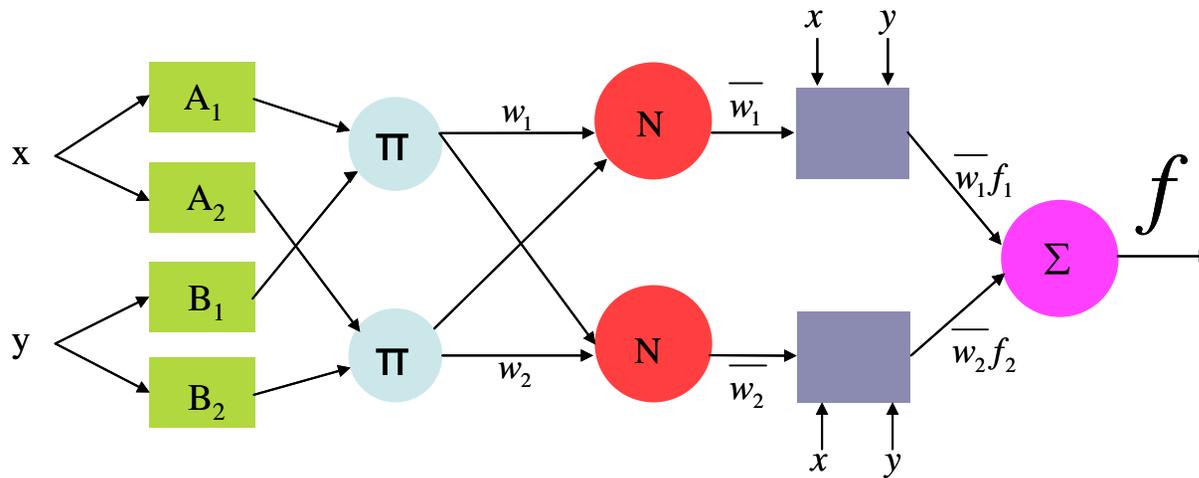


Figura 3.28 SIAN, modelo fusionado totalmente

Algoritmo SIAN

Un sistema difuso puede considerarse como un mapa no lineal parametrizado, llamado f . La expresión explícita de f es

$$f(x) = \frac{\sum_{l=1}^m y^l \left(\prod_{i=1}^n \mu_{A_i^l}(x_i) \right)}{\sum_{l=1}^m \left(\prod_{i=1}^n \mu_{A_i^l}(x_i) \right)} \quad 3.46$$

donde y^l es un lugar de la salida en el razonamiento Mamdani o es una constante si se aplica el razonamiento Sugeno. La función de membresía $\mu_{A_i^l}(x_i)$ corresponde a la entrada $x = [x_1, \dots, x_n]$ de la regla l .

El "y" (and) conectivo de la premisa es manejada por medio de un producto y proceso difuso inverso (método del centro de gravedad).

Esto puede entonces escribirse como

$$f(x) = \sum_{i=1}^m w_i b_i(x) \quad 3.47$$

Donde $w_i = y^i$ y

$$b_j(x) = \frac{\prod_{i=1}^n \mu_{A_i^j}(x_i)}{\sum_{l=1}^m \left(\prod_{i=1}^n \mu_{A_i^l}(x_i) \right)} \quad 3.48$$

Si F es un continuo, un mapa no lineal sobre un conjunto compacto, entonces f puede aproximar F a cualquier exactitud deseada, es decir $F \approx f_{FS}$. Teoremas bien conocidos para aproximación a la teoría de polinomios pueden ser extendidos a los conjuntos difusos (Wang, 1997).

Teorema 1

Permita a F ser una función con límites en $[a,b]$ y $E = \{x_1, \dots, x_k\}$ un conjunto de puntos en $[a,b]$. Entonces existe un polinomio de mínimos cuadrados de grado $\leq n$, p_n^k , que minimiza

$$\sum_{i=1}^k |F(x_i) - p(x_i)|^2 \quad 3.49$$

sobre todos los polinomios de grado $\leq n$.

Teorema 2

Si $F \in C[a,b]$, entonces para cualquier $n \geq 0$, existe el mejor polinomio aproximador π_n de grado $\leq n$ tal que

$$\|F - \pi_n\|_{\infty} \leq \|F - p\|_{\infty} \quad 3.50$$

sobre los polinomios p de grado $\leq n$.

Se puede considerar también que el problema más simple de aproximar hacia varios puntos de forma finita.

Teorema 3

Si F es una función con límites en $[a,b]$ y $E = \{x_1, \dots, x_k\}$ un conjunto de puntos en $[a,b]$, entonces existe el mejor polinomio aproximador π_n^k de grado $\leq n$, p_n^k el cual minimiza

$$\max_{0 \leq i \leq k} |F(x_i) - p(x_i)| \quad 3.51$$

sobre todos los polinomios de grado $\leq n$.

El mensaje de los Teoremas puede resumirse diciendo que los polinomios son densos en el espacio de las funciones continuas. Lo mismo puede decirse se las funciones trigonométricas.

Estructura SIAN

Considere un tipo de sistema difuso del tipo Sugeno teniendo la base de reglas

1. Si x es A_1 y y es B_1 , entonces $f_1 = p_1x + q_1y + r_1$
2. Si x es A_2 y y es B_2 , entonces $f_2 = p_2x + q_2y + r_2$

Permita a las funciones de membresía de los conjuntos difusos $A_i, B_i, i=1,2$, ser μ_{A_i}, μ_{B_i} .

En la evaluación de las reglas, escoja el *producto* para la T-norma (unión lógica y).

1. Evaluar los resultados de las premisas de las reglas en

$$w_i = \mu_{A_i}(x) \mu_{B_i}(y), i = 1, 2. \quad 3.52$$

2. Evaluar la implicación y las consecuencias de las reglas genera

$$f(x, y) = \frac{w_1(x, y)f_1(x, y) + w_2(x, y)f_2(x, y)}{w_1(x, y) + w_2(x, y)} \quad 3.53$$

o dejando los argumentos fuera

$$f = \frac{w_1 f_1 + w_2 f_2}{w_1 + w_2} \quad 3.54$$

Esto puede ser separado en fases por medio de la definición de

$$\bar{w}_1 = \frac{w_1}{w_1 + w_2} \quad 3.55$$

Entonces f puede ser escrita como

$$f = \bar{w}_1 f_1 + \bar{w}_2 f_2 \quad 3.56$$

4. Técnicas de Análisis de Series de Tiempo

El análisis inteligente de sistemas (extracción de conclusiones valiosas acerca de su comportamiento) requiere del uso de series de tiempo de datos medidos con sensores. Si el sistema es lineal, una gran cantidad de técnicas bien establecidas están a disposición del analista. En el caso de los fenómenos no lineales, el análisis resulta más complejo e involucra otros campos del conocimiento. El problema se complica aún más debido a la condición simultánea de abundancia y escasez de datos: megabytes de información que describen un parámetro y la imposibilidad de medir otras variables importantes en la descripción e interpretación del fenómeno.

Para aclarar lo anterior, revisemos el ejemplo de la Fig. 4.1 que muestra un sistema mecánico masa-resorte y dos conjuntos de series de tiempo obtenidos de sensores que miden la posición y la velocidad de la masa. Un sistema como este puede considerarse lineal: responde en proporción a los cambios. Pero cuando se trata del movimiento pendular, el sistema reacciona de manera no lineal: si la masa es jalada un *poco*, el movimiento forzado tendrá un *pequeño* efecto sobre la posición de la masa, pero si es excitada de tal forma que se balancee hasta una posición invertida (referencia el punto de reposo), *mínimas desviaciones* en las condiciones iniciales (ángulo de aplicación de la fuerza, por ejemplo) tendrán *grandes efectos* en su respuesta.

Esta distinción es de suma importancia en la ciencia en general y en el análisis de datos en particular. Si el sistema bajo estudio es lineal, uno puede caracterizar los datos usando estadística (media, desviación estándar, etc.), ajustar curvas a ellos (aproximación de funciones) y realizar gráficas que permitan entender su comportamiento. Si se requiere un análisis más detallado, el comportamiento del sistema lineal puede ser representado por medio de un esquema *entrada + función de transferencia* \rightarrow *salida* usando algún modelo que trabaje en el dominio del tiempo o en el de la frecuencia.

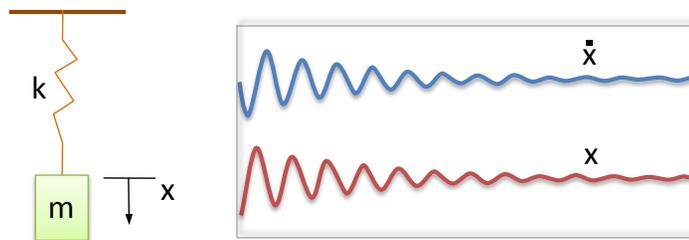


Figura 4.1 Sistema masa-resorte (desplazamiento y velocidad de la masa)

Los sistemas no lineales, por su parte, presentan tan diversos comportamientos que las operaciones de procesamiento tradicionales resultan inútiles. Esta clase de fenómenos no se pueden descomponer de la manera estándar (*entrada + función de transferencia* \rightarrow *salida*) ni se puede simplemente pasar un filtro para limpiar la señal de ruido y manipularla como proveniente de un sistema de comportamiento más simple. Además, el concepto de conjunto discreto de componentes espectrales no tiene sentido en muchos problemas no lineales por lo que usar transformadas para llevarlos del dominio del tiempo al dominio de la frecuencia es inoperante.

Otra complicación en el análisis no lineal es el acceso a suficiente información para describir completamente el sistema. En la mayoría de esta clase de sistemas en la naturaleza, las variables de estado son inaccesibles físicamente, no existen sensores adecuados para medirlas, o peor aún, las *verdaderas* variables de estado no se conocen. La identificación de comportamientos en el caso de sistemas *controlados* (aquellos donde se cuenta con datos *acción* \rightarrow *reacción*) es directa pero en la mayoría de los sistemas naturales (o algunos construidos por el hombre con materiales naturales) la información disponible para su análisis es parcial. Lo único con lo que se cuenta son mediciones de respuestas a eventos dudosamente definidos (el control de las entradas no es posible y prácticamente son desconocidas) por lo que el cuestionamiento de si se puede llegar a identificar un sistema de este tipo (establecer la estructuración matemática, los parámetros funcionales, la categorización de comportamientos, etc) es una pregunta abierta.

Resulta evidente que, bajo estas condiciones, solamente será posible alcanzar un cierto conocimiento general del proceso que subyace en las conexiones expuestas por los datos disponibles (Bendat 1990; Priestly 1988; Tong 1990; Kantz y Schreiber 1997). El manejo eficiente de este argumento resulta clave en cualquier estudio empírico cuya finalidad sea *modelar* (predecir, validar teorías, describir fenómenos, sugerir nuevas hipótesis y delimitar el aprendizaje). Conforme las computadoras abren la puerta a diversas aproximaciones, nuevos conjuntos de hipótesis deben ser probados, nuevos códigos deben ser generados, mejores metodologías deberían ser desarrolladas y la relación entre la complejidad de los datos y las técnicas usadas para modelarlos debe guardar un mejor equilibrio dentro de los modelos científicos.

Los sistemas geosísmicos, raramente pasivos, tienen entradas (parcialmente definidas) y salidas (contienen un alto grado de ruido, esto es, una componente estocástica muy grande) y las relaciones establecidas entre ellas resultan mayormente de aproximaciones empíricas. A partir de lo anteriormente expuesto, el análisis de estos sistemas, usando series de tiempo, debe ser estudiado teniendo en cuenta: i) que no es posible mostrar explícitamente el proceso detrás de los datos y ii) que a través de las teorías lineales es ineficiente inferir información de los datos.

En nuestro empeño de generar modelos con series de tiempo sísmicas que sean suficientemente buenos para ser usados en predicción, los métodos de caracterización y análisis provenientes de la teoría dinámica no lineal resultan muy atractivos en la caracterización de las series y en la inferencia de comportamientos futuros basados en los registros de aceleraciones.

El objetivo del siguiente apartado es presentar las bases conceptuales de los análisis clásicos y avanzados de series de tiempo. La importancia de esta revisión radica en que el mundo matemático es un concepto muy abstracto y muchas veces no es del todo claro cómo una idea o teorema nos acerca al mundo, siendo la tendencia sobrevalorar la aplicación de las matemáticas donde no existe una conexión real. Además se incluye una breve explicación sobre una teoría matemática (Teoría del Caos) que ofrece al analista (cualquiera que sea su rama de estudio) medios para el manejo más eficiente de información y la posibilidad de modificar su visión matemática de los fenómenos que le conciernen, de manera que la observación y el análisis le resulten más provechosos.

El viejo paradigma

En el desarrollo de las ciencias clásicas y las matemáticas varios son los axiomas que han afectado nuestro pensamiento y se han convertido en parte del paradigma científico que prevalece hasta nuestros días:

Determinismo- el conocimiento completo del estado actual de un sistema genera una completa capacidad para enunciar comportamientos pasados y predecir futuros

Linealidad- los modelos estándar lineales son suficientes para definir el ambiente que nos rodea

Reduccionismo- un sistema complejo puede ser analizado eficientemente en términos de sus partes constitutivas

Complejidad- problemas complejos deben tener soluciones complejas

Aleatoriedad- fenómenos que tengan apariencia aleatoria no tiene patrones naturales distinguibles.

Desde muchos puntos de vista, la ciencia clásica puede ser vista como la búsqueda de la certidumbre. El paradigma Cartesiano-Newtoniano establece que el mundo físico está hecho de entidades básicas con distintas propiedades que las distinguen unas de otras, separando y reduciendo el mundo físico a sus entidades básicas puede obtenerse un universo completamente predecible y por lo tanto controlable.

“Este universo es gobernado por leyes inmutables y sus patrones de comportamiento son semejantes a los de una enorme máquina” (De Jong, 1990). Los límites en este enfoque de estudio resultan obvios así que la ciencia moderna ha virado la tendencia hacia herramientas menos restrictivas como la Teoría del Caos, la cual puede ser vista como el siguiente paso en la búsqueda científica por la certeza.

¿Qué es el Caos?

El Caos (en un sentido teórico matemático) es muy difícil de definir. No existe ninguna definición de Caos matemáticamente aceptada y numerosas discusiones, en términos filosóficos, se han establecido sobre el hecho de si pudiera existir alguna (Davis, 1994). Para los propósitos de esta investigación lo que se requiere es sólo aclarar los conceptos *sistema dinámico* y *sensibilidad a condiciones iniciales*.

Para un científico un *sistema* es una colección de objetos que están interrelacionados. Ejemplos de sistemas son: la población de conejos, el sistema solar, los sismos en una región. Un *sistema matemático* es aquel en que sus características sobresalientes pueden ser cuantificadas matemáticamente en términos de variables. Un conjunto particular de valores para las variables de este tipo de sistemas es llamado un *estado* del sistema. Un *sistema dinámico* cambia en el tiempo y se define comúnmente por medio de un *estado inicial* y las *reglas* (conjunto de ecuaciones) para cambiar de *estado* en algún tiempo (futuro o pasado).

Un ejemplo de sistema dinámico (May y Ester, 1976) es la población de algunas especies de pescados que se define con una sola regla: la ecuación logística $x_{t+1} = r(x_t - x_t^2)$, una ecuación no lineal debido al término x_t^2 . Siendo x la fracción de la población máxima posible de peces y x_t la fracción de la población en el tiempo t . Aquí el tiempo puede sólo ser discreto en cantidades como 0, 1,2, por lo que ésta es una ecuación de diferencia del sistema dinámico. Un valor inicial, x_0 , es elegido y sustituido dentro de la regla para calcular x_1 . El proceso se repite y los valores x_2, x_3, \dots son calculados.

El símbolo r es un parámetro que determina algún tipo de crecimiento o factor de ajuste (supervivencia). Para una población particular de peces el valor del parámetro r permanece constante pero para diferentes poblaciones de peces debería tener diferentes valores. En contraste, la variable x_t cambia en el tiempo para cada población. Un objetivo de la teoría del caos es estudiar cómo el valor de r afecta el comportamiento de la dinámica de la población en el tiempo.

El lector interesado puede desarrollar los cálculos con esta ecuación logística (o verificar en la literatura sobre Caos los exhaustivos análisis de la ecuación de Mandelbrot $x_{t+1} = x_t^2 + c$, la cual presenta exactamente la misma dinámica) y descubrir qué tan complicado este simple sistema puede llegar a ser. Aquí sólo se apuntarán algunos detalles que se consideran útiles para el alcanzar el objetivo de esta sección.

Por ejemplo, si el parámetro r es 2.1, entonces la población pronto decrecerá hacia un valor estable de población de aproximadamente 0.52, no importa el valor de la población de arranque (tanto como sea estrictamente entre 0 y 1). Si el parámetro cae por debajo del 1 la población se extingue. Dentro de este rango la población final alcanza un valor fijo. Todo parece estar progresando de manera predecible hasta que el parámetro rebasa el 3. Repentinamente la población final no decae hacia un valor único sino que oscila entre dos valores durante todo un año. Como el parámetro se incrementa cada dos años, el ciclo continúa pero los valores bajos y altos se mueven alejándose. Un incremento mayor del parámetro hace que repentinamente la población se mueva de un ciclo de 2 hacia uno de 4. Estas divisiones desde un valor único a un ciclo de 2 y después a uno de 4 son llamadas *bifurcaciones*. Conforme el parámetro se incrementa, estas bifurcaciones se dirigen más rápidamente hacia los ciclos 4,8,16, ..., etc. En un cierto punto toda la periodicidad parece desaparecer y la población comienza a fluctuar de manera muy complicada y aparentemente aleatoria, que ha sido llamada caótica. Sin embargo, conforme el parámetro se incrementa y atraviesa esta región caótica, la población comienza otra vez a regularse y baja hacia un periodo impar (alrededor del 5to ciclo).

Sensibilidad a condiciones iniciales

Existen varios aspectos del caos que están bellamente ilustrados por la ecuación logística. Para ciertos valores del parámetro r la población tiende a un comportamiento periódico. Para otros valores la población nunca se aproxima a un comportamiento periódico. Los valores de r que no llevan a poblaciones periódicas son llamados la región caótica y se dice que el sistema exhibe caos (en el sentido matemático) sólo en esta región.

La región caótica de la ecuación logística se compone de sub-regiones no caóticas llamadas ventanas periódicas. Si uno observa muy cercanamente dentro de estas ventanas periódicas existen bifurcaciones dobles periódicas que producen una sub-región caótica más pequeña. Esta sub-región más pequeña tiene todavía ventanas de periodicidad aún más pequeñas. Cuando alguna porción de esta sub-región es magnificada, la región pequeña presenta comportamiento muy similar al de la región total. Esta propiedad de sub-regiones entre regiones sucede en cada posible magnificación. La propiedad de similitud en cada nivel de escala es un sello en los sistemas caóticos. Un sistema caótico no puede ser estudiado descomponiéndolo en pequeñas piezas ya que cada pieza será tan complicada en su detalle como lo es el sistema completo. Por esta razón la teoría del caos es inherentemente anti-reduccionista y por lo tanto es reconocida como una teoría holística.

Dentro de la región caótica de la ecuación logística la población fluctúa de manera impredecible. Sin embargo, si la población se grafica para muchas generaciones el patrón emerge. Los puntos de población se agruparán en algunas zonas y podrían desaparecer completamente en otras (llamados *atractores extraños* y son ejemplos de objetos geométricos conocidos como *fractales*).

En la región periódica de la ecuación logística la población decrece hacia el mismo valor independientemente del valor de inicio. En la región caótica la situación es muy diferente: dos valores de arranque diferentes pueden llevar a resultados completamente distintos (incluso para longitud de tiempo infinita) aún con inicios extraordinariamente cercanos. Esto es lo que se conoce como *sensibilidad a condiciones iniciales*.

El Caos contra una visión lineal del mundo

El método Cartesiano-Newtoniano propone, como primer método de estudio, reducir un sistema físico a un sistema de ecuaciones y después resolverlas para determinar comportamientos. La antigua revolución en el pensamiento científico culminó en el legado de Newton de la visión del universo como un gigantesco mecanismo donde bajo condiciones de ambiente idénticas se apreciarán comportamientos de respuesta idénticos. Un ingeniero que conoce las especificaciones de la máquina o de los materiales con los que trabaja y el estado que éstos guardan en cualquier momento puede, en principio, manejarlo precisamente en cualquier instante de tiempo (Stewart, 1989).

Ciertamente esta ha sido una aproximación muy productiva para la ciencia en los últimos 300 años. En un universo *máquina* parece no haber lugar para el caos y la dependencia en condiciones iniciales, ¿por qué entonces esta aproximación Newtoniana ha sido tan efectiva por tanto tiempo? Y ¿por qué tomó tanto tiempo descubrir el caos?

La respuesta es, por supuesto, compleja pero una gran parte de ella es que hasta la mitad del siglo XX los matemáticos y los físicos se concentraron en estudiar sólo sistemas dinámicos lineales. Los científicos apoyados en matemáticas clásicas se concentran en ajustar el mundo a comportamientos lineales por una razón pragmática: no pueden resolver nada más con este tipo de planteamientos.

Caos y Determinismo

Incluso los sistemas lineales bajo la perspectiva Cartesiana-Newtoniana han sido siempre ambiciosos matemáticamente -las ecuaciones son usualmente muy difíciles de resolver. El *sueño* de completa predictabilidad para cualquier sistema complejo ha sido siempre más un *ideal* que una *realidad* práctica. Ahora comprendemos, a partir de la teoría del caos, que la predicción total ha sido siempre una falsa meta. Los sistemas no lineales tienen una limitación inherente a partir de que, en la región caótica, la exactitud absoluta es necesaria para predicciones útiles. Algunos sistemas podrían manifestar una mezcla de comportamientos predecibles y no predecibles (Kellert, 1993).

Una de las pruebas para la *buena* investigación científica es la *repetibilidad*. En el paradigma Cartesiano-Newtoniano decir que se puede *explicar* un evento comúnmente significa que podemos predecirlo. Si las únicas alternativas en el determinismo para concluir sobre fenómenos muy complejos es la aleatoriedad, entonces este determinismo es atractivo como una verdad *a priori* o una pregunta científica de metodología imperativa (Earman, 1986).

El caos ha dado otra opinión a esta dicotomía. Kellert (1993) apunta que el término determinismo puede ser visto en por lo menos cuatro formas y las enlista en el siguiente orden, desde la más simple y menos restrictiva hasta la más robusta y completa:

Ecuaciones diferenciales o de diferencias a partir de un modelo correcto del sistema.

Evolución única, es decir, la evolución del sistema se fija una vez que nosotros especificamos el estado del sistema en cualquier momento.

La determinación de valores (como atributo).

Predictibilidad total (lo que sea que esto signifique, se recomienda la discusión sobre el significado de *predicción* en Davis, 1994).

El caos nos ha obligado a reconsiderar tres de los cuatro significados de Kellert para decidir sobre el determinismo dentro de un sistema. La visión más simple, que es la de los modelos con ecuaciones de diferencia o con ecuaciones diferenciales, es la más usada pero debe tenerse en cuenta cuando se usa y construyen modelos de sistemas dinámicos a partir de estas ecuaciones que: i) el comportamiento del sistema no puede ser estudiado por reducción en partes, ii) los resultados no son pruebas descriptivas y iii) los sistemas no pueden ser estudiados si las descripciones son instantáneas.

Una opinión personal...

Es justo preguntarse si la teoría del *caos* es una moda, camina en dirección de una teoría matemática de la catástrofe o se convierte más en una religión/creencia que en una teoría formal. ¿El *caos* revolucionará la ciencia?. Las respuestas a estos cuestionamientos las dará el tiempo, pero de lo que sí estoy convencida es de que matemáticamente la teoría del caos es válida, importante, está presente y significativamente cambiará la manera en la que se estudia la naturaleza.

El *caos* no elimina la predicción, el *caos* se concentra en el hecho de qué clase de predicción es posible y cuáles son los límites de nuestras predicciones. El *caos* nos ayuda a enfocarnos en aspectos básicos importantes y notables que han sido despreciados por nuestra limitación teórico-práctica. En este trabajo de tesis se postula a la teoría del caos como la herramienta que nos ayuda en la búsqueda del orden, de la armonía, en la búsqueda que nos conduce a *conceptos generales* más que a leyes.

"... son los modelos, no las leyes, los que forman el corazón de la ciencia..."

(Kellert, 1993).

4.1. Mapas de Recurrencia

Dentro de la sismología existen dos aspectos que han sido motivo de exhaustivas investigaciones y aún se consideran problemas que deben ser resueltos. Uno de ellos involucra el uso de ciertas hipótesis (por lo general restrictivas) acerca de la naturaleza de la fuente de vibración. El segundo se refiere a la selección de los métodos apropiados para estudiar las señales que expresan movimientos de terreno (procesos no-estacionarios). La sugerencia de algunos investigadores sobre la no linealidad involucrada en la generación sísmica y la respuesta del suelo (García et al., 2003; Huang y Turcotte, 1990a, 1990b, entre otros) alerta sobre una reconsideración de los métodos y técnicas involucradas en su análisis. En esta investigación se propone el uso de los Mapas de Recurrencia MR como herramienta alternativa para evitar las *suposiciones* y para enmarcar a los estudios sísmicos en un contexto *no estacionario*.

La dinámica de sistemas *reales* se caracteriza por un cierto número de *estados* coexistiendo y por la presencia de *fluctuaciones*. La evolución a largo plazo de estos sistemas está dominada por las transiciones entre estos diferentes estados (Luchinsky et al., 1998; Feudal y Gregobi, 1997). Sistemas de este tipo son imposibles de resolver analíticamente y simplificarlos hacia sistemas lineales para hacerlos objeto de estudio de herramientas como transformaciones de Laplace o argumentos de superposición (análisis de Fourier) es obviar las partes del sistema que interfieren, cooperan, compiten o interactúan de maneras muy complejas.

El propósito de esta sección es presentar las condiciones básicas que permitan la aplicación de la Teoría de Sistemas Dinámicos en el estudio de la respuesta sísmica de depósitos de suelo blando. Esta breve discusión no se concentra en las ideas "puras" sobre el caos sino en la descripción de técnicas de análisis geométrico (topológico), en particular los MR (Eckman et al., 1987), para determinar patrones de comportamiento en los movimientos registrados en la ciudad de México. Sin el uso de hipótesis drásticas ni desechando aspectos *naturales*, los MR permiten extraer información relevante a partir de un análisis inverso: dada una respuesta monitoreada se dibujan sus *trayectorias* en *espacios* convenientes y a partir de ellas se encuentran las soluciones geométricas sin resolver las ecuaciones que gobiernan al propio sistema.

Cartas de comportamiento de procesos

La teoría del caos se concentra en la caracterización de los fenómenos complejos. Por ejemplo, el balanceo de un péndulo está gobernado por la ecuación

$$\ddot{x} + \frac{g}{L} \sin x = 0$$

4.1

donde x es el ángulo que forma el péndulo con la vertical, g es la aceleración debida a la gravedad y L es la longitud del péndulo. La no linealidad hace que la ecuación del péndulo sea muy difícil de resolver analíticamente. Comúnmente para ángulos pequeños se invoca la aproximación $\sin x \approx x$ para $x \ll 1$. Esto transforma el problema en uno lineal y puede ser resuelto fácilmente. Pero restringiendo el valor de x a valores muy pequeños se están despreciando los movimientos donde el péndulo puede girar incluso sobre su punto de sujeción. Una manera de extraer información usando mediciones del comportamiento del sistema es a través de métodos geométricos.

Suponga una solución al sistema del péndulo para una condición inicial particular $x_1(t)$ y $x_2(t)$ (posición y velocidad). Si se construye un espacio abstracto con coordenadas (x_1, x_2) , entonces la solución $(x_1(t), x_2(t))$ corresponde a un punto moviéndose a lo largo de una curva llamada *trayectoria* y el espacio se conoce como *espacio de fase* del sistema (Fig. 4.1). Este tipo de cartas son una descripción empírica de la posibilidad de predicción en una serie de tiempo y el hecho de no imponer un cierto modelo a los datos expuestos hace que no se vean afectadas por el paradigma usado en la explicación de las observaciones.

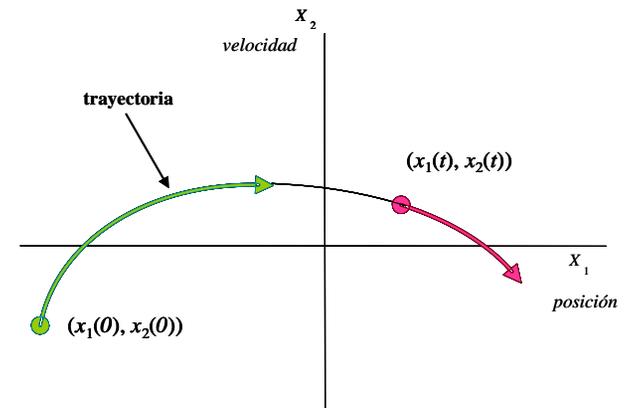


Figura 4.1 Espacio de fase

Representación del Espacio de Fase

Los sistemas dinámicos se describen a través de su evolución (lo que involucra al *tiempo*) en algún *espacio de fase* $\Gamma \subset \mathbb{R}^d$. Pueden ser expresados, por ejemplo, con ecuaciones diferenciales ordinarias

$$\dot{x}(t) = F(x(t)), \quad 4.2$$

o en tiempo discreto $t = n\Delta t$ por medio de mapas de la forma

$$x_{n+1} = f(x_n) \quad 4.3$$

Una serie de tiempo puede ser vista como una secuencia de observaciones $\{\delta_n = \delta(x_n)\}$ realizadas a través de una función de medición $\delta(\cdot)$. Ya que la secuencia $\{\delta_n\}$ (usualmente escalar) no representa adecuadamente el *espacio de fase* (multidimensional) del sistema dinámico, deben ser empleadas algunas técnicas para descubrir la estructura multidimensional usando sólo los datos disponibles. La técnica de reconstrucción más empleada es el *método del retraso*.

Los vectores en un nuevo espacio, el *espacio embebido*, se forman a partir de los valores retrasados en el tiempo de las mediciones escalares originales $\delta_n = (\delta_{n-(m-1)\tau}, \delta_{n-(m-2)\tau}, \dots, \delta_n)$. El número m se llama *dimensión embebida*. El tiempo τ es generalmente referido como el *retraso*. Los conocidos teoremas de Takens (1981) y Sauer (Sauer et al., 1991) establecen que si la secuencia $\{\delta_n\}$ son mediciones escalares del *estado* de un sistema dinámico, entonces -bajo ciertas hipótesis- el retraso genera una imagen uno-a-uno del conjunto original $\{x\}$, siempre y cuando m sea suficientemente grande. La implementación es directa y no requiere mayor explicación. Si N mediciones escalares están disponibles, el número de vectores embebidos es $N - (m - 1)d$.

Existen diversos trabajos acerca de la elección de m y d , una conclusión general es que la elección de los valores óptimos depende solamente del tipo de aplicación. En esta investigación se usa el método de información recíproca (*mutual information*; Fraser y Swinney, 1986; Palus, 1995) e inspecciones visuales de representaciones con varios valores de retraso para concluir sobre el tiempo de retraso ideal para esta aplicación. Por otro lado, después de varios análisis empíricos se determinó que el método estadístico de los *falsos vecinos* (*false neighbors*; Kennel et al., 1992) es una buena guía para elegir el valor de la dimensión embebida. Para los lectores interesados en este tema se sugiere Hegger et al., (1999).

Definiciones básicas

Los Mapas de Recurrencia MR son una herramienta para la interpretación cualitativa de series de tiempo que permiten detectar gráficamente patrones ocultos y cambios estructurales en los datos (Eckmann, et al., 1987).

Un MR es una representación bi-dimensional de una trayectoria individual que conserva la dependencia temporal y espacial de la serie de tiempo original. Las series de tiempo se expanden hacia las ordenadas y las abscisas y cada punto (i,j) en el plano es coloreado de acuerdo a la distancia entre dos puntos de trayectoria y_i y y_j . Existen MR "sin frontera" donde el píxel en la posición (i,j) se codifica a color de acuerdo con un valor de distancia, mientras que en un MR "con frontera" el píxel (i,j) es negro si la separación está dentro de una franja de valores específica y es blanco cuando la distancia tiene cualquier otro valor. Por ejemplo, para un MR "sin frontera", si el punto 117 en una trayectoria está a 14 unidades de distancia del punto 9435, el píxel en la posición $(117, 9435)$ tendrá el color que corresponda al valor de espaciamiento igual a 14. El punto $(9435,117)$ se colorea de manera similar aunque los MR no son necesariamente simétricos (Eckmann, et al., 1987).

La Fig.4.2 muestra tres MR sin frontera (en lo sucesivo las siglas MR se refieren sólo a mapas de este tipo) generados a partir de diferentes conjuntos de datos: una serie de tiempo derivada del muestreo de la función $sen(t)$, una serie de tiempo del sistema Lorenz y la representación del ruido. El color en estos gráficos va desde amarillos-blanco para espaciamientos muy pequeños hasta azules-negro para distancias muy grandes, como se muestra en las barras de calibración de la Fig. 4.2.

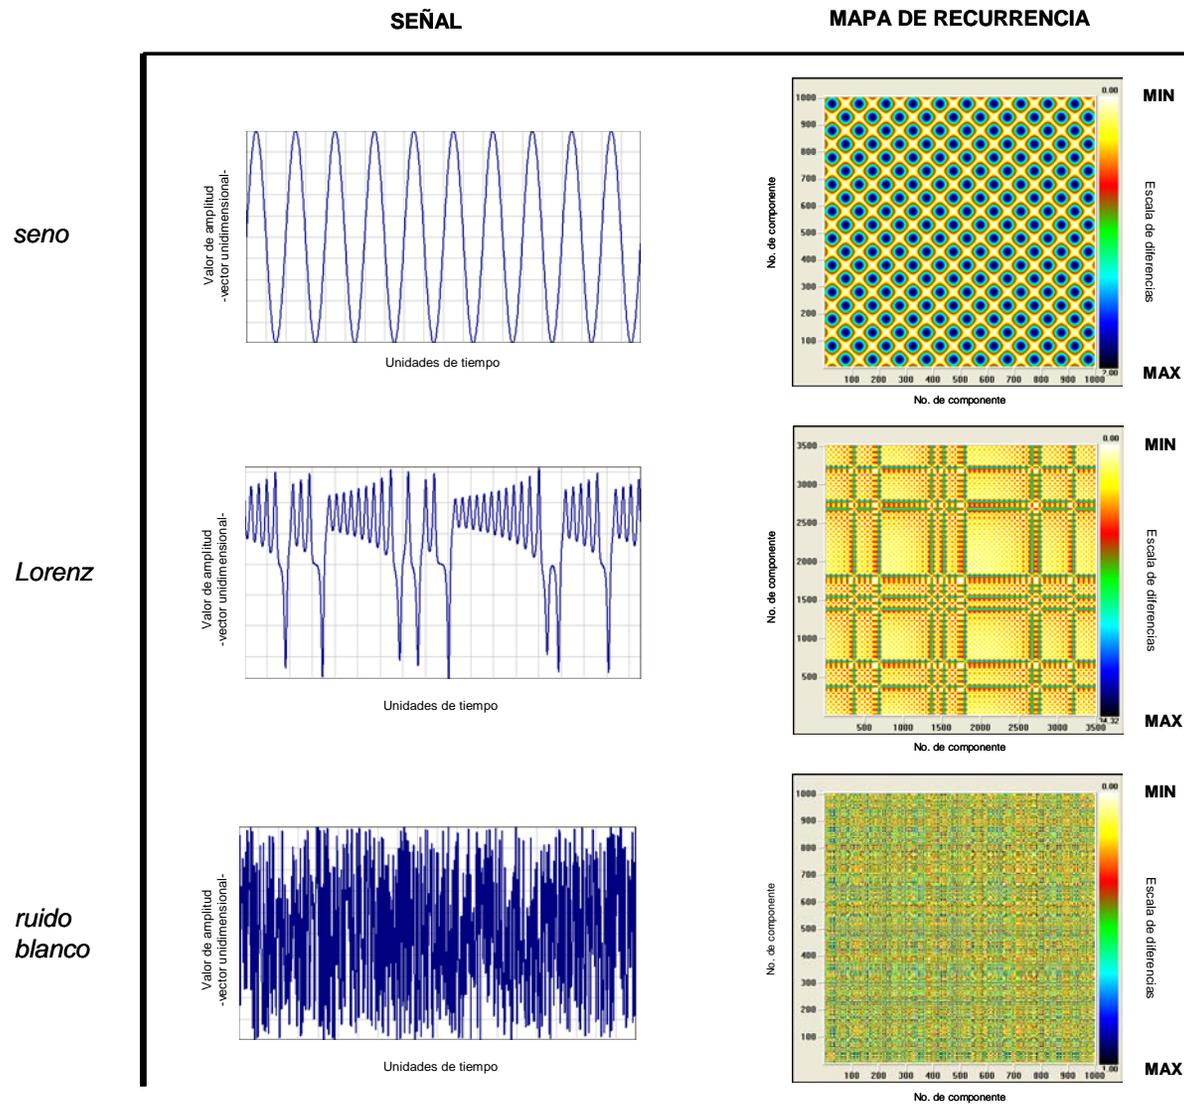


Figura 4.2. Ejemplos de mapas de recurrencia para sistemas deterministas, caóticos y aleatorios.

El MR de la onda seno es relativamente fácil de comprender; cada uno de los bloques de color representa la mitad del periodo de la señal (el sombreado del punto (w,v) en este gráfico refleja la distancia entre $sen w$ y $sen v$; si $w - v = \pi/2$, por ejemplo, la distancia es grande). El MR de Lorenz, que representa un conjunto de datos caóticos, es más complicado a pesar de tener una apariencia estructurada (bloques semejantes a los de la señal periódica). Esta señal, se sabe, no es periódica, por lo que los elementos estructurales repetidos deben ser explicados y clasificados comparándolos con las geometrías correspondientes al ruido blanco, señal que representa el comportamiento aleatorio y el extremo en estructuración nula.

Con estos sencillos ejemplos se observa que los MR son visualmente llamativos, favorables en la búsqueda de correlaciones ocultas en datos altamente complicados, no demandan la estacionalidad en las series de tiempo y son particularmente útiles en el análisis de sistemas cuya dinámica podría estar cambiando. La aplicación de MR en esta investigación responde a la necesidad de encontrar un significado a las aparentes relaciones expuestas en los registros de movimientos de terreno (por lo menos en su expresión en el dominio de la frecuencia). Con el uso de los MR y sus estructuras dependientes de tipos de comportamiento, se intenta responder a los cuestionamientos sobre la mecánica del fenómeno sísmico sin involucrar el uso de funcionales prohibitivos.

Los trabajos previos a este respecto están orientados hacia aplicaciones muy concretas y los resultados cuantitativos están sesgados. En esta propuesta metodológica se pretende extender, formalizar y sistematizar el manejo de MR con el propósito de encontrar propiedades cualitativas y cuantitativas útiles en la práctica ingenieril.

Construyendo un MR

En esta sección se apuntan brevemente algunos aspectos básicos de los MR y se describe cómo se genera un MR a partir de un conjunto de datos experimentales. El primer paso en el procedimiento estándar es reconstruir la dinámica por medio de embeber la serie de tiempo uni-dimensional en el espacio de reconstrucción d_E -dimensional usando el método del retraso de coordenadas.

Dado un sistema cuya dimensión topológica sea d , el muestreo de una variable de estado individual es equivalente a proyectar la dinámica del espacio de fase d -dimensional hacia uno de los ejes. *Embeber* es similar a describir esas dinámicas pero en diferentes ejes. El Teorema de Takens garantiza que la dinámica reconstruida, si está propiamente embebida, es equivalente a la dinámica del verdadero sistema detrás de los datos, en el sentido que los invariantes dinámicos (dimensiones generalizadas y el espectro de Lyapunov (explicar brevemente esto), por ejemplo) son idénticos (Packard et al., 1980; Takens, 1981).

El proceso correcto para *embeber* es sujeto de numerosos trabajos en la literatura lo que ha generado gran cantidad de argumentos y algoritmos heurísticos para su determinación (Abardanel, 1995). Dentro de este proceso el problema básico es la elección de dos parámetros (el retraso y la

dimensión del espacio de reconstrucción) que garanticen el correcto embebimiento de los datos. Ésta es una tarea difícil porque en general no se tiene conocimiento *a priori* del valor óptimo de d ; se cuenta únicamente con una serie de tiempo uni-dimensional y a partir de ella se pretende aprender lo más posible acerca del sistema que generó los datos.

Embebimiento de Coordenadas Retrasadas

Para reconstruir una dinámica se debe contar con los datos experimentales en forma de serie:

$$\{x_1, x_2, \dots, x_N\} \quad 4.4$$

La reconstrucción de las coordenadas retrasadas del posible *espacio de fase* dinámico multidimensional a partir de la variable única observable x está gobernada por dos parámetros, dimensión de embebimiento d_E (llamada m en algunos textos técnicos) y tiempo de retraso τ . La trayectoria resultante en R^{d_E} es:

$$\{y_1, y_2, \dots, y_M\} \quad 4.5$$

donde $m = N - (d_E - 1)\tau$ y $y_k = (x_k, x_{k+\tau}, x_{k+2\tau}, \dots, x_{k+(d_E-1)\tau})$ para $k=1,2,\dots,m$. Note que usando $d_E = 1$ se regresa a la serie original; embebimiento uni-dimensión es equivalente a no embeber. Una elección adecuada de d_E y τ es crítica en este tipo de reconstrucción y debe realizarse con inteligencia; sólo valores "correctos" de estos dos parámetros generan embebimientos que garantizan ser topológicamente equivalentes a la dinámica del *espacio de fase* original (no observado) (Packard et al., 1980; Takens, 1981; Sauer et al., 1991).

Asumiendo que el embebimiento de coordenadas retrasadas es correcto, se asume que un MR de una trayectoria reconstruida presenta gran similitud con el MR de su verdadera dinámica. Más aún, se espera que cualquier propiedad de la trayectoria reconstruida inferida a partir de este MR sea propia del *verdadero* sistema. Debido a esta cualidad de los MR, distintos sistemas han sido estudiados bajo la misma perspectiva de análisis, lo que ha originado que muchas áreas del conocimiento se vean beneficiadas de esta simple y efectiva metodología (Fig. 4.3).

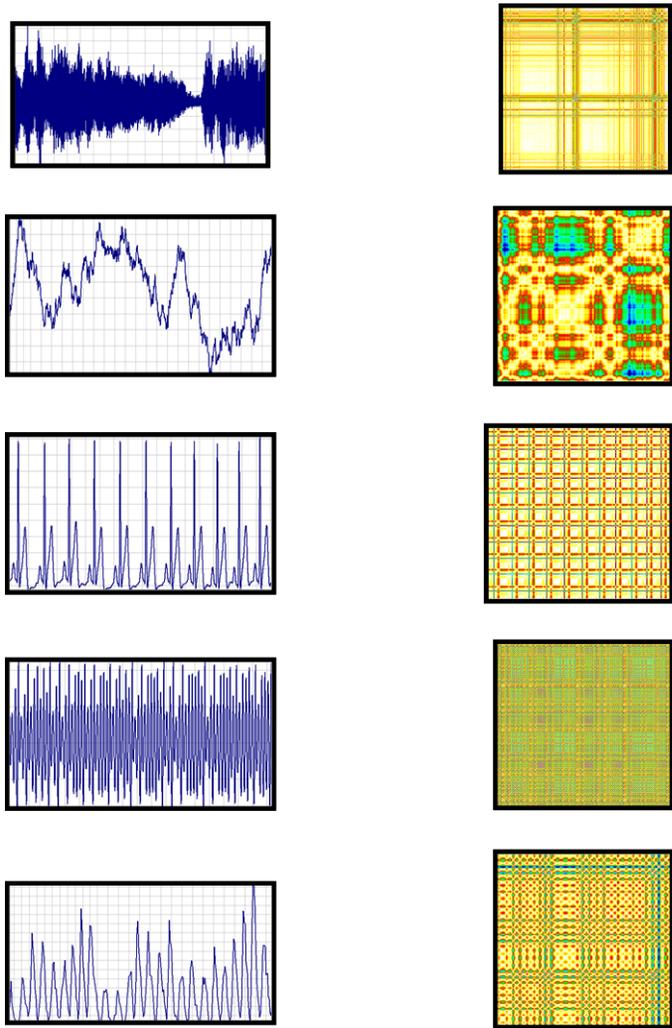


Figura 4.3. Aplicaciones en diferentes campos del conocimiento

Cálculo de las distancias

Los MR están basados en las distancias entre puntos en una trayectoria por lo que un paso muy importante en su construcción es la elección de la norma D . En este trabajo de investigación se usa la máxima norma (en uni-dimensión la máxima norma es equivalente a la p-norma euclidiana) por dos razones: i) su fácil implementación y ii) el hecho de que la máxima distancia que se alcanza en los cálculos de recurrencia (la diferencia entre la medición más grande y la más pequeña en la serie de tiempo) es independiente de la dimensión embebida d_E para esta norma en particular. Esto significa que podemos hacer comparaciones directas entre los MRs generados usando diferentes valores de d_E sin re-escalar los mapas.

Proceso de Construcción: Ejemplo numérico

Para expandir la señal 1D a un espacio de fase de M dimensiones, se sustituye cada observación de la señal original $X(t)$ con el vector $y_i = (x_i, x_{i+d}, x_{i+2d}, \dots, x_{i+(m-1)d})$ donde i es el índice del tiempo, m es la dimensión a la que se embebe y d es el tiempo de retraso. Como resultado se tiene una serie de vectores $Y = y_1, y_2, y_3, \dots, y_{N(m-1)d}$ donde N es la longitud de la serie original. La idea de la reconstrucción es capturar los estados del sistema original en cada una de las salidas observadas. Cada estado desconocido $S(t)$ en el tiempo, t , se aproxima con un vector de coordenadas retrasadas $Y(t) = \{x_i, x_{i-d}, x_{i-2d}, \dots, x_{i-(m-1)d}\}$.

Ahora, analicemos la serie de tiempo de los precios al cierre de una semana típica en el índice Dow Jones:

9/25/98 8029
 10/2/98 7785
 10/9/98 7900
 10/16/98 8417
 10/23/98 8452
 10/30/98 8592
 11/6/98 8975

...

Si $d=1$ y $m=3$, los vectores reconstruidos se definen como:

$Y(10/9/98) = \{7900, 7785, 8029\}$

$Y(10/16/98) = \{8417, 7900, 7785\}$

$Y(10/23/98) = \{8452, 8417, 7900\}$

...

La distancia Euclidiana entre los vectores $Y(10/9/98)$ y $Y(10/16/98)$ es

$$D(Y(10/9/98), Y(10/16/98)) = [(7900-8417)^2 + (7785-7900)^2 + (8029-7785)^2]^{1/2} = 583$$

Usando un código de color dependiente de la distancia máxima entre vectores, el mapa resultante se presenta en la Fig. 4.4

Este breve resumen intenta sólo cubrir los aspectos básicos de la metodología de construcción de MR, se recomienda al lector interesado en la cuantificación, calificación y determinación de elementos gráficos en caracterización de MR y demás herramientas topológicas para analizar señales, la consulta del Apéndice 4.1.A.

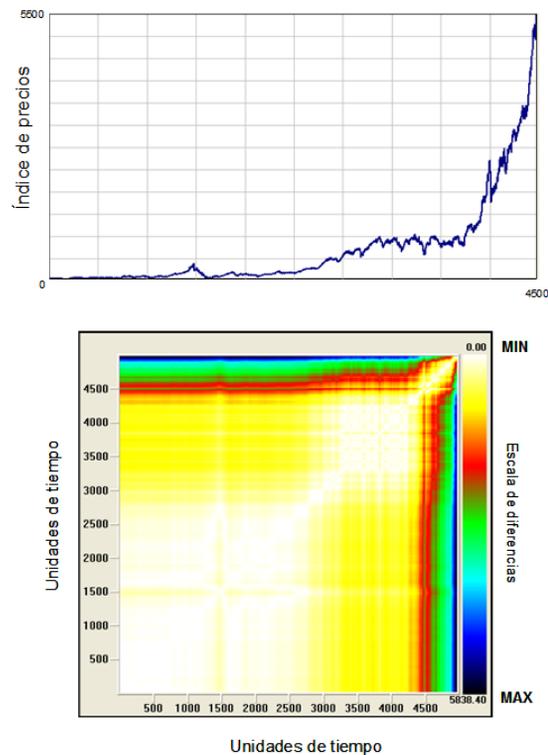


Figura 4.4. Ejemplo de aplicación

4.2. Eigenfaces

Sin duda la habilidad humana para reconocer miles de caras e identificarlas a primera vista, aún con cambios en condiciones de peso, expresión, envejecimiento y distracciones como lentes, barbas, o peinados, es una facultad impresionante. Un modelo computacional que trabaje con estímulos multidimensionales y codifique y/o agrupe imágenes de manera tan eficiente como el cerebro humano es una tarea extremadamente difícil.

Es entonces el reconocimiento de patrones automático uno de los mayores retos en el diseño moderno de sistemas de información. Existen dos tendencias de análisis a este respecto. El primer método está basado en conceptos de la teoría de información, particularmente en el método de análisis de componentes principales. Basados en la expansión de Karhunen-Loeve, siendo M. Kirby y L. Sirovich (Kirby y Sirovich, 1990; Sirovich y Kirby, 1987) los que demostraron que cualquier cara puede ser representada en términos de un sistema de coordenadas eficiente. Poco tiempo después, M. Turk y A. Pentland modifican esta propuesta y establecen el método de reconocimiento de caras *eigenfaces EF* (Turk y Pentland, 1991) considerado como la primera tecnología práctica en el reconocimiento automático de rostros (Velasco, 1998).

Un segundo método propone la extracción de aspectos particulares a partir de partes básicas de la cara: ojos, nariz, boca, y barba. En este método, con la ayuda de plantillas deformables y matemáticas exhaustivas se genera información numérica relevante que conforma un arreglo monumental de vectores característicos (Yuille et al., 1989).

Eigenfaces para reconocimiento

El sistema de reconocimiento EF trabaja con imágenes organizadas en una base de datos. Por medio de la comparación de aspectos comunes y diferencias entre las imágenes individuales, el sistema EF genera un conjunto multi-dimensional de *eigenfaces* organizado bajo un patrón particular.

En lenguaje de teoría de información, EF plantea la extracción de la información relevante en una cara, su codificación de una manera eficiente y la comparación con modelos codificados de manera similar para su identificación. En términos matemáticos, en EF se deben encontrar los componentes principales de las imágenes o *eigenvectores* de la matriz de covarianza de un conjunto de caras, siendo estos *eigenvectores* la representación numérica de las características que describen la variación entre imágenes.

Cada imagen en el archivo de entrenamiento (conjunto de imágenes seleccionadas como representativas) puede ser descrita exactamente en términos de una combinación lineal de *eigenfaces*. El número de *eigenfaces* es igual al número de imágenes en el archivo de entrenamiento. Sin embargo, las caras pueden ser aproximadas usando sólo los mejores *eigenfaces* (aquellos

que tienen los *eigenvalores* más altos) y que participan en mayor medida en la varianza del conjunto de imágenes.

La ventaja más atractiva de EF es su velocidad y eficiencia. Las aplicaciones más exitosas han demostrado que EF reduce 1/1000 veces la cantidad de datos necesaria para identificar a un individuo comparada con el tamaño de la imagen completa (Lau Technologies, 1999).

Conceptos básicos en reconocimiento de patrones

Un *patrón* es la descripción de un *objeto*. De acuerdo con la naturaleza de los patrones a ser reconocidos, la tarea del *reconocimiento* puede ser dividida en dos grandes tipos (González y Tou, 1974):

a) Reconocimiento de aspectos concretos. Se refiere al reconocimiento sensorial e incluye reconocimiento de patrones aural y visual. Es considerado un problema psico-fisiológico que involucra la relación entre la persona y un estímulo físico. Este proceso involucra la identificación y clasificación de patrones temporales y espaciales. Ejemplos de patrones espaciales son los caracteres, huellas digitales, objetos físicos e imágenes. Los patrones temporales incluyen el habla, las series de tiempo, los electrocardiogramas y las firmas.

b) Reconocimiento de aspectos abstractos. Trata con la identificación conceptual donde viejos argumentos o soluciones a problemas resueltos en el pasado pueden ser reconocidos y actualizados.

Clases y Patrones. El reconocimiento de patrones puede ser definido como la categorización de los datos en clases identificables a través de aspectos significantes (derivados de la identificación de detalles irrelevantes).

Una *clase* es una categoría determinada por algunas características o aspectos comunes entre los elementos que la constituyen. Las singularidades de clase son comunes en todos los patrones que agrupa y son referidos como aspectos intra-conjunto. Las características que representan las diferencias entre clases pueden ser referidas como aspectos inter-conjunto.

Un *patrón* es la descripción de cualquier miembro de una clase. Por conveniencia, los patrones se representan con vectores:

$$X = \begin{bmatrix} x_1 \\ x_2 \\ \dots \\ \dots \\ x_n \end{bmatrix}$$

4.6

donde cada elemento x_j representa una característica de ese patrón (X se convierte en un punto en un espacio euclidiano n -dimensional).

El diseño de un sistema automático de reconocimiento de patrones involucra:

1. La representación de los objetos a ser reconocidos a través de las mediciones (problema de detección). Cada cantidad medida describe una característica de un patrón u objeto y forma parte del vector de información. El conjunto de patrones que pertenecen a una misma clase corresponde a un ensamble de puntos cercanos en una región del espacio de características. Un ejemplo simple se muestra en la Figura 4.3 para dos clases de patrones denotados por w_1 y w_2 .
2. La extracción de aspectos o atributos característicos a partir de datos y la reducción de la dimensionalidad de los vectores (problema de pre-procesamiento). Los aspectos intra-conjunto no agregan información discriminatoria y pueden ser ignorados. Si el conjunto completo de aspectos discriminatorios para cada clase puede ser determinado con las mediciones disponibles, el reconocimiento y la clasificación de patrones podría ser reducido a un proceso simple de ajuste (o tabla de apariencias). Sin embargo, en la mayoría de los problemas de reconocimiento prácticos, la determinación de un conjunto completo de aspectos discriminatorios es extremadamente difícil o imposible de conseguir.
3. Los procedimientos de decisión durante la identificación y la clasificación. Después de que los datos han sido expresados en forma de puntos en el espacio de patrones, se requiere que la computadora decida sobre M diferentes clases, en el espacio constituido por M regiones. El problema de reconocimiento se concentra en la generación de las fronteras de decisión que separan las M clases sobre la base de los vectores observados.

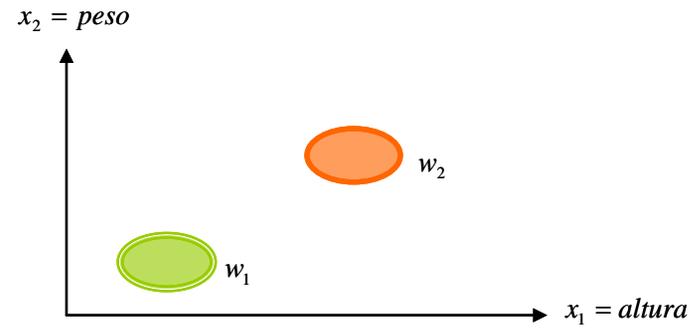


Figura 4.3 Dos clases de patrones. Cada patrón es caracterizado por dos mediciones: altura y peso. El vector del patrón tiene la forma $x = \{x_1, x_2\}^T$

Calculando las eigenfaces

Permita a una imagen $I(x,y)$ ser un arreglo bi-dimensional de $N \times N$ con valores de intensidad de 8-bits. Esta imagen puede ser considerada como un vector de dimensión N^2 por lo que una imagen típica de tamaño 256×256 se convierte en un vector de dimensión 65536, o un punto en un espacio 65536-dimensional.

Las imágenes faciales no se distribuyen aleatoriamente en este enorme espacio (todos los rostros humanos tienen una configuración similar) y por lo tanto pueden ser descritas con un sub-espacio de menor dimensión. La idea básica en el análisis de componentes principales (o la expansión de Karhunen-Loeve) es encontrar los vectores de mayor participación en la distribución de las imágenes dentro del espacio entero.

Estos vectores definen el subespacio de las imágenes faciales, el cual se llama en EF *espacio de caras*. Cada vector es de longitud N^2 (describe una imagen de $N \times N$) y es una combinación lineal de las imágenes faciales originales. Porque estos vectores son los eigenvectores de la matriz de covarianza de las imágenes originales, y porque ellos tienen apariencia de caras, nos referimos a ellos como *eigenfaces*.

Definiciones:

A continuación se detallan aspectos de lenguaje y terminología que serán empleados durante la descripción del algoritmo de evaluación de las eigenfaces.

Una matriz A de $N \times N$ se dice que tiene un eigenvector X y eigenvalor correspondiente λ si

$$AX = \lambda X \quad 4.7$$

Evidentemente, la ec. 4.7 puede sostenerse sólo si

$$\det|A - \lambda I| = 0 \quad 4.8$$

si la ec. 4.7 es expandida, se obtiene un polinomio de grado N -ésimo cuyas raíces son los eigenvalores. Esto prueba que existen siempre N eigenvalores (no necesariamente distintos). Eigenvalores iguales que provienen de las raíces múltiples son llamados "degenerados".

Una matriz es llamada simétrica si es igual a su transpuesta,

$$A = A^T \quad \text{o} \quad a_{ij} = a_{ji} \quad 4.9$$

es llamada ortogonal si su transpuesta es igual a su inversa,

$$A^T A = AA^T = I \quad 4.10$$

y finalmente, es llamada normal si ella conmuta con su transpuesta,

$$AA^T = A^T A \quad 4.12$$

Teorema. Los eigenvalores de una matriz simétrica real son todos reales. Por el contrario, los eigenvalores de una matriz real no-simétrica pueden incluir valores reales, pero podrían incluir pares de valores conjugados complejos. Los eigenvalores de una matriz normal (con eigenvalores no degenerados) son completos y ortogonales, extendiendo el espacio de vectores N -dimensional.

Proceso:

Permita al conjunto de entrenamiento de imágenes de caras ser $\Gamma_1, \Gamma_2, \dots, \Gamma_M$ entonces el promedio del conjunto está definido por

$$\Psi = \frac{1}{M} \sum_{n=1}^M \Gamma_n \quad 4.13$$

Cada cara difiere del promedio por el vector

$$\Phi_i = \Gamma_i - \Psi \quad 4.14$$

a)



b)



Figura 4.4 a) Ejemplo de archivo de entrenamiento (conjunto de caras), b) Promedio de cara del archivo de entrenamiento

Un ejemplo del conjunto de entrenamiento se muestra en la Fig. 4.4(a) y el promedio de caras en la Fig. 4.4(b).

Este conjunto de *enormes* vectores se sujeta al análisis de componentes principales para buscar el conjunto de M vectores ortonormales, u_n , que mejor describa la distribución de los datos. El k -ésimo vector, u_k , se elige de modo que

$$\lambda_k = \frac{1}{M} \sum_{n=1}^M (u_k^T \Phi_n)^2 \quad 4.15$$

sea un máximo, sujeto a

$$u_l^T u_k = \delta_{lk} = \begin{cases} 1 & \text{si } l = k \\ 0 & \text{otro caso} \end{cases} \quad 4.16$$

Los vectores u_k y escalares λ_k son los eigenvectores y eigenvalores, respectivamente de la matriz de covarianza C

$$C = \frac{1}{M} \sum_{n=1}^M \Phi_n \Phi_n^T = AA^T \quad 4.17$$

donde la matriz $A = \{\Phi_1, \Phi_2, \dots, \Phi_n\}$.

La matriz de covarianza C es una matriz simétrica real de $N^2 \times N^2$ y determinar los N^2 eigenvectores y eigenvalores es una tarea impráctica si se toman en cuenta los tamaños típicos de las imágenes. El problema entonces es idear un método computacional que permita, de manera eficiente, encontrar estos eigenvectores.

Si el número de puntos de datos en el espacio de imágenes es menor que la dimensión del espacio ($M < N^2$), entonces habrá sólo $M-1$ en lugar de N^2 eigenvectores significativos. Los eigenvectores remanentes están asociados con eigenvalores iguales a cero. Se puede trabajar para los eigenvectores N^2 -dimensionales, primero resolviendo los eigenvectores de una matriz de $M \times M$ (una matriz de 16×16 en lugar de una de $16,384 \times 16,384$) tomando combinaciones lineales de las imágenes de caras Φ_i .

Considere los eigenvectores v_i de $A^T A$ tal que

$$A^T A v_i = \mu_i v_i \quad 4.18$$

Premultiplicando ambos lados por A tenemos que

$$AA^T A v_i = \mu_i A v_i \quad 4.19$$

de lo que se puede concluir que $A v_i$ son los eigenvectores de $C = AA^T$.

Siguiendo este tipo de análisis, construimos la $M \times M$ -matriz $L = A^T A$, donde $L_{mn} = \Phi_m^T \Phi_n$, y se encuentran los M eigenvectores, v_i de L . Estos vectores determinan combinaciones lineales del M -conjunto de entrenamiento (imágenes faciales) para formar las eigenfaces u_i .

$$u_l = \sum_{k=1}^M v_{lk} \Phi_k \quad l = 1, \dots, M \quad 4.20$$

Con este análisis, los cálculos se reducen considerablemente, desde el orden del número de píxeles de la imagen (N^2) al orden del número de imágenes en el archivo de entrenamiento (M). En la práctica, el conjunto de entrenamiento de las imágenes es relativamente más pequeño ($M \ll N^2$) y los cálculos son más manejables. Los eigenvalores asociados nos permiten jerarquizar los eigenvectores de acuerdo con su utilidad en la caracterización de la variación entre las imágenes.

El éxito de este algoritmo se basa en la evaluación de los eigenvalores y eigenvectores de la matriz real simétrica L (conjunto de imágenes de entrenamiento). La búsqueda inicial en la ecuación característica (ec. 4.8) es un método computacional "pobre" para encontrar eigenvalores. Durante la fase de programación del algoritmo en este trabajo de investigación, se usó un método más eficiente en la evaluación de los eigenvalores y eigenvectores (Press, 1988). Primero, la matriz simétrica real es reducida a su forma tridiagonal con la ayuda del algoritmo "householder". Este algoritmo reduce una matriz simétrica A de $N \times N$ a su forma tridiagonal por medio de $N-2$ transformaciones ortogonales. Cada transformación anula la parte requerida de una columna completa y el correspondiente renglón completo. Después de eso, los eigenvalores y eigenvectores se obtienen con la ayuda de transformaciones QR de Gram-Schmidt. La idea básica detrás del algoritmo QR es que cualquier matriz simétrica real puede ser descompuesta en la forma $A=QR$ donde Q es ortogonal y R es triangular superior. La carga de trabajo en el algoritmo QR es $O(N^3)$ por iteración para una matriz *normal*, lo cual no es factible, sin embargo, la carga es sólo $O(N)$ por iteración para una matriz tridiagonal, haciendo de este algoritmo una alternativa extremadamente eficiente.

Usando EF para clasificar una imagen

Las imágenes eigenfaces calculadas a partir de los eigenvectores de L , forman un conjunto base con el que se describe cualquier imagen facial. Sirovich y Kirby evaluaron una versión limitada de esta metodología en un conjunto de $M=115$ imágenes de hombres caucásicos digitizados de manera controlada, y encontraron que 40 eigenfaces fueron suficientes para una muy buena descripción de todas las imágenes. Con $M'=40$ eigenfaces, los errores

cuadráticos medios (píxel por píxel) en versiones de representación de las caras fue de cerca del 2%.

En la práctica, un pequeño subconjunto de M (M') puede ser suficiente para la identificación, ya que la representación exacta de la imagen original no es el principal requerimiento técnico. Con base en esta idea, el sistema EF propuesto aquí permite al usuario especificar el número de eigenfaces (M') que va a ser usado en reconocimiento. Para máxima exactitud, el número de eigenfaces debería ser igual al número de imágenes en el archivo de entrenamiento.

En esta metodología, las eigenfaces se expanden en un sub-espacio M' -dimensional del espacio de imágenes original N^2 . Los eigenvectores significantes M' de la matriz L son aquellos con los eigenvalores asociados más grandes.

Una nueva imagen (Γ) es transformada en sus componentes eigenface (se proyecta en el espacio de caras) por medio de una simple operación,

$$w_k = u_k^T (\Gamma - \Psi) \quad 4.21$$

para $k=1, \dots, M'$. Esto describe un conjunto de multiplicaciones y sumas de imágenes punto por punto, operaciones desarrolladas, aproximadamente, a una tasa sobre el hardware de procesamiento de la imagen actual, con una complejidad computacional de $O(N^4)$.

Los pesos forman un vector característico,

$$\Omega^T = [W_1, W_2, \dots, W_{M'}] \quad 4.22$$

que describe la contribución de cada eigenface en la representación de la imagen analizada (de entrada). El vector característico se usa en el algoritmo (estándar) de reconocimiento de patrones para determinar, bajo un número predefinido de clases, la mejor descripción de la cara. Las clases faciales Ω_i pueden ser calculadas promediando los resultados de la representación eigenface sobre un pequeño número de imágenes faciales (pueden ser incluso sólo una) de cada individuo.

La clasificación se desarrolla por comparación entre los vectores característicos de los miembros catalogados y el vector característico de la imagen de entrada. Esta comparación se define con la distancia euclidiana entre los dos miembros y debe ser más pequeña que un límite predefinido ϵ_k (ec.4.23). Si la comparación está bajo el límite, entonces la cara es clasificada como "conocida", de otra manera es clasificada como "desconocida" y puede ser adicionada a la librería de caras con su vector característico para su uso posterior, acción que permite que el sistema EF se actualice y aprenda a reconocer nuevas imágenes.

$$\frac{\|\Omega - \Omega_k\|}{\|\Omega_k\|} \leq \epsilon_k \quad 4.23$$

Reconstruyendo una imagen con EF

Una imagen puede ser reconstruida usando su vector característico y las eigenfaces con

$$\Gamma' = \Psi + \Phi_f \quad 4.24$$

donde

$$\Phi_f = \sum_{i=1}^{M'} W_i u_i \quad 4.25$$

La ec. 4.24 establece que la imagen bajo consideración es reconstruida sumando al promedio del conjunto de entrenamiento la contribución W_i de cada eigenface (ec. 4.25). El grado de ajuste o "relación de error de reconstrucción" puede ser expresado por medio de la distancia euclidiana entre el original y la imagen reconstruida

Relación de error en reconstrucción

$$\frac{\|\Gamma' - \Gamma\|}{\|\Gamma\|} \quad 4.26$$

Como puede observarse, este error se incrementa conforme los miembros del conjunto de entrenamiento difieren grandemente entre ellos. Esto se debe a la adición del promedio de imágenes. Cuando los miembros difieren de cada uno (especialmente en el fondo de la imagen) el promedio de imágenes se hace más "contaminado" y esto incrementa el error.

Existen cuatro posibles estados en una imagen de entrada y su vector patrón:

- Cerca del espacio de caras y cerca de una clase de caras
- Cerca del espacio de caras pero no cerca de una clase de caras conocida
- Distante del espacio de caras y cerca de una clase de caras
- Distante del espacio de caras y no cerca de una clase de caras conocida.

En el primer caso, un individuo es reconocido e identificado. En el segundo caso, un individuo desconocido se presenta al sistema para su inclusión como clase. Los últimos dos casos indican que la imagen no es una imagen de cara. El caso tres puede ser el ejemplo de una clasificación falsa, que puede evitarse transformando la ec. 4.25 a

$$\frac{\|\Phi - \Phi_f\|}{\|\Phi_f\|} \leq \phi_k \quad 4.27$$

donde ϕ_k es un límite pre-establecido por el usuario para la definición de una imagen de entrada como perteneciente a la clase de caras k -ésima.

Resumen del procedimiento de reconocimiento EF

- Forme una librería de imágenes faciales de los individuos conocidos
- Escoja un conjunto de entrenamiento que incluya un número de imágenes (M) para cada persona con alguna variación en expresión y en iluminación
- Calcule la matriz L (de $M \times M$) y encuentre sus eigenvectores y eigenvalores, escoja los eigenvectores M' con los eigenvalores asociados más altos
- Combine el conjunto de imágenes de entrenamiento normalizado de acuerdo con la ec. 4.20 para producir las M' -eigenfaces. Almacene estos eigenfaces para su uso posterior
- Para cada miembro en la librería de caras, calcule y almacene un vector característico de acuerdo con la ec. 4.21.
- Escoja un límite ε de acuerdo con la ec. 4.23 que defina la distancia máxima permitida desde cualquier clase de caras. Opcionalmente puede escoger un límite ϕ de acuerdo con la ec. 4.26 que defina la distancia máxima permitida desde el espacio de caras
- Para identificación de una nueva imagen, calcule su vector característico de acuerdo con la ec. 4.22 y compárelo con los vectores característicos almacenados de los miembros de la librería de caras. Si la comparación satisface la condición de la ec. 4.23 por al menos un miembro, entonces clasifique esta imagen de cara como "conocida", en caso contrario una pérdida ha ocurrido y se debe clasificar como "desconocida", si se desea se puede agregar este miembro a la librería de caras con su vector característico.

5. Resultados

A continuación se presenta a) la evaluación de las velocidades de ondas de corte a partir de los resultados de una prueba de penetración de cono y b) el análisis de la respuesta sísmica del Valle de México. Estos modelos *aproximados* demuestran la conveniencia de utilizar RNs y sistemas de LD en la ingeniería geosísmica.

5.1. Estimación de la velocidad de ondas de corte V_s a partir de la resistencia a la penetración del cono q_c .

Las ecuaciones que expresan comportamientos en medios de suelo para ser consideradas (operando en conjunto) un modelo satisfactorio:

- deben ser *completas*, es decir, ser capaces de elaborar juicios o dictar sentencias sobre comportamientos para todos los estados de esfuerzos y deformaciones,
- la identificación de sus parámetros debe resultar de un número pequeño de pruebas estándar (o simples) realizadas sobre los materiales,
- y deben estar fundamentadas en interpretaciones físicas de las respuestas del material.

La primera característica es esencial cuando se diseñan modelos de aplicación práctica y la segunda solamente es *deseable*. La tercera propiedad asegura que el tiempo ocupado en el estudio se está invirtiendo en generar un modelo *útil* y no solamente un elaborado ejercicio de ajuste de curvas de rendimiento limitado (eficiente sólo sobre los datos que están siendo ajustados).

Teniendo en cuenta estas características y de acuerdo con el proceso empírico de creación de modelos se plantea el siguiente esquema de solución al problema de obtener la velocidad de ondas de corte V_s a partir de resistencias de punta en ensayos de cono q_c :

- SISTEMA: Depósitos de suelo del valle de México
- PROCESO: Propagación de ondas de corte en un medio de suelo
- ENTRADAS (datos): Resistencia a la penetración del cono, propiedades índice y caracterización espacial de la relación entrada-salida
- MODELO: sistema neurodifuso
- SALIDA (resultado): Velocidad de ondas de corte V_s

SISTEMA

La Ciudad de México es una de las metrópolis más antiguas en el hemisferio occidental. Las arcillas del subsuelo de la Ciudad tienen propiedades peculiares: su contenido de agua excede en ocasiones 400%, su índice de plasticidad supera frecuentemente 300% y el índice de compresión C_c puede alcanzar valores de 10 (en la mayoría de los suelos en el mundo es menor a 1).

Los sedimentos lacustres de origen volcánico de la Ciudad de México presentan singulares propiedades índice y mecánicas que desvían su comportamiento de la mayoría de los patrones registrados en otros suelos arcillosos. Su respuesta ante carga estática y dinámica es compleja y aún representa un desafío de interpretación. La composición de los depósitos (sedimentos heterogéneos, volcánicos, lacustres, con una proporción y variedad de microfósiles no determinada) los ubica como sujetos no propios de clasificaciones simples. Numerosos han sido los intentos de caracterizar el subsuelo de la Ciudad de México siendo el antecedente más completo el reportado por Marsal y Mazari (1959).

- Mineralogía

Los suelos lacustres se forman mediante procesos de erosión y transporte, seguidos de deposición y consolidación bajo su propio peso. El comportamiento de los suelos lacustres depende principalmente de dos factores: composición y estructura. El término composición se refiere a la naturaleza de las partículas: tamaño, forma y mineralogía mientras que la estructura se refiere a la disposición geométrica y espacial de los materiales.

La mineralogía controla el tamaño, la forma y las características de las partículas de suelo, siendo estas características y su interacción con la fase líquida quienes determinan la plasticidad, compresibilidad, resistencia y permeabilidad del material por lo que su conocimiento es fundamental en la interpretación de las propiedades de los suelos. Sin embargo, los resultados de los estudios mineralógicos realizados por diferentes investigadores a menudo varían (debido a los métodos de análisis y la preparación de las muestras, entre otros factores). En particular las experiencias en la Ciudad de México (e.g., Zeevaert, 1949; Marsal y Mazari, 1959; Lo, 1962; Mesri et al., 1975; Gómez-Looh, 1987; Peralta y Fabi, 1989; Díaz-Rodríguez, et al. 1998) llevan a concluir que el subsuelo es un material singular donde el orden de abundancia de los minerales varía erráticamente y resulta demasiado aventurado tratar de generalizar la proporción y diversidad de los componentes con alguna precisión.

- Zonificación estratigráfica de la Ciudad de México

Basados en una gran cantidad de sondeos realizados a diferentes profundidades se han definido tres zonas geotécnicas en la Ciudad de México (Fig. 5.1): la Zona del Lago, la Zona de Transición y la Zona de Lomas. A continuación se describen sólo las características estratigráficas de la Zona del Lago (zona lacustre) por ser el área de aplicación del modelo propuesto.

Estratigrafía típica de la zona lacustre

En la Fig. 5.2 se muestran perfiles típicos de los depósitos de la Zona del Lago. Estos perfiles de q_c muestran claramente que existe gran variación en los depósitos de suelo clasificados como Zona del Lago. Es evidente que identificar estos tres perfiles con el mismo calificativo llevará a interpretaciones erróneas por parte del modelo neurodifuso, por lo que se considera necesario recurrir a una zonificación geotécnica más fina que además de "Lago" incluya otro calificativo, como la propuesta por Tamez et al. (1987), la cual se detalla más adelante. Note que en la Fig 5.2 se agrega un segundo calificativo para identificar a qué área dentro de la Zona corresponde cada uno de los tres sondeos.

Con el mismo propósito, es indispensable caracterizar la variabilidad de las estratigrafías en función de la profundidad. A través de los valores de resistencia y esfuerzos efectivos, de pruebas granulométricas y de clasificaciones hechas sobre los materiales que constituyen los depósitos de este tipo se pueden identificar seis estratos característicos (en orden ascendente desde 40 m de profundidad hacia la superficie del terreno):

- Estrato 1: Arenas con grava (40-38 m).

Constituida por fragmentos de roca volcánica (las partículas mayores alcanzan un tamaño de hasta 1.5 cm), arena con grava y una matriz de limo. En comparación con el resto de la columna estratigráfica este estrato es de granulometría gruesa. El contenido de agua no supera el 25%, la resistencia q_c es del orden de 50-60 kg/cm² y la velocidad de propagación de ondas de corte V_s varía alrededor de los 110 m/s.

- Estrato 2: Arenas con grava y arenas limosas (38-36 m).

Granulométricamente la zona se caracteriza por una rápida transición de sedimentos gruesos a una textura de arenas limosas. El contenido de agua tiene un valor promedio de 100%, con un q_c de 40 kg/cm² y una V_s del orden de 100 m/s.

- Estrato 3: Limos arcillosos con arena (36-30 m).

Se compone de limos arcillosos con poca arena (excepcionalmente el contenido de arena alcanza un 50%). El valor de q_c varía de 15 a 22 kg/cm² y V_s es del orden de 75 m/s. Es la zona considerada como transición entre condiciones de depósito subaéreas y condiciones incipientes de depósito lacustre.

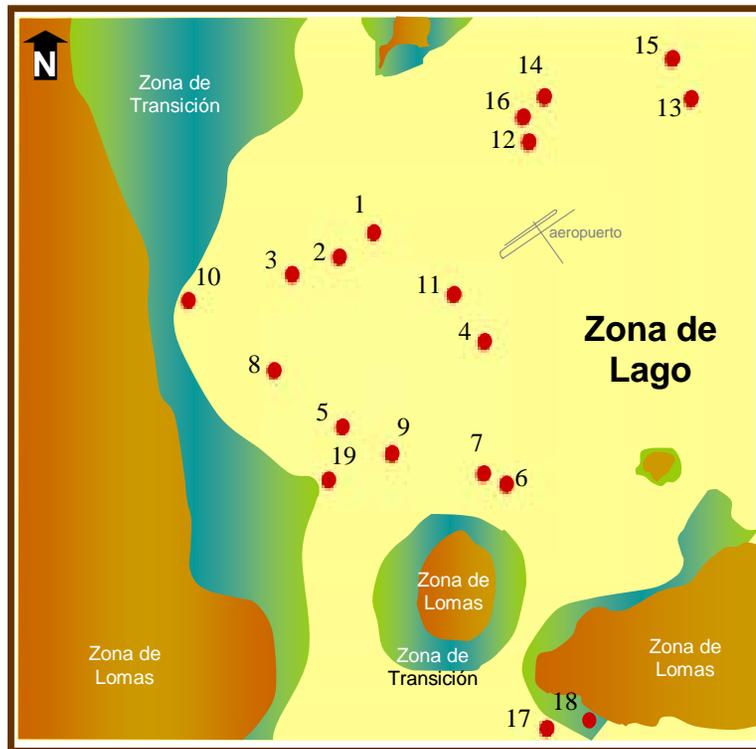


Figura 5.1 Zonas geotécnicas del valle de México

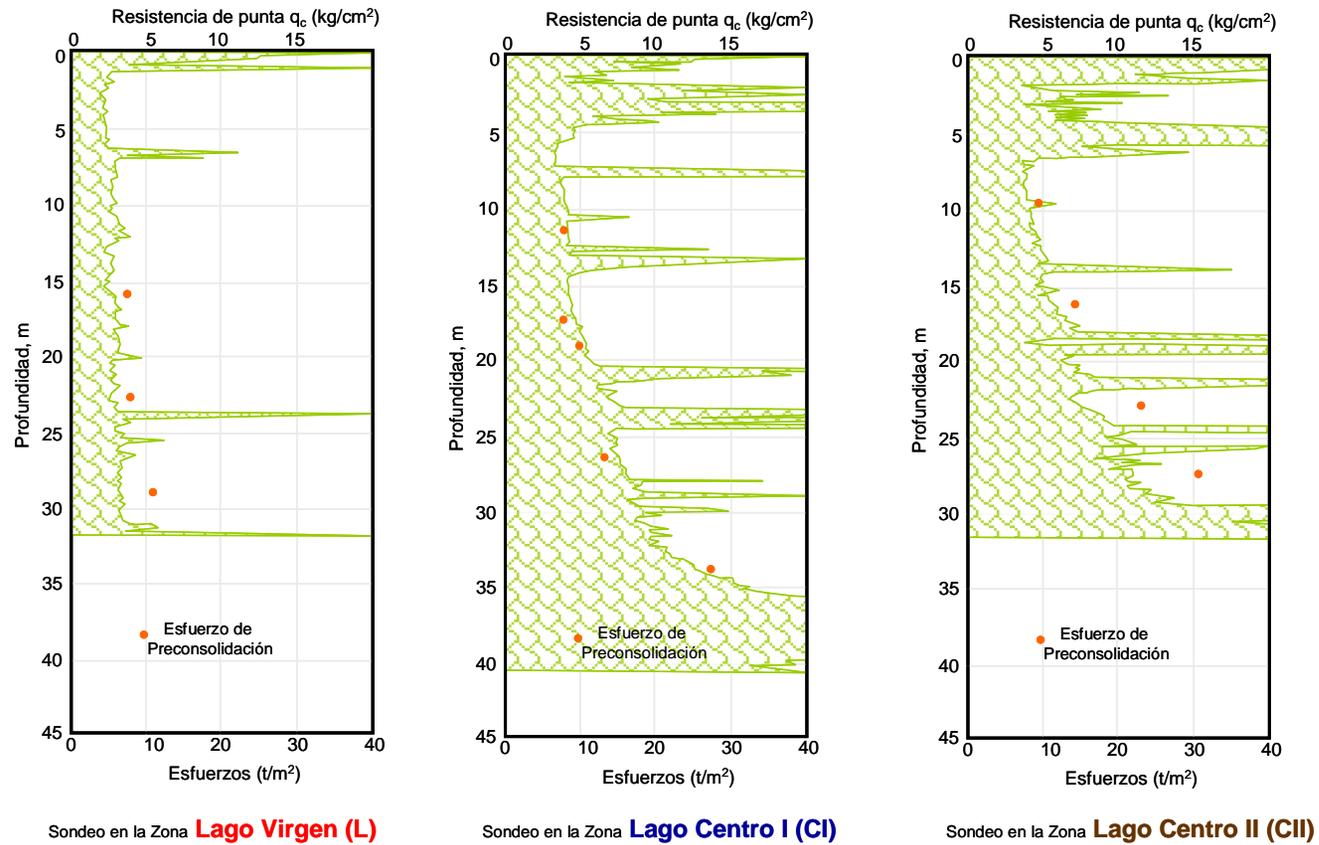


Figura 5.2 Perfiles de resistencias típicos de la zona del Lago (típicos de cada subzona geotécnica)

- Estrato 4: Limos arcillosos o arcillas limosas (30-7 m).

Esta es la capa más importante desde el punto de vista de la geotecnia, principalmente debido a su alta compresibilidad ($m_v = 0.1$ kg/cm²). El estrato se compone de limos arcillosos o arcillas limosas con poca arena. Se tienen varios lentes de arena interestratificados. El contenido de agua se incrementa con el decremento de la profundidad (aproximadamente 220% a 30 m y hasta 420% a 7 m). Los promedios de límite líquido, límite plástico e índice de plasticidad son 338, 80 y 308%, respectivamente. El valor de q_c es casi lineal con la profundidad y V_s es casi constante en este tramo con un promedio de 81 m/s.

- Estrato 5: Limo arcilloso con arena (7-3 m).

En la base de esta zona se encuentra un horizonte de arena que presenta el mayor contenido de arena (85%) de todo el perfil. La granulometría de esta zona corresponde a una arena con variaciones a limo arenoso y limo arcilloso. El valor de q_c es de aproximadamente 24 kg/cm² y el contenido de agua exhibe una tendencia a decrecer sin poder concretar en su valor y variación.

- Estrato 6: Relleno artificial (3-0 m).

La zona superficial es un relleno artificial producto de la actividad humana.

- Sub-Zonificación Geotécnica de la Zona del Lago

De acuerdo con la localización e historia de cargas, la Zona del Lago se ha dividido en tres sub-zonas (Fig. 5.3) atendiendo a la importancia relativa de dos factores: 1) el espesor y propiedades de la costra superficial y 2) la consolidación inducida en cada sitio. En el manual del COVITUR (Tamez et al., 1987), usado ampliamente en el diseño de cimentaciones en el valle de México, se describe cada sub-zona de la siguiente manera (cita textual):

- Lago Virgen (LV). Aunque, a consecuencia de las acciones del hombre, ya no existen arcillas tan blandas como las que existieron hace 400 años, resulta razonable identificar como arcillas en condición virgen a las más blandas de lo que ahora es el vaso del exlago de Texcoco. Sin embargo, como consecuencia del creciente desarrollo de esa zona, las sobrecargas en la superficie se han incrementado e intensificado.
- Lago Centro I (LCI). Corresponde al sector no colonial de la Ciudad el cual se desarrolló a partir de principios de este siglo y ha estado sujeto a las sobrecargas generadas por construcciones pequeñas y

medianas. Las propiedades mecánicas del subsuelo en esta zona representan una condición intermedia entre las del Lago Virgen y las del Lago Centro II. La resistencia de punta del cono eléctrico se ha incrementado por las sobrecargas.

- Lago Centro II (LCII). Esta sub-zona está limitada por la antigua traza de la Ciudad y en ella la historia de cargas aplicadas en la superficie ha sido muy variable por lo cual se presentan las siguientes condiciones extremas: 1) arcillas fuertemente consolidadas por rellenos y grandes sobrecargas de construcciones aztecas y coloniales; 2) arcillas blandas, asociadas a lugares que han alojado plazas y jardines durante largos periodos de tiempo, y 3) arcillas muy blandas en los cruces de antiguos canales. Asimismo, el intenso bombeo para surtir de agua a la Ciudad se refleja en el aumento general de la resistencia de los estratos de arcilla por efecto de la consolidación inducida, como se observa en la Fig.5.2.

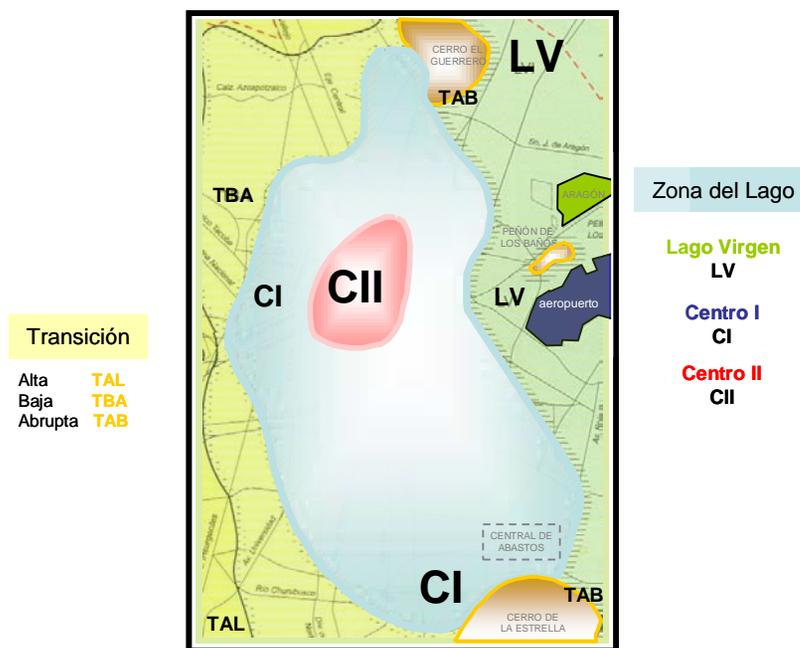


Figura 5.3 Sub-zonas geotécnicas del valle de México

PROCESO

En el Capítulo 2 de este trabajo de tesis se han expuesto los antecedentes y bases teóricas de la propagación de ondas de corte a través de un medio de suelo. Es importante señalar que el método conexionista que se propone en este trabajo no intenta modelar el fenómeno propagación ni caracterizar exhaustivamente los suelos del valle (objetivo poco funcional) sino pretende servir como confiable marco práctico de análisis y cálculo de valores de V_s a partir de las resistencias q_c de los materiales por el que se propaga el tren de ondas sísmicas.

Para el científico dedicado al estudio de los suelos ésta puede ser una herramienta numérica-lingüística que le permita: 1) estudiar formalmente las propiedades dinámicas de los suelos en un ambiente de información escasa,

incompleta y contaminada, 2) generar conclusiones *inteligentes* sobre patrones de comportamiento, y 3) incrementar el conocimiento científico a través de guías matemáticas con significado *natural*.

El **Proceso** en este estudio es la propagación de V_s , pero el esquema matemático a continuación expuesto (sistema neurodifuso) vincula el valor numérico de V_s con parámetros de suelo, por lo que la solución a este inciso es sólo un planteamiento *fenomenológico* relacionado con el *proceso*. Lo anterior significa que el sistema neurodifuso es capaz de describir las *manifestaciones* del *proceso* y eventualmente de relacionarlas con causas, pero no de explicar la estructura o el procedimiento que las genera (Fig. 5.4).

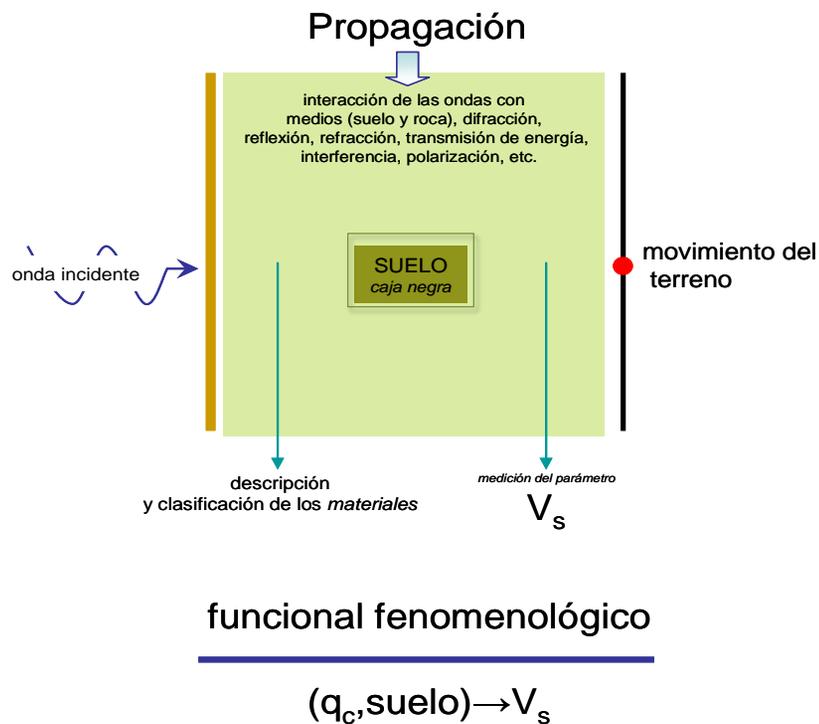


Figura 5.4 Descripción conceptual del funcional neurodifuso

Uno de los parámetros que describe la propagación de ondas de cortante es la velocidad y este valor depende, entre otros factores, de las características del medio por el que se transmite. El funcional fenomenológico que se plantea contiene sólo algunos aspectos de la propagación de ondas de corte: la variable objetivo V_s y descripciones paramétricas y/o lingüísticas del medio.

ENTRADAS

Una importante fuente de variabilidad en los resultados de ensayos geotécnicos y sísmicos es el procedimiento (aplicación de una metodología estándar) y el control de calidad en su desarrollo. Por esta razón para la alimentación del modelo neurodifuso se seleccionó información de sitios estudiados, interpretados y publicados por una misma entidad (en este caso el Instituto de Ingeniería, UNAM) de tal forma que la información mantenga este sesgo y el efecto *incierto* sobre los resultados pueda considerarse constante.

Los sitios que conforman la base de datos (círculos numerados en la Fig. 5.1) fueron elegidos de acuerdo con la disposición de perfiles de V_s y la existencia de mediciones de resistencias y propiedades índice y/o mecánicas. La subzona geotécnica y el tipo de información (uso en el desarrollo del modelo) de cada sitio se presentan en la Tabla 5.1.

La información común en los 19 sitios es el perfil de resistencias a la penetración del cono eléctrico q_c , el de velocidades de ondas de corte V_s y pesos volumétricos del suelo γ_s (se usa indistintamente en este capítulo γ_s o γ como en otros textos técnicos), esta propiedad no disponible en las

mismas profundidades en las que se determinaron los perfiles de q_c y V_s . La velocidad de onda de corte fue medida con las técnicas de sonda suspendida (sitios 1, 2, 4, 5, 6, 7, 8, 9, 17, 18 y 19) y *down hole* (sitios 3, 10, 11, 12, 13, 14, 15 y 16) y los perfiles se presentan discretizados a cada metro. En 9 sitios se conoce el contenido natural de agua w y los límites plásticos, mientras que esfuerzos efectivos, presión de poro y valores de cohesión se consiguieron en sólo 5 sitios. En la extrapolación de las propiedades medidas en un punto (probeta) hacia características atribuibles a estratos "homogéneos" debe tenerse especial cuidado en aquellas que presenten importantes variaciones espaciales ya que su inclusión como variables de modelado minimizaría e incluso eliminaría las ventajas de usar mediciones de campo para caracterizar depósitos de suelo. Los fundamentos en la selección de las variables de mayor calidad para la construcción de la estructura fenomenológica fueron confiabilidad y suficiencia. Si bien no se conoce *a priori* la relación funcional ni jerarquía entre las propiedades que conforman la base de datos, se pueden reconocer aspectos que manifiesten una dudosa representabilidad.

En un sencillo análisis paramétrico se determinó que de los 383 los patrones en la base de datos (Fig. 5.5) menos del 20% permite incluir expresiones adicionales sobre el medio (peso volumétrico γ_s , estado de esfuerzos σ , presión de poro u , índice de plasticidad I_p , contenido de agua w , cohesión c) por lo que relaciones más complejas entre las características del suelo y su capacidad de transmisión de ondas de corte resulta poco factible usando el conjunto original.

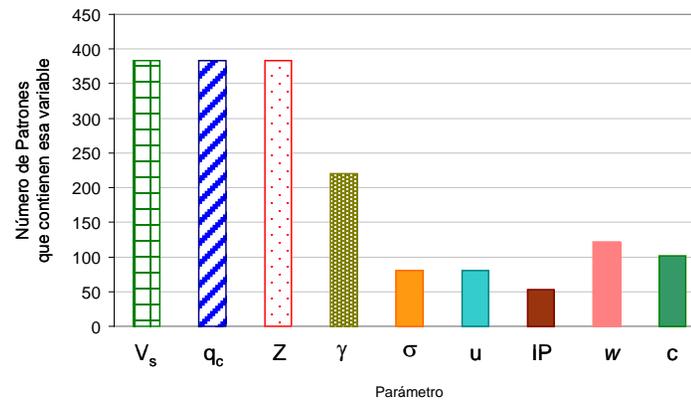


Figura 5.5 Representación de cada variable sobre el número de patrones en la base de datos

Tabla 5.1 Base de Datos

Sitio/número (Figura 1)	Sub-Zona	Geotécnica	Uso del patrón durante el desarrollo del modelo
Tlaltelolco/1	CI (Centro I)		Entrenamiento
Alameda/2	CII (Centro II)		Prueba
Plaza Córdoba/3	CII (Centro II)		Entrenamiento
Velódromo/4	CII (Centro II)		Entrenamiento
SCT/5	CI (Centro I)		Entrenamiento
CAF/6	CI (Centro I)		Entrenamiento
CAO/7	CI (Centro I)		Entrenamiento
CUPJ/8	CI (Centro I)		Prueba
Eugenia/9	CI (Centro I)		Entrenamiento
El Águila/10	CI (Centro I)		Entrenamiento
Línea B/11	L (Lago Virgen)		Entrenamiento
Av. 510/12	L (Lago Virgen)		Entrenamiento
Calle Urano/13	L (Lago Virgen)		Prueba
Nonoalco/14	CI (Centro I)		Prueba
Plaza Aragón/15	L (Lago Virgen)		Prueba
Río Remedios/16	L (Lago Virgen)		Entrenamiento
Tláhuac B/17	L (Lago Virgen)		Prueba
Tláhuac D/18	L (Lago Virgen)		Entrenamiento
5 de febrero/19	CI (Centro I)		Entrenamiento

Debe recordarse que un sistema difuso es capaz de manejar *vacíos* de información pero la *no-presencia* debe estar relacionada con el comportamiento general del funcional que se construye y de alguna manera se debe *sujetar* (declarar fronteras numéricas y condiciones de no-existencia) la "ocurrencia" de falta de datos. En esta base de datos existieron criterios prácticos (posiblemente basados en un conocimiento parcial sobre la estratigrafía) para la selección de las profundidades a las que se extraerían las muestras de acuerdo con su significado sobre la longitud de columna de suelo estudiada. Sin tener acceso a estos criterios y usando las propiedades tal como se reportan en los informes, la aplicación de los escasos valores de γ_s , σ , u , c o ω sobre los valores de campo (q_c , V_s , Z) origina incongruencias

que ningún sistema inteligente sería capaz de resolver incluso con la ayuda de un *experto* humano (vea el ejemplo con γ_s mostrado en la Fig. 5.6). ¿Por qué suceden estas contradicciones numéricas/descriptivas?. Una posible respuesta sería que las probetas no son representativas de los estratos determinados a través de pruebas de campo, o bien que los estratos así definidos no son reales, es decir, que las variaciones en valores reportados por las pruebas (de resistencia o sísmicas, por ejemplo) pueden deberse a efectos externos no relacionados con el comportamiento de la masa de suelo. Si no se pueden identificar ni la fuente de la incertidumbre ni el grado en el que afecta nuestra apreciación del medio, en esta investigación se elige utilizar parámetros con vínculos directos en la búsqueda de relaciones.

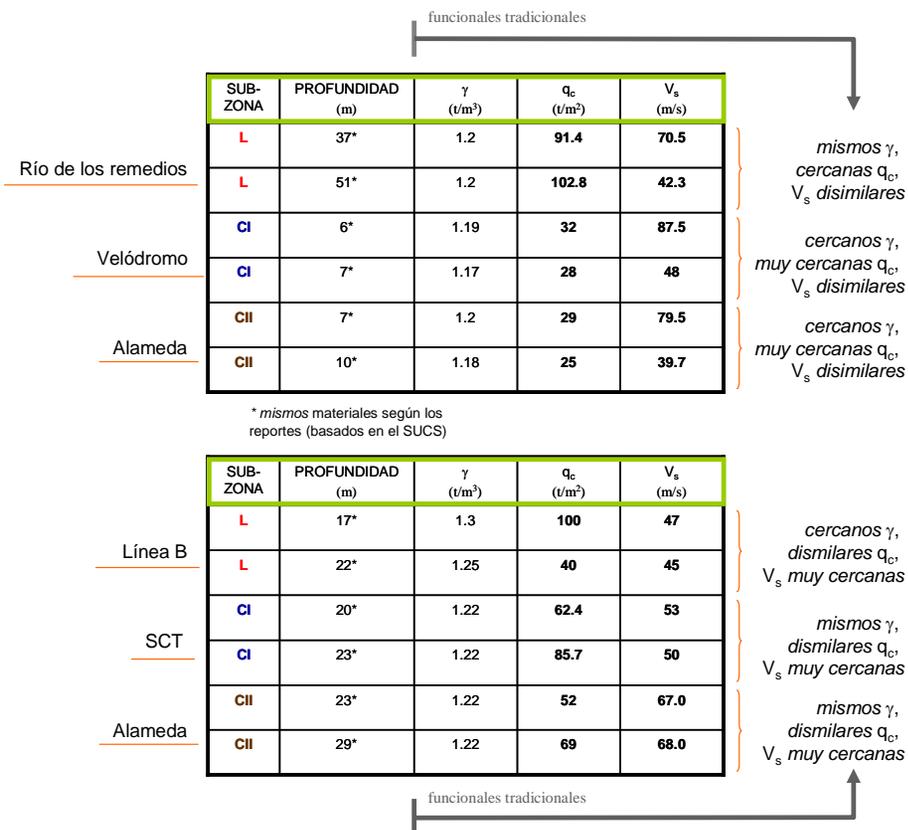


Figura 5.6 Incongruencias numérico-descriptivas en la base de datos original

De acuerdo con lo anterior, $[q_c, V_s, Z]$ es una combinación paramétrica simple y confiable. Es necesario puntualizar que si bien se están eliminando propiedades incluidas en la mayoría de los funcionales que tratan de relacionar resistencias y velocidades, éstas en realidad están implícitas en los valores reportados de q_c si se acepta que la resistencia de los materiales naturales depende de su densidad, de su plasticidad y de la condición de esfuerzos *in situ*, entre algunas de las condiciones reconocidas (motivo de otra disertación sería el análisis de las variables que no se estudian –por limitaciones teóricas y/o tecnológicas– y posiblemente tienen mayor conexión con el comportamiento mecánico y dinámico de los suelos).

Por otro lado, de acuerdo con conceptos de lo difuso, la definición de las entradas procura la selección de descripciones (numéricas y lingüísticas) cuya cercanía permita construir funciones matemáticas *naturales* y eficientes. El peso volumétrico, el contenido natural de agua, la cohesión, incluso el valor de los esfuerzos verticales efectivos no se encuentran en la vecindad del espacio (relacionadas numérica o lingüísticamente con las entradas declaradas) que ocupan las propiedades estimadas *in situ* (condiciones de ensaye *reales*).

El pre-proceso controlado (manejo y preparación de muestras, reproducción de condiciones de esfuerzos) y su interpretación en el post-proceso (relación de comportamientos complejos con funciones simplistas) colocan a estas propiedades lejos de los atributos de las pruebas de campo. Entonces, ¿por qué estos parámetros son incluidos en la mayoría de los funcionales para estimar V_s ? Porque la información de resistencias q_c resulta insuficiente si se le propone como la única dependencia de una variable tan compleja como V_s . Es decir, la naturaleza (no lineal y multidimensional, así no se conozca cabalmente la dimensión a la que pertenece) de la variable objetivo obliga a la construcción de premisas múltiples (mayor número de variables de entrada). Entonces se impone la inclusión de alguna característica numérica conectada con los materiales y/o la variable objetivo.

Aumentar la dimensión de la relación $q_c \rightarrow V_s$ con la variable *profundidad* Z , además de agregar un *contador* (nodo usado en modelos neuronales para dar idea de *secuencia*) sirve para separar los puntos con valores *muy cercanos* de resistencia que puedan tener velocidades *muy lejanas* (o viceversa). Como se explicó en la descripción del **Sistema** (depósitos de suelo del valle de México), las estratigrafías típicas de L, CI y CII comparten valores de q_c , V_s y tipos de suelo, siendo la profundidad a la que se encuentran estos materiales la que introduce la variación espacial de la velocidad. Al nodo contador Z se yuxtapone el nodo clasificador *Zona* para que, como dupla, expliquen al sistema las salidas de V_s en el rango de profundidades estudiadas a través de los perfiles de q_c , así cada relación será particular de cierta sub-zona geotécnica.

Una importante diferencia entre el planteamiento neurodifuso y los funcionales existentes es la inclusión de Z en la estimación de V_s . Z otorga la cualidad de *continuidad* a las estimaciones y hace que subconjuntos de patrones formen parte del semiespacio bajo una línea en estudio (a 90° a partir de la superficie) mientras que *Zona* ubica a estos subconjuntos

(pertenecientes a un sitio) sobre el plano del valle (sin hacer uso de coordenadas geográficas $[X,Y]$ esto es una referencia o situación geotécnica) lo que ejemplifica un mapeo tridimensional: $V_s = f(q_c, Z, Zona)$. En las funciones que no incluyen la variable Z se trata a cada punto de medición como un individuo que pertenece a una población (todos los posibles valores de resistencia y velocidad en la zona del Lago) y se asume que la variación en V_s depende únicamente de la resistencia y algunas propiedades (comúnmente la densidad del suelo) y que éstas a su vez están libres de contaminación o errores de medición (incertidumbre). Esta condición es ideal pero difícilmente se alcanza en ensayos de campo sobre materiales naturales.

Después de considerar los aspectos geotécnicos y de modelado anteriormente expuestos, se proponen como entradas del sistema:

- q_c *resistencia*
- Z *profundidad*
- Zona* *Sub – zona geotécnica*

A pesar de la inclusión de los nodos *clasificador* y *contador* existen todavía incongruencias en la base de datos que, en este trabajo de investigación, se solucionan a través de un pre-proceso difuso de agrupación (*fuzzy clustering*) que al mismo tiempo equilibra la cantidad de información dentro del espacio de entradas y salidas (elimina nubes densas de patrones a través de un *típico* que las representa). Como primer paso se define el intervalo numérico donde tienen significado las variables (Fig. 5.7).

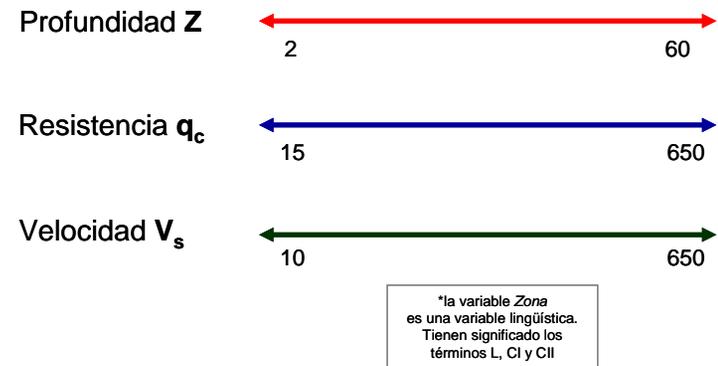


Figura 5.7 Bases numéricas de las entradas y salida

Después, de acuerdo con el conocimiento y experiencia sobre el fenómeno, la importancia o jerarquía de cada variable y la cantidad de líneas (patrones) en la base de datos se establecen las distancias sobre una función de membresía P_i (trapecio) que exponen la completa similitud ϵ o la total disimilitud δ entre patrones. Expresadas en porcentaje, estas fronteras son recomendaciones subjetivas por lo que deben probarse varias combinaciones de (ϵ, δ) para definir los conjuntos de *típicos* más representativos, es decir, cuáles bases de datos (modificadas) cubren ordenadamente el espacio paramétrico (Tabla 5.2).

En la Fig. 5.8 se muestran gráficos bidimensionales de las entradas y V_s para la base de datos original y la agrupación elegida como más eficiente (combinación C). La nueva base de datos consta de 207 patrones de entrenamiento y a partir de este momento estos *típicos* son usados como base de datos en la etapa de entrenamiento neurodifuso. Los sitios etiquetados como *Prueba* (ver Tabla 5.1) han sido apartados para la etapa de validación y no son sujetos de ningún tipo de procesamiento (representan condiciones de trabajo reales).

Tabla 5.2 Combinaciones de (ϵ, δ) para obtención de típicos

	ENTRADAS		SALIDA	REDUCCIÓN
<i>nueva</i> BASE DE DATOS	Profundidad (m)	Resistencia q_c (t/m²)	V_s (m/s)	de 259 patrones a
A	0.5-1.0%	0.15-1.0%	0.15-1.0%	246
B	1.0-2.0%	0.30-1.0%	0.30-1.0%	202
C	1.0-4.0%	0.30-2.0%	0.30-2.0%	207
D	2.0-2.0%	0.60-1.0%	0.60-1.0%	243
E	1.5-3.0%	0.45-3.0%	0.45-3.0%	147
F	2.0-3.0%	2.0-3.0%	2.0-3.0%	99
G	2.5-3.5%	2.5-3.5%	2.5-3.5%	78
H	3.0-3.0%	3.0-3.5%	3.0-3.5%	85

→ la más equilibrada

*el número de patrones original es de 259 (se excluyeron 124 para su uso en la etapa de prueba)

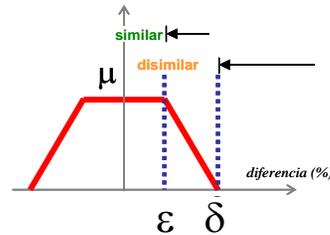


Figura 5.8 Reducción de base *original* de patrones a conjunto de *típicos*

MODELO

1. Descripción del Proyecto

VARIABLES DE ENTRADA	3
VARIABLES DE SALIDA	1
VARIABLES INTERMEDIAS	0
BLOQUES DE REGLAS	1
REGLAS	108
FUNCIONES DE MEMBRESÍA	14

2. Estructura del Sistema

La estructura del sistema permite identificar el flujo de inferencia difusa desde las variables de entrada hasta las variables de salida. Transformar las interfaces de entrada consiste en traducir entradas análogas hacia valores difusos. La inferencia difusa toma lugar en los bloques de reglas (control difuso). La salida de estos bloques son variables lingüísticas que se transforman en variables análogas por medio de un proceso inverso difuso.

En la Fig. 5.9 se muestra la estructura del sistema difuso propuesto en este trabajo de investigación, que incluye: 1) interfaces de entrada, 2) bloques de reglas y 3) interfaces de salida. Las líneas conectores simbolizan el flujo de datos.

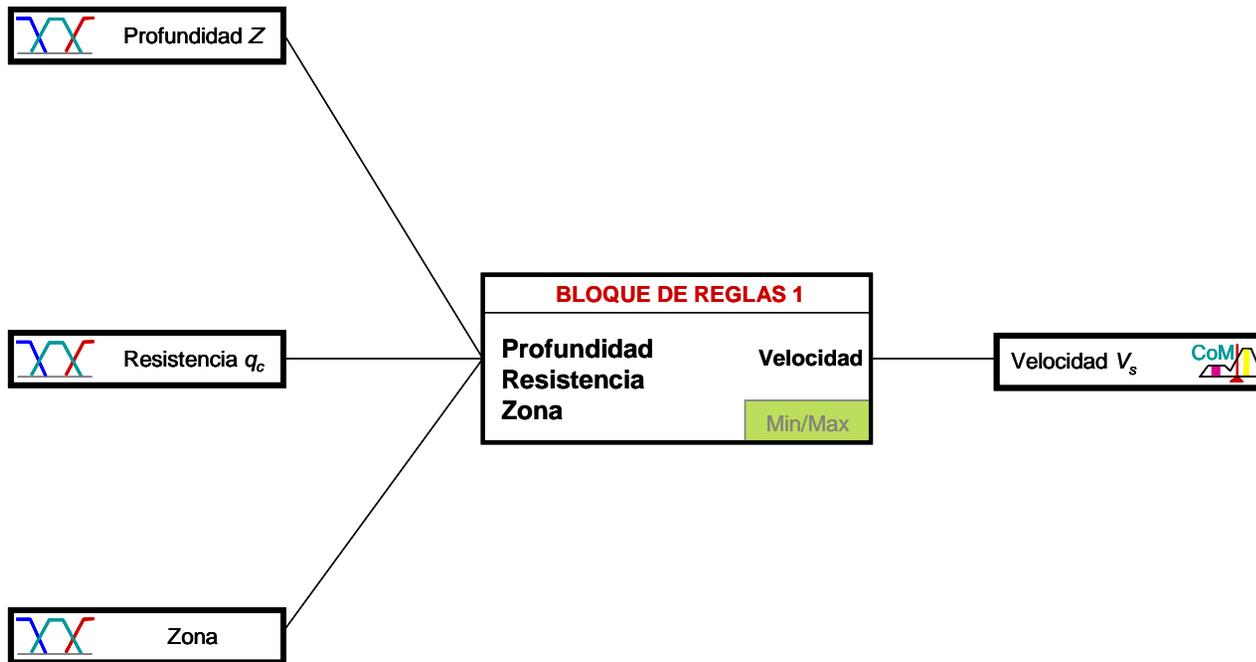


Figura 5.9 Estructura del Sistema de Lógica Difusa

- 3. Variables

A continuación se definen las variables lingüísticas y sus funciones de membresía. Estas variables sirven para traducir los valores *reales* en valores *lingüísticos*. Los posibles valores de una variable lingüística no son números sino los llamados términos lingüísticos. A cada término le corresponde una

función de membresía que se define con unos cuantos puntos sobre el espacio [*base de variable, membresía*]. A continuación se enlistan las variables, sus bases, sus términos, el método difuso y el inverso difuso aplicado en cada una de ellas.

- Entradas

#	Nombre de la Variable	Tipo	Unidad	Min	Max	Nombre de los Términos
1	Profundidad Z		m	0	70	Superficial Formación Profundo
2	Resistencia q_c		t/m ²	0	700	Blando Medio Firme Roca
3	Zona		clase	0	80*	Lago Centro I Centro II

* carece de significado físico

Métodos Difusos

	Calcula FMB*		Busca FMB**
	Variable categórica		Display
	Entrada difusa		

*se almacenan los puntos de definición de las funciones de membresía FMB

**se calculan las de las funciones de membresía FMB completas

- Salida

#	Nombre de la Variable	Tipo	Unidad	Min	Max	Nombre de los Términos
4	Velocidad V_s		m/s	0	700	Baja Media Alta Muy alta

Métodos Difusos Inversos

	Centro de Máximos (CoM)		Promedio de Máximos (MoM)
	Centro de Área (CoA)		Hiper CoM
	Salida difusa		Fuerza

* para generar el "resultado más plausible" use el Promedio de Máximos y la "mejor concesión" se obtiene con el Centro de Máximos y el Centro de Áreas.

Funciones Propuestas:

- **Profundidad Z**

De acuerdo con el modelo estratigráfico inicialmente propuesto por Marsal y Mazari, la secuencia de los suelos de la antigua zona lacustre está integrada por: 1) la costra superficial (en muchas partes cubierta con rellenos artificiales de espesor variable que pueden llegar a ser de varios metros), 2) formación arcillosa superior (arcillas blandas a muy blandas) y 3) la primera capa dura (separa la primera formación arcillosa de la segunda constituida por arcillas más consolidadas).

Esta identificación se llevó a cabo a través de pautas visuales y táctiles además de estimaciones de contenidos de agua y límites de consistencia pero incluso los más recientes sondeos de cono eléctrico no han modificado mayormente los rangos de profundidades a los que se encuentran cada tipo de suelo (clasificados según el Sistema Unificado de Clasificación de Suelos SUCS). Con base en lo anterior, a continuación se describen las tres etiquetas propuestas para la variable Profundidad (Fig. 5.10).

Superficial. Definida como función triángulo otorga el valor de pertenencia CERO a la cota 0+0.00 (superficie). El valor típico UNO se encuentra a los 10 m a partir de los cuales decrece la membresía hasta regresar a CERO a los 20 m.

Formación. Definida como función triángulo otorga el valor de pertenencia CERO al rango 0m→10m. A partir de este valor la pertenencia crece gradualmente hasta encontrar el valor típico UNO a los 30 m, desde esta profundidad decrece la membresía hasta regresar a CERO a los 50 m.

Profundo. Definida como función hombro otorga el valor de pertenencia CERO al rango 0→25m. A partir de los 25 m la membresía crece gradualmente hasta encontrar el valor típico UNO a los 50 m (profundidad aproximada donde todos los sitios presentan o han presentado valores de resistencia y velocidad propias de materiales *firmes*). Todas las profundidades más allá de este valor (hasta el límite de operación del sistema ≈70 m) serán típicas del término profundo. Si los materiales y velocidades discrepan en este rango de profundidades se propone que la diferencia la marquen los valores de resistencia (asociados con la compresibilidad de los materiales) y la zona geotécnica.

- **Resistencia q_c**

Los cambios de resistencia a la penetración que ocurren en la secuencia estratigráfica del subsuelo de la Ciudad se suceden en concordancia con las variaciones en los contenidos de agua y cargas aplicadas. Para ser congruentes con las hipótesis descritas en la elección de variables de entrada, los estratos así definidos son el punto de partida en la declaración de las etiquetas de q_c . Los valores típicos y las fronteras de la NO pertenencia están basados en las descripciones del **Sistema** (suelos del valle). Se reconocen dentro de la costra superficial la existencia de rellenos artificiales, suelos blandos y costra seca. En el caso de la formación arcillosa superior se pueden encontrar arcillas preconsolidadas (superficiales y profundas), arcillas normalmente consolidadas y lentes duros. La capa dura es un depósito heterogéneo cuya cementación es errática y su espesor es muy variable. La dificultad en su muestreo no permite definir confiablemente sus propiedades mecánicas, así que el cono eléctrico es una de las herramientas más adecuadas de exploración que permite identificar sus peculiaridades. Después y hasta el límite de operación del sistema (en términos de Profundidad) se encuentra la formación arcillosa inferior que consta de estratos de arcilla separados por lentes duros.

De acuerdo con lo anterior se eligieron cuatro etiquetas para la descripción de la resistencia que presentan los suelos que componen la estratigrafía de la zona del Lago (Fig.5.11).

Blando. Definido como función triángulo otorga el valor de pertenencia CERO a la resistencia nula. A partir de este valor la membresía crece gradualmente hasta encontrar el valor típico UNO cuando q_c alcanza las 100 t/m². La pertenencia decrece a partir de 100 y hasta 200 t/m² donde regresa a pertenencia CERO.

Medio. Definido como función triángulo otorga el valor de pertenencia CERO al rango 0→100 t/m² desde donde comienza a crecer la membresía hasta alcanzar el típico a las 200 t/m². De 200 a 300 t/m² el valor de pertenencia desciende y permanece en CERO hasta el límite de operación del sistema.

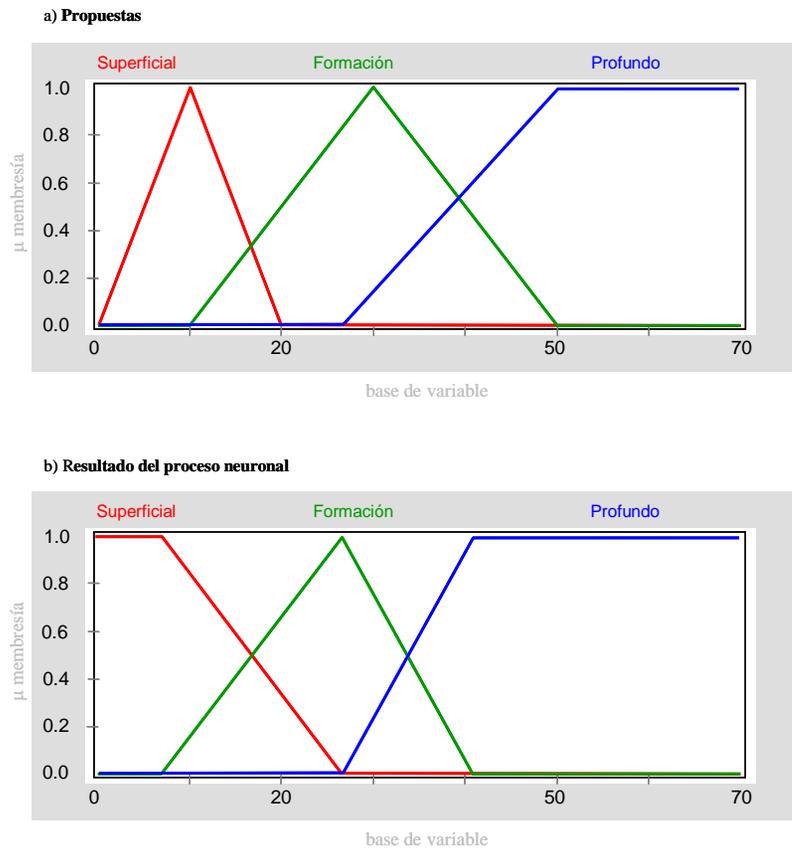
Firme. Definido como función triángulo otorga el valor de pertenencia CERO al rango 0→200 t/m² desde donde comienza a crecer la membresía hasta alcanzar el típico a las 350 t/m². De 350 a 500 t/m² el valor de pertenencia desciende y permanece en CERO hasta el límite de operación del sistema.

Roca. Definida como función hombro otorga el valor de pertenencia CERO al rango 0→ 400 t/m². A partir de este valor la membresía crece gradualmente hasta encontrar el valor típico UNO a las 500 t/m², siendo esta resistencia el valor promedio de los reportados en capa dura para los sitios de la base de datos. Todas las resistencias más allá de este valor (y hasta el límite de operación del sistema 700 t/m²) serán típicas del término *roca*.

- **Zona Geotécnica Zona**

De acuerdo con lo declarado en la descripción del **Sistema** y la elección de **Variables**, se incluye la caracterización detallada de la zona del Lago por subzonas. La base numérica de esta variable carece de significado físico. Si bien era posible incluir un nodo de clase que definiera la pertenencia *cerrada* a cada subzona, se decidió que la mejor manera de expresar esta empírica subdivisión sobre el plano de la cuenca, es a través de clases difusas. Esta variable no se abre al entrenamiento por tratarse de una categoría subjetiva y cuya liga con los valores de resistencias, profundidades y velocidades es sólo a través de apreciaciones (su fundamento numérico relacionado con mediciones *reales* ocasionaría contradicciones en muchos de los patrones de la base de datos).

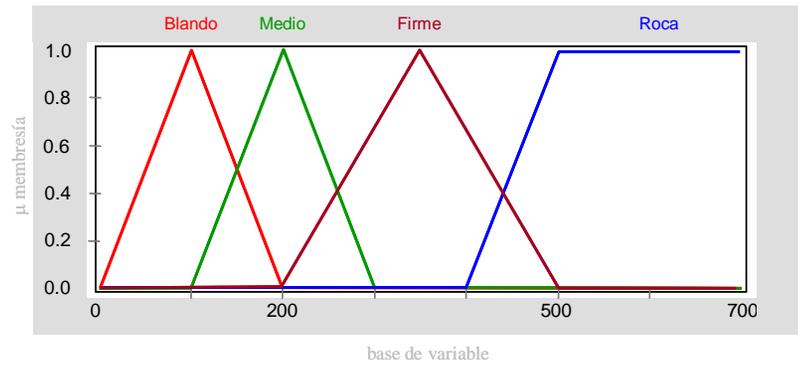
Si esta variable de clase se abiera al entrenamiento, las funciones redefinidas tendrían un sentido difícil de interpretar bajo el esquema difuso hasta ahora planteado. Para que esta modificación tuviera una repercusión en el conocimiento del fenómeno, sería necesario colocar a esta variable en la parte de las conclusiones y adicionar más términos geotécnicos y geográficos en las premisas (Fig.5.12).



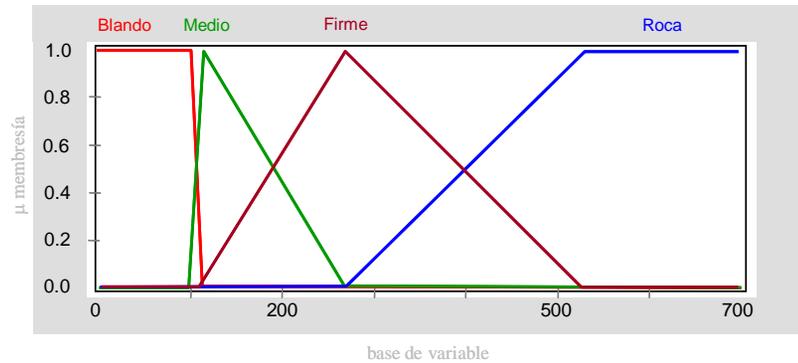
Término	Forma	Definición (base,membresía) PROPUESTA	Definición (base,membresía) después del entrenamiento NEURONAL
Superficial	lineal	(0,0);(10,1);(20,0);(70,0)	(0,1);(6.99,1);(26.54,0);(70,0)
Formación	lineal	(0,0);(10,0);(30,1);(50,0);(70,0)	(0,0);(6.99,0);(26.54,1);(40.86,0);(70,0)
Profundo	lineal	(0,0);(30,0);(50,1);(70,1)	(0,0);(26.54,0);(40.86,1);(70,1)

Figura 5.10 Funciones de Membresía (FMB) para la variable Profundidad, a) propuestas, b) resultado del entrenamiento neuronal

a) Propuestas



b) Resultado del proceso neuronal



Término	Forma	Definición (base,membresía) PROPUESTA	Definición (base,membresía) después del entrenamiento NEURONAL
Blando	lineal	(0,0);(100,1);(200,0);(700,0)	(0,1);(96.5,1);(104.9,0);(700,0)
Medio	lineal	(0,0);(100,0);(200,1);(300,0);(700,0)	(0,0);(96.5,0);(104.9,1);(264,0);(700,0)
Firme	lineal	(0,0);(200,0);(350,1);(500,0);(700,0)	(0,0);(104.9,0);(264,1);(525,0);(700,0)
Roca	lineal	(0,0);(400,0);(500,1);(700,1)	(0,0);(264,0);(525,1);(700,1)

Figura 5.11 Funciones de Membresía (FMB) para la variable Resistencia, a) propuestas, b) resultado del entrenamiento neuronal

Lago Virgen. Definida como función triángulo otorga el valor de pertenencia CERO al valor numérico inicial (cero). El típico (pertenencia UNO) se otorga cuando el usuario declare 20 unidades y a partir de este punto la membresía decrece hasta regresar a CERO en 40 unidades y hasta el límite de operación de 80 unidades.

Centro I. Definida como función triángulo otorga el valor de pertenencia CERO al rango 0→20 unidades. El típico (pertenencia UNO) se otorga cuando el usuario declare 40 unidades y a partir de este punto la membresía decrece hasta regresar a CERO en 60 unidades y hasta el límite de operación de 80 unidades.

Centro II. Definida como función triángulo otorga el valor de pertenencia CERO al rango 0→40 unidades. El típico (pertenencia UNO) se otorga cuando le usuario declare 60 unidades y a partir de este punto la membresía decrece hasta regresar a CERO en 80 unidades.

No usar la función hombro en los extremos *Lago Virgen* y *Centro II* se debe precisamente a la necesidad de cubrir las deficiencias en la definición de todas las clases. Cuando el usuario tenga muy pocos argumentos para decidir sobre otorgarle o no la etiqueta de “sitio típico” de cierta subzona a un patrón en particular basta con alejarse a la izquierda o hacia la derecha si las dudas sobre su pertenencia lo acercan o alejan (con evidencias) de cierta subzona.

- **Velocidad V_s**

Los cambios de velocidades ocurren de manera muy similar a los reportados en la descripción de la variable resistencia q_c . Para ser congruentes con las hipótesis declaradas en la elección de variables de entrada, las etiquetas definidas para q_c son el punto de partida en la declaración de las etiquetas de V_s . Los valores típicos y las fronteras de la NO pertenencia están basados en lo descrito en **Sistema** (Fig.5.13).

Baja. Definida como función triángulo otorga el valor de pertenencia CERO a la velocidad nula. A partir de este valor la membresía crece gradualmente hasta encontrar el valor típico UNO cuando V_s alcanza los 100 m/s. La pertenencia decrece a partir de 100 y hasta 200 m/s donde regresa a pertenencia CERO.

Media. Definida como función triángulo otorga el valor de pertenencia CERO al rango 0→100 m/s desde donde comienza a crecer la membresía hasta alcanzar el típico a los 200 m/s. De 200 a 300 m/s el valor de pertenencia descende y permanece en CERO hasta el límite de operación del sistema (700 m/s).

Alta. Definida como función triángulo otorga el valor de pertenencia CERO al rango 0→200 m/s desde donde comienza a crecer la membresía hasta alcanzar el típico a los 350 m/s. De 350 a 500 m/s el valor de pertenencia descende y permanece en CERO hasta el límite de operación del sistema.

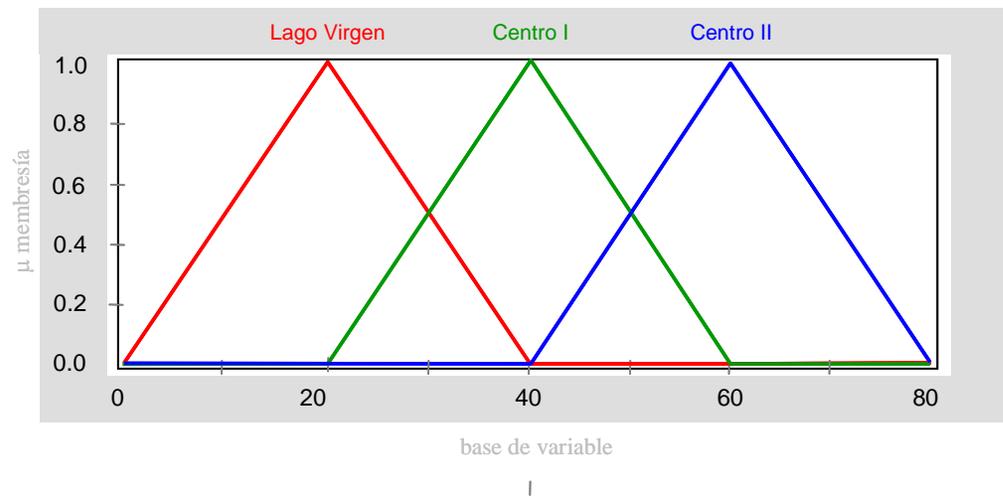
Muy alta. Definida como función hombro otorga el valor de pertenencia CERO al rango 0→ 400 m/s. A partir de este valor la membresía crece gradualmente hasta encontrar el valor típico UNO a las 500 m/s, siendo esta

resistencia el valor promedio de los reportados en capa dura para los sitios de la base de datos. Todas las resistencias más allá de este valor (hasta el límite de operación del sistema 700 m/s) serán típicas del término *muy alta*. Si los materiales y resistencias discrepan en este rango de velocidades se propone que la diferencia la marquen los valores de profundidad (asociada con la estratigrafía) y la zona geotécnica.

Funciones generadas a partir del entrenamiento Neurodifuso:

La aplicación de la tecnología neurodifusa permite la generación automática del sistema difuso (basado en el esquema propuesto) que combina la intuición y la heurística ingenieril a través de lenguaje práctico, sin necesidad de recurrir a modelos matemáticos rigurosos.

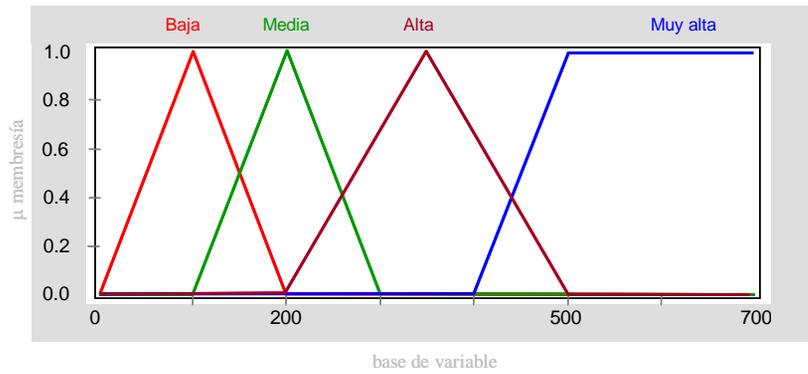
Hasta este punto se ha construido la estructura *vacía* del sistema de lógica difusa que estima V_s . Se definieron las variables lingüísticas, términos y funciones de membresía. Dentro de este sistema *vacío* existe un bloque de reglas (contiene 108) con todas las posibles combinaciones entre las premisas y las conclusiones. Todas las reglas inician con grado de soporte (DoS) CERO, lo que significa que el entrenamiento neurodifuso afectará mayormente a las reglas que tienen influencia significativa sobre el comportamiento global del sistema.



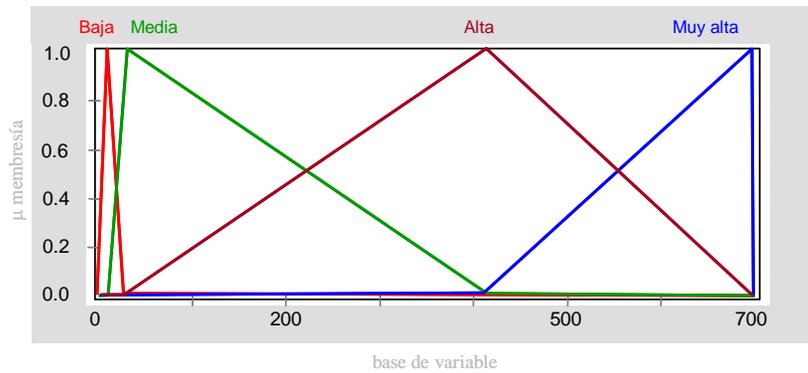
Término	Forma	Definición (base,membresía) PROPUESTA	Definición (base,membresía) después del entrenamiento NEURONAL
Lago Virgen	lineal	(0,0);(20,1);(40,0);(80,0)	no abiertos al aprendizaje
Centro I	lineal	(0,0);(20,0);(40,1);(60,0);(80,0)	no abiertos al aprendizaje
Centro II	lineal	(0,0);(40,0);(60,1);(80,1)	no abiertos al aprendizaje

Figura 5.12 Funciones de Membresía propuestas (FMB) para la variable Zona

a) Propuestas



b) Resultado del proceso neuronal



Término	Forma	Definición (base,membresía) PROPUESTA	Definición (base,membresía) después del entrenamiento NEURONAL
Baja	lineal	(0,0);(100,1);(200,0);(70,0)	(0,0);(11.1,1);(26.5,0);(700,0)
Media	lineal	(0,0);(100,0);(200,1);(300,0);(700,0)	(0,0);(11.1,0);(26.5,1);(413.4,0);(700,0)
Alta	lineal	(0,0);(200,0);(350,1);(500,0);(700,0)	(0,0);(26.5,0);(413.4,1);(698.9,0);(700,0)
Muy Alta	lineal	0,0);(400,0);(500,1);(700,0)	(0,0);(413.4,0);(698.9,1);(700,0)

Figura 5.13 Funciones de Membresía (FMB) para la variable Velocidad, a) propuestas, b) resultado del entrenamiento neuronal

Ya que un paradigma neurodifuso es altamente estructurado, es posible definir exactamente cuales componentes del sistema deben ser modificados en el entrenamiento e incluso pueden abrirse términos específicos o reglas individuales. En esta investigación la parte del sistema que fue enteramente sostenida por la *sabiduría* humana fue la variable *Zona* (con sus tres etiquetas). Las demás variables (incluidos todos sus términos) y todas las reglas en el único bloque construido fueron abiertas de tal forma que el entrenamiento completara o corrigiera los aspectos donde no existe suficiente experiencia (conocimiento) o donde esta erudición pudiera ser derivada de los datos.

Al tiempo que se desarrolla el entrenamiento, el sistema se optimiza de acuerdo con el error entre los valores estimados y los propuestos de prueba; sin embargo, y en contraste con las redes neuronales, el resultado del entrenamiento es un sistema de lógica difusa que puede ser optimizado *a mano*. La optimización *en línea* (cerrado el entrenamiento se propone un ejemplo de prueba y se ajustan los valores de los términos y de los grados de soporte de tal forma que se cumplan las condiciones que impone ese ejercicio en particular) permitió la corrección de algunos valores de variables para *típicos* que causaban que el sistema se *atascara* (generación de mismos valores de salida para valores de entrada distintos) en algunas importantes evaluaciones.

A continuación se describe el sistema de lógica difusa “puro” resultante, que puede ser implementado en microcontroladores, PC's, estaciones de trabajo e incluso en controladores tipo PLC (*Programmable Loop Controller*) y PAL (*Programmed Array Logic*).

Funciones resultado del Entrenamiento:

- **Profundidad Z**

Superficial. Propuesta como función *triángulo* fue modificada a función *hombro* con lo que se otorga el valor de pertenencia UNO a la cota 0+0.00 (superficie). El valor típico continúa hasta cerca de 10 m y a partir de este valor la membresía disminuye a CERO más allá de los 25 m. Resulta lógica esta nueva definición si se piensa que no crece la pertenencia a la *superficie* conforme se avanza en la columna estratigráfica, sino al contrario. El hecho de que exista un rango entre los 0 y casi 10 m donde las profundidades son típicamente superficiales es congruente con los espesores de costra en algunas zonas del valle.

Formación. Esta función se mantiene como *triángulo* y sigue otorgando el valor de pertenencia CERO al rango 0→casi 10 m. A partir de este valor la pertenencia crece gradualmente hasta encontrar el valor típico UNO poco antes de los 30 m, al mismo tiempo que se deja de ser *superficial*, esta es una modificación mínima en la definición numérica pero importante desde el punto de vista de modelado. Antes la pertenencia a este término se anulaba a los 50 m, después del entrenamiento se reconoce que deja de ser *Formación* a los 40 m y la pendiente derecha del triángulo cambió de tal forma que después de los 32 m la membresía a la serie arcillosa superior es menor de 0.5.

Profundo. Definida como función *hombro* mantiene el valor de pertenencia CERO en el rango 0→casi 25m. A partir de este valor la membresía crece gradualmente hasta encontrar el valor típico UNO cerca de los 40 m. Igual que en las funciones propuestas, el inicio del término profundo se localiza en el punto típico de la etiqueta formación, pero el sistema entrenado considera que este mismo punto (26.5 m) es la frontera de pertenencia a los estratos *superficiales*.

- **Resistencia q_c**

Blando. Definido inicialmente como función *triángulo* después del entrenamiento se convierte en función *hombro* con valor de pertenencia UNO en el rango de 0→casi 100 t/m². A partir de este valor la pendiente decreciente del medio trapecio es casi vertical –entre 100 y hasta cerca de 105 t/m² pasa de $\mu = 1$ a $\mu = 0$ –(la verticalidad indicaría una frontera cerrada).

Medio. La modificación de la función se llevó a cabo en la parte izquierda del *triángulo* que ahora presenta una frontera casi cerrada con el término que le antecede (*Blando*). Compartiendo la misma pendiente (invertida) que el extremo derecho de la función *hombro* que le antecede, otorga el valor de pertenencia UNO a las 105 t/m², desde donde decrece la membresía hasta hacerse nula a las 264 unidades. A partir de este valor la pertenencia permanece en CERO hasta el límite de operación del sistema. Si se analizan las fronteras casi verticales de las etiquetas *Blando* y *Medio*, se puede decir que el sistema finalmente considera que los materiales con resistencias de 0 a casi 100 t/m² son típicos de una etiqueta *nueva*, a partir de este rango decrece la pertenencia hasta anularse en 264 unidades, justamente cuando se alcanza la resistencia típica de un material *Firme*. El sistema trabaja realmente con tres etiquetas en lugar de cuatro como inicialmente se propuso. Esta fusión será llamada: término *Blando-Medio*.

Firme. La función *triángulo* inicial es expandida hacia la izquierda y se recorre el punto de arranque a 105 t/m². El valor típico disminuye 110 t/m² y a partir de este valor desciende hasta alcanzar CERO poco después de las 500 t/m², manteniéndose así hasta el límite de operación del sistema. Esta modificación se debe a la “nueva” etiqueta (*Blando-Medio*) y a la necesidad de generar, para suelos firmes, un típico menos lejano de los valores de resistencia para suelos blandos.

Roca. La función *hombro* se mantiene casi con el mismo rango de resistencias con valor típico de UNO (de 500 t/m² hasta el límite de operación del sistema). El cambio sucede en la pendiente creciente. Inicia en la nulidad de la etiqueta *Medio* y crece sobre la parte derecha de la etiqueta *Firme*. En la distribución propuesta se definió el rango [300-400] como valores propios de terreno *Firme*, no apropiados para ubicarlos en la etiqueta *Roca*. El sistema, al contrario, reconoce que el valor típico de *Firme* es correcto, pero cualquier otra resistencia en la base de la variable dentro del triángulo *Firme*, podrá pertenecer a otro término en cierto grado.

Es decir, para ambos lados del triángulo *Firme* existe la pendiente inversa, del lado izquierdo con *Medio* y del lado derecho con *Roca* (por ejemplo, 200 t/m² son 0.5-*Medio* y 0.5-*Firme*, mientras que 400 t/m² es 0.5-*Firme* y 0.5-*Roca*). Esto es una indicación de la existencia de patrones que requieren una explicación adicional de las relaciones entre resistencias, materiales y velocidades con las variables *Z* y *Zona*.

- **Velocidad V_5**

Baja. Definida como una función triángulo con una base de 200 m/s, después del entrenamiento neuronal se convierte en una función triángulo mucho más estrecho con una base de 11 m/s. A partir del típico alrededor de los 5 m/s, la membresía decrece gradualmente hasta CERO cerca de los 20 m/s. A pesar de este corto rango de operación esta etiqueta se mantuvo dentro del sistema (una posibilidad era su eliminación) y las reglas de operación asociadas a ella mantienen grados de soporte lejos del cero.

Media. La función triángulo ahora otorga el valor de pertenencia CERO al rango 0→5 m/s desde donde comienza a crecer la membresía hasta alcanzar el típico cerca de los 20 m/s. De 20 a 400 m/s el valor de pertenencia descende y permanece en CERO hasta el límite de operación del sistema (700 m/s). Es importante señalar que esta función recorrió su típico de 200 a 20 m/s pero extendió su base de operación de 200 a 400 m/s.

Alta. Esta función triángulo se define ahora con pertenencia CERO entre los 0 y casi 20 m/s desde donde comienza a crecer la membresía hasta alcanzar el típico a los 400 m/s. Al contrario de las funciones propuestas, la etiqueta *alta* opera hasta el límite del sistema.

Muy alta. Definida como función hombro es modificada a función triángulo con una frontera casi vertical cerca del límite de operación del sistema (700 m/s). Otorga el valor de pertenencia CERO al rango 0→casi 400 m/s. A partir de este valor la membresía crece gradualmente hasta encontrar el valor típico UNO poco antes de los 700 m/s. La pertenencia y límite casi vertical en los 700 m/s ejemplifica la condición extrema de este rango de velocidades, es decir, para ser considerada realmente alta debe ser ≈ 700 m/s, de otra forma puede pertenecer (en grado significativo) a la etiqueta *Alta*.

Si se observan las funciones modificadas se puede concluir que las velocidades *bajas* están bien acotadas por un rango muy estrecho (comparado con la dimensión de la base de variable) que hacia la derecha de este rango los valores no manifiestan una caracterización más detallada y que el extremo de operación con una frontera vertical indica que los patrones con valores cercanos a 700 m/s son típicos de una función triángulo isósceles cuya rama derecha se extiende más allá de los 700 m/s (no se puede pensar que la pertenencia de, por ejemplo, 710 m/s al término *Muy Alta* pueda ser CERO).

- **Bloque de Reglas**

El bloque de reglas contiene la estrategia de control del sistema de LD. Cada bloque confina todas las reglas para un mismo contexto. Un contexto está definido por las mismas variables de entrada y de salida. La parte “Si” de las reglas describe la situación para la cual se diseñaron las reglas. La parte “Entonces” describe la respuesta del sistema en operación. El grado de soporte (DoS) se usa para dar peso a cada regla de acuerdo con su importancia.

En esta investigación, el procesamiento de las reglas comienza con el cálculo de la parte “Si” con el operador MIN-MAX (el operador MIN es una generalización del Y boleano, mientras que el MAX lo es de O). La composición difusa (acción que combina las reglas para conseguir una conclusión) se desarrolla con el método MAX para que sólo las reglas dominantes sean evaluadas.

Todas las reglas del sistema “vacío” inician con nulo grado de soporte (DoS = CERO), lo que significa que el entrenamiento afectará mayormente a las reglas que tienen influencia significativa sobre el comportamiento global del sistema. Ejemplos de las reglas y los grados de soporte (después del proceso neuronal) se muestran en la Fig. 5.14

Profundidad Z		Resistencia q_c	Zona	DoS	Velocidad V_s
Superficial	Superficial	Blando	Lago	0.98	Baja
Superficial	Superficial	Blando	Lago	0.80	Media
Superficial	Superficial	Blando	Centro I	1.00	Baja
Superficial	Superficial	Blando	Centro I	0.70	Media
Superficial	Superficial	Blando	Centro II	0.48	Baja
Superficial	Superficial	Blando	Centro II	0.41	Media
Formación	Formación	Medio	Lago	1.00	Baja
Formación	Formación	Medio	Lago	1.00	Media
Formación	Formación	Medio	Centro I	0.00	Alta
Formación	Formación	Medio	Centro I	0.29	Muy Alta
Profundo	Profundo	Blando	Centro I	0.00	Baja
Profundo	Profundo	Blando	Lago	0.00	Baja
Profundo	Profundo	Roca	Centro II	1.00	Alta
Profundo	Profundo	Roca	Centro I	0.95	Muy Alta

Figura 5.14 Algunos ejemplos de grados de soporte (DoS) obtenidos por entrenamiento neuronal para las reglas construidas en el sistema *vacío* original (mayor DoS, mayor influencia en las evaluaciones)

SALIDA

Un modelo, como conjunto de relaciones que se usan para representar de forma sencilla una porción de la *realidad* empírica, se construye para lograr consistencia con una base de datos. La consistencia entre los datos y el modelo no implica la consistencia entre el modelo y la *realidad*. Lo único que se puede afirmar es que las suposiciones del investigador no son contradictorias y por lo tanto pueden tomarse como válidas. Pero esta validez no significa que sean la única explicación del fenómeno objeto de estudio, ni que expresen suficientemente todos los comportamientos pertenecientes a la *realidad* estudiada. Bajo este contexto, ¿cuáles son las ventajas de usar un análisis de regresión sobre las operaciones difusas o viceversa?

El objetivo de una regresión matemática es analizar un modelo (función matemática) que explique el comportamiento de una variable (endógena, explicada o dependiente) utilizando la información numérica de un conjunto de variables (explicativas, exógenas o independientes). Los coeficientes (parámetros) denotan la magnitud del efecto de las variables explicativas, esto es, representan los pesos de la regresión o de la combinación de las predictoras sobre la variable explicada.

A pesar de que superficialmente la aplicabilidad de estos métodos resultaría ilimitada, cuando se adaptan a fenómenos *naturales* se debe tomar en cuenta que: 1) la asociación no implica causalidad, es decir, que exista una fuerte asociación entre dos (o más) variables no es suficiente para obtener conclusiones sobre relaciones causa→efecto, 2) la *exploración* de los datos no implica la *confirmación* de teorías; los parámetros asociados pocas veces tienen significado físico y los funcionales matemáticos son *rígidos* y poco *robustos* lo que hace muy probable que cuando las predicciones del modelo resulten absurdas la estructura matemática (y sus hipótesis) tenga que desecharse, y 3) los resultados de este tipo de análisis proporcionan una buena indicación del comportamiento simplificado de los individuos en la base de datos, es decir, gran cantidad de conocimiento debe ser obviado para *obligar* a datos particulares a ajustarse a planteamientos preconcebidos.

Por otro lado, el beneficio sustancial de la LD es la posibilidad de describir el comportamiento del sistema con relaciones simples Si→Entonces. La optimización del comportamiento del sistema de LD se puede hacer directamente a partir del conocimiento del ingeniero (o experto en el tema) y/o a través de entrenamiento (en esta investigación, neuronal) para extraer la información causa→efecto contenida en datos numéricos y lingüísticos. Un sistema de LD es *flexible* y *poderoso*, la interpretación de la información y las relaciones entre variables (entradas y salidas) es explícita y siempre ajustable. Las estimaciones con el conjunto de reglas y operaciones difusas tienen *significado natural* ligado con la experiencia, lo que trasciende en mejoras inmediatas al conocimiento.

A continuación se presentan perfiles de V_s calculados con el sistema difuso (optimizado neuronalmente) y las funciones semiempíricas de Ovando&Romo (1991) y Jaime&Romo (1988) (descritas en el Capítulo 2). En las mismas gráficas se incluyen las velocidades medidas en campo para sustentar las conclusiones acerca del desempeño (eficiente anticipación al comportamiento *natural*) de las herramientas presentadas.

Ejemplos de estimaciones para sitios incluidos en la Base de Datos de Entrenamiento

- Sitio: **Línea B** (Lago Virgen)

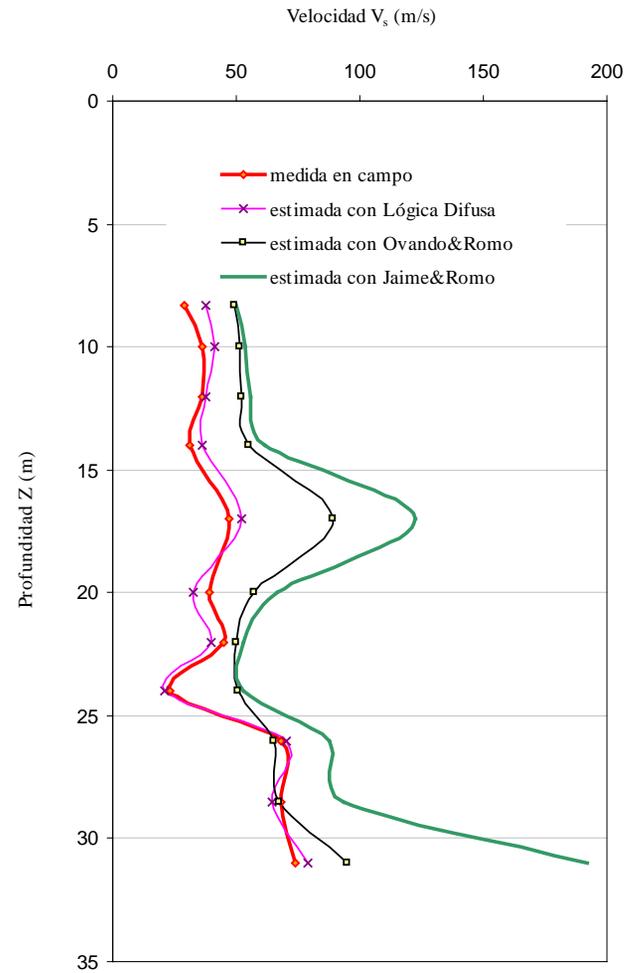


Figura 5.15 Perfiles V_s (medido y estimados) para el sitio Línea B

1. La tendencia en la variación de la velocidad con la profundidad (*casi* constante) es perseguida puntualmente por el modelo difuso a diferencia de los resultados obtenidos con los funcionales semiempíricos (Ovando y Romo, 1991; Jaime y Romo, 1988) que sobreestiman la mayor parte de las V_s y generan máximos de hasta más del 200% de los valores *reales* (Fig.5.15).
2. Uno de los puntos de mayor diferencia entre los valores de V_s medidos y estimados es a $Z= 17$ m ($\gamma= 1.3$ t/m³, $q_c= 100$ t/m² y $V_s \sim 45$ m/s). En los funcionales de Ovando&Romo y Jaime&Romo la magnitud de V_s es directamente proporcional al valor de γ y q_c . Los valores reportados de estas dos variables indican presencia de materiales *firmes*. Numéricamente y de manera *cerrada* los dos funcionales estiman velocidades *altas* pero la velocidad medida es *baja-media*. ¿Los valores registrados de γ y q_c están equivocados?, ¿las velocidades contienen tal grado de contaminación que debiera considerarse equivocado el valor medido durante el ensaye geofísico?. ¿Cuál descripción de material es la correcta, la que se deduce de la propiedad índice y mecánica o la que indica la propiedad dinámica?
3. Para el sistema de LD este patrón, como miembro de *Superficial* y de *Formación* en un mismo grado, con resistencia *Blanda-Media* (ambas en calidad de *típico*) y ubicado en la subzona *Lago Virgen*, activa reglas (mayor DoS) que dirigen el resultado hacia velocidades *Medias* (para zona *L*, resistencias *Medias* y profundidades *Formación* no hay activación *importante* de velocidades *Bajas*). Entonces para el sistema de LD no existen incongruencias entre la propiedad registrada y la descripción del material (V_s *difusa* ~ 55 m/s, velocidad *Media*). La estimación difusa es tan certera (muy cercana al valor medido en campo) porque usa la experiencia sobre estratigrafías del valle, involucra relaciones *naturales* entre las variables y trata con interpretaciones fenomenológicas (Fig. 5.16).

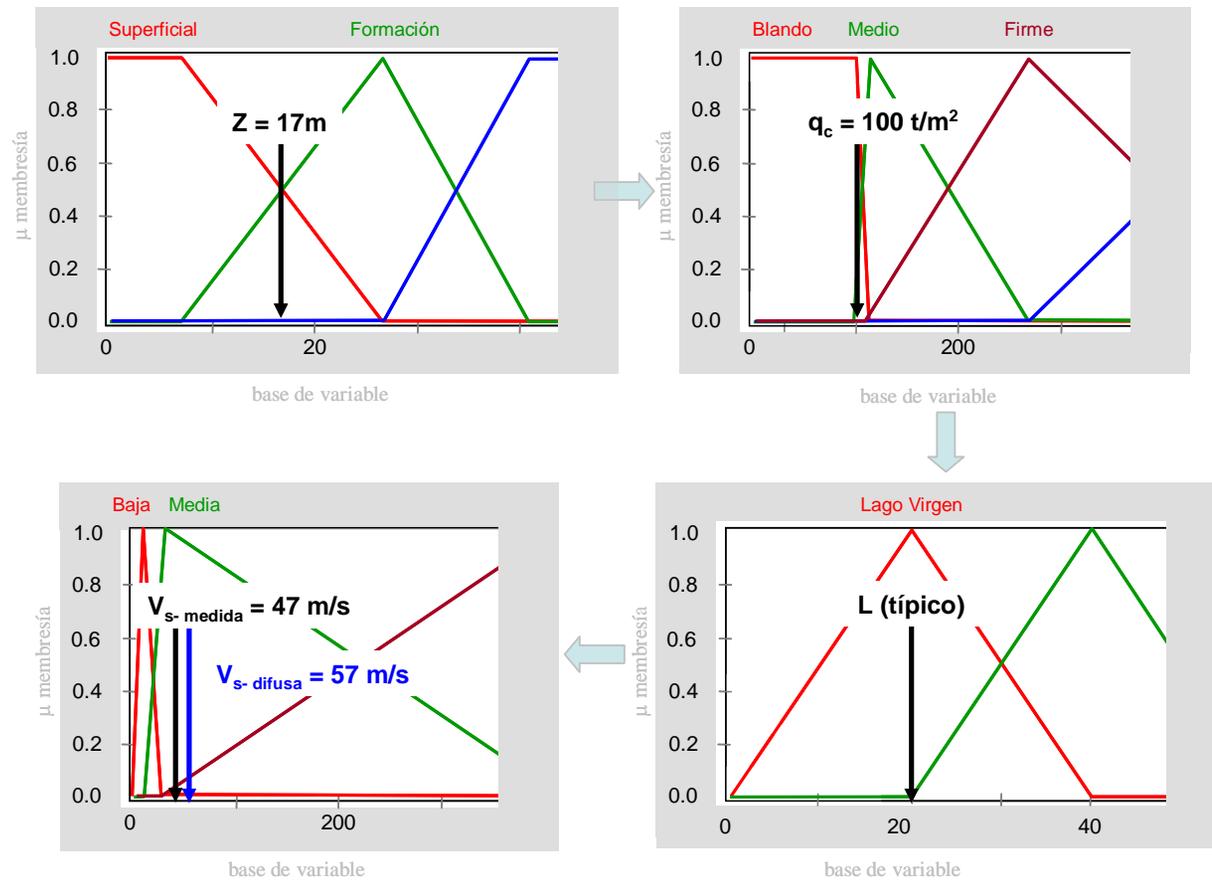


Figura 5.16 Descripción difusa de un patrón de entrada (Sitio: Línea B)

- Sitio: CAF (Centro I)

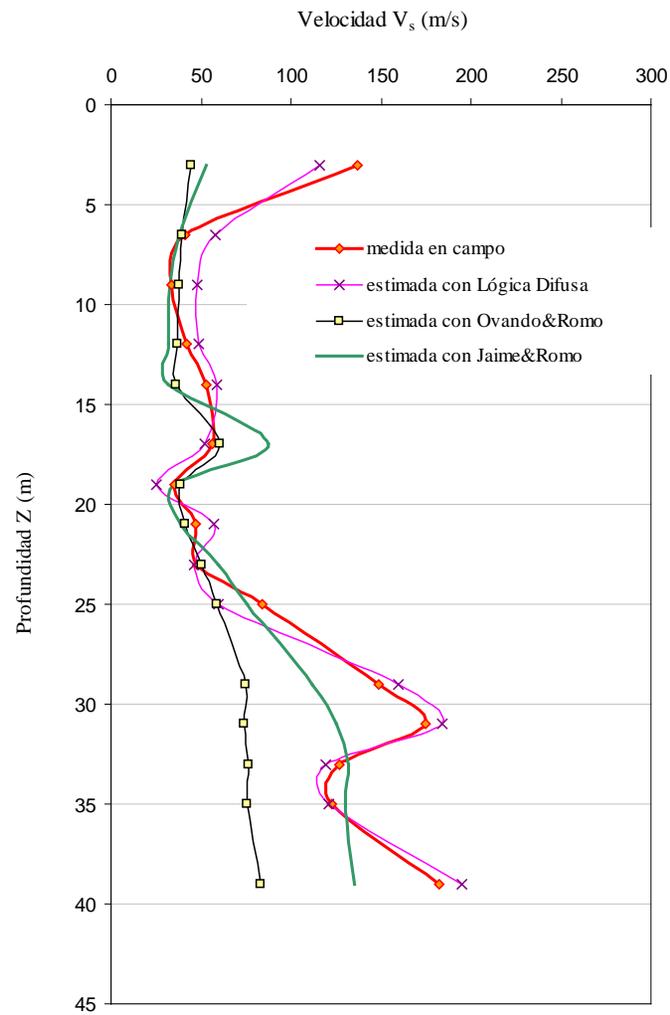


Figura 5.17 Perfiles V_s (medido y estimados) para el sitio CAF

1. Los valores medidos en campo indican la presencia de una capa de material más denso cerca de la superficie y a partir de esta zona un incremento constante de la resistencia (y las velocidades) con la profundidad. El hiperbólico de Ovando&Romo interpreta las variaciones de pesos volumétricos y resistencias con un perfil de velocidades casi constante con la profundidad. En este sitio la función semiempírica de Jaime&Romo persigue mejor la tendencia del comportamiento pero no identifica la costra superficial, ni el estrato más firme alrededor de los 30 m (Fig.5.17).

El primer punto de estimación en el perfil, la costra superficial, reporta las siguientes propiedades:

Z (m)	γ (t/m ³)	q_c (t/m ²)	V_s (m/s)
3	1.3	40	137

Es importante puntualizar que el parámetro peso volumétrico, se usa para identificar materiales en la mayoría de los modelos semi-empíricos que tratan con propiedades mecánicas y dinámicas. Observe cómo para un punto tan superficial el valor de γ es de los más altos sobre su base numérica pero la resistencia medida podría ser catalogada por un experto como propia de un suelo *blando*. Ambos funcionales (Ovando&Romo y Jaime&Romo) son más sensibles al valor de q_c que al de γ así que sus respuestas en términos de V_s son muy similares: velocidades *bajas*.

Sin embargo, la *realidad* es otra. Los niveles de V_s medidos corresponden a materiales *firmes* (costra superficial). De acuerdo con el sistema difuso, la respuesta (conclusión) surge de la combinación de entradas (premisas) que activa con DoS igual a UNO a la regla que estima velocidades *bajas*, con poco menos de UNO la de velocidad *media* y apenas arriba del 10% la de velocidades *altas*.

Si bien, la regla de mayor peso es la de velocidades *bajas* (con típico en ~ 25 m/s), existe la posibilidad de que se active (con DoS alto) la regla que genera una velocidad *media*. El valor medido está próximo a los 100 m/s. La respuesta inicial del sistema de LD (durante las primeras 100 iteraciones del proceso de entrenamiento) rondaba los 50 m/s. Las siguientes 100 iteraciones no mostraron mejoría en las evaluaciones así que se decidió *sujetar* este caso para generar una modificación *en línea* del comportamiento del sistema de LD.

Usando una herramienta gráfica difusa que permite modificar el valor de DoS neuronal con sólo mover la salida dentro del esquema de FMBs de esa variable (se coloca la flecha de resultado donde se necesita y se verifica que estos nuevos valores no afecten mayormente la correlación obtenida en los otros patrones hasta ese momento del proceso de entrenamiento), se *obliga* al sistema cerrado a acercarse a este valor a través de equilibrar los pesos de las reglas cercanas a las activadas. En un primer intento se logró un ajuste más cercano (~ 75 m/s) y a partir de este valor se re-abrieron los componentes del sistema al re-entrenamiento pero se concedió mínima libertad a las reglas modificadas *a mano*, de esta forma el sistema equilibra la modificación de pesos re-evaluando todo el bloque de reglas para verificar que el nivel de error se mantuviera dentro del criterio establecido en el arranque del proyecto.

Finalmente, el sistema incrementó el valor DoS de la regla que involucra a la velocidad *alta* y hubo un pequeño decremento en el DoS de la regla que involucra a los suelos *superficiales*, con resistencia *blanda*, típicos de CI que presentan velocidades *medias* (Fig. 5.18).

Profundidad Z	Resistencia q_c	Zona	DoS	Velocidad V_s
Superficial	Blando	Centro I	1.00	Baja
Superficial	Blando	Centro I	0.70	Media
Superficial	Blando	Centro I	0.20	Alta

Figura 5.18 Extracto del bloque de reglas del sistema de LD *cerrado*

- Sitio: CAO (Centro I)

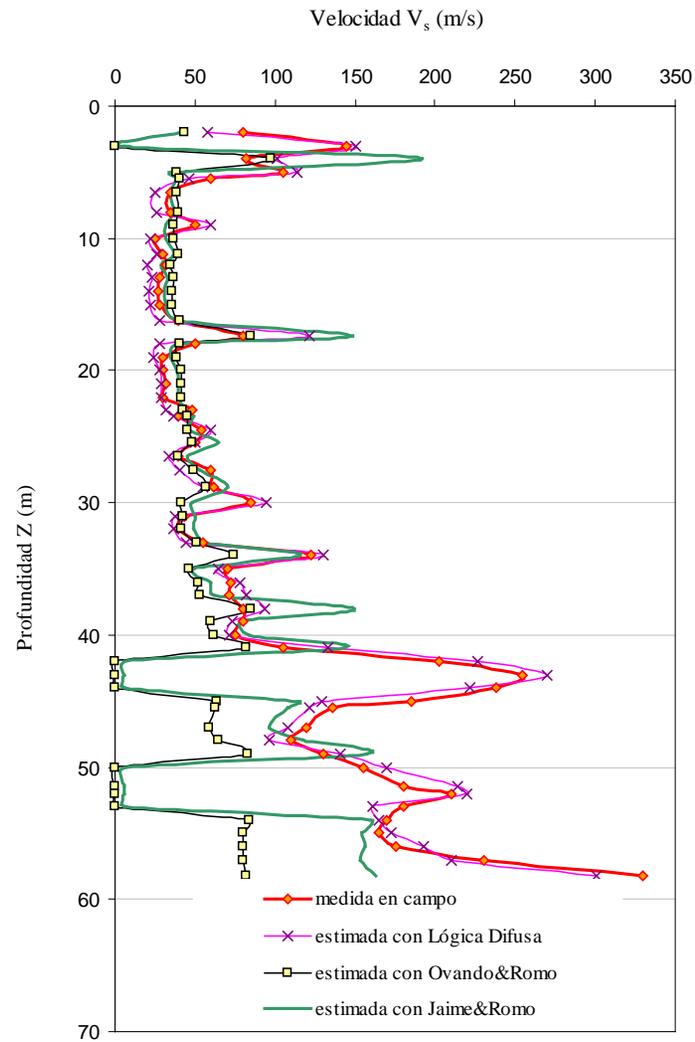


Figura 5.19 Perfiles V_s (medido y estimados) para el sitio CAO

1. Este es uno de los sitios más estudiados en todo el valle y del que se conocen más propiedades para definir su estratigrafía, condición que lo ha calificado como un típico adecuado para desarrollar funcionales (incluidos Ovando&Romo y Jaime&Romo). Si a través de sus relaciones numéricas se determinaron (modificaron) los parámetros asociados a la estructura matemática resulta axiomático que las estimaciones sean cercanas a los valores medidos en campo. Las velocidades en la formación arcillosa son bien evaluadas por los 3 métodos aunque las mayores diferencias se encuentran entre las mediciones y las estimaciones de Jaime&Romo. Acercándonos a los estratos más firmes ambos modelos semiempíricos fallan dramáticamente mientras que el sistema difuso persigue la tendencia de manera adecuada (Fig. 5.19).
2. Atención especial merecen las profundidades donde la prueba CPT indica AVANCE (valores con $V_s = 0$ en el gráfico anterior). Los AVANCES requieren de interpretación y el criterio para determinar su naturaleza contiene diferencias de acuerdo con el grado de experiencia y el nivel técnico del profesional que los analiza. En términos generales, cuando los puntos que anteceden a la profundidad con AVANCE reporten valores de resistencia *bajos*, se considera que el avance se debe a la presencia de suelos *blandos*, por el contrario, si lo anteceden resistencias CPT *altas* se considera que el material es tan *firme* que impidió el paso de la punta cónica. Entonces el ingeniero de la práctica dibuja su perfil como más convenga de acuerdo con estos lineamientos y el conocimiento que se tenga sobre las condiciones estratigráficas del área. La comparación de la actuación entre los tres modelos, en puntos AVANCE, no puede realizarse si se acepta que un análisis de regresión no calcula respuestas donde existan *vacíos* de información por lo que en estas profundidades no existe una estimación *cerrada* de velocidad. Como se observa en la Fig. 5.20, si se tuviera que tomar como válido el valor anterior al AVANCE, la velocidad resultaría demasiado baja, si por el contrario, se tomara el nivel del valor V_s que sigue al AVANCE la velocidad sería sobreestimada. No es práctica común calcular el promedio de velocidades.
3. Analicemos ahora qué sucede en los AVANCES cuando se aplica la LD. En los análisis con “valores desconocidos” es necesario determinar si la no-presencia se debe a una *pérdida* (no se consiguió monitorear el dato por errores en la operación) o si tiene significado físico (la *ausencia* representa un comportamiento propio del fenómeno analizado). En este caso, no contar con valor numérico de la variable q_c y contar con el término lingüístico AVANCE significa *algo* sobre la propuesta fenomenológica.

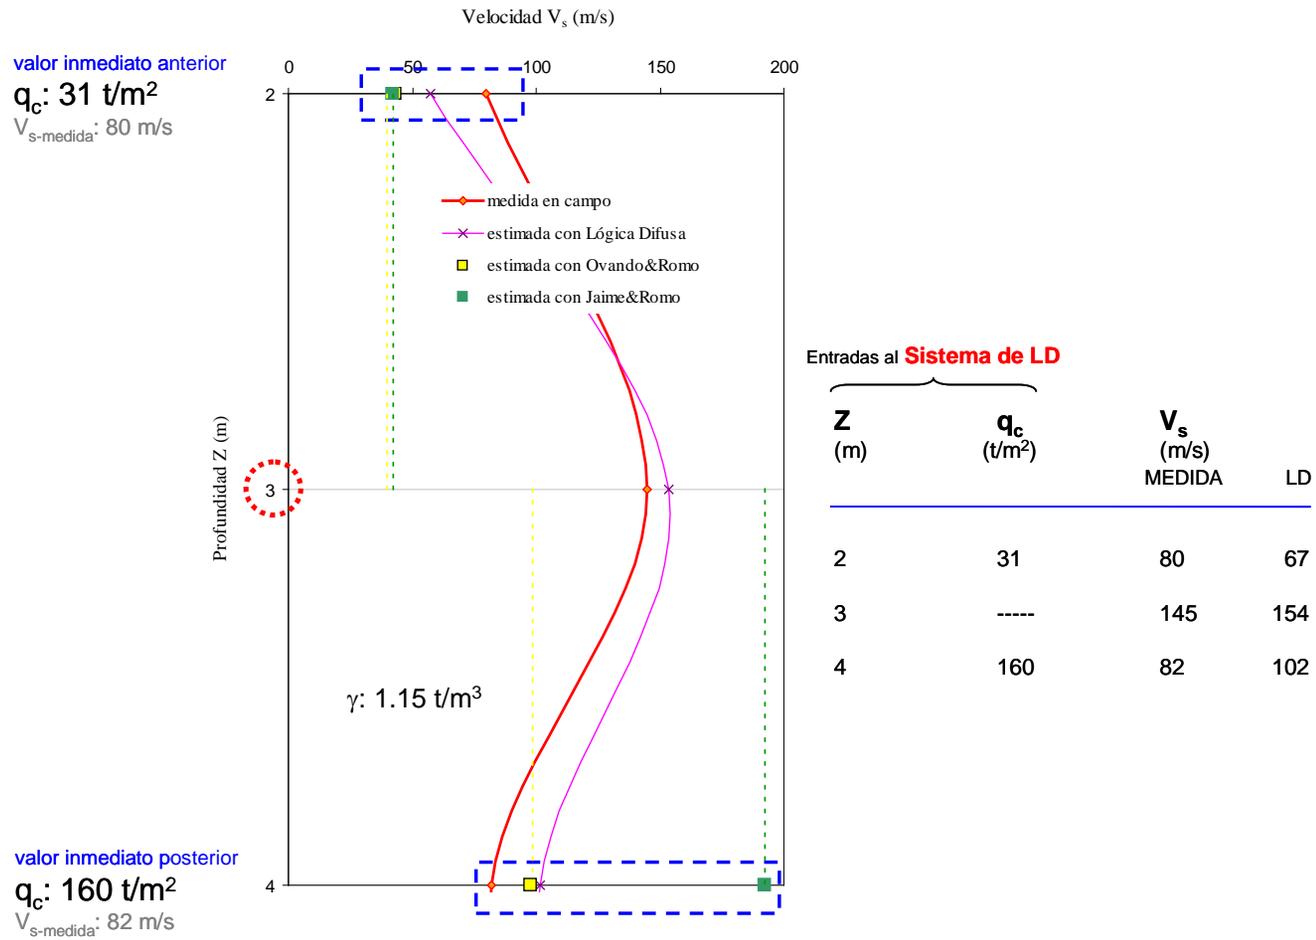


Figura 5.20 Análisis de AVANCE en puntos cercanos a la superficie

Se revisan las reglas activadas por los puntos anteriores y posteriores a la profundidad de avance y a través de las reglas con mayor peso (DoS) se decide sobre el valor más probable de V_s de acuerdo con: las condiciones estratigráficas para esa subzona geotécnica, la profundidad y los materiales que le conforman. Las reglas que fueron analizadas se muestran en la Fig. 5.21. El análisis difuso se dirige conforme el flujo de información mostrado en la Fig. 5.22.

La información contenida en las entradas (mismos valores de pesos volumétricos y diferencias en el valor de Z) indica que a los 43, 52 y 58 m de profundidad se tienen intercalaciones de material firme que alcanzan velocidades de hasta 350 m/s, ¿es esto cierto? (Fig. 5.23). La respuesta podría

ser “no”. Sin embargo, la LD permite, de la misma manera que lo hace el criterio práctico, seleccionar las reglas que se activan en la vecindad de los puntos con AVANCE y reconocer las condiciones (subzona y estratigrafía) para estimar una V_s más equilibrada. ¿Por qué es ventajosa la metodología difusa comparada con la convencional?. Porque la elección es sobre reglas y no sobre valores puntuales. Las reglas constituyen comportamientos y esto significa multidimensión. Las premisas y conclusiones que se usaron para generar el espacio de soluciones constituyen el conocimiento empírico y numérico que sobre el fenómeno se tiene, y la elección de una de estas ligas (Si→Entonces) no significa que las demás no estén actuando al mismo tiempo, una regla nunca es *individuo*, una regla es una parte del bloque que contiene a la estructura y a los parámetros.

Profundidad Z	Resistencia q_c	Zona	DoS	Velocidad V_s
Superficial	Blando	Centro I	0.70	Media
Superficial	Blando	Centro I	0.20	Alta
Superficial	Media	Centro I	0.10	Baja
Superficial	Media	Centro I	0.00	Media

Figura 5.21 Reglas activadas para el análisis de V_s

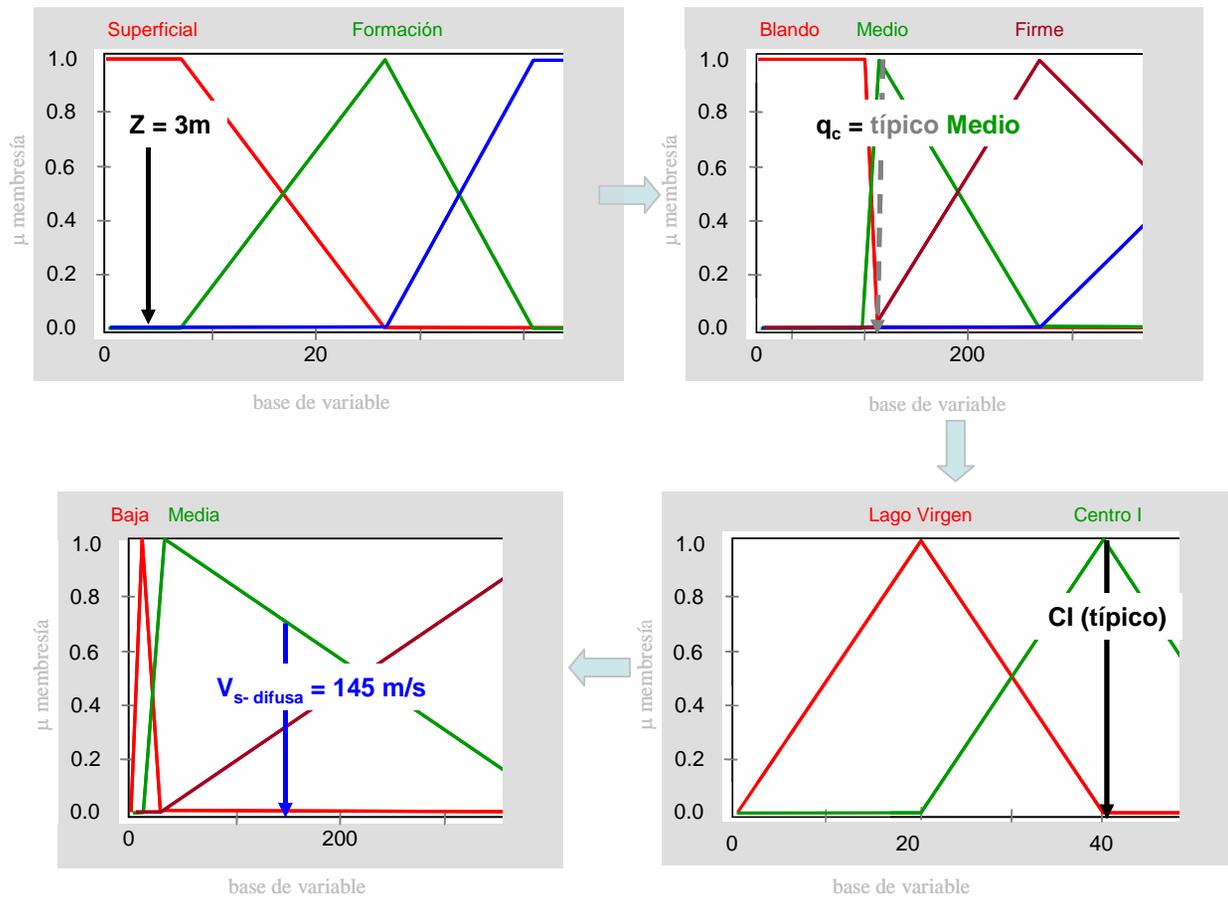


Figura 5.22 Flujo de información difusa para el sitio CAO

Sitio: Av. 510 (Lago Virgen)

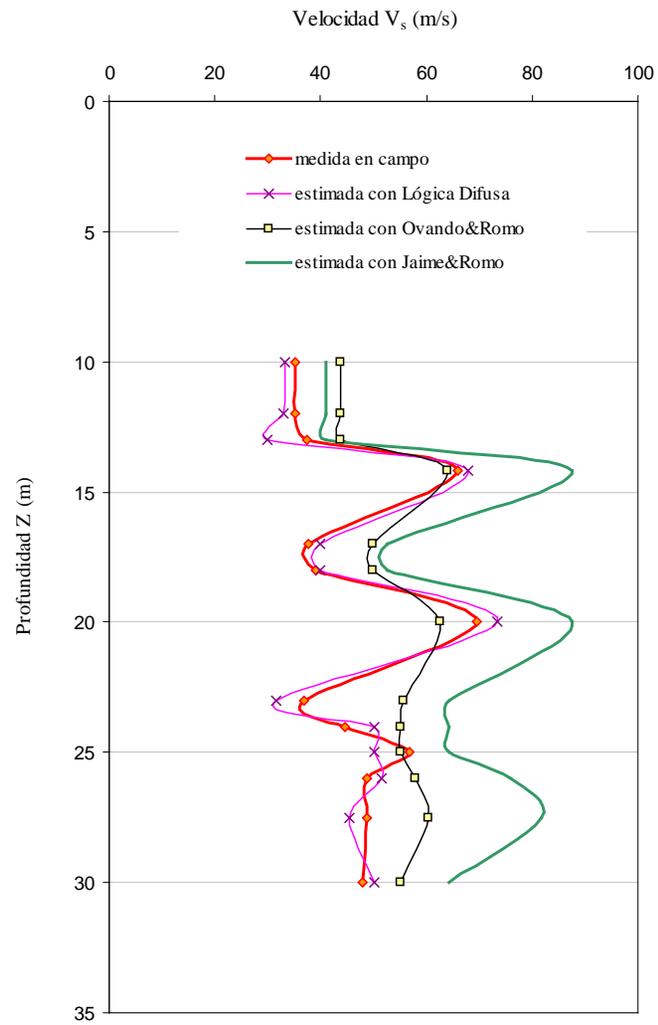


Figura 5.24 Perfiles V_s (medido y estimados) para el sitio Av. 510

1. Los tres modelos consiguen reproducir la tendencia de máximos y mínimos que presenta el perfil medido. El modelo de Ovando&Romo genera un perfil casi constante con la profundidad con sólo un máximo (a 15 m aprox.) producto del alto valor de resistencia reportado en campo para en ese punto. El caso de las estimaciones con Jaime&Romo son más certeras en la ubicación de los máximos y mínimos pero todas las evaluaciones sobrestiman los valores medidos (Fig.5.24).
2. Todos los patrones del perfil presentan resistencias etiquetadas como *blandas*, con profundidades que pasan de *superficial* a *formación* en un sitio típico de subzona *Lago Virgen*. El sistema de LD identifica claramente las intercalaciones de material *un poco* más denso pero no permite que las velocidades alcancen los valores de la siguiente etiqueta (*media*). Esto se debe a que para sitios de la subzona *L*, en este rango de profundidades y resistencias, las reglas activadas con mayor peso sólo tienen valores de salida con etiqueta *baja* (existen activaciones para etiqueta *media*, pero el proceso inverso difuso mantiene la respuesta en el rango de valores señalados).

En la Fig. 5.25 se presentan los comparativos para los restantes sitios incluidos en el archivo de entrenamiento. Para apreciar de mejor manera la remarcable habilidad del sistema de LD en la estimación *inteligente* de valores de V_s se eliminaron de los gráficos los perfiles de los funcionales semiempíricos, sin embargo es necesario puntualizar que las correlaciones más altas entre V_s medido y V_s estimado con Ovando&Romo y Jaime&Romo se consiguieron en los casos anteriormente comentados.

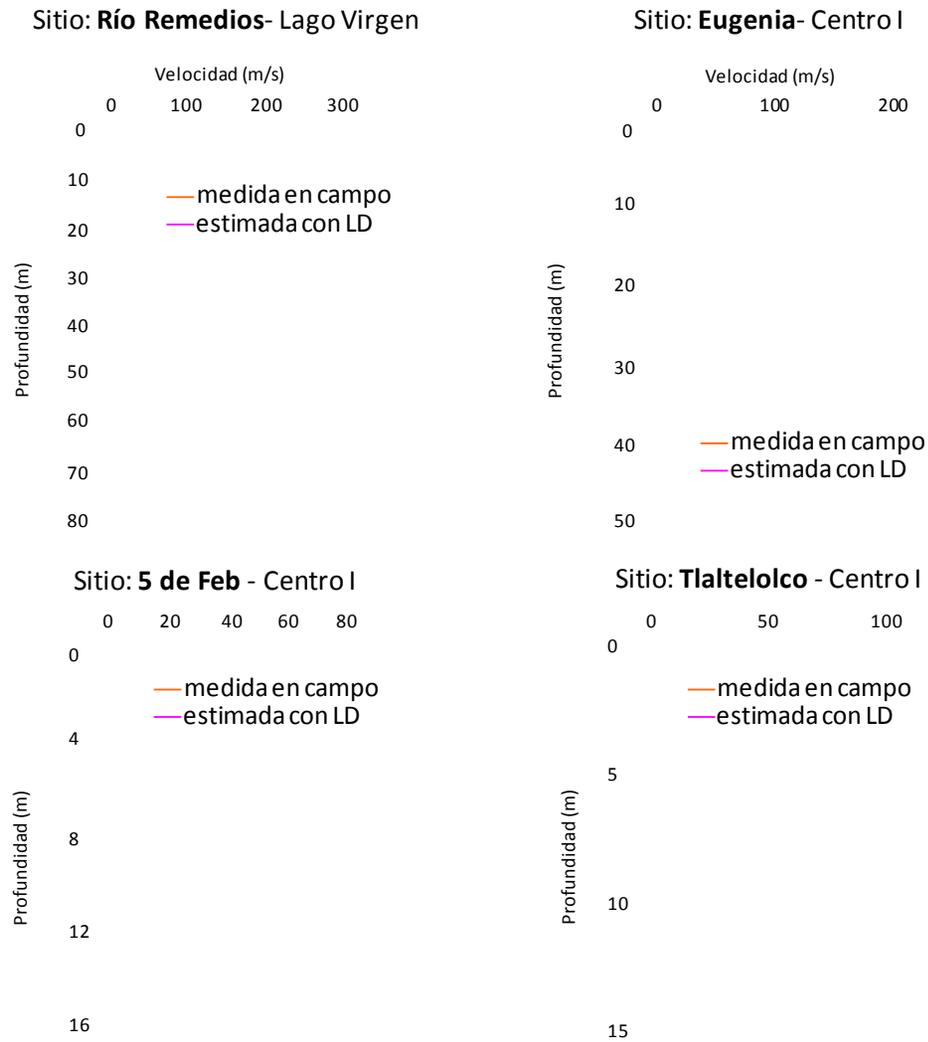


Figura 5.25 Perfiles V_s (medidos y estimados) para sitios incluidos en el archivo de entrenamiento

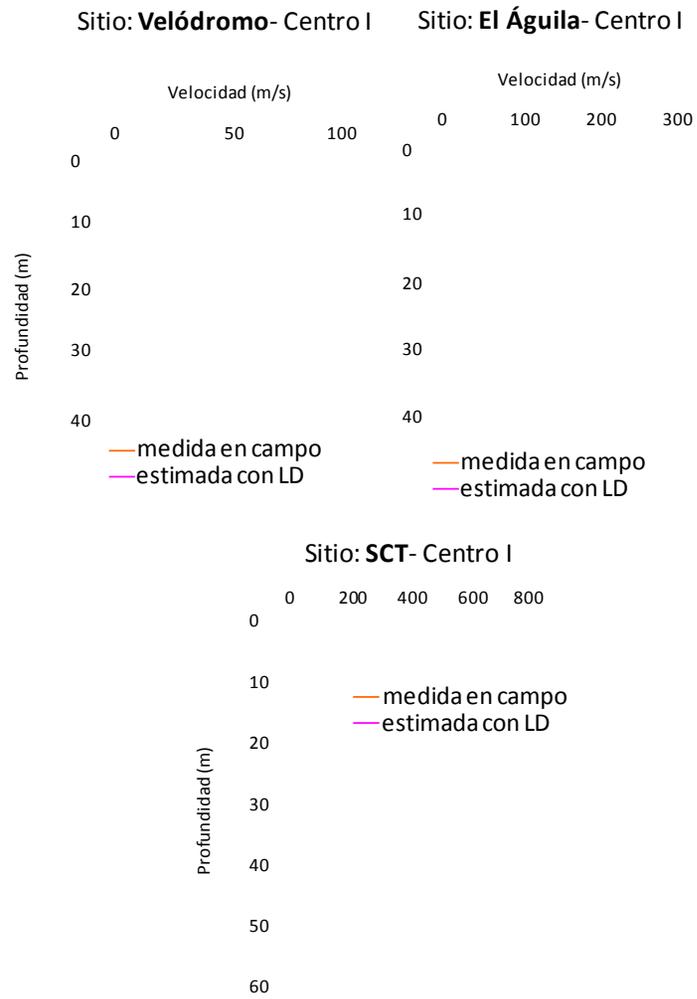


Figura 5.25 Perfiles V_z (medidos y estimados) para sitios incluidos en el archivo de entrenamiento (continúa)

Ejemplos de estimaciones para sitios no incluidos en la Base de Datos de Entrenamiento, etapa de Validación del sistema

- Sitio: Plaza Aragón (Lago Virgen)

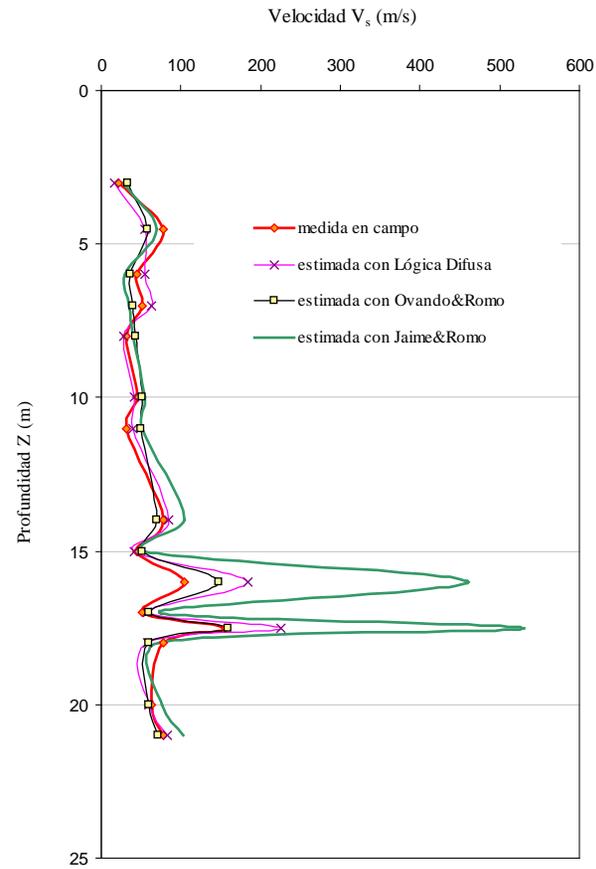


Figura 5.26 Perfiles V_s (medidos y estimados) para el sitio Plaza Aragón

Los patrones que constituyen este perfil no fueron incluidos en la base de entrenamiento por lo que las estimaciones representan casos prácticos de prueba para el sistema difuso, el autor desconoce si fueron sujetos de análisis durante el desarrollo de los funcionales semiempíricos.

1. El conjunto de velocidades *objetivo* es estimado adecuadamente por los tres funcionales en el rango $Z = 3 \rightarrow 15m$, las diferencias por encima de los criterios de ajuste se encuentran a partir de los 15 m (Fig.5.26).
2. En el caso de las velocidades que son sobreestimadas es necesario hacer un análisis adicional. El funcional empírico de Jaime&Romo estima velocidades *muy altas*, típicas de materiales *muy firmes*, debido al valor de resistencia que se obtiene de la prueba CPT en los puntos $Z= 16$ y 17.5 m. La aproximación que logra el esquema

de Ovando&Romo resulta muy adecuada en estas dos profundidades y equilibra los valores de pesos volumétricos con las elevadas resistencias para generar velocidades *medias*. Sin embargo, esta no es la constante de comportamiento para los 19 sitios analizados y el resultado presentado ratifica la manera cómo este funcional (Ovando&Romo) impone una severa restricción de crecimiento en los valores de V_s conforme Z profundiza si no se excede *cierto* nivel de resistencia (ejemplo adicional de este comportamiento en el gráfico del sitio SCT).

3. En el caso de la LD se tiene el siguiente planteamiento de información (Fig. 5.27):

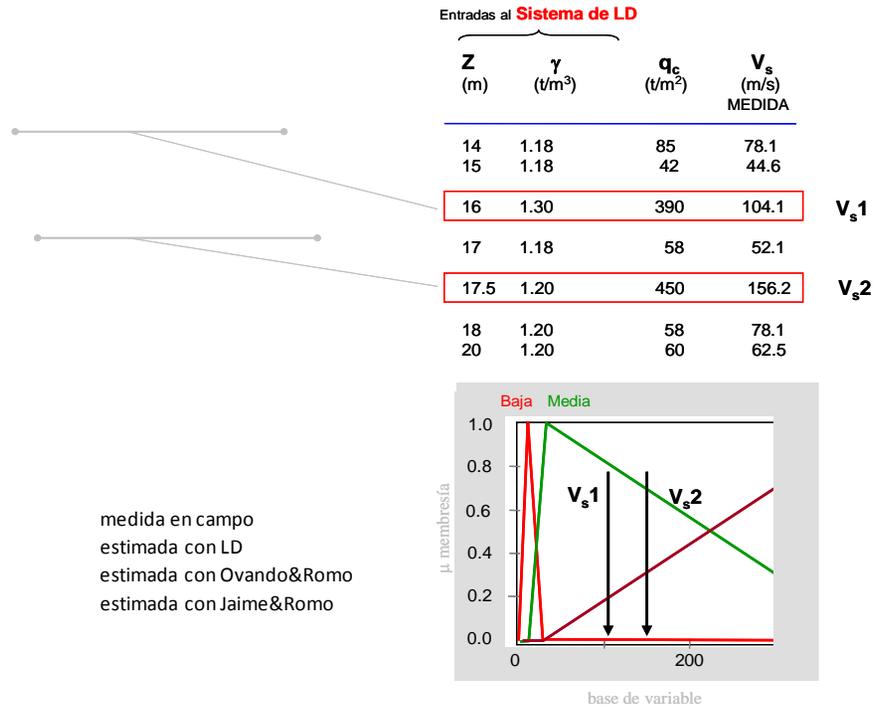


Figura 5.27 Análisis de entradas y V_s (medidas y estimadas)

Como se observa en la Fig. 5.27, los valores de peso volumétrico y de resistencia indican suelos más *firmes* por lo que se espera un gran incremento en la velocidad de acuerdo con las reportadas en Z 's menores. La interpretación difusa de esta evaluación es (Fig. 5.28):

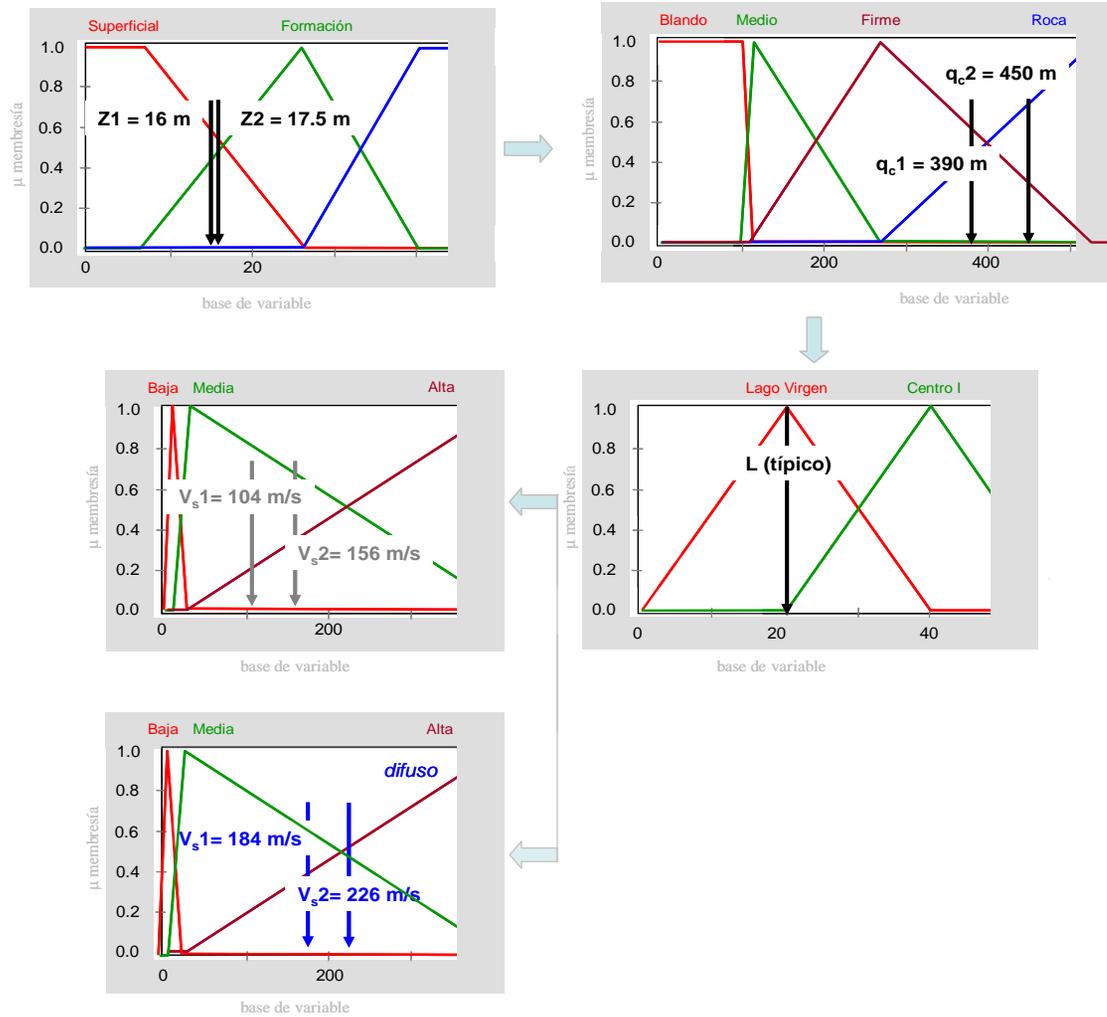


Figura 5.28 Interpretación difusa del cálculo de V_s

Las diferencias entre medidos y estimados con LD tienen una justificación de acuerdo con las descripciones del sitio (profundidades y subzona) y las resistencias de campo. Para suelos que presentan resistencias *firmes*, cercanas a las típicas de *roca*, aún perteneciendo a la subzona L, se activan reglas de comportamiento que dirigen las estimaciones hacia la zona de V_s *medias-altas* (Fig. 5.29). Los valores reportados en campo, tendientes a *bajos*, representan una contradicción numérica cuando se les sitúa en el espacio del **Sistema** (suelos del valle de México). Si bien estas incompatibilidades no son concluyentes, sí requieren de una consideración especial para la definición estratigráfica y la valoración de su respuesta ante carga dinámica.

Profundidad Z	Resistencia q_c	Zona	DoS	Velocidad V_s
Superficial	Firme	Lago Virgen	0.00	Baja
Superficial	Firme	Lago Virgen	0.85	Media
Superficial	Firme	Lago Virgen	0.60	Alta
Superficial	Roca	Lago Virgen	0.00	Baja
Superficial	Roca	Lago Virgen	0.75	Alta

Figura 5.29 Reglas activadas para solucionar la incongruencia entre resistencias y velocidades

- Sitio: CUPJ (Centro I)

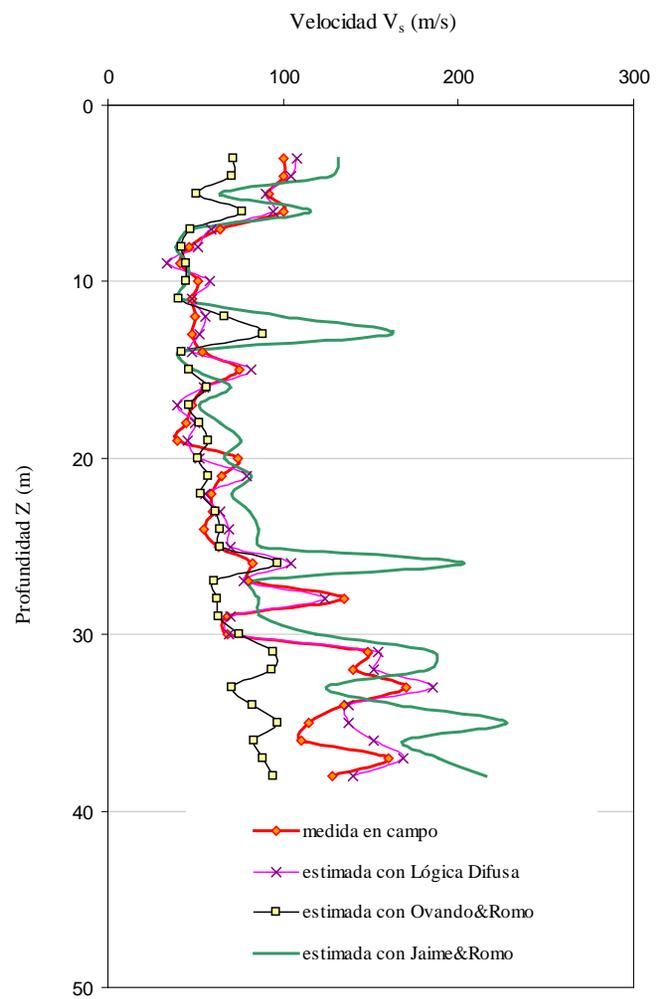


Figura 5.30 Perfiles V_s (medido y estimados) para el sitio CUPJ

1. La capacidad de generalización del sistema difuso y los funcionales empíricos pareciera muy similar cuando se observa el perfil de este sitio. La tendencia en el crecimiento de las velocidades conforme se avanza en la profundidad es reconocida por las tres metodologías. Incluso la formación arcillosa, con velocidades que oscilan entre 40 y 70 m/s, está identificada en la mayoría de los puntos de evaluación con desviaciones que no rebasan el 10% (Fig.5.30).
2. A ciertas profundidades se presentan diferencias entre lo medido y lo evaluado que pueden generar caracterización de materiales completamente diferentes (por lo menos en términos de respuesta dinámica). Observe los valores reportados en la Z más cercana a la superficie (Fig.5.31). El punto A es una subestimación de la V_s medida y significa que este funcional da un mayor peso numérico al valor de q_c mientras que en C se sobreestima la velocidad de acuerdo con un postulado que no equilibra la participación de q_c y γ , significado de la diferencia reportada.

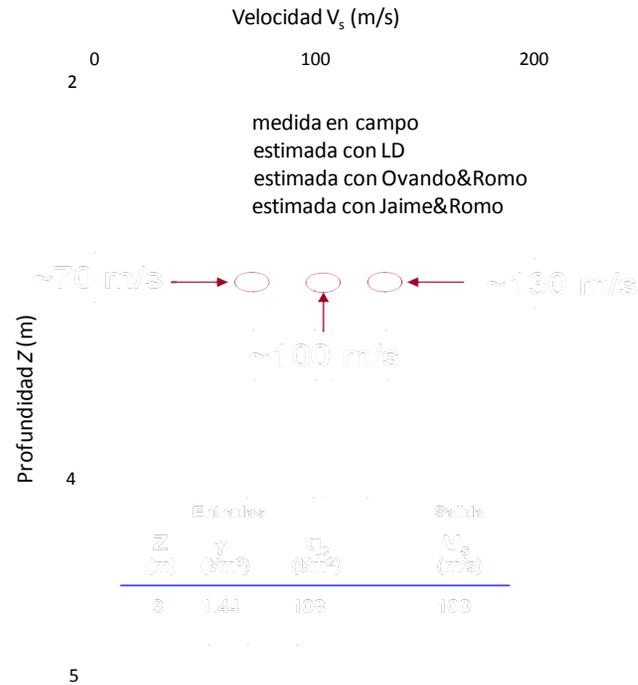


Figura 5.31 Análisis del punto más superficial

Revisemos qué significa este patrón para el sistema difuso (Fig.5.32):

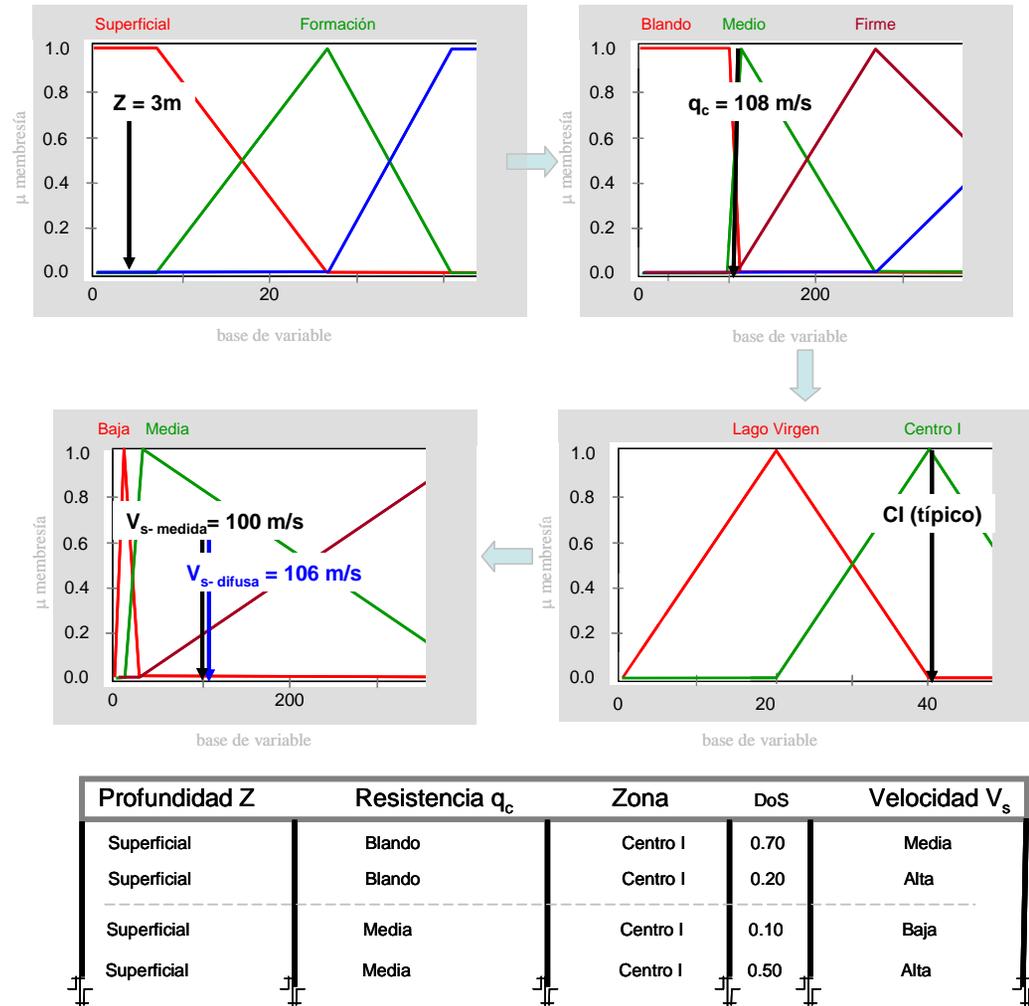


Figura 5.32 Flujo de información para calcular V_s

Siendo un patrón típico de *Centro I, superficial*, con pertenencia casi UNO a las etiquetas de resistencia *baja y media*, activa las reglas que dirigen el valor de V_s hacia valores *medios-altos*. Es notable la capacidad del sistema para mediar entre las características de costra superficial y el nivel de velocidades que un material de este tipo puede alcanzar, conocidas la resistencia y la zona del valle a la que pertenece el sitio. El hecho de que no se incluyan los valores de los pesos volumétricos y se obtengan eficientes resultados es una indicación de la contaminación de esta variable descriptiva (γ) y la dudosa representabilidad cuando tiene que actuar acoplada con otro parámetro más *natural* (medido en campo).

En la Fig.5.33 se muestran las estimaciones para los perfiles restantes del conjunto apartado para la prueba del sistema difuso.

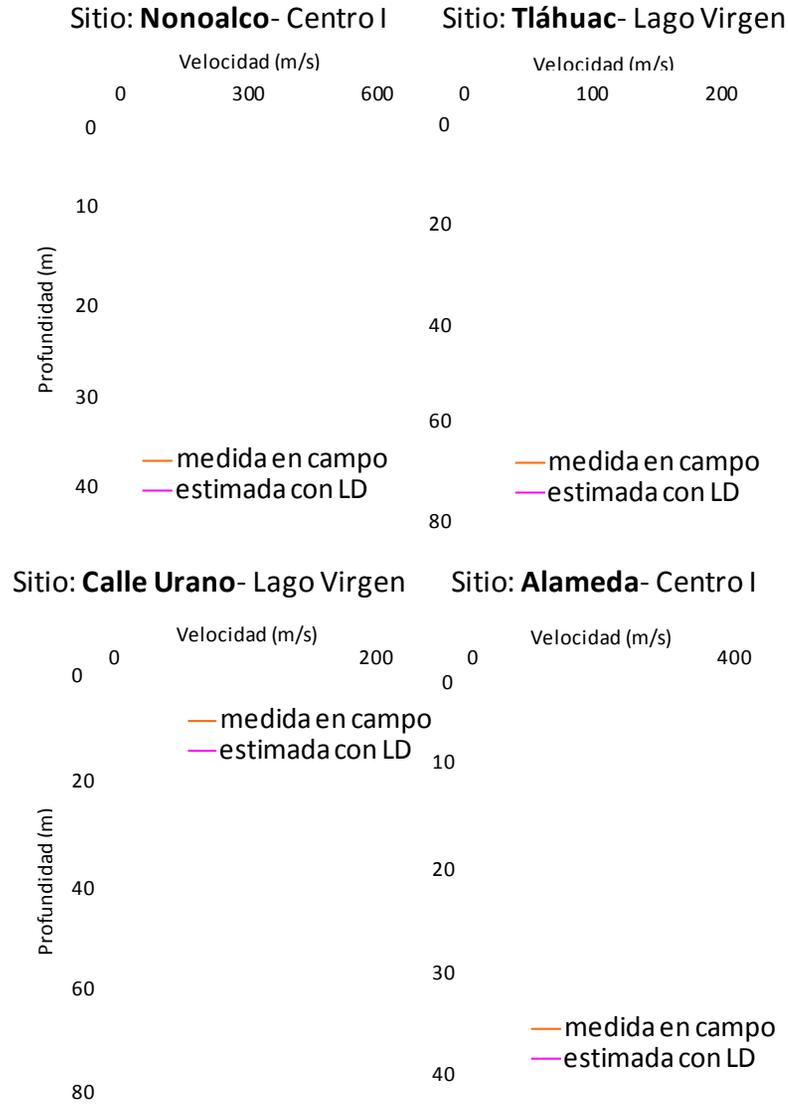


Figura 5.33 Perfiles V_z (medidos y estimados) para sitios no incluidos en el archivo de entrenamiento

Observando estos resultados se concluye que el sistema de LD demuestra ser una ventajosa alternativa para determinar valores de V_s a partir de pruebas de q_c . Si se considera que la estructura difusa es un software para PC que sólo requiere del usuario la declaración de las entradas (aceptando *vacíos* de información) y el ambiente en el que desea se presenten los resultados (gráfico, numérico o lingüístico), el desempeño de esta estructura es considerablemente más ventajoso que el de los modelos semiempíricos. Las mínimas diferencias entre lo medido y lo estimado y el reconocimiento de las variaciones en la velocidad con estimaciones *casi* consecutivas ($\Delta Z = 1m$) ponen de manifiesto la sobresaliente capacidad de generalización del sistema. A diferencia de los otros funcionales (los presentados en los comparativos y la mayoría de los reportados en la literatura sobre el tema), el sistema de lógica difusa sí cumple con las características de un buen modelo matemático:

- Es COMPLETO, es decir, es capaz de elaborar juicios y dictar sentencias sobre comportamientos en todos los estados que conforman el espacio de entradas y salidas.
- Es SIMPLE, es posible identificar los parámetros de trabajo (entradas) del modelo por medio de un número pequeño de pruebas estándar realizadas sobre los materiales.
- Es NATURAL, el modelo está fundamentado en interpretaciones físicas de las respuestas, contiene valores numéricos traducidos a instancias lingüísticas que es la manera en que los humanos reconocemos y aprendemos de nuestro entorno. Las estimaciones difusas tienen siempre una conexión con la experiencia por lo que *crecen* de acuerdo con las mejoras en los procesos de monitoreo y ensaye.

Descripción de la actuación del sistema ante un caso práctico:
Línea de Transmisión Chapingo-Lago

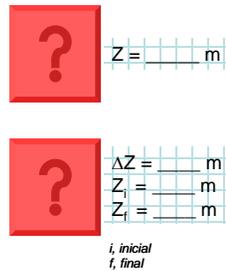
- Entradas:

1. Valor(es) de Resistencia (q_c). Seleccione la opción

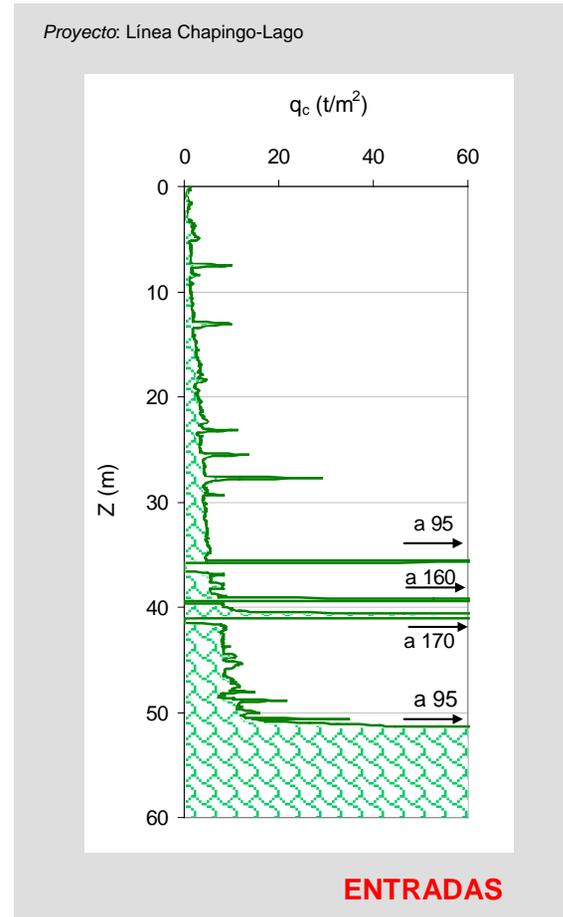


En el caso PUNTO aparece la pantalla para escribir el valor de q_c . En el caso VECTOR el usuario tiene oportunidad de *examinar* sus archivos para cargar la columna de resistencias o bien, declarar la existencia de un dispositivo acoplado a la PC (donde está instalado el sistema) a través del cual se harán las lecturas *en línea* (monitoreo de la prueba CPT en tiempo real, por ejemplo).

2. Profundidades asociadas a cada q_c .



Dependiendo de la opción elegida en el punto 1 aparecerá la opción para el valor puntual de Z o la opción que permite definir los límites y espaciamiento del nodo contador (nodo profundidad). En el caso que nos ocupa (sondeo localizado sobre la línea de transmisión Chapingo-Lago, Lago de Texcoco) se eligió la opción vector y se cargó información para hacer crecer Z desde los 2 a los 51 m de profundidad con un ΔZ de 1 m. La pantalla “perfil entradas” se presenta a continuación:



3. Subzona Geotécnica

En este apartado el usuario puede elegir entre

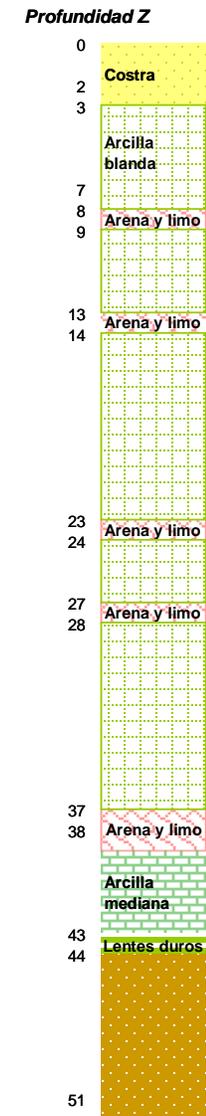


AYUDA



SUBZONA

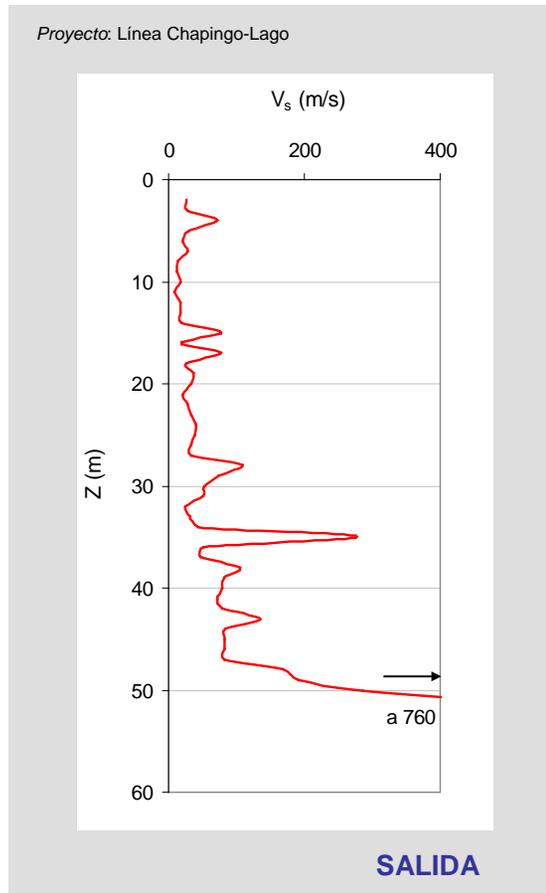
En el icono SUBZONA se requiere la declaración en términos lingüísticos [*típico de la zona o entre la zona - y la zona --*] de la pertenencia a alguna de las tres subzonas que aparecen en pantalla (ver Fig.5.3). El sistema traducirá numéricamente el término indicado. Cuando se elija AYUDA el sistema permite al usuario el cálculo de las tres opciones típicas (L, CI y CII) o bien, que se *cargue* una estratigrafía (descripción de materiales y profundidades) y gráficamente se compare con las típicas de cada subzona. Para el ejemplo analizado se tiene el siguiente reporte estratigráfico:



Cuando se realiza la comparación entre esta columna (además del comparativo entre el perfil de resistencias del sitio y los declarados como típicos en la Fig.5.2) y las almacenadas en la memoria del sistema difuso como propias de cada subzona, se concluye que el sitio tiene características de *Lago Virgen* y *Centro I* en igual proporción. Así, por medio de un análisis más conciente se puede seleccionar el valor numérico más adecuado para la variable *Zona* (=50).

- Salida:

La estimación reportada para el sitio Línea Chapingo-Lago, considerando un vector de profundidades (de 2 a 52 metros) al que se le asocia un vector de resistencias (con un máximo de 170 t/m²) y considerándole un sitio típico de *L* en la misma proporción que de *Cl*, es la siguiente:



Por ser este un sitio del que no se conoce con certeza su pertenencia a alguna subzona, como un ejercicio numérico se realizó una revisión de resultados para los tres casos típicos: L (*Zona=20*), CI (*Zona=40*) y CII (*Zona=60*). No se observa variación importante cuando se comparan los perfiles de velocidades para CI y CII, mientras que sí existen diferencias entre CI y L. Cuando se compara el perfil que pertenece a ambos subgrupos ($\mu_{CI} = 0.5, \mu_L = 0.5$) con el que sólo pertenece a uno de ellos se encuentran importantes diferencias en la localización del estrato firme.

Las conclusiones sobre el efecto mínimo de declarar pertenencia a CI o CII sobre los resultados de velocidades son consecuentes con algunos hallazgos durante la construcción y prueba del modelo difuso, pero es necesario realizar estudios con más sitios que pertenezcan a ambas zonas (la base de datos contiene 3 sitios de CII y 9 de CI) para poder ratificar la deducción sobre la existencia de sólo dos subzonas geotécnicas dentro de la zona del Lago, la Virgen y la Centro.

Aquí terminaría el análisis con el sistema difuso, sin embargo, para este sitio se cuenta con el perfil de V_s . En la Fig.5.34 se presentan los valores medidos en campo y su comparación con los estimados con lógica difusa para demostrar cómo la sencillez de operación y análisis no disminuye las habilidades predictivas del sistema.

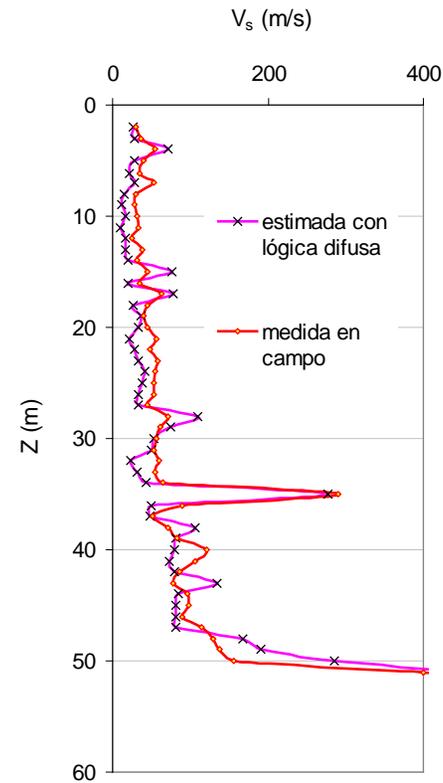


Figura 5.34 Resultados del sistema difuso para un ejemplo práctico

Estimación de G y λ

A continuación se presenta el esquema neuronal que modela la reducción de la resistencia al corte y el incremento del amortiguamiento del suelo arcilloso del valle de México y que completa la caracterización dinámica propuesta en este inciso de resultados.

Teniendo en cuenta las características del proceso empírico de creación de modelos, el planteamiento para obtener el módulo de rigidez al corte G y la relación de amortiguamiento λ en un rango de deformaciones por corte $\gamma\%$ útil en la práctica ingenieril, contiene:

- SISTEMA: Arcillas plásticas típicas del valle de México
- PROCESO: Reducción/Incremento de la/el resistencia/amortiguamiento por carga dinámica
- ENTRADAS (datos): Índice de plasticidad de la masa del suelo I_p y un vector de deformaciones $\gamma\%$
- MODELO: Red Neuronal RN
- SALIDA (resultados): $(G, \lambda) = f(\gamma\%, I_p)$

Es importante recordar que las relaciones empíricas, comúnmente usadas en ingeniería geotécnica para correlacionar propiedades, tienen como propósito estimar valores, necesarios en análisis y diseño, por medio del uso de alguna propiedad índice que sea relativamente más barata y más fácil de obtener. Si efectivamente existe una relación entre las propiedades, esto ofrece una manera eficiente (por lo menos económicamente hablando) de obtener los parámetros de suelo requeridos. La mayoría de las veces las relaciones empíricas están muy lejos de la perfección y las incertidumbres asociadas con estas aproximaciones difícilmente pueden ser cuantificadas para establecer la verdadera confianza sobre los métodos y sus resultados. De ahí la importancia de la generación de herramientas *inteligentes* que permitan trabajar en marcos de indeterminación paramétrica (conceptual y numérica) y que representen modelos estándar, aseguibles y prácticos.

La Fig. 5.35 muestra la aproximación de dos relaciones hipotéticas que han sido establecidas a partir de datos. Claramente, el uso de la relación A resultaría más confiable. Pero un ingeniero podría estar condicionado al uso de la relación B. ¿Cómo puede medir la consistencia de la función?, ¿la confianza en B puede ser mejorada si se incrementa el número de pruebas (directas o indirectas) usadas en la construcción del funcional?, ¿por cuánto?, ¿cómo puede decidir sobre la descalificación de alguna expresión (función matemática) bajo ciertas exigencias de estudio?.

Este tipo de dilema es propio del análisis y estimación de propiedades dinámicas. Sin intentar dar respuesta a los cuestionamientos anteriores (muy difícil en este *incierto* escenario teórico-práctico) el módulo neuronal presentado a continuación ejemplifica una aproximación robusta, flexible y de fácil comprensión, para la estimación preliminar de los parámetros G, λ dependientes de $\gamma\%$.

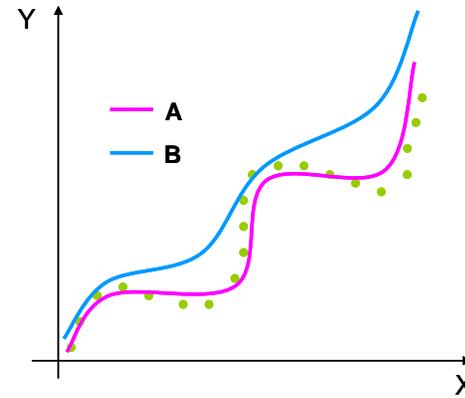


Figura 5.35 Ejemplos de funciones construidas a partir de datos

El siguiente planteamiento neuronal trata de cubrir respuestas generales y bajo ninguna circunstancia busca interpretar y concluir sobre lo acertado de expresar el complejo comportamiento dinámico de los suelos a través de dos parámetros (G, λ) ni ponderar el uso de las RNs sobre algunas otras herramientas o funcionales matemáticos. A través de la descripción de su construcción y su aplicación sobre algunos sitios estudiados con el módulo neurodifuso $V_s = f(q_c, Z, Zona)$, este esquema conexionista se ratifica como una buena alternativa de cálculo, consecuente con el grado de experiencia y conocimiento sobre el tema y la variabilidad reconocida en los ensayos de laboratorio.

Sistema

La descripción de los materiales que conforman los depósitos del valle de México se incluye en la sección anterior (**Sistema** en el **Modelo** neurodifuso), sin embargo, es importante mencionar algunas de las características básicas que dirigen la actuación del modelo neuronal *dinámico* (el término "*dinámico*" se deriva de "propiedad dinámica" y no se relaciona con RNs de retroalimentación).

La respuesta característica de las arcillas plásticas del valle de México la calificarían como un material, en cierto sentido, entre sólido y líquido (su incompresibilidad es muy elevada -109 N/m^2- y su módulo de Poisson cerca de 0.499). Estudios en laboratorio realizados desde la década de los 80 reafirmaron el hecho de que las cargas dinámicas/cíclicas (compresión y corte) en estas arcillas blandas saturadas son normalmente "no drenadas". Debido a que el agua no tiene resistencia al corte, los esfuerzos dinámicos/cíclicos de corte "no drenados" son resistidos completamente por el esqueleto de suelo, lo que produce en las arcillas de muy alta plasticidad, un comportamiento fuertemente no lineal, histerético e irreversible, con una

gran disipación de energía asociada y una gran degradación de la resistencia durante los distintos ciclos de carga.

El comportamiento de una arcilla blanda bajo carga dinámica depende fuertemente del nivel de deformación de corte cíclica inducida al suelo $\gamma\%$. Para pequeñas deformaciones la respuesta esfuerzo-deformación es lineal, el suelo no disipa mucha energía en cada ciclo histerético (bajo amortiguamiento) y prácticamente no hay degradación de la rigidez/resistencia con el número de ciclos de carga. Para grandes deformaciones la respuesta esfuerzo-deformación de corte empieza a ser fuertemente no lineal con mucha más disipación de energía por ciclo (alto amortiguamiento) y con una considerable degradación de la rigidez/resistencia causada por la carga cíclica.

Las deformaciones para las cuales se produce la transición del comportamiento de pequeñas a grandes deformaciones dependen de la plasticidad de la arcilla y se acotan típicamente entre $10^{-2}\%$ y $10^{-1}\%$. Arcillas más plásticas (I_p más alto) tienden a localizar esta transición al final de este rango ($10^{-1}\%$), mientras que en arcillas de baja plasticidad y en otros suelos no plásticos, como en aluviones y arenas, ésta se localiza en el límite inferior ($10^{-2}\%$). Así, las arcillas con un alto I_p son más flexibles que los suelos menos plásticos y mantienen un comportamiento lineal (con poca energía de disipación sin degradación de la rigidez) para valores elevados de $\gamma\%$ (Fig. 5.36).

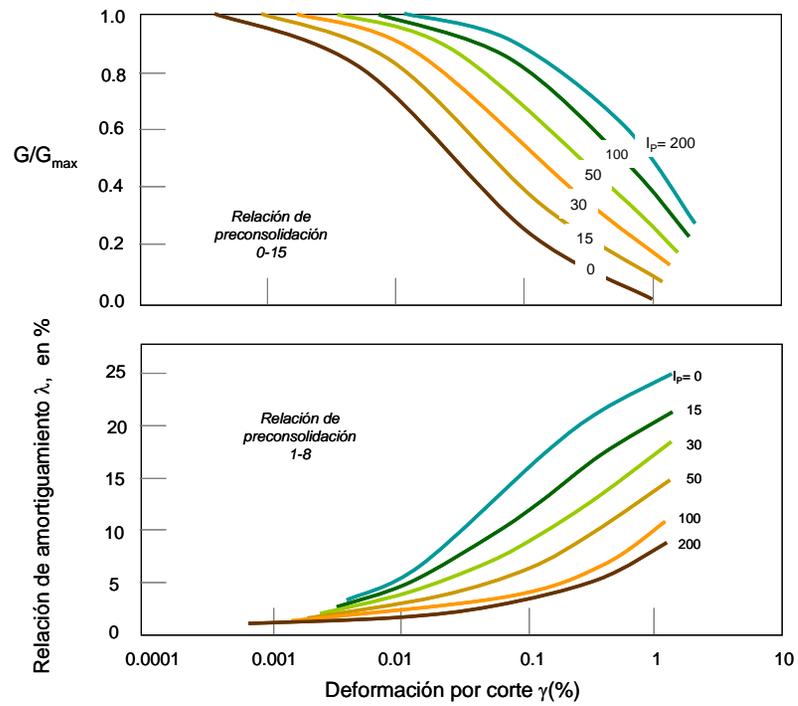


Figura 5.36 Efecto de la plasticidad de la arcilla sobre las curvas de degradación de módulo y amortiguamiento (modificadas de Kramer, 1996)

La arcilla de la Ciudad de México parece ser un caso extremo de esta familia de suelos flexibles y lineales (considerada en la literatura como una de las posibles causas del comportamiento de amplificación durante el terremoto del 19 de Septiembre de 1985). Con valores extremos de I_p , el suelo de la Ciudad de México durante algunos sismos ha presentado comportamientos verdaderamente lineales y exhibido menos amortiguamiento interno que otras arcillas (Fig. 5.37). Sin embargo, hay que apuntar que algunas arcillas plásticas de otros sitios del mundo, bajo ciertas condiciones, pueden también ser bastante lineales y aproximarse al comportamiento del suelo de la Ciudad de México.

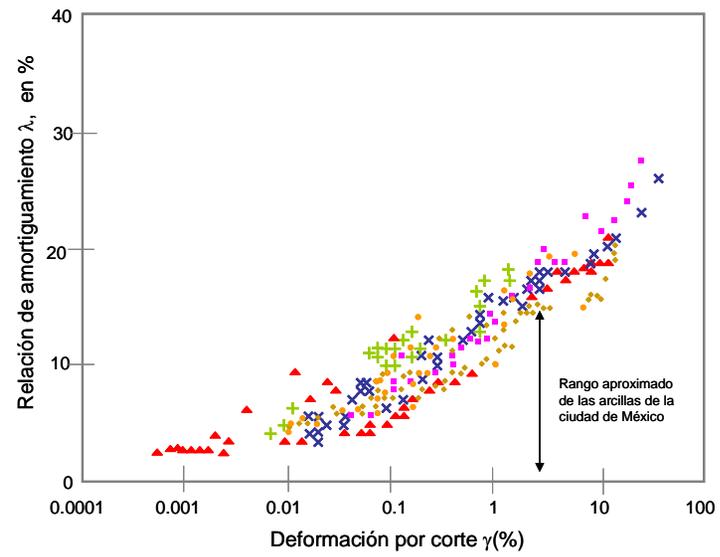
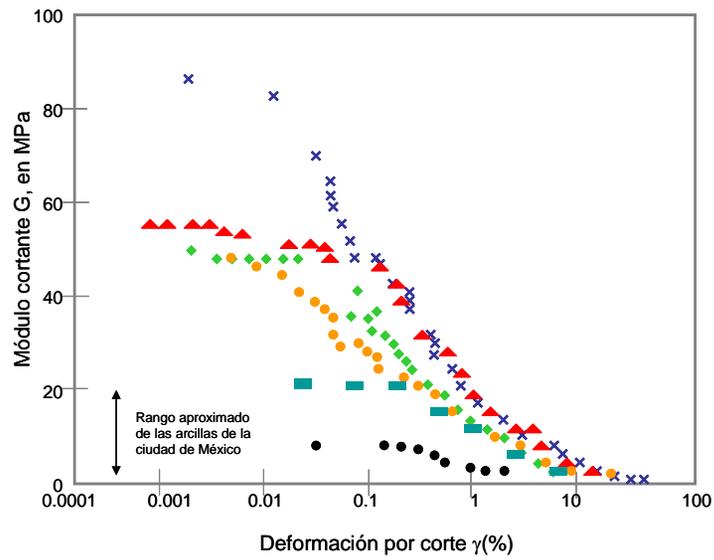


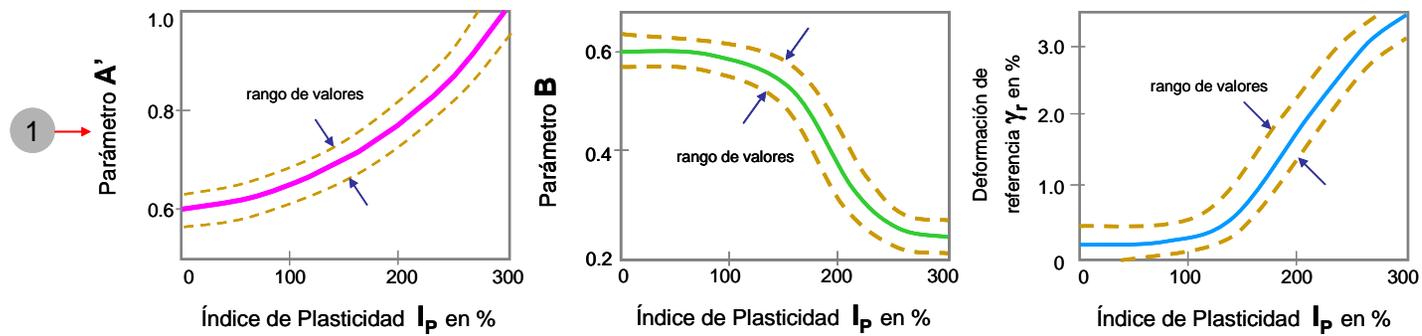
Figura 5.37 Comparación de la atenuación de la rigidez y aumento del amortiguamiento de las arcillas del valle de México y las arcillas marinas de la sonda de Campeche (modificada de Romo y Ovando, 1999)

Proceso

Para acoplar las hipótesis derivadas de la experiencia sísmica y las conclusiones resultado de exploraciones en laboratorio, el proceso se explica a través de funciones matemáticas que la práctica ingenieril ha establecido como válidas para interpretar el comportamiento dinámico de los suelos arcillosos. La incorporación a estos conocidos planteamientos de: i) *inteligencia* (unidades neuronales) y ii) *experiencia* (realimentación con resultados prácticos), modifica el paradigma otorgándoles flexibilidad y robustez ante situaciones de información incompleta o vaga.

El **Proceso** resulta de la concepción *lineal equivalente* de esfuerzo-deformación (materiales viscoelásticos lineales) donde se observa a los parámetros de amortiguamiento y resistencia como dependientes de la deformación angular. La resistencia del suelo se caracteriza por el módulo de rigidez al corte máximo G_{max} movilizado a bajas deformaciones y una curva de reducción de módulo normalizado G/G_{max} . El comportamiento amortiguador se caracteriza por la relación de amortiguamiento λ , la cual se incrementa con el crecimiento de la amplitud de deformación. La forma de las curvas de reducción de módulo y amortiguamiento son influenciadas, principalmente, por la plasticidad del suelo.

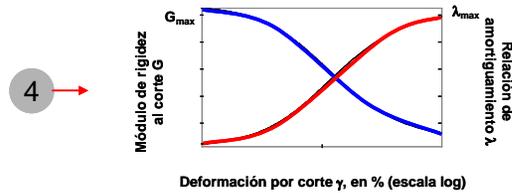
El uso de las velocidades de onda de corte V_s es, en general, la forma más confiable de evaluar G_{max} in situ ($G = \rho V_s^2$, donde ρ es la densidad de masa), mientras que para modelar la reducción (no lineal) del módulo G se utiliza el comportamiento inferido de la documentación de numerosos ensayos de laboratorio. La caracterización completa y detallada de este comportamiento es muy complicada y existen una gran variedad de puntos de vista para abordar el problema, todos de manera *aproximada*. Tomando esta tendencia como la más acertada para abordar una tarea tan compleja, en esta investigación se generó una RN que se sostiene de información *mecánica* (de acuerdo con el proceso de generación de curvas G/G_{max} versus $\gamma\%$ y λ versus $\gamma\%$ mostrado en la Fig. 5.38) e información *experimental pura* (algunos ejemplos de estos datos en la Fig. 5.39).



2 →
$$H(\gamma\%) = \left[\frac{(\gamma\% / \gamma_r)^{2B}}{1 + (\gamma\% / \gamma_r)^{2B}} \right]^A$$

$$G = G_{\max} (1 - H(\gamma\%))$$

3 →
$$\lambda = \lambda_{\max} (1 - G / G_{\max})$$



- 1 Con I_p obtenga A' , B y γ_r
- 2 Estime $H(\gamma\%)$
- 3 Calcule G y $\lambda = f(H(\gamma\%))$
- 4 Construya las curvas G y $\lambda = f(\gamma\%)$

Figura 5.38 Proceso de generación de la información *mecánica* (modificado de Romo y Ovando, 1996)

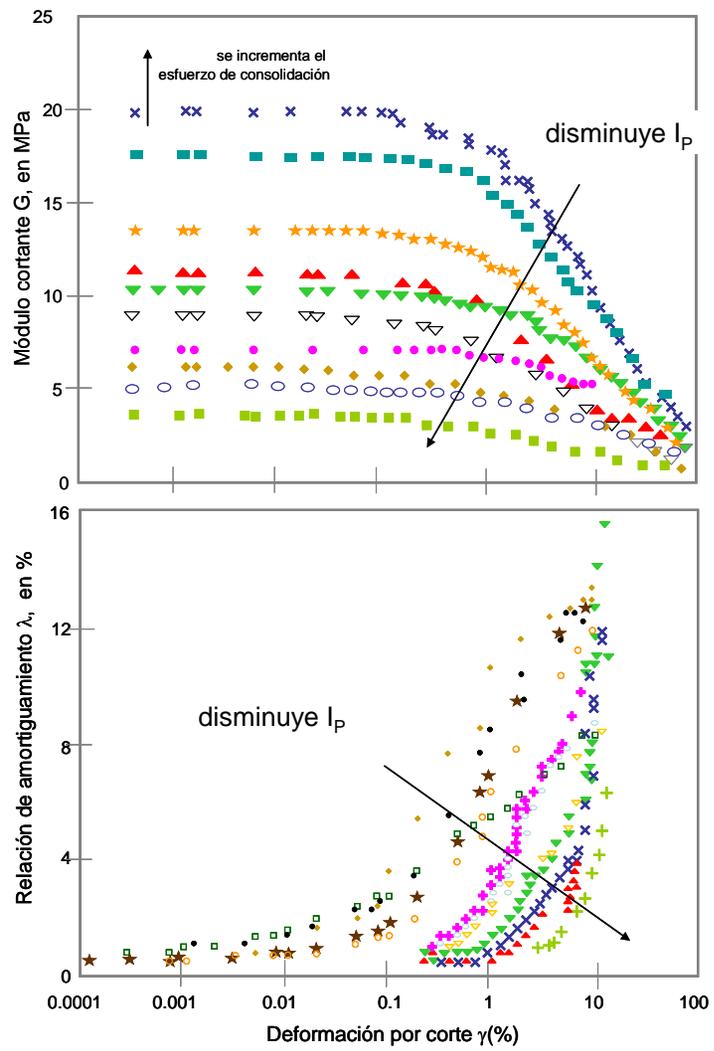


Figura 5.39 Algunos ejemplos de curvas de degradación de módulo y amortiguamiento obtenidas de ensayos realizados con materiales típicos del valle (modificado de Kramer, 1996)

Entradas

De entre los parámetros que dirigen la tarea por modelar, se reconoce que la forma de la curva de reducción del módulo G/G_{max} es influenciada más por el índice plástico que por la relación de vacíos (Dobry y Vucetich, 1987; Sun et al., 1988; Seed e Idriss, 1970) (Fig. 5.40) mientras que el efecto de la presión de confinamiento efectiva sobre el comportamiento del módulo es más notable en suelos de baja plasticidad (Iwasaki et al., 1978; Kokoshu, 1980) (Fig. 5.41).

Con base en esta evidencia práctica y las variables independientes que intervienen en los modelos hasta el momento desarrollados (como el hiperbólico), se propone como única entrada neuronal para describir las condiciones del material al índice de plasticidad I_p del suelo y a la deformación angular $\gamma\%$ como el nodo contador que dirige la construcción de las curvas paramétricas. La V_s y el peso volumétrico de la masa de suelo se usan en post-proceso para calcular externamente G_{max} y generar la curva de módulo normalizado G/G_{max} versus $\gamma\%$.

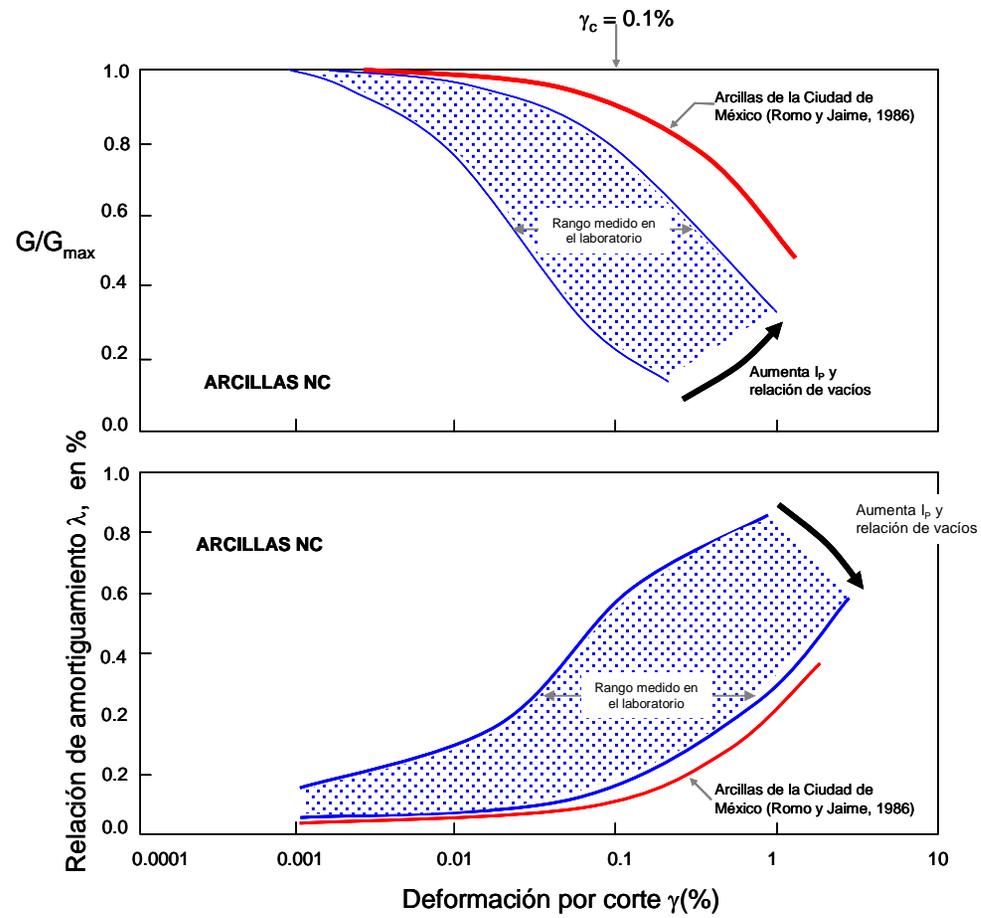


Figura 5.40 Efecto de la relación de vacíos sobre el comportamiento *dinámico* (modificada de Kramer, 1996) (revisar valores de las ordenadas de la curva del amortiguamiento)

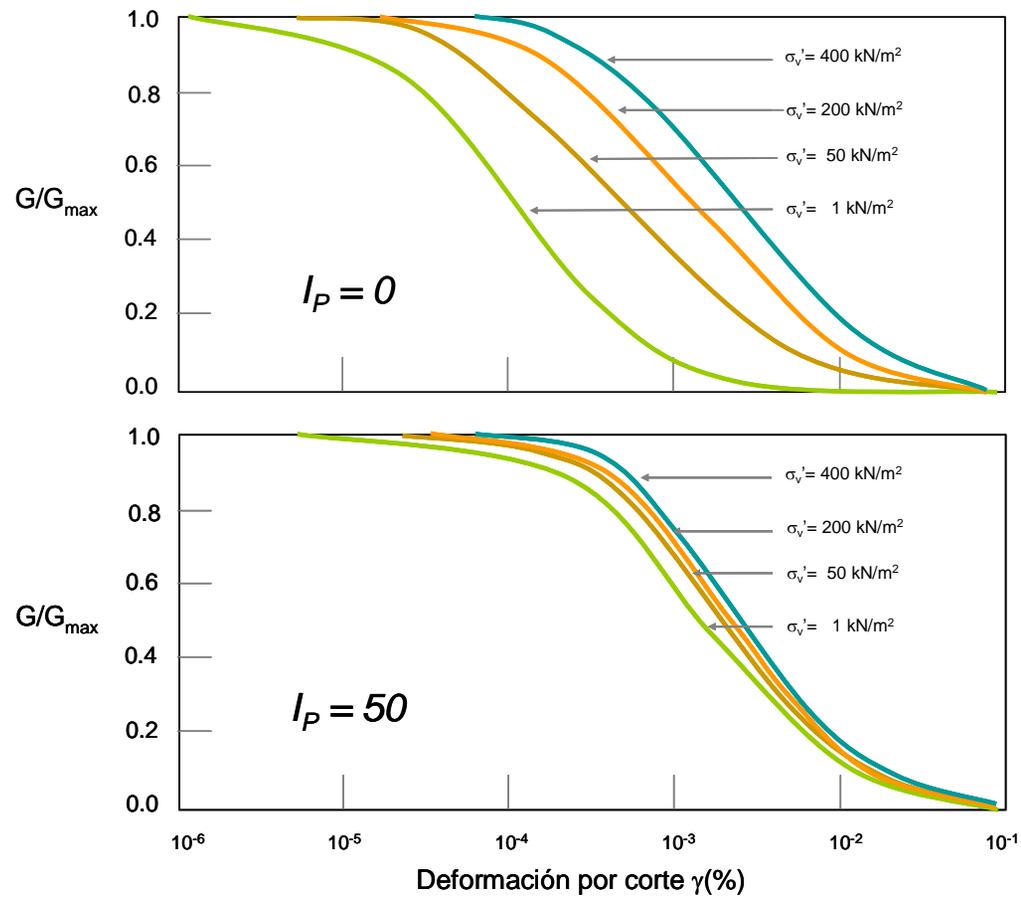


Figura 5.41 Efecto de la presión de confinamiento efectiva sobre el comportamiento *dinámico* (modificada de Kramer, 1996)

Modelo

Reconociendo la capacidad de las RNs de actuar como aproximadores universales de funciones, más concretamente, atendiendo al hecho de que una red, conteniendo al menos una capa oculta con suficientes unidades no lineales, puede aprender cualquier tipo de función o relación entre un grupo de variables de entrada y salida, en esta investigación se presenta un modelo neuronal para modelar el **Proceso** definido escasamente (paramétricamente) y con alto contenido de ruido (fallos implícitos en los datos).

Los datos de entrenamiento, como ya se declaró, se dividen en dos grupos: *mecánicos* y *experimentales puros*. Acoplar patrones *puros* a las estimaciones

mecánicas permite una mejor definición de los casos frontera (valores de I_p bajos y muy altos) y la eliminación de las ambigüedades que ocasionan las franjas de valores de los parámetros A , B y γ_r (misma entrada I_p diferentes valores de salida (G, λ)).

Una vez validada la base de datos de entrenamiento (verificación de congruencia entre patrones), se probaron diversas estructuras neuronales y bajo el criterio que jerarquiza como más apta a la red con menor número de nodos (menos tiempo-máquina) y mayor ajuste sobre los comportamientos objetivo, se concluyó que la combinación mostrada en la Fig. 5.42 es la más exitosa.

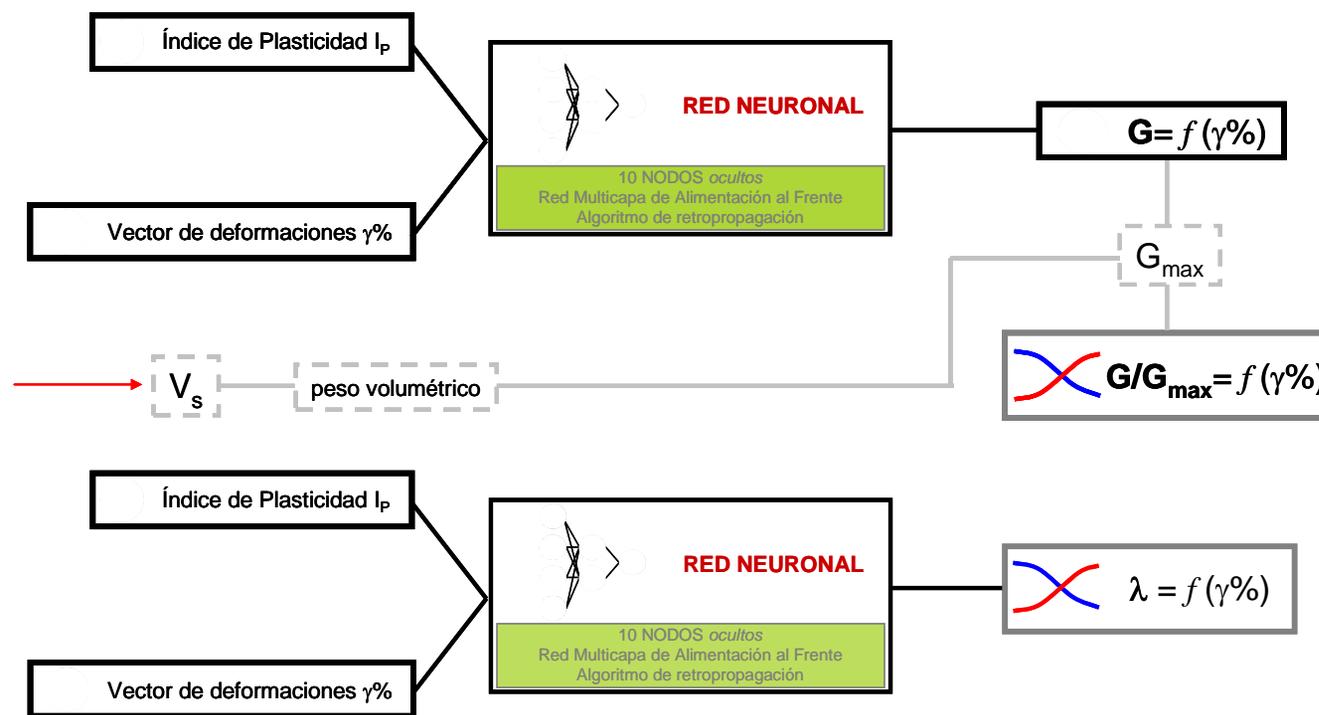


Figura 5.42 Topología más exitosa para modelar: $(G/G_{max}, \lambda) = f(I_p, \gamma\%)$

Salida

A continuación se presentan algunos ejemplos de las estimaciones neuronales para estratigrafías típicas del valle y que están incluidas en la base de datos del modelo neurodifuso $V_s = f(q_c, Z, Zona)$. El esquema neuronal, en una primera ventana de entradas, solicita los valores de I_p y $\gamma\%$ (Fig. 5.43). Posteriormente para la construcción de la curva del módulo G normalizado, el sistema requiere del valor de V_s y peso volumétrico. En caso de que el usuario desconozca la velocidad de ondas de corte, se llama al módulo neurodifuso $V_s = f(q_c, Z, Zona)$ para su estimación. En la Fig. 5.43 se presentan los resultados para los sitios SCT y CDAO, típicos de la Zona Centro I. Como se observa en la figura, el modelo neuronal responde satisfactoriamente al reto de caracterizar dos importantes aspectos del comportamiento dinámico de los suelos (G, λ) de manera simple y bajo conceptos racionales.

Entre los resultados para SCT y CDAO se encuentran puntos (para SCT en $Z=17\text{m}$ y 23m y para CDAO en $Z=33\text{m}$ y 43m) que representan ejemplos *típicos* de entrenamiento (patrones con los que se midió la actuación del modelo durante su construcción) y para sustentar lo dicho sobre la capacidad de generalización del modelo neuronal también se presentan soluciones en modo de trabajo *directo* o prueba (para SCT en $Z=5\text{m}$ y 20m y para CDAO en $Z=39\text{m}$ y 55m).

Como se observa en la Fig.5.43 las tendencias preconcebidas para los distintos materiales es bien reconocida por el modelo neuronal y estas curvas representan una manera sencilla, económica y directa de obtener estos importantes parámetros dinámicos a partir del I_p . Es necesario apuntar que el efecto del confinamiento no es nulificado en esta propuesta, se propone que el usuario mantenga una posición de alerta sobre la cualidad plástica del material que está estudiando y use el valor de I_p como más convenga a los efectos de su análisis. Como ya se ha mencionado anteriormente, las propiedades índice precisamente son sólo indicaciones de ciertas condiciones y cualidades de los materiales, pero es su vaga y simple naturaleza la que nos permite adicionarles criterios prácticos para enriquecerlas.

Los valores cerrados de I_p difícilmente pueden considerarse *naturales* y la extrapolación de estos resultados puntuales hacia cualidades de estratos de varios metros de espesor significa una simplificación a veces demasiado aventurada. Así, sabiendo que es sumamente sencillo obtener las curvas de degradación de módulo y amortiguamiento, un usuario con el reporte de un valor de I_p para un material extraído a una profundidad Z , y quizá con un parcial conocimiento del peso volumétrico y la historia de cargas, podría adherir criterios empíricos y modificar la expresión numérica de la cualidad de plasticidad o bien, calcular una banda de valores posibles en los que se podría ubicar el verdadero comportamiento de la masa de suelo.

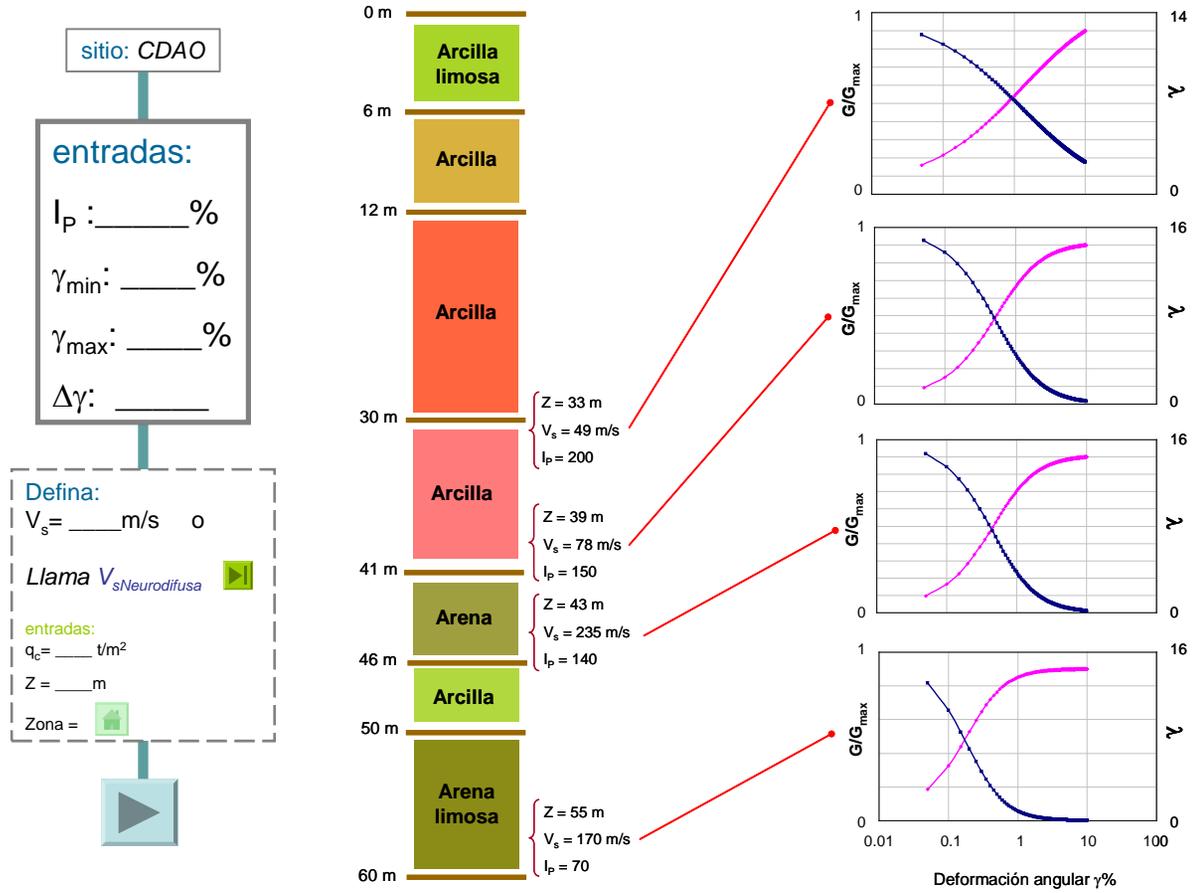


Figura 5.43 Estimaciones neuronales para algunos puntos sobre las estratigrafías de los sitios CDAO y SCT

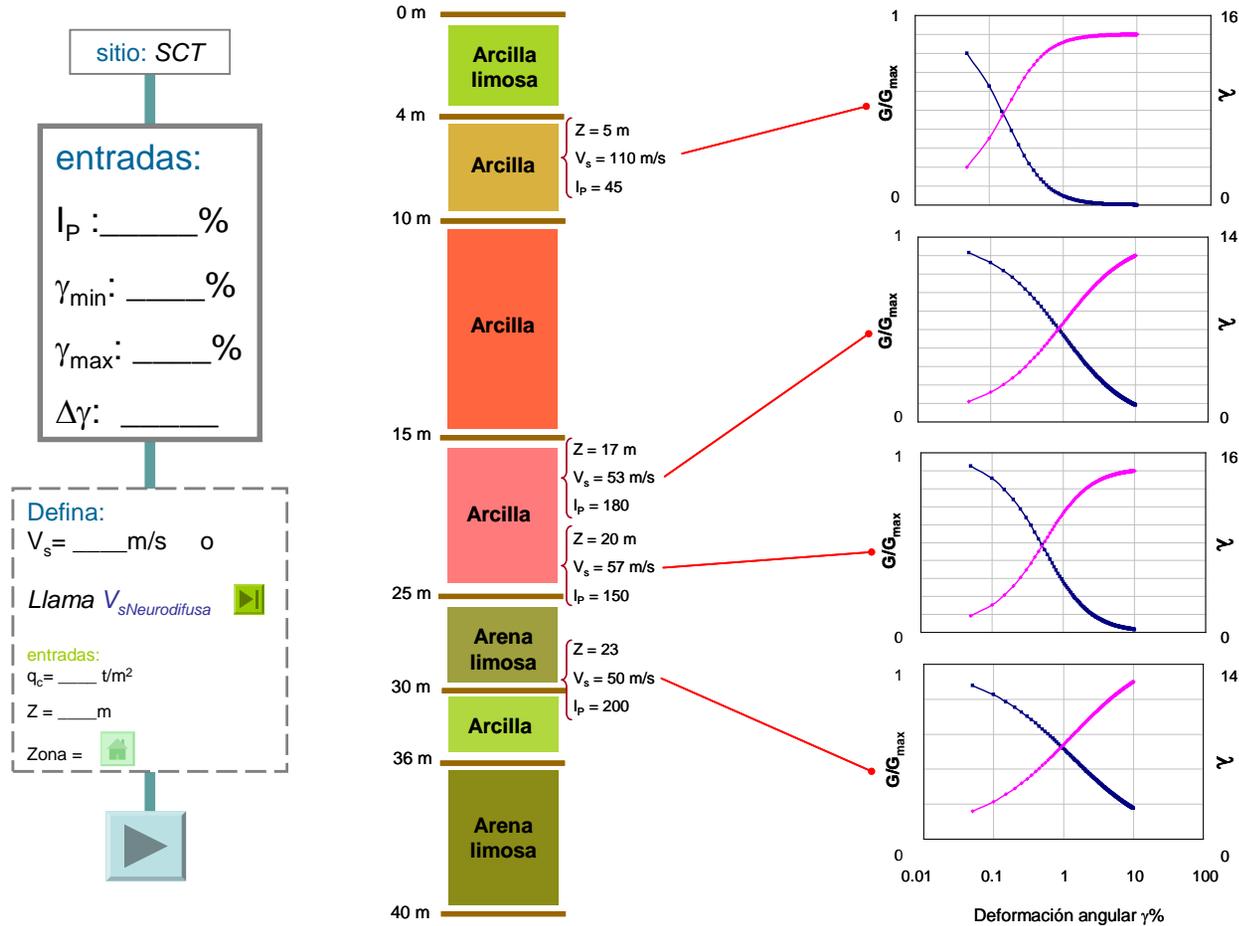


Figura 5.43 Estimaciones neuronales para algunos puntos sobre las estratigrafías de los sitios CDAO y SCT (continúa)

Hasta el momento se han detallado ventajosas características de la RN en cuanto a objetividad teórica, operación e interpretación de resultados. Para ilustrar la capacidad del modelo en casos prácticos, a continuación se presentan ejemplos del desempeño neuronal ante una situación práctica. En las Figs. 5.44-47 se muestran comparaciones entre los valores obtenidos de ensayos en materiales arcillosos de alta plasticidad de un sitio ubicado en el área de Texcoco (Zona de Lago) (Mayoral et al. 2007) y las curvas generadas con el módulo neuronal en modo de trabajo directo. Las arcillas ensayadas presentan índices de plasticidad que van de 100 a más de 250% y cubren profundidades de 2 hasta casi 23 m.

Las estimaciones neuronales a poca profundidad (Fig. 5.44) resultan muy cercanas a los resultados de laboratorio. Observe que, de entre los resultados presentados en esta batería de gráficos, éste es el correspondiente al valor de I_p más alto y la cercanía entre medido y estimado es la más notable. Este es un sesgo del modelo muy marcado, estimaciones más cerca del reporte de laboratorio conforme crece la plasticidad del suelo, mientras que para suelos menos plásticos los resultados neuronales se acercan más a lo que dicta el conjunto de datos *mecánicos*.

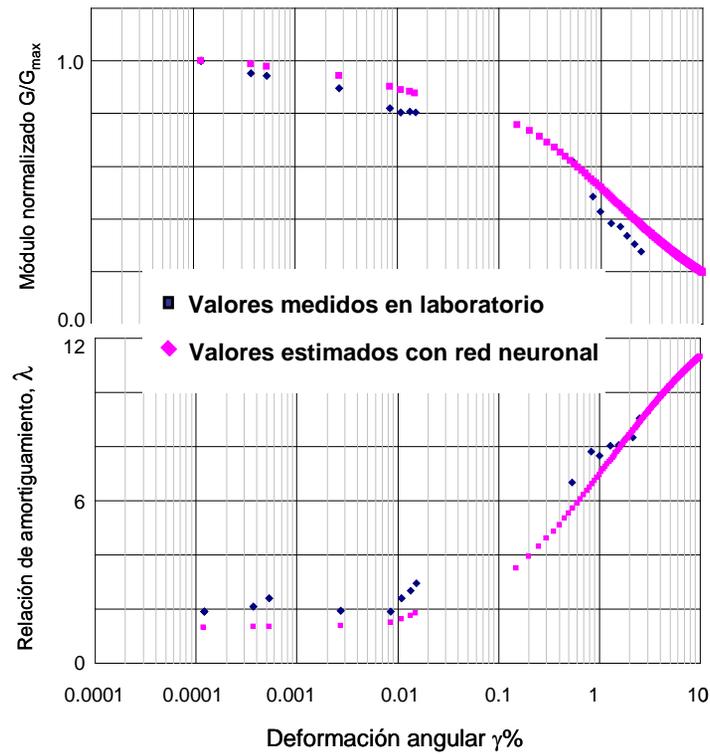


Figura 5.44 Estimaciones neuronales en modo de trabajo directo. Propiedades: $Z = 2.4$ a 2.6 m , $I_p = 265$

Las curvas mostradas en la Fig. 5.45 son las que mayores diferencias presentan en predicción, sin embargo es necesario apuntar que esto sólo sucede para niveles de deformación altos (arriba del 1%). Este efecto resulta lógico si se examinan las tendencias de las curvas *mecánicas* incluidas en el entrenamiento. No se considera que esta sea una indicación de un mal comportamiento del funcional neuronal, de hecho el promedio de los ejemplos estudiados con las mismas condiciones paramétricas (I_p , peso

volumétrico y estado de esfuerzos aproximado) guardan una tendencia más cercana a la curva neuronal que a la reportada de laboratorio. ¿Cuál de los dos comportamientos es el correcto?, ¿alguno podría ser mejorado?, ¿de qué manera?. Las respuestas a estos cuestionamientos están lejos del alcance de esta investigación, pero lo que sí se puede recomendar es que el uso posterior de las curvas (G, λ) debe mantener la sentido con la que han sido propuestas y determinadas: simpleza y fragmentación.

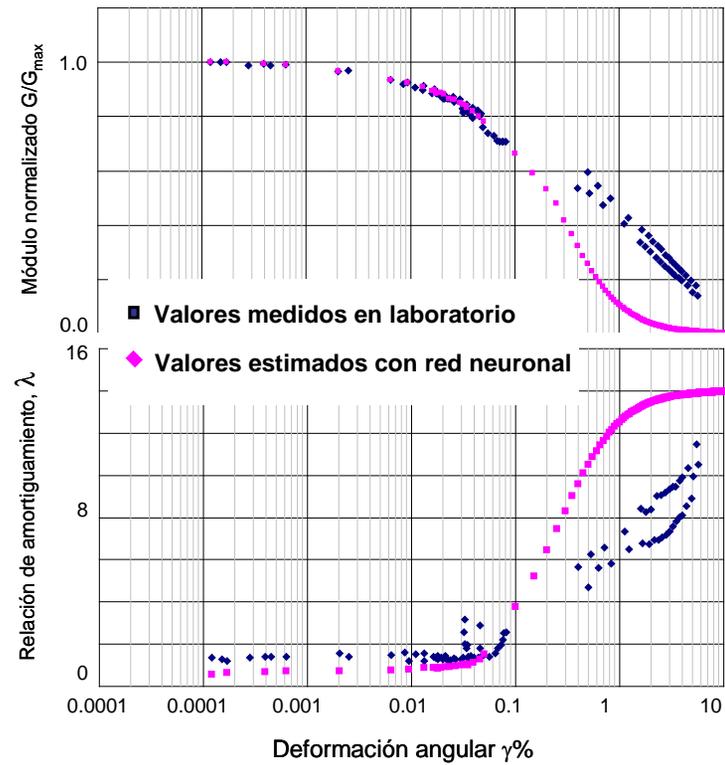


Figura 5.45 Estimaciones neuronales en modo de trabajo directo. Propiedades: $Z = 6.2$ a 6.4 m , $I_p = 106$

Los ejemplos restantes (Figs. 5.46 y 5.47) son considerablemente mejores que el anterior y el uso de cualquiera de las curvas, medida o estimada, no repercutiría en grandes diferencias si se usan en un programa de cálculo de respuestas sísmicas en suelos blandos.

Con base en toda la información gráfica y la propuesta del modelo como software ingenieril, se puede calificar a esta RN como una atractiva alternativa para la caracterización aproximada y preliminar del comportamiento dinámico de los suelos plásticos del valle de México.

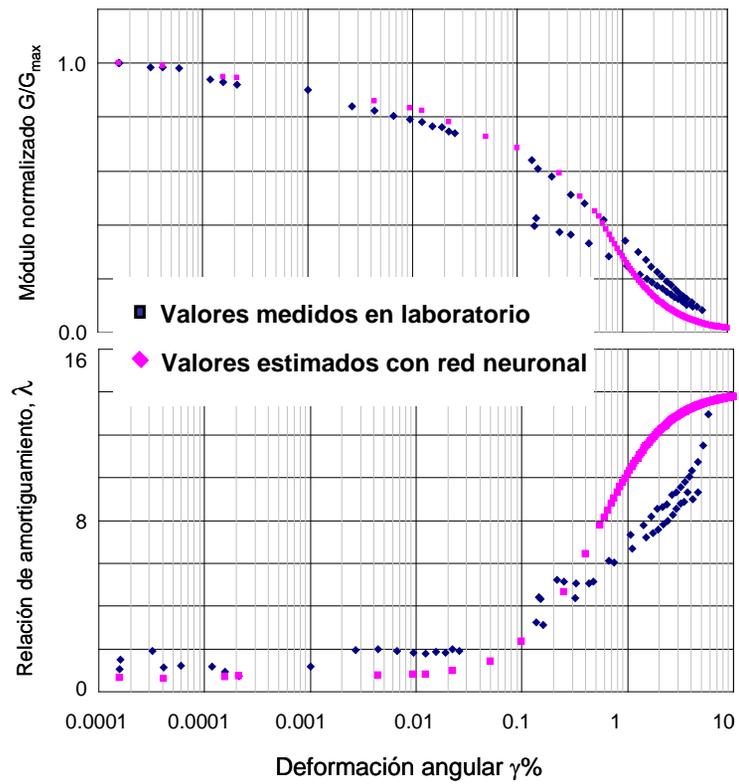


Figura 5.46 Estimaciones neuronales en modo de trabajo directo. Propiedades: $Z = 9.0$ a 9.2 m , $I_p = 139$

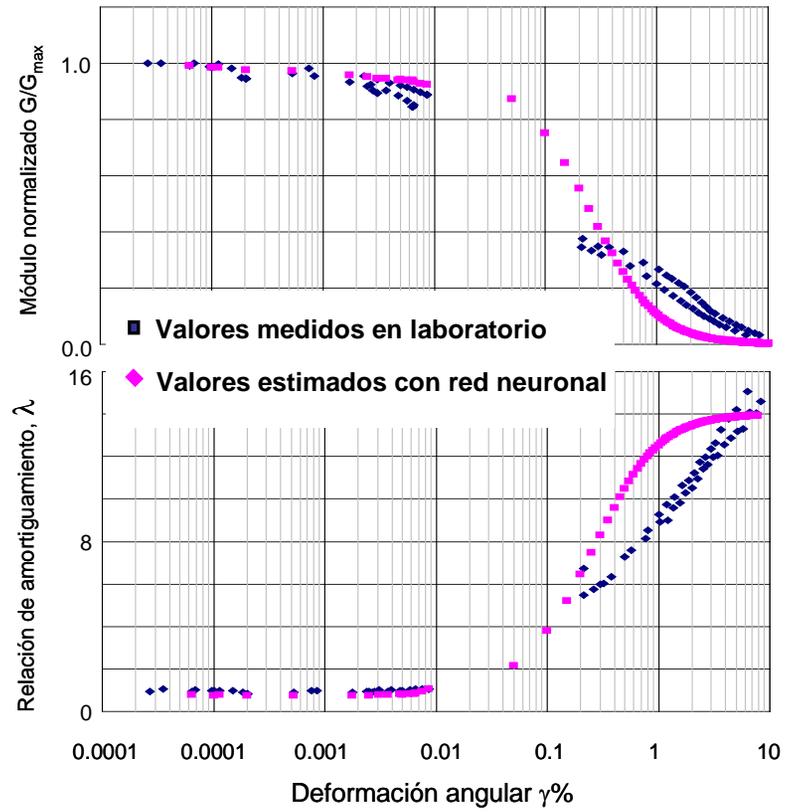


Figura 5.47 Estimaciones neuronales en modo de trabajo directo. Propiedades: $Z = 22.6$ a 22.8 m , $I_p = 100$

5.2 Estimación de movimientos de terreno en la Ciudad de México

En la Ciudad de México, como en muchos otros lugares del mundo, la amenaza de los sismos a las actividades humanas es suficiente para requerir su consideración cuidadosa en el diseño de estructuras. El objetivo del diseño sísmico es producir estructuras u obras civiles que resistan ciertos niveles de sacudidas sísmicas sin daños considerables.

La descripción de estas sacudidas (movimientos o respuestas de terreno) es uno de los problemas más importantes en ingeniería geosísmica. Bajo condiciones ideales, un análisis de respuesta de terreno *completo* debería modelar el mecanismo de ruptura en la fuente, la propagación de las ondas de esfuerzo a través de la corteza terrestre hasta la parte superior del manto rocoso (bajo un sitio en particular) y la modificación de este movimiento en roca por efecto de los suelos depositados sobre ella. En realidad, el mecanismo en la ruptura es tan complicado y la naturaleza de la transmisión de energía entre la fuente y el sitio tan incierto que un modelado completo no es práctico para aplicaciones comunes en ingeniería.

La tendencia funcional es que a través de métodos empíricos desarrollados con sismos registrados se generen relaciones predictivas *muy simples* donde se proponga el movimiento en la base rocosa y se cuantifique su transformación de acuerdo con propiedades dinámicas de los suelos.

Teniendo en cuenta estos fundamentos de análisis y de acuerdo con el proceso empírico de creación de modelos, se plantea el siguiente esquema de solución al problema de estimación de movimientos de terreno en la Ciudad de México:

SISTEMA: Depósitos de suelo del valle de México

PROCESO: Propagación de ondas sísmicas

ENTRADAS (datos): *Parámetros E* que describen la demanda sísmica (evento) y *Parámetros S* que describen al depósito (sitio)

MODELO: Red Neuronal RN

SALIDA (resultado): $ERA_{sitio}^* = f(\text{sismo}, \text{depósito de suelo})$

*Espectro de Respuesta de Aceleraciones

Es importante recordar que, actualmente, mucha de la dificultad en la especificación de movimientos de terreno resulta del crédito inevitable que se le otorga a decisiones subjetivas basadas en información *incierta o incompleta*. Un modelo alternativo debe evitar la inclusión de afirmaciones poco científicas sobre los **Sistemas** y más que acudir a simplificaciones sobre la naturaleza de los **Procesos**, debería minimizar el número de variables básicas para poder predecir las derivadas con suficiente aproximación y confiabilidad de acuerdo con los datos disponibles. Bajo un punto de vista ingenieril, un modelo así se prefiere porque simplifica las decisiones de diseño y genera procedimientos más robustos.

Sistema

El efecto del tipo de suelo sobre la amplitud y la naturaleza de las ondas sísmicas ha sido reconocido como crucial en la estimación del peligro sísmico. Esto es particularmente importante en las arcillas de la Ciudad de México cuyas características de plasticidad y linealidad a altas deformaciones la convierten en un interesante y muy valioso caso de estudio.

La Ciudad de México está localizada en la cuenca de un viejo lago, la parte oeste de la Ciudad yace sobre depósitos de suelo firme y roca, mientras que la parte este se encuentra sobre depósitos de arcilla suave que llenaron la cuenca del antiguo lago (Fig. 5.48). Entre la formación dura y los depósitos de arcilla se encuentra una zona de transición, donde el suelo presenta características de rigidez mayores pero involucra algunos estratos importantes de arcilla blanda. En el área del lago, los depósitos de arcilla se encuentran sobre formaciones muy duras cuyas velocidades de propagación de ondas de corte son comparables con las de una roca suave.

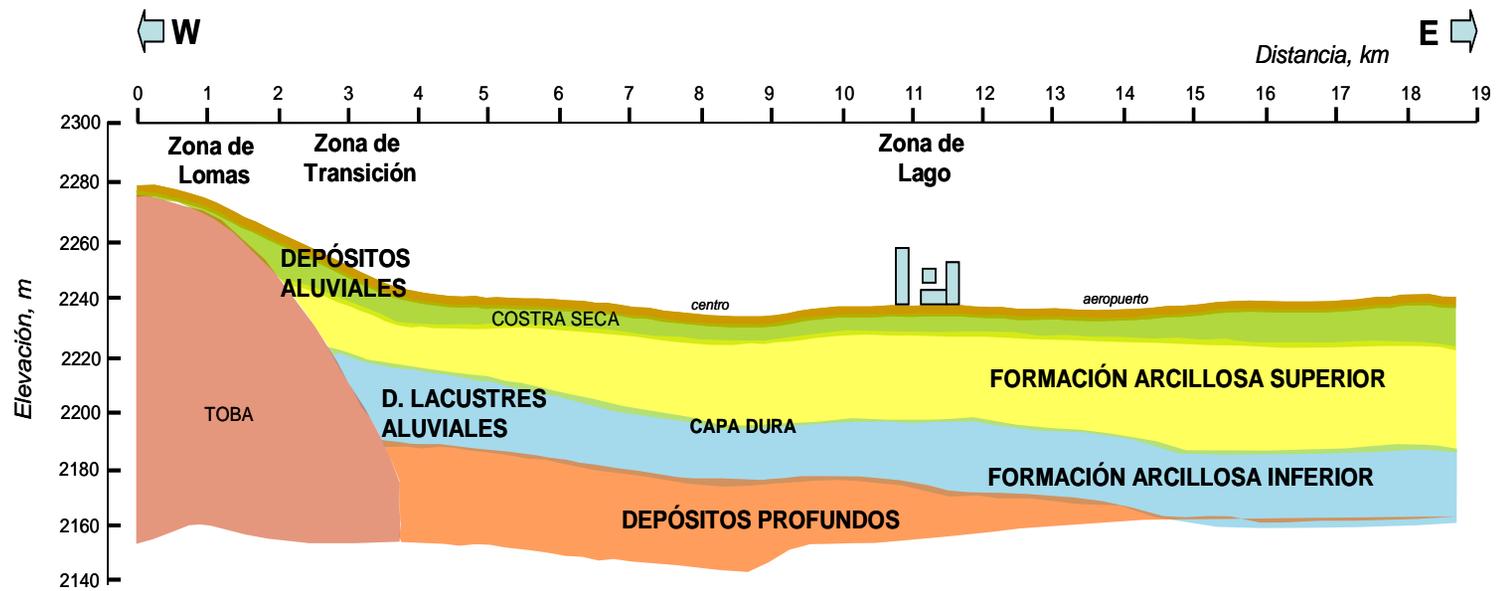


Figura 5.48 Estratigrafía general de la Ciudad de México (modificada de Mooser, 2000)

El reconocimiento de esta secuencia geotécnica generó hace más de 45 años la zonificación pionera de Marsal y Mazari (1959), la cual ha experimentado algunos cambios en la ubicación de las fronteras de cada zona pero la descripción de las características típicas de los materiales, a pesar de los sondeos y estudios desarrollados hasta la fecha, continúa siendo casi la misma dentro del código actual de construcción (Figs. 5.49 y 5.50):

Zona de Lomas (Zona I). Se encuentran formaciones de roca por derrame de lavas o suelos generalmente firmes (tobas volcánicas). Pueden encontrarse algunos estratos arenosos en estado suelto o cohesivos intercalados o en la superficie.

Zona de Transición (Zona II). Integrada por estratos arenosos y limo-arenosos intercalados con capas de arcilla lacustre. Su espesor varía entre decenas de centímetros y no más de 20 m a partir de los cuales se encuentran los depósitos profundos.

Zona de Lago (Zona III). Está constituida por depósitos de arcilla de alta compresibilidad y alto contenido de agua (espesores entre 20 y 100 m) con intercalaciones de capas areno-limosas o arcillosas de consistencia firme a muy dura con espesores variables de centímetros a varios metros. Estos depósitos arcillosos suelen estar cubiertos superficialmente por suelos aluviales y rellenos artificiales.

Es importante señalar que los suelos lacustres de la Ciudad de México han sido fuente de muchos problemas serios de ingeniería. Los tres principales problemas a los que se enfrentan los ingenieros durante el diseño y construcción de edificaciones y cimentaciones son:

- Las propiedades singulares de los sedimentos
- El hundimiento regional
- La alta sismicidad

Lo relativo a las propiedades, tanto físicas, químicas, mineralógicas, hidráulicas y mecánicas (estáticas y dinámicas) ya se mencionaron en los capítulos anteriores. El hundimiento de la Ciudad desde su descubrimiento en 1891 (inicialmente acotado entre 3-5 cm/año) aumentó a 15-30 cm/año en 1947 para situarse en la actualidad entre 5-7 cm/año. En algunos lugares de la Ciudad de México se presentan fuertes asentamientos e incluso llegan a experimentar la aparición de fisuras y grietas. Estos dos aspectos ligados con la particular sismicidad que afecta al valle, sin duda dibujan un panorama de análisis complicado y multifacético.

b) 2000

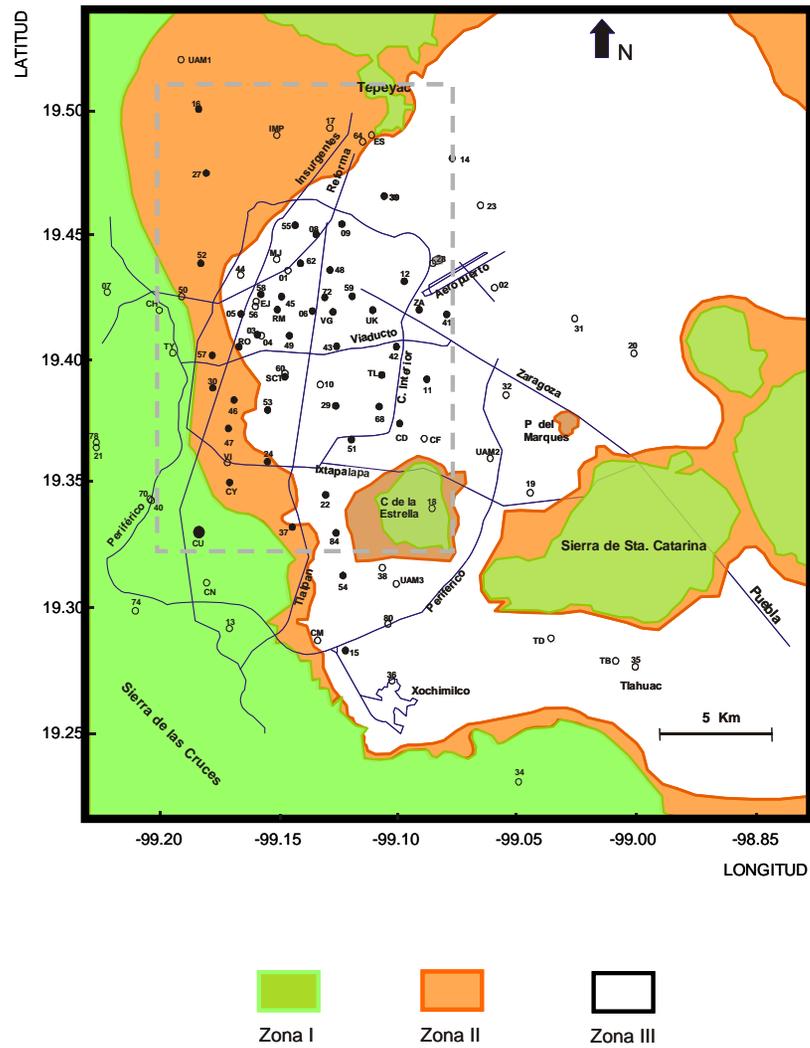


Figura 5.50 Zonificación geotécnica del valle de México: a) Marsal y Mazari (1959), b) Auvinet et al. (2000)

Proceso

La propagación de ondas sísmicas no se modela en el esquema matemático expuesto en este trabajo de investigación, sino que se vincula la expresión numérica (ERA en superficie) de una de sus manifestaciones más evidentes (movimiento de la masa de suelo) con algunos parámetros que caracterizan al evento sísmico generador del **Proceso**. La solución neuronal es un planteamiento *fenomenológico*, es decir, el modelo es capaz de describir las manifestaciones del **Proceso** y eventualmente de relacionarlas con *causas*, pero no de *explicar* la estructura que las generan (Fig.5.51).

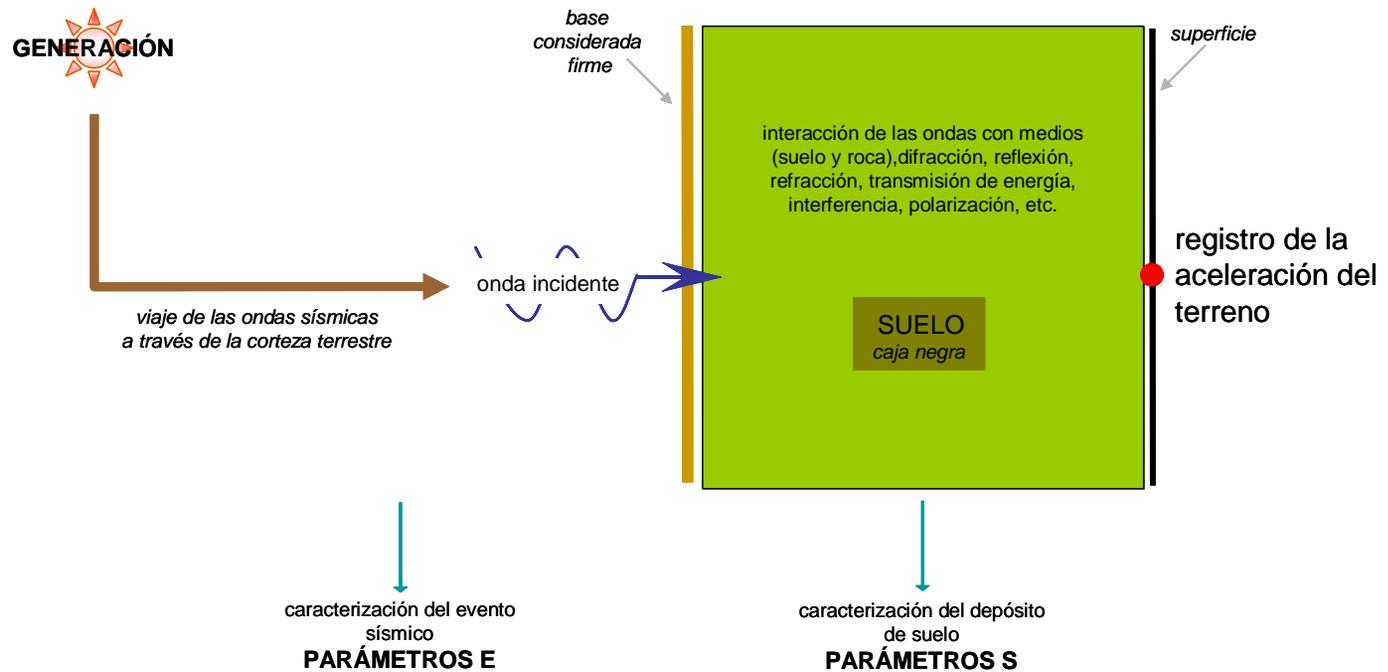


Figura 5.51 Planteamiento fenomenológico para evaluar la respuesta del terreno ante la ocurrencia de un sismo

El método conexionista que se describe a continuación, no intenta modelar el fenómeno de propagación de ondas sísmicas ni caracterizar integralmente la respuesta del valle, sino servir como una práctica herramienta *científica* para el reconocimiento de patrones de comportamiento y su predicción numérica. Esta aproximación permite: 1) estudiar formalmente el movimiento a través de Espectros de Respuesta de Aceleraciones ERA (5% de amortiguamiento) dentro de un ambiente de información escasa, incompleta y contaminada, 2) generar conclusiones *inteligentes* sobre los procesos (acción→reacción) y 3) delimitar nuestro conocimiento y dirigir futuras investigaciones a través de guías matemáticas con significado *natural*.

- Entradas

PARÁMETROS

En los análisis de respuesta de terreno básicamente lo que se hace es modificar los movimientos en roca, producto de la acción de fuerzas sísmicas, considerando el efecto de un perfil de suelo. Debe aclararse que este tipo de movimientos se refieren a un afloramiento rocoso relacionado con el sitio y no se asignan directamente a la base del perfil, ya que, a menos que la roca sea muy rígida, los movimientos en la base serán diferentes de aquellos en superficie.

La demanda sísmica, representada con el movimiento en el afloramiento rocoso, requiere de una adecuada caracterización por medio de *medidas*. Dentro de los cuantificadores más directos se encuentran los de amplitud (valores máximos de aceleración, velocidad y desplazamiento), los de frecuencia (espectros de Fourier y de Respuesta) y los de duración.

Amplitud. Es común en diseño y análisis caracterizar la fuerza de la sacudida sísmica usando un parámetro simple como la aceleración, velocidad o desplazamiento máximos. Estos parámetros han ganado gran aceptación porque son fácilmente incorporados en métodos estándar pseudo-estáticos, sin embargo, la caracterización de una historia de tiempo transitoria usando sólo un valor de amplitud resulta demasiado escasa.

Frecuencia. Para definir el contenido de frecuencias de la sacudida se requiere de un Espectro de Amplitudes de Fourier EAF o de un Espectro de Respuesta de Aceleraciones ERA. Los ERA, obtenidos aplicando movimientos de terreno a la base de un conjunto de osciladores de un grado de libertad 1GDL (con mismas relaciones de amortiguamiento) y graficando las respuestas máximas de cada oscilador como función de su frecuencia o periodo natural, son los más ampliamente usados en la ingeniería práctica porque describen las características de frecuencia en una forma directamente aplicable al diseño y análisis estructural.

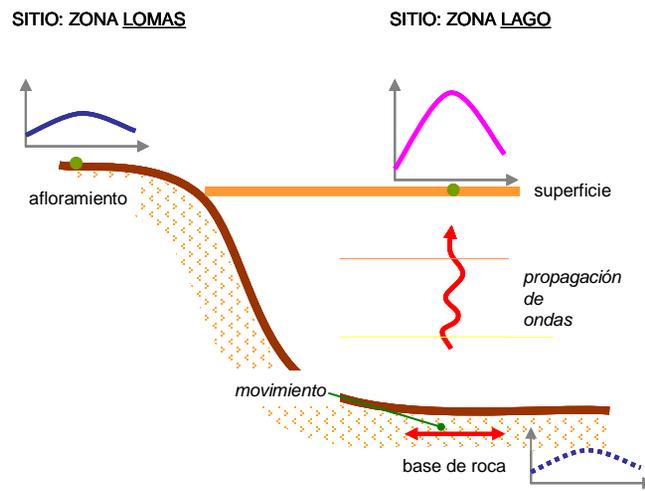
Duración. Además de la fuerza y el contenido de frecuencias, la duración de la sacudida tiene gran influencia en el comportamiento de las estructuras. La duración de la sacudida *fuerte* se incrementa con el crecimiento de la magnitud. El potencial de daño inducido por sismo es función de la duración de los movimientos de terreno *significativos* y es particularmente importante en la respuesta sísmica de estructuras dúctiles, la estabilidad de los suelos no cohesivos y el comportamiento de taludes y presas.

Para definir las variables de entrada de este postulado conexionista se tomaron en cuenta estas generales bases teóricas y las ventajas del modelado con RNs.

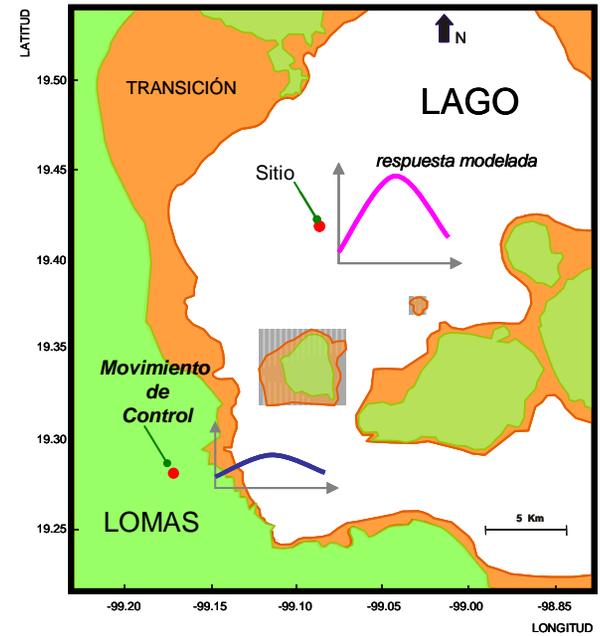
Entrada E-1. Movimiento de Control MC

Reconociendo la importancia del que se considera *movimiento en la base*, independientemente del método que se siga para su transformación, y sabiendo que los registros en afloramientos rocosos, como representaciones de las sacudidas en la base dura de los depósitos de suelo del valle de México, forman parte importante de las incertidumbres epistémicas en el modelado de movimientos de terreno, en esta investigación se propone un replanteamiento de la demanda sísmica como a continuación se describe:

- Revisando íntegramente el tipo y nivel de conocimiento disponible sobre esta entrada se plantea mudar el concepto *movimiento en la base* a *movimiento de control* (Fig.5.52). No se hacen hipótesis sobre la naturaleza ni expresión numérica de las sacudidas en la base firme de un depósito. El lugar de la demanda sísmica en el vector de entradas lo ocupa un ejemplo de respuesta registrado en superficie que *controla* las diferencias frecuenciales y de amplitud entre cada evento (Fig. 5.52b).
- La base de datos con registros de 22 sitios en zona de Lago, 10 en Transición y 1 en Lomas permite elegir de entre estos 33 depósitos el punto de control que funja como demanda sísmica. Si los materiales que conforman el depósito y el medio que rodea a la estación acelerográfica no han sufrido cambios sustanciales en el periodo que cubre la historia sísmica monitoreada, entonces las diferencias en los acelerogramas se deberán únicamente a la sismogénesis y a la trayectoria (dirección y distancia fuente→sitio). La selección del *movimiento de control* se basa en el número de eventos registrados y la validación de las comparaciones entre los resultados de esta tesis y los obtenidos de otros procesos numéricos. La estación CU (Ciudad Universitaria), sitio en roca blanda, fue elegida para controlar el aprendizaje neuronal *entrada→salida*.



a)



b)

Figura 5.52 Demandas sísmicas: a) Movimiento en la Base, b) Movimiento de Control

- Para ser consecuentes con las características que deben contener las demandas sísmicas, los registros en CU se transforman a dominios espectrales para señalar contenido frecuencial y amplitud. En esta investigación se compararon los EAFs y los ERAs de registros que cubren desde la década de los 60 y hasta el sismo de Tehuacán, Puebla, en 1999. En las Figs. 5.53 y 5.54 se muestran algunos ejemplos gráficos de estos vectores.

Debe recordarse que en un modelo neuronal toda la información se usa en la construcción de las relaciones paramétricas, así que de la adecuada expresión del fenómeno a través de las entradas dependerá el éxito de la aplicación. Sin polemizar acerca del significado de los espectros en el ámbito de las estructuras, de la sismología, de la geotecnia, incluso de las matemáticas y observando solamente los gráficos que despliegan (tenga en mente que finalmente son cadenas de números ante la red neuronal) ¿cuál de las dos expresiones, EAFs o ERAs, es más ventajosa numéricamente?

Los EAFs tienen distintas longitudes dependiendo de la señal que los origina por lo que su inclusión como columna o renglón en la matriz de entradas no es directa (deben ser el mismo número de nodos para todos los patrones). Un EAF es de alta complejidad numérica (crestas y valles consecutivos en todo el espectro) y la identificación de tendencias, frecuencias de corte, de esquina y las fundamentales requiere suavizar los espectros o trazar envolventes, procesamiento que no se realiza bajo argumentos fenomenológicos. Los ERAs, con una longitud pre-establecida para todos los registros, con simpleza de forma que permite ubicar detalles característicos en ciertos periodos y con una directa utilidad práctica en cada componente vectorial, se muestran como ventajosas alternativas para expresar el *movimiento de control*.

- Un ERA de CU es un vector de periodos y ordenadas espectrales (*T periodo, OE ordenada*) que la RN lee y busca las relaciones con condiciones particulares de respuesta en cada sacudida. ¿Es suficiente un ERA para representar numéricamente las diferencias paramétricas entre cada evento?. Observe de nuevo las Figs.5.53 y 5.54. La respuesta claramente es no. ERAs con mismo efecto de trayectoria (dirección y distancia fuente→sitio) parecen no responder a cambios en profundidad focal o magnitud, algunos otros espectros muy similares (numéricamente) provienen de epicentros muy lejanos con magnitudes separadas en más de dos unidades.

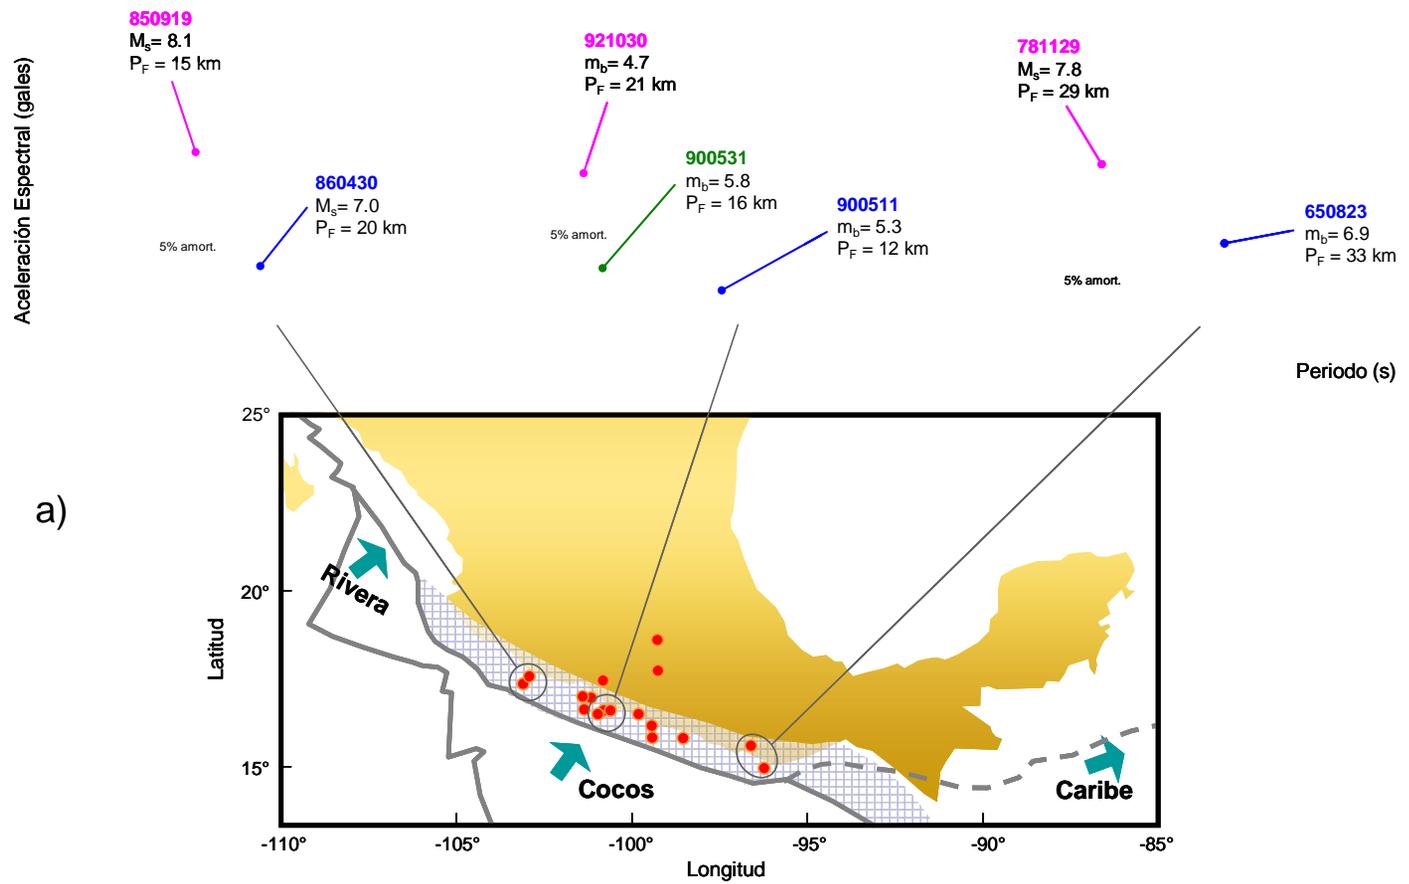


Figura 5.53 Algunos ejemplos de a) ERAs para sismos incluidos en la base de datos, CU-sitio en roca blanda

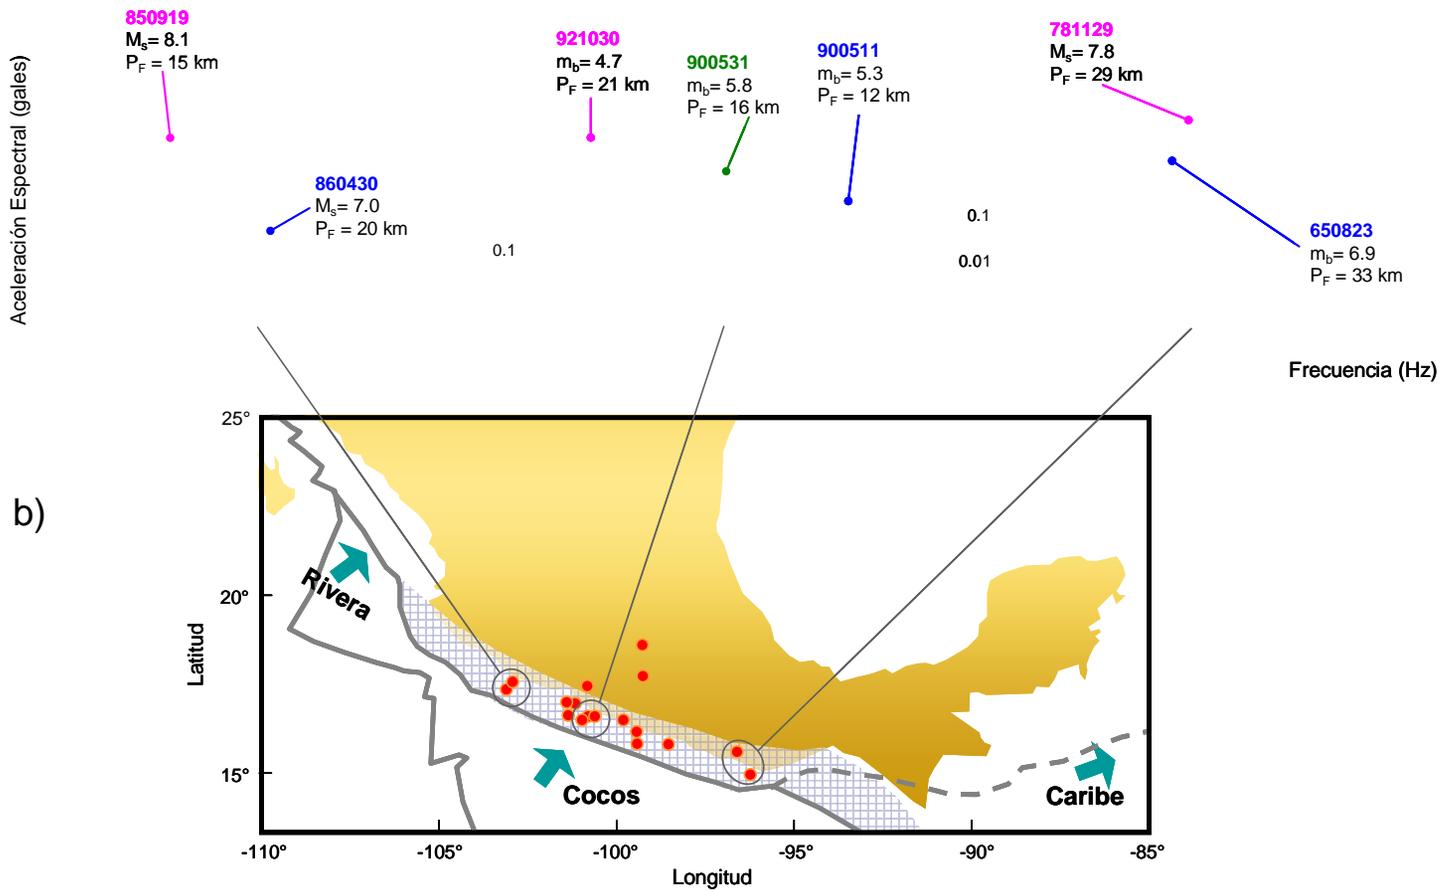


Figura 5.54 Algunos ejemplos de b) EAFs para sismos incluidos en la base de datos, CU-sitio en roca

Expresar cabalmente la tectónica mexicana (complejas señales no estacionarias producto de mecanismos *parcialmente* comprendidos) parece mucha responsabilidad para los ERAs de CU. En este trabajo de investigación se propone adicionar al vector (*T,OE*) información sobre la zona sismogénica, la magnitud, la profundidad focal y la distancia fuente-sitio para evidenciar características de cada historia de aceleraciones que pudieran estar enmascaradas por los ERAs.

Resulta indiscutible que éstas no son las únicas o las mejores variables para caracterizar comportamientos y respuestas sísmicas, incluso es imposible para un ser humano visualizar de qué manera se relacionan o integran con la información vectorial de un ERA y concluir acerca de su *real* utilidad, pero definitivamente la simpleza de estos parámetros en la interpretación del fenómeno sismo→movimiento es muy ventajosa y, como se demostrará posteriormente con las predicciones neuronales, resuelve eficazmente el problema de expresión de la demanda sísmica.

Entrada E-2. Tectónica de México *TM*.

Los grandes temblores en México ($M_s \geq 7.0$) a lo largo de la costa del Pacífico, son causados por la subducción de las placas oceánicas de Cocos y de Rivera bajo la placa de Norteamérica y por ello son conocidos como sismos de subducción (Kostoglodov y Bandy, 1994) (Fig. 5.55). El terremoto más grande que ha ocurrido en México en el presente siglo (Jalisco, 3 de junio de 1932, $M_s = 8.2$) ocurrió sobre la interfaz de la placa de Rivera y la de Norteamérica (Singh et al, 1985a) y muestra que una placa pequeña, joven y con una velocidad relativamente baja de subducción es capaz de generar grandes temblores.

Los grandes temblores también ocurren en el continente con profundidades de unos 60 km. (Fig.5.55, Zona generadora de sismos profundos). En este caso los temblores presentan un mecanismo de fallamiento normal que refleja el rompimiento de la litosfera oceánica subducida (Singh et al, 1985b). Son menos frecuentes pero se sabe que pueden causar grandes daños, ejemplos importantes son los sismos de Oaxaca -15/01/1931, $M_s=7.8$ -, el de Orizaba -23/08/1973, $M_s=7.3$ - y el de Huajuapán de León -24/10/1980, $m_b=7.0$ - .

En menor número se encuentran los temblores que han ocurrido dentro de la placa continental los cuales, dependiendo de su ubicación, han generado daños considerables en los asentamientos humanos ($M_s \geq 7.0$). Existe también lo que podría llamarse sismicidad de fondo, temblores con $M_s \geq 5.0$, cuyo origen no puede asociarse a ninguna estructura geológica en particular.

De acuerdo con lo expresado anteriormente, se pueden definir dos grandes zonas generadoras de sismos que afectan al valle de México: Zona de Subducción y Zona de Sismos Profundos. No se cuenta con un número suficiente de patrones (número de registros similar al de las otras zonas) generados en la placa Continental y debidos a la sismicidad de Fondo, además, considerando las incertidumbres que se tienen sobre los

mecanismos y su potencial de daño, los patrones cuyo epicentro los ubiquen en estas zonas se considerarán pertenecientes a la Zona de Sismos Profundos.

Entonces, es el epicentro del sismo el que dirige la declaración del nodo de clase *TM*. Cuando $TM = 0$ se trata de un epicentro en Zona de Subducción, en el caso de $TM = 1$ nos estamos refiriendo a un evento de la Zona de Sismos Profundos, Continental o de Fondo.

Entrada E-3. Magnitud *M*.

La magnitud (M_L, M_s, m_b, M_w , entre las más usadas) como dígito asociado a la cantidad de energía liberada o tamaño de un sismo tiene limitantes de aplicación bajo condiciones en el registro.

Es práctica común cuando se construyen relaciones para estimar aceleraciones de terreno que se elija alguna escala como base y a partir de ella los patrones (eventos) que por alguna razón no reporten el criterio seleccionado sean procesados para homogenizar magnitudes. Este proceso sobre *M* no repercute en mejoras a la expresión (caracterización) del tamaño del sismo (Huerta y Reinoso, 2002) sino que resulta de la búsqueda de mejores ajustes entre datos medidos y funcionales matemáticos. Para elegir la escala de entrada al esquema neuronal es necesario concienciar sobre la teoría que sustenta a cada alternativa.

La *magnitud*, teóricamente sin límite superior, está limitada por la resistencia de las rocas en la corteza terrestre y la longitud de ruptura *probable* en la falla. La magnitud local M_L , introducida por Richter, se determina a partir de la máxima amplitud registrada por un sismógrafo Wood Anderson. La magnitud de ondas superficiales M_s se basa en la amplitud máxima producida por las ondas superficiales Rayleigh. Debido a que M_s no aplica para sismos con profundidad focal mayor a 50 km (no se generan ondas superficiales con suficiente amplitud) fue creada la magnitud de ondas de cuerpo m_b basada en la amplitud de ondas de cuerpo con períodos cercanos a 1.0 s. M_s y m_b no reflejan adecuadamente el tamaño de sismos muy grandes pues subestiman su valor debido a la saturación de las escalas.

Reconociendo deficiencias en M_L, M_s y m_b se generó el concepto “momento sísmico” para designar el tamaño de un sismo en función directa de las propiedades físicas de la roca y de las dimensiones del área que sufre la ruptura. La magnitud de momento M_w , derivada del “momento sísmico”, es actualmente una de las escalas más usadas en estudios sísmicos. Las magnitudes de sismos *históricos* fueron recalculadas usando esta nueva escala y los cambios más notables se encontraron en sismos muy grandes, como el sismo de Chile de 1960 con una magnitud M_s de 8.3 y M_w de 9.5 convirtiéndose así en el sismo de mayor magnitud hasta hoy registrado.

Existe también la magnitud energía M_E que es una medida del potencial de daño a las estructuras y requiere del cálculo del flujo de energía sobre un amplio rango de frecuencias y la magnitud de duración M_d que es una variación del concepto de magnitud local que se emplea en algunas redes y es calculada con base en la duración del registro.

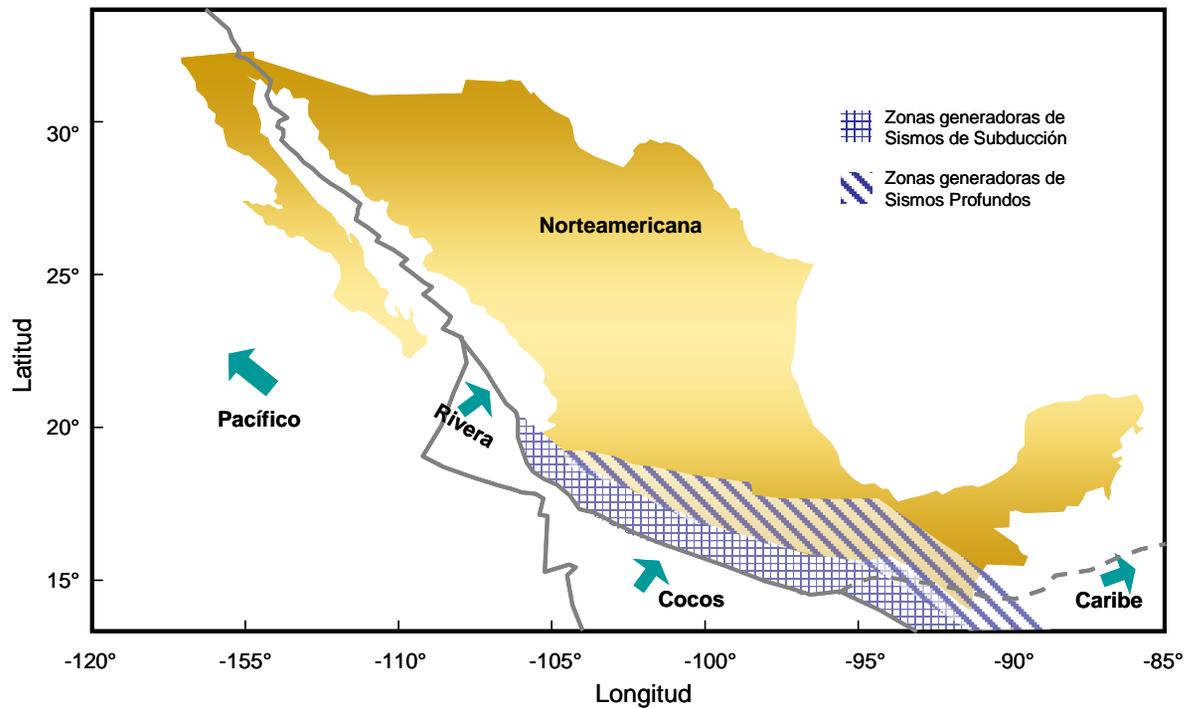


Figura 5.55 Grandes Zonas Sismogénicas de la República Mexicana

Con base en estas breves descripciones se puede concluir que i) existe una imprecisión inherente a todos los cálculos para obtener M , ii) cada escala cubre un aspecto importante del fenómeno pero ninguna hace uso del *conocimiento* en su totalidad y iii) la escala más usada y aceptada en la comunidad sismológica, M_w , es útil para *alejarse* a los sismos *extremos* de las densas nubes de eventos con intensidad *media*, donde la mayoría de las escalas reportan valores de M muy similares.

Por lo tanto podemos concluir que la *mejor* expresión para *medir* un sismo es aquella que sirva para los propósitos del modelo (*tarea*) y las transformaciones de escalas dependen exclusivamente de los criterios de ajuste numérico. M en un entorno neuronal puede ser expresada sin procesamientos, aprovechando las ventajas de las redes para trabajar en ambientes numéricos contaminados (incongruencias e indeterminaciones).

En esta investigación, considerando la naturaleza de la base de datos, se propone hacer uso del valor de magnitud más alto reportado en el acelerograma como una referencia *aproximada* de características

particulares de cada sismo. Para sismos de intensidad *media* la mayoría de los eventos contienen $M_L, M_s, o m_b$ y las diferencias entre ellas es de muy pocas décimas de punto y en el caso de eventos extremos se cuenta con M_w como el valor más alto reportado.

M neuronal es un dígito de clase con base numérica amplia. La RN identifica *individuos* tomando en cuenta las diferencias *importantes* o *sutiles* entre unidades de M . Las condiciones marcadas por las otras variables de entrada dirigen la ocurrencia de cierta M máxima. A diferencia de los funcionales tradicionales que persiguen congruencia entre M altas \rightarrow OE altas y M bajas \rightarrow OE bajas, en esta investigación, donde no se buscan leyes *no naturales* ni ajustar planteamientos subjetivos y *vagos*, se plantea tomar libremente el valor máximo de M y dejar que el *conocimiento* básico (expresado con las otras variables de entrada) sirva para que la red *aprenda* y genere las relaciones paramétricas sin hipótesis restrictivas.

Entrada E-4. Distancia Epicentral D_E .

En la literatura se pueden encontrar tantas maneras de medir la distancia fuente-sitio como funcionales sísmicos publicados. Esta medida (la distancia horizontal más cercana a la proyección vertical de la ruptura, la distancia más cercana a la superficie de ruptura, la distancia más cercana a la superficie de ruptura sísmogénica o la distancia hipocentral, por mencionar algunas) es, tradicionalmente, la manera como se expresa el fenómeno de propagación de ondas. Tal responsabilidad obliga a la definición, lo más cabalmente posible, de la dimensión de la fuente y la localización y profundidad epicentral.

En principio, con el tiempo, la estructura detallada 3D de la corteza terrestre podría ser conocida y un modelo de propagación de ondas podría ser determinado para cada fuente y sitio específicos, pero actualmente nuestro conocimiento y nuestra experiencia no nos permiten asegurar que los planteamientos sobre fuentes y epicentros están libres de incertidumbre. El argumento en el que se basa este trabajo de tesis para proponer la distancia fuente-sitio neuronal es que la variabilidad entre las relaciones de movimientos de terreno se debe al fenómeno de propagación de ondas y en ese sentido es mejor obviar cualquier descripción confusa.

En esta investigación se propone a la D_E , distancia calculada sobre la superficie de la Tierra entre el punto de observación y el epicentro del sismo (fácil de calcular, de interpretación simple y directa), como la descripción numérica *aproximada* del efecto de la distancia sobre el fenómeno de propagación de ondas sísmicas (Fig. 5.56).

Entrada E-5. Profundidad Focal P_F .

La profundidad focal es comúnmente usada como variable para etiquetar sismogénesis y su aplicación en regresiones se limita a marcador de clases. Para zonas de subducción, como la mexicana, 50 km es una frontera aceptada para separar sismos interplaca ($P_F < 50$ km) de los intraplaca ($P_F \geq 50$ km) (Tichelaar y Ruff, 1993; Youngs et al., 1997). Sin embargo, este tipo de límites son siempre motivo de discusión cuando se estudian fenómenos naturales: 49.9 km y 50.1 km pertenecen a sismogénesis distintas?. Una respuesta *inteligente* a este cuestionamiento involucra a P_F y al mismo tiempo a otros parámetros del fallamiento, por lo que declarar a P_F como nodo de clase genera planos que no expresan adecuadamente el fenómeno, lo que hacen es reducir la dimensión del problema a niveles manejables con herramientas matemáticas elementales.

P_F neuronal tiene la cualidad de nodo numérico. En esta investigación se considera que esta variable, en su forma *básica*, permite al modelo extraer mejores nexos paramétricos y no limita la flexibilidad conexionista. Diferenciar conjuntos (mecanismos de falla) a través de una frontera cerrada (50 km) no genera conexiones neuronales eficientes sino que agrega incongruencias a la expresión de cada evento.

La tripleta (TM, D_E, P_F) representa la información sobre la propagación de ondas permitiendo que (TM, M, [T,OE]) exprese la severidad y potencial de daño en la zona urbana del valle de México.

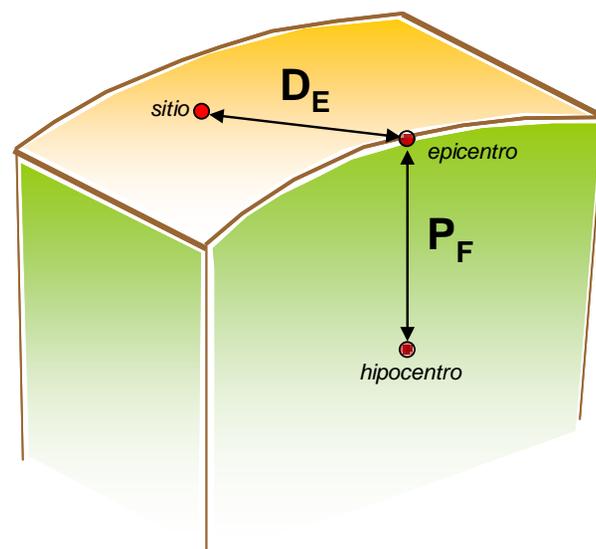


Figura 5.56 Parámetros de entrada directamente asociados a la geometría fuente-sitio

PARÁMETROS S

La influencia de las condiciones locales del suelo en la fuerza de la sacudida del terreno ha sido ampliamente reconocida como un factor que contribuye a la distribución geográfica de las fallas del terreno y daño estructural durante sismos. De particular interés es la amplificación de los movimientos de terreno y el progresivo ablandamiento de los suelos cohesivos (considerado comportamiento *no lineal*) durante sacudidas muy severas.

Registros obtenidos de eventos telúricos en todo el mundo han sido la base para estudios cuantitativos de la influencia de la respuesta del suelo en las características de los movimientos en términos de aceleración, velocidad, desplazamiento y amplitud espectral. Este tipo de estudios ha permitido definir un conjunto de factores (Tabla 5.3) como los operadores del desarrollo de movimientos significativos en cualquier rango de periodos.

Tabla 5.3 Resumen de factores que inciden sobre los movimientos debidos a sismos

SISMOLÓGICOS	GEOLÓGICOS	GEOTÉCNICOS	OTROS
Intensidad de la sacudida, o entrada	Tipo (s) de Suelo (s)	Resistencia de los suelos a bajas deformaciones (velocidad de ondas de corte o máximo módulo cortante)	Efectos 2D y 3D (topografía de la sub-superficie de la base rocosa, efectos de cuenca)
Características frecuenciales del movimiento de entrada	Espesor del depósito de suelo	Contraste de resistencia (impedancia) entre el estrato rocoso y los suelos que lo sobreyacen	
Duración de los movimientos de entrada	Tipo de roca que subyace	Características de amortiguamiento de las unidades de suelo	
	Estructura geológica	Comportamiento degradante del módulo de corte dinámico de los suelos	
		Relación entre la deformación por corte y el esfuerzo cortante para unidades de suelo predominantes	
		Periodo del sitio	

En el caso de los depósitos de suelo de la Ciudad de México, estos factores se traducen en características locales de respuesta dinámica de estratos de arcillas blandas de alta plasticidad y compresibilidad alternadas por lentes más duras de arena, y una particular relación entre la disposición y geometría de estos estratos y la morfología de la cuenca (depósitos de arcilla muy delgados comparados con su extensión lateral). La observación cuidadosa de esta situación y la historia sísmica registrada, ha llevado a pensar que en la mayor parte de la Ciudad la respuesta dinámica del suelo puede ser estudiada por medio de la teoría de propagación unidimensional de ondas -1D- (Rosenbleuth, 1952; Herrera y Rosenbleuth, 1965; Seed e Idriss, 1969; Romo y Jaime, 1986 y Romo y Seed, 1986).

El razonamiento básico en la teoría 1D dicta que, cuando una falla rompe, las ondas de cuerpo viajan en todas direcciones reflejándose y refractándose en diferentes materiales geológicos y que debido a la diferencia entre las velocidades de propagación de ondas entre los materiales (en materiales poco profundos *generalmente* menores a las de los materiales más

profundos) los rayos inclinados que inciden en los contactos entre capas horizontales *normalmente* se reflejan hasta que en las inmediaciones de la superficie llegan a ser prácticamente verticales.

Después, es necesario concienciar sobre las siguientes hipótesis: i) todos los contactos entre capas de material son horizontales, ii) la respuesta de un depósito de suelo está predominantemente causada por la propagación vertical de ondas SH a partir del lecho rocoso que se extiende por debajo de las capas superficiales del terreno, iii) el suelo (homogéneo e isótropo) y el lecho rocoso son infinitamente extensos en la dirección horizontal y iv) los suelos pueden ser caracterizados como un conjunto de materiales o estratos elástico-viscosos por medio de su rigidez al corte, G , y su amortiguamiento, λ .

Con respecto al suelo, los parámetros de caracterización dinámica se consideran primero lineales y posteriormente se aproximan a la no linealidad mediante un proceso *equivalente* donde se buscan valores de (G, λ) compatibles con ciertos niveles de deformación $\gamma\%$.

En el caso de que el perfil del terreno tenga varios estratos de materiales diferentes (suelo estratificado), el proceso puede generalizarse resolviendo la ecuación de propagación de ondas para cada estrato con las condiciones de contorno, en los contactos entre ellos, de igualdad de desplazamientos y de tensión tangencial.

Mientras los modelos de suelo elástico, uniforme e isótropo son muy útiles para ilustrar la influencia de las condiciones del suelo en las características del movimiento del terreno, no son del todo útiles para el análisis práctico de los problemas de respuesta del terreno. Los problemas *reales* de respuesta normalmente consisten en depósitos de suelo con estratos de diferentes características de rigidez y amortiguamiento y con contornos en los cuales la energía de la onda elástica incidente puede reflejarse y/o transmitirse.

Así, después de esta breve revisión teórica del modelado *tradicional* de la respuesta sísmica debemos apuntar que, si bien nuestras actuales estimaciones representan una formidable cantidad de trabajo, meritorias aproximaciones intelectuales y significativos avances técnicos, todavía está lejano el día en el que podamos dejarnos seducir por el confort de nuestros, ahora, *familiares* argumentos y sentarnos a esperar a que la ciencia computacional desarrolle máquinas más veloces y poderosas. Una crítica científica podría argumentar que las más elaboradas de nuestras investigaciones no son más que *castillos de naipes* construidos sobre modelos simplistas con cimientos débiles anclados a relativamente pocas observaciones. Es claro que una postura así es muy radical pero convendría *equilibrar* y aceptar que se requieren *mejores* herramientas de análisis para un manejo *inteligente* de las observaciones (experiencia) si de lo que se trata es de avanzar en el conocimiento.

Mi percepción es que muchos ingenieros eluden la conclusión de que los procesos sísmicos tienen un alto grado de variabilidad y que nuestro conocimiento actual sobre ellos es muy incierto, por la manera en que somos socializados y entrenados como científicos para buscar siempre patrones en las observaciones. En esta investigación se propone mantener esta posición de búsqueda sin dejar de reconocer que el tipo de información, nuestro nivel de conocimiento y la *verdadera* capacidad de las actuales herramientas de análisis nos obligan a buscar alternativas para abordar el modelado de un fenómeno tan complejo como la respuesta sísmica.

Revisemos los aspectos referidos al suelo que deben tomarse en cuenta cuando se modelan respuestas de sitio. Como se observa en la Fig. 5.57 la mayoría de los parámetros de suelo reconocidos, por medio de la experiencia sísmica, con influencia en la magnitud de los efectos de sitio están relacionados con su aplicación en la teoría de propagación de ondas 1D.

Para responder a las hipótesis teóricas sobre los materiales y la propia naturaleza del fenómeno se incluyen características geométricas, de impedancia, resistencia, y comportamiento dinámico con traducción *incierta* a la respuesta observada en campo. En otros capítulos de esta tesis ya se ha abordado el problema de extrapolar condiciones puntuales a estratos de varios metros de espesor, las precauciones necesarias cuando se trabajan

parámetros obtenidos de pruebas in situ, y el debate sobre la linealidad o *casi*-linealidad del comportamiento dinámico de las arcillas de la Ciudad de México.

Se propone entonces concentrar la descripción de las características del suelo en las condiciones más *naturales* registradas numéricamente y obviar las variables derivadas de otros postulados de análisis.

El “tipo de suelo” y el “espesor del estrato”, a pesar de contener cierta subjetividad en su determinación, representan las variables más *básicas* de toda la columna (ver Fig. 5.57). Sin embargo, la determinación lingüística y numérica de estos parámetros contiene un alto grado de subjetividad.

La codificación establecida en el SUCS (Sistema Unificado de Clasificación de Suelos) representa un planteamiento bien organizado y una estructura de análisis muy clara, pero transportar estos lineamientos a materiales dispuestos masivamente en la naturaleza requiere de experiencia y estudios adicionales a las pruebas recomendadas en el propio Sistema. En el caso de estudios en la Ciudad de México hay quienes *prefieren* discretizar los depósitos en un mínimo de estratos y por otro lado, se han desarrollado análisis minuciosos que involucran un volumen importante de capas y propiedades. La definición de las fronteras estratigráficas así como de las propiedades promedio en cada capa repercute significativamente en los resultados finales de los análisis 1D. Antes de presentar la manera en que se expresará al *suelo* neuronalmente es necesario convenir en los siguientes razonamientos:

- a) Los registros en superficie contienen información de cada una de las capas, superficiales y profundas, que conforman un depósito.
- b) Inmersos en cada acelerograma están el espesor, material y número de estratos, las impedancias entre capas, las características dinámicas de las masas de suelo interactuando como miembros de una misma columna, la topografía que afecta al sitio e, incluso, aspectos de la propagación de ondas que no distinguimos en este tipo de historias de tiempo.
- c) Considerar todas las variables que intervienen en la propagación de ondas es prácticamente imposible si se intenta disgregar o reducir el fenómeno a unidades simples de análisis. En la aproximación neuronal se reconoce la relación espacial entre las historias registradas en todo el valle y se asocian en un planteamiento multidimensional.
- d) Dentro de este enfoque, las diferencias entre los ERAs registrados en un mismo sitio se deberán únicamente a factores sismogénicos y de directividad, de la misma manera, las diferencias entre los ERAs registrados durante un mismo sismo en sitios aledaños se refieren a condiciones de suelo y topografía particulares.

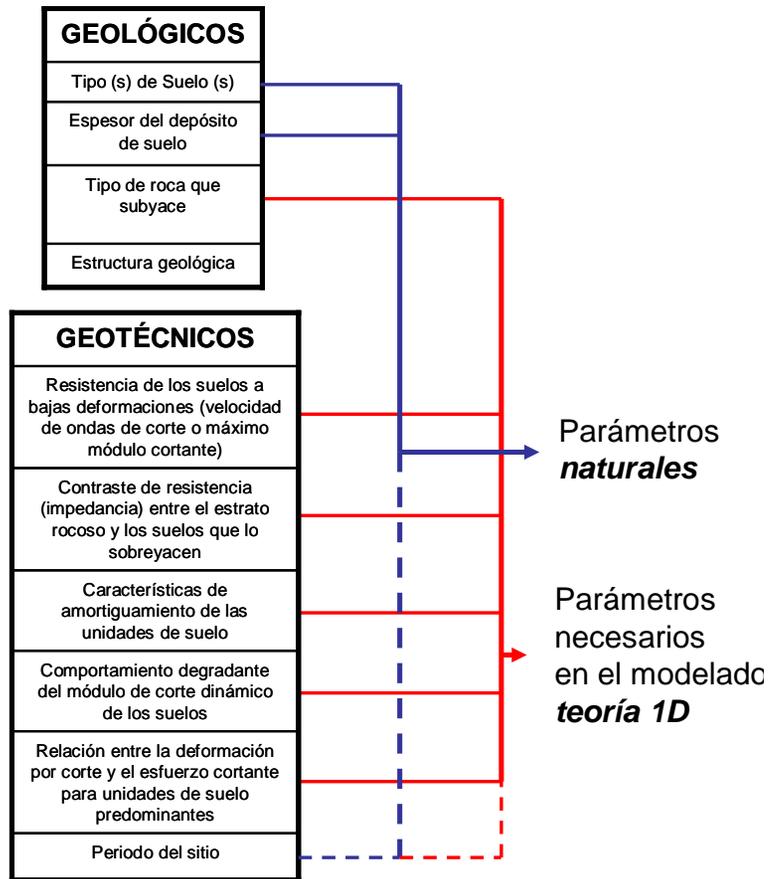


Figura 5.57 Factores relacionados con los suelos y que tienen influencia en los efectos de sitio

En la Fig. 5.58 se observa el resumen gráfico del planteamiento anterior. El **Sistema** lo conforman la cuenca y los suelos depositados. El monitoreo en un punto es parte de una respuesta global. En este modelo no se busca dar solución a la ecuación de propagación de ondas ni se pretende que el esquema neuronal sea una formulación *alternativa* a dicha ecuación.

La idea de modelado neuronal es *inductiva*, siendo la herramienta para inferir el fenómeno la red neuronal y las observaciones para lograrlo los registros sísmicos y algunas características de los depósitos de suelo.

Si el **Sistema** y las estaciones de monitoreo se mantienen, describir al suelo se reduce a caracterizar la situación de la estación dentro del **Sistema** (Fig. 5.59) dejando a un lado la controversial tarea de definir completamente el comportamiento de los suelos ante cargas dinámicas.

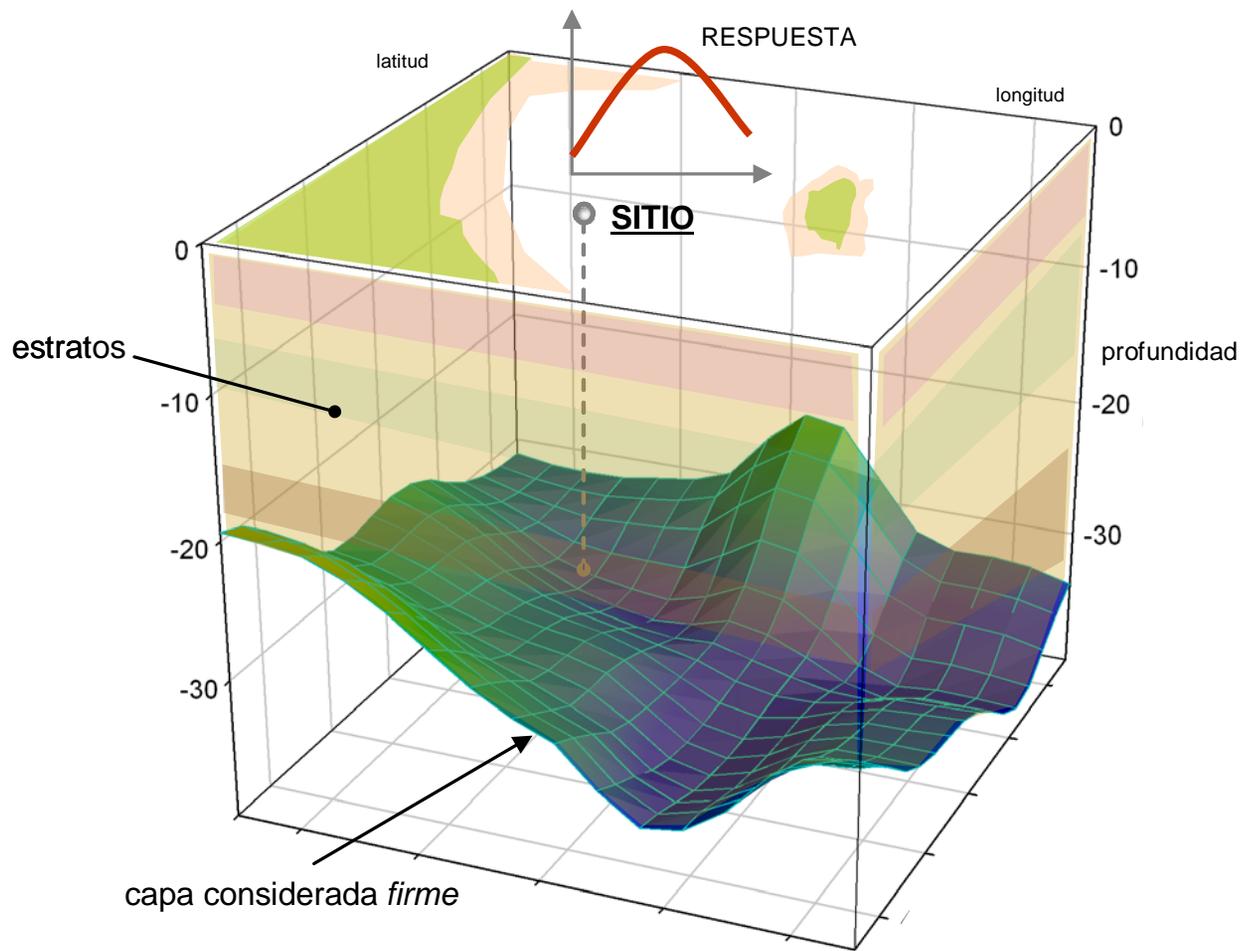


Figura 5.58 Resumen gráfico del Sistema

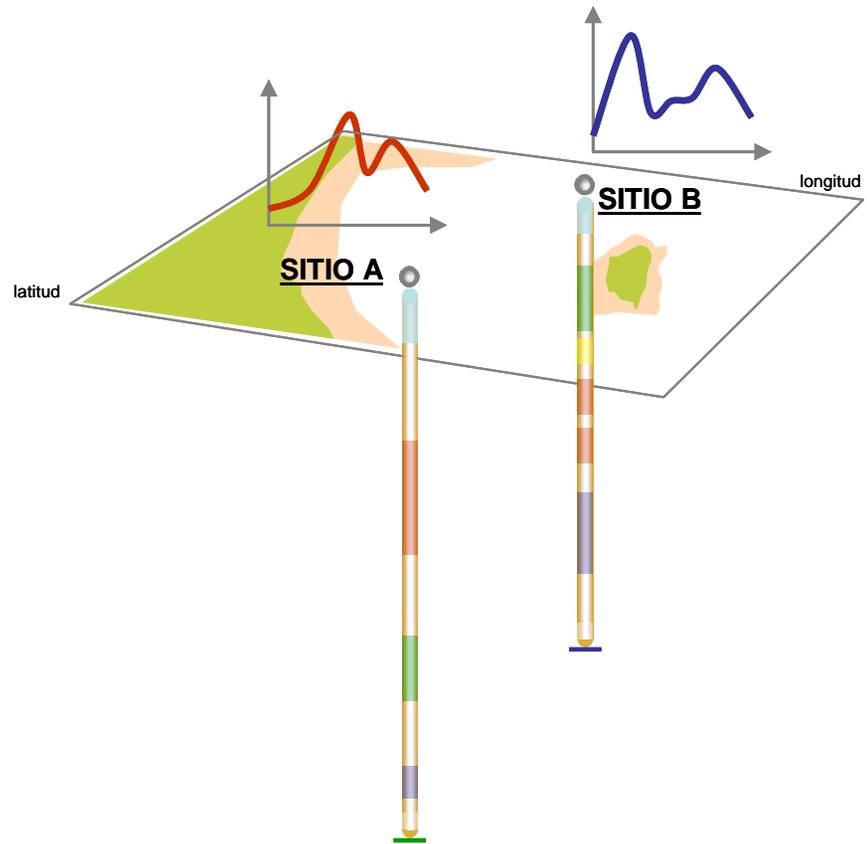


Figura 5.59 Representación de las respuestas medidas dentro del *espacio*

La propuesta de esta investigación es considerar la expresión del periodo fundamental proporcionada por el clásico modelo 1D de propagación vertical de ondas de corte $T_s = 4H/V_{S(P)}$ (H es el espesor del depósito y $V_{S(P)}$ la velocidad de onda de corte promedio) para caracterizar con variables *naturales* al depósito de suelo.

Es importante señalar que no es competencia de esta variable dirigir las respuestas espectrales máximas de la RN, estrictamente sirve para caracterizar con pocos dígitos la situación de las estaciones. De entre otros parámetros T_s se eligió porque i) el valor de H varía sobre el valle de acuerdo con (X,Y) , ii) $V_{S(P)}$, aún como parámetro promedio, da idea de la rigidez del depósito y su valor, por ser obtenido *in situ*, tiene referencia *espacial (Sistema)*.

Con base en estudios de campo y laboratorio que fueron desarrollados para evaluar la rigidez dinámica de los estratos de suelo se definieron los periodos de los sitios contenidos en la base de datos (Tabla 5.4) (Sarmiento, 2001; Lermo et al., 1988).

Algunos de los sitios de los enlistados en la Tabla 5.4 reportan el mismo valor de T_s lo que numéricamente para la RN representaría estaciones que, ante un mismo evento, generan una misma respuesta. Después de verificar en la base de entradas→salidas que esto no siempre, sucede se decidió cambiar el valor calculado por uno más *conveniente*.

La variación, como se observa en la última columna de la Tabla 5.4, se aplica a los decimales del periodo lo que no representa ninguna incongruencia fenomenológica (modificar *un poco* $V_{S(P)}$ o H generarían estos nuevos valores) y numéricamente incide en la creación de un ejemplo diferente. En la Fig. 5.60 se muestra la situación sobre la zonificación geotécnica de los sitios usados durante el entrenamiento de la RN.

Tabla 5.4 Sitios contenidos en la base de datos

Zona: Lago

No.	Clave (mapa)	Nombre estación	Lat (N)	Long (W)	T _s	T _s final
1	JC54 (54)	Jard de Coyoacán	19.313	99.127	1.20	1.20
2	MI15 (15)	Miramontes	19.283	99.125	1.30	1.30
3	DFRO (RO)	Roma	19.405	99.166	1.30	1.35
4	IB22 (22)	Ibero	19.345	99.130	1.40	1.40
5	CH84 (84)	Culhuacán	19.330	99.125	1.40	1.44
6	SI53 (53)	San Simón	19.375	99.148	1.40	1.48
7	SCT (SCT)	SCT	19.393	99.147	2.00	2.00
8	CJ03 (03)	CU Juárez	19.410	99.157	2.05	2.05
9	TL08 (08)	Tlatelolco	19.450	99.134	2.10	2.10
10	C105 (05)	Cibeles	19.419	99.165	2.10	2.13
11	TL55 (55)	Tlatelolco 2	19.436	99.143	2.15	2.15
12	RMAS (RM)	Roma A Sup	19.420	99.155	2.20	2.20
13	GA62 (62)	Garibaldi	19.439	99.140	2.20	2.24
14	LI58 (58)	Liverpool	19.426	99.157	2.20	2.28
15	VG09 (09)	Valle Gómez	19.454	99.123	2.40	2.40
16	BL45 (45)	Balderas	19.425	99.148	2.40	2.45
17	RM48 (48)	Rodolfo Méndez	19.436	99.128	2.50	2.50

Zona: Lago

No.	Clave (mapa)	Nombre estación	Lat (N)	Long (W)	T _s	T _s final
18	HJ72 (72)	Hospital Juárez	19.425	99.130	2.60	2.60
19	XP06 (06)	Xochipilt	19.420	99.135	2.60	2.65
20	BO39 (39)	Bondojoito	19.465	99.105	2.70	2.70
21	BA49 (49)	Buenos Aires	19.410	99.145	2.80	2.80
22	VM28 (28)	Villa del Mar	19.381	99.125	2.90	2.90
23	CA59 (59)	Candelaria	19.426	99.118	3.00	3.00
24	JA43 (43)	Jamaica	19.405	99.125	3.00	3.05
25	AP68 (68)	Apatlaco	19.381	99.107	3.10	3.10
26	AR14 (14)	Aragón	19.481	99.076	3.40	3.40
27	CDAO (CD)	Central Abastos Oficina	19.372	99.096	3.50	3.50
28	UNKS (UK)	Un Kennedy Sup	19.419	99.111	3.50	3.55
29	TLAS (TL)	Tlacotal Sup	19.397	99.105	3.60	3.60
30	DM12 (12)	Deport Moctezuma	19.431	99.096	3.60	3.65
31	ZARS (ZA)	Zaragoza Sup	19.419	99.088	4.00	4.00
32	HA41 (41)	Hangares	19.418	99.079	4.00	4.05
33	AU11 (11)	Autódromo	19.392	99.067	4.20	4.20

Tabla 5.4 Sitios contenidos en la base de datos

Zona: Transición

No.	Clave (mapa)	Nombre estación	Lat (N)	Long (W)	T _s	T _s final
1	CO47 (47)	Coyoacán	19.371	99.170	0.50	0.50
2	DR16 (16)	Deport Reynosa	19.501	99.183	0.55	0.55
3	COYS (CY)	Esta. 6 Coyoacán	19.348	99.169	0.60	0.60
4	EO30 (30)	Esparza Oteo	19.389	99.177	0.65	0.65
5	GR27 (27)	Granjas	19.475	99.180	0.80	0.80
6	ES57 (57)	Escandón	19.402	99.177	0.85	0.85
7	AU46 (46)	Ángel Urraza	19.383	99.168	0.85	0.88
8	ME52 (52)	Marianao Escobedo	19.438	99.182	0.90	0.90
9	DX37 (37)	Xotepingo	19.332	99.144	0.95	0.95
10	AO24 (24)	Alberca Olímpica	19.358	99.154	1.00	1.00

Modelo

En la Fig. 5.61 se muestra la propuesta de topología neuronal para estimar las respuestas en el valle. A pesar de los intentos por simplificar la representación numérica entradas→salida, la distribución de los ejemplos (un ejemplo es una respuesta en un sitio relacionada con un evento) se observa poco eficiente.

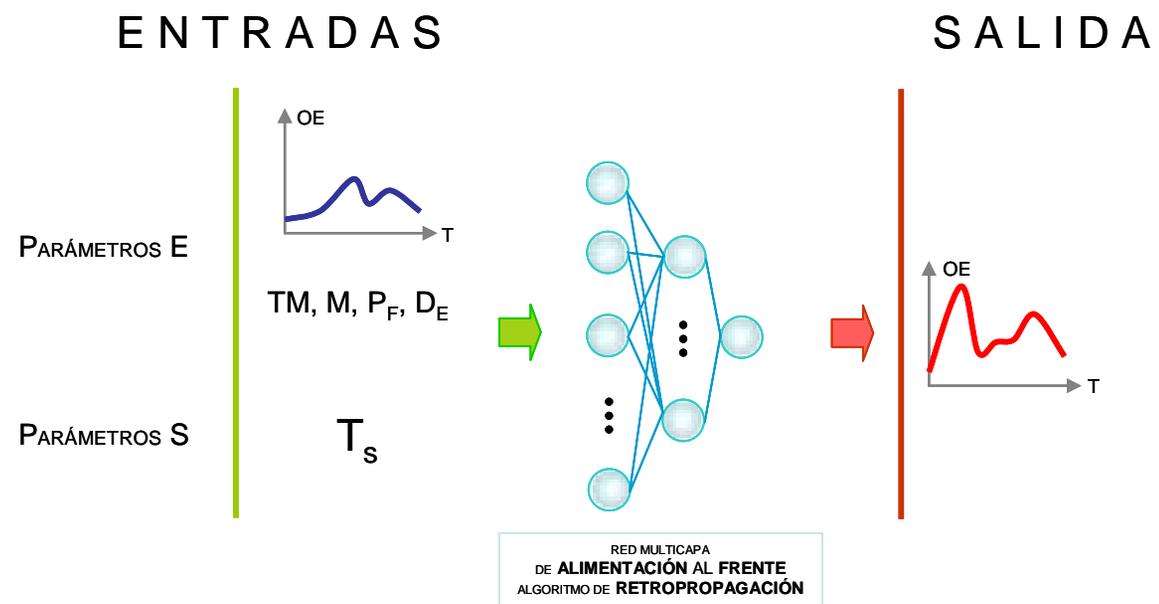


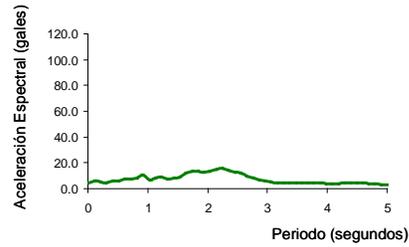
Figura 5.61 Esquema neuronal para la estimación de las respuestas en el valle de México

Observe la Fig. 5.62. Un ERA con 50 puntos ($\Delta T= 0.1$, desde $T= 0$ hasta $T= 5$ s) es un ejemplo compuesto de 50 líneas o patrones de comportamiento asociados al vector [TM,M,D_E,P_F] de valores numéricos constantes, durante el análisis de un mismo sismo.

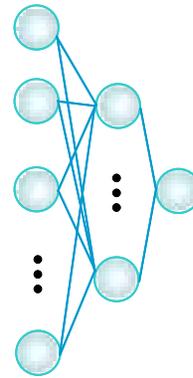
El vector T indica la longitud de cada ejemplo y asocia directamente los valores de acción→reacción (ordenadas espectrales de entrada y salida). El nodo casificador T_S, constante al analizar un mismo sitio, indica la situación en superficie.

En cada uno de los 43 sitios se cuenta con una historia sísmica registrada que genera cerca de 300 posibles ejemplos, por lo que espectros con 50 puntos generarían una base de datos con al menos 15000 líneas. Este acomodo (ERAs en columna) permite detallar las relaciones periodo a periodo pero acarrea un problema de dimensión.

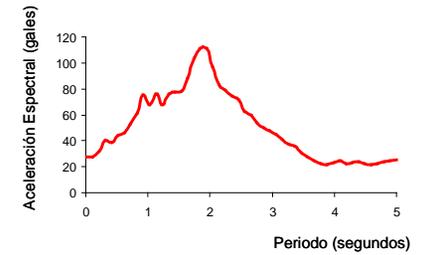
ENTRADAS



T	OE	T _s	TM	M	P _F	D _E
0.01	4.85	2	0	6.5	30	320
0.11	5.74	2	0	6.5	30	320
0.21	5.34	2	0	6.5	30	320
0.32	4.83	2	0	6.5	30	320
0.42	5.79	2	0	6.5	30	320
0.52	6.20	2	0	6.5	30	320
0.62	7.13	2	0	6.5	30	320
0.72	7.41	2	0	6.5	30	320
0.82	8.13	2	0	6.5	30	320
0.93	10.50	2	0	6.5	30	320
1.03	7.08	2	0	6.5	30	320
1.13	8.42	2	0	6.5	30	320
1.23	8.88	2	0	6.5	30	320
1.33	7.71	2	0	6.5	30	320
1.44	8.41	2	0	6.5	30	320
1.54	9.28	2	0	6.5	30	320
1.64	11.92	2	0	6.5	30	320
⋮						
4.39	4.40	2	0	6.5	30	320
4.49	4.56	2	0	6.5	30	320
4.59	4.29	2	0	6.5	30	320
4.69	3.80	2	0	6.5	30	320
4.80	3.56	2	0	6.5	30	320
4.90	3.29	2	0	6.5	30	320
5.00	3.01	2	0	6.5	30	320



SALIDA



OE _{sitio}
27.58
27.84
31.92
40.45
38.93
43.80
46.40
53.20
60.80
75.10
68.18
75.78
67.76
75.66
77.81
78.13
88.30
⋮
23.68
22.25
21.78
22.61
23.65
24.66
25.30

Figura 5.62 Representación de la demanda y respuesta sísmica: ERAs en columna

La tarea que se le asigna a la RN es encontrar, para cada conjunto que describe la acción de un sismo, las relaciones entre las ordenadas del ERA de control y las del sitio de análisis cuando de 6 entradas, el valor de 4 unidades permanecen constantes, un nodo funge como contador y sobre la variación del nodo OEcontrol reside principalmente el comportamiento de la OEsalida.

Ahora, comparando los conjuntos de un mismo evento registrado en diferentes sitios, éstos se componen de un nodo contador, cuatro unidades de entrada constantes (incluida la OEcontrol) y es T_s el nodo que se encargaría de describir dentro del esquema neuronal los cambios entre las ordenadas espectrales registradas en CU y las medidas en distintos puntos sobre la superficie del valle.

A pesar de los intentos por minimizar la complejidad del fenómeno *efecto de sitio* al emplear funciones lineales o cuasi-lineales para transferir la información registrada en roca hacia la superficie del terreno por medio de factores simplistas, las respuestas en suelos blandos son una tarea multidimensional y no lineal. Entonces habrá de reconocerse que, alimentar al modelo con sólo un nodo conductor de respuesta, a pesar de la robustez de las RNs, no corresponde al orden de complejidad de la tarea asignada.

Observe la Fig. 5.63. Los ERAs en renglón generan una base de datos con 55 unidades de entrada. Si cada línea, o patrón de comportamiento, es un ejemplo de una respuesta en un sitio debida a la acción de un sismo, entonces la base se compone de cerca de 300 líneas.

En esta representación el nodo T no es necesario si cada OE se ubica en una posición inamovible durante el modelado. $[TM, M, D_E, P_F]$ y T_s se colocan al lado de las posiciones espectrales y el mapeo se realiza hacia las 50 salidas que constituyen el ERA de respuesta.

Este acomodo, con la verdadera participación de todos los nodos para indicar variaciones en el ERA de salida, se vislumbra más adecuado. Sin embargo, la base de datos tiene características particulares que la hacen todavía muy compleja: i) la historia registrada no es proporcional en todas las estaciones, ii) el número de ejemplos resulta *corto* comparado con el número de entradas, y iii) el rango numérico de los Parámetros E y S no se cubre *ordenadamente* (pocos ejemplos de eventos extremos, gran población sobre la media).

Dentro de estas condiciones existe una constante y es el desequilibrio entre el despliegue de múltiple información en las entradas y el tamaño (en número de ejemplos) de la base de datos.

Con base en todo lo descrito anteriormente, se advierten claramente los aspectos conductores del modelo neuronal:

- NO se conoce la estructura matemática que relaciona al evento con la respuesta
- NO se puede afirmar sobre la suficiencia ni pertinencia de las variables que describen al fenómeno
- NO se extrae completa ni congruente información a través de ERAs vectoriales
- NO se representa, en la historia sísmica registrada, un vasto conjunto de combinaciones paramétricas.

En esta investigación estos puntos conforman el contexto de modelado y no, como en análisis lineales convencionales, se trata de obstáculos insolubles objetos de evasión.

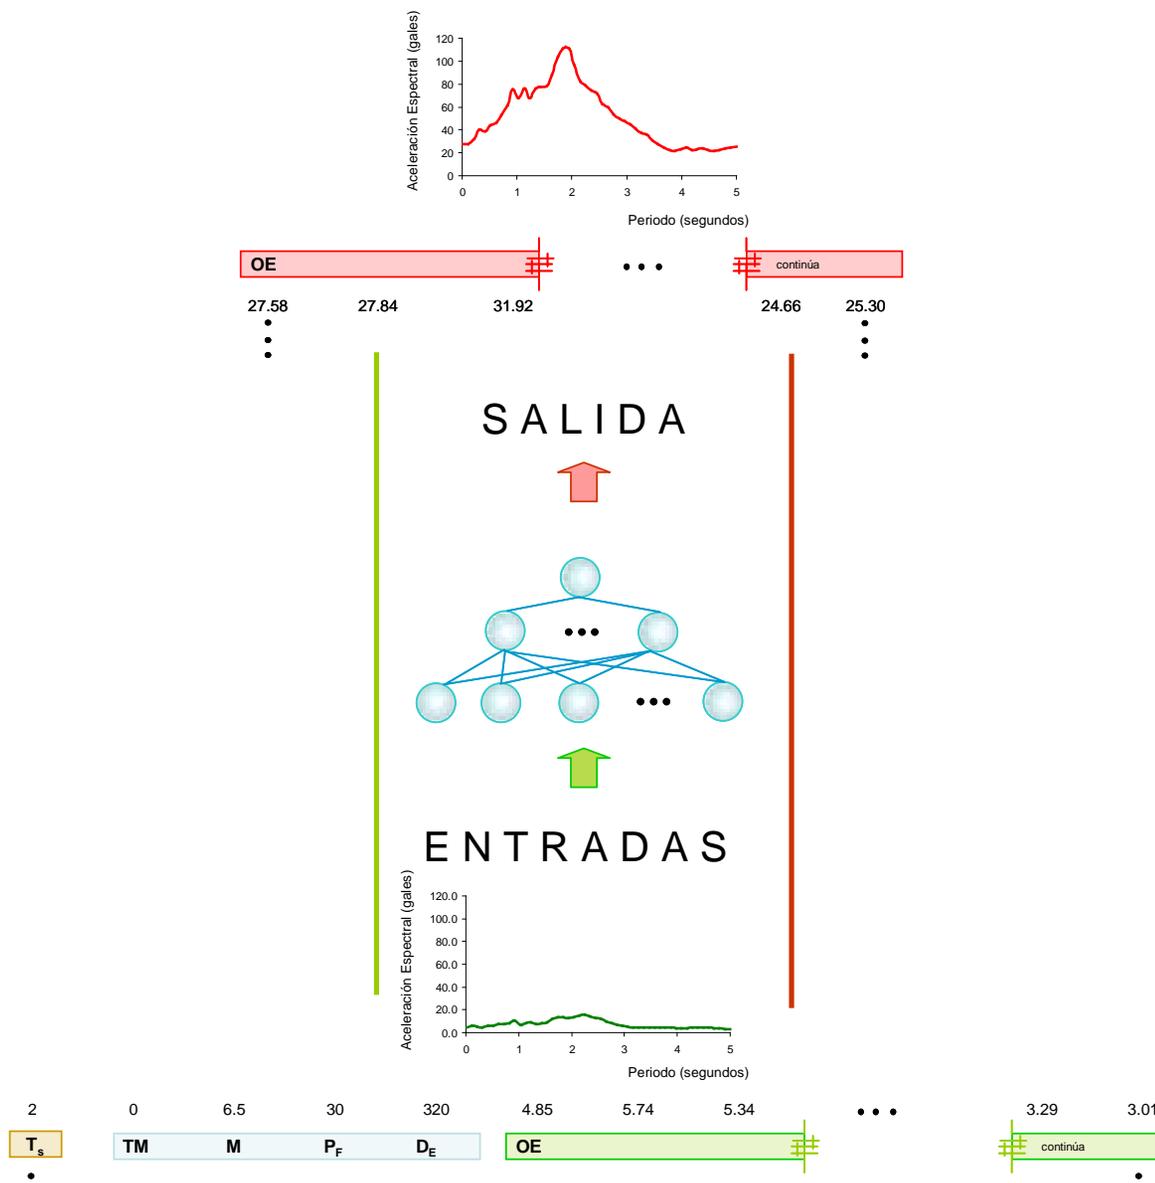


Figura 5.63 Representación de la demanda y respuesta sísmica: ERAs en renglón

- Pre-procesamiento de los ERAs

Los suelos, como sistemas reales, se caracterizan por un cierto número de estados coexistiendo y por la presencia de fluctuaciones. Sistemas de este tipo no deben ser resueltos analíticamente simplificándolos hacia sistemas lineales porque se estarían eludiendo las partes del sistema que interfieren, cooperan, compiten o interactúan de maneras muy complejas.

Aplicando la Teoría de Sistemas Dinámicos en el estudio de la respuesta sísmica de depósitos de suelo blando, en particular aplicando los Mapas de Recurrencia MR, se intenta extraer información relevante a partir de un análisis inverso: dada una respuesta monitoreada se dibujan sus trayectorias en espacios *convenientes* y a partir de ellas se encuentran las *soluciones geométricas* sin resolver las ecuaciones que gobiernan al propio sistema.

Para generar los MR de nuestro conjunto de datos experimentales el primer paso es reconstruir la dinámica embebiendo la serie de tiempo unidimensional (ERA) en el espacio de reconstrucción dimensional usando el método del retraso de coordenadas. Existen interesantes trabajos (Iwansky y Bradley, 1998) donde se demuestra que los MR de datos experimentales parecen ser independientes cuantitativa y cualitativamente de la dimensión embebida, por lo menos en términos de análisis geométrico de las estructuras que se despliegan.

En esta investigación se hará uso de la unidimensión porque precisamente se busca desplegar información geométrica de los sistemas de suelo y sus patrones de respuesta sin buscar contundencias sobre naturalezas aleatorias o deterministas.

En el cálculo de la distancia entre OEs se usa la máxima norma (en 1D la máxima norma es equivalente a la p-norma euclidiana) por su facilidad de implementación y la posibilidad de hacer comparaciones directas entre los MRs generados usando diferentes valores sin re-escalar los mapas.

Por cuestiones de espacio y dado que el entendimiento humano (*promedio*) no detecta patrones entre cientos de multiestructuras, sólo se muestran algunos casos representativos de la base de datos para establecer la lectura de un MR, la interpretación de las estructuras que despliega, y para tratar su introducción dentro de un contexto sísmico.

En la Fig. 5.64 se muestran las partes que componen un MR construido a partir de información de un ERA. Todos los MR construidos en esta tesis partieron de ERAs de 1000 puntos por lo que las imágenes son la expresión gráfica de matrices de 1000x1000 píxeles. En las ordenadas y abscisas se cuenta con 1000 posiciones donde se coloca el valor de la distancia entre puntos ij (para detalles vea el Capítulo 4).

Una vez que se tienen las diferencias referidas a cada posición ij se codifican con base en un esquema de colores en el que conforme se avanza de colores cálidos a fríos las distancias entre puntos se van haciendo mayores: inicia en BLANCO para valor nulo y culmina en NEGRO para la máxima distancia calculada. Cada MR cuenta con la misma barra de colores “espectral” cambiando sólo los valores acotados en sus extremos dependiendo de las amplitudes del ERA y las relaciones entre las máximas respuestas de osciladores de diferentes periodos.

Interpretación gráfica de un MR. Para mostrar las estructuras típicas en MRs de ERAs se muestran los MRs de los registros obtenidos en SCT, CDAO, Hangares, Balderas, Garibaldi, Candelaria y el sitio de *control* (CU-roca).

Cuando se exploran las estructuras desplegadas en un MR se deben verificar condiciones globales y particulares que en conjunto describen la *imagen* de la dinámica del sistema reconstruido. Ciertas características se identifican e interpretan de manera directa, como la homogeneidad para señales estacionarias o en sistemas puros estocásticos los agregados de puntos desestructurados.

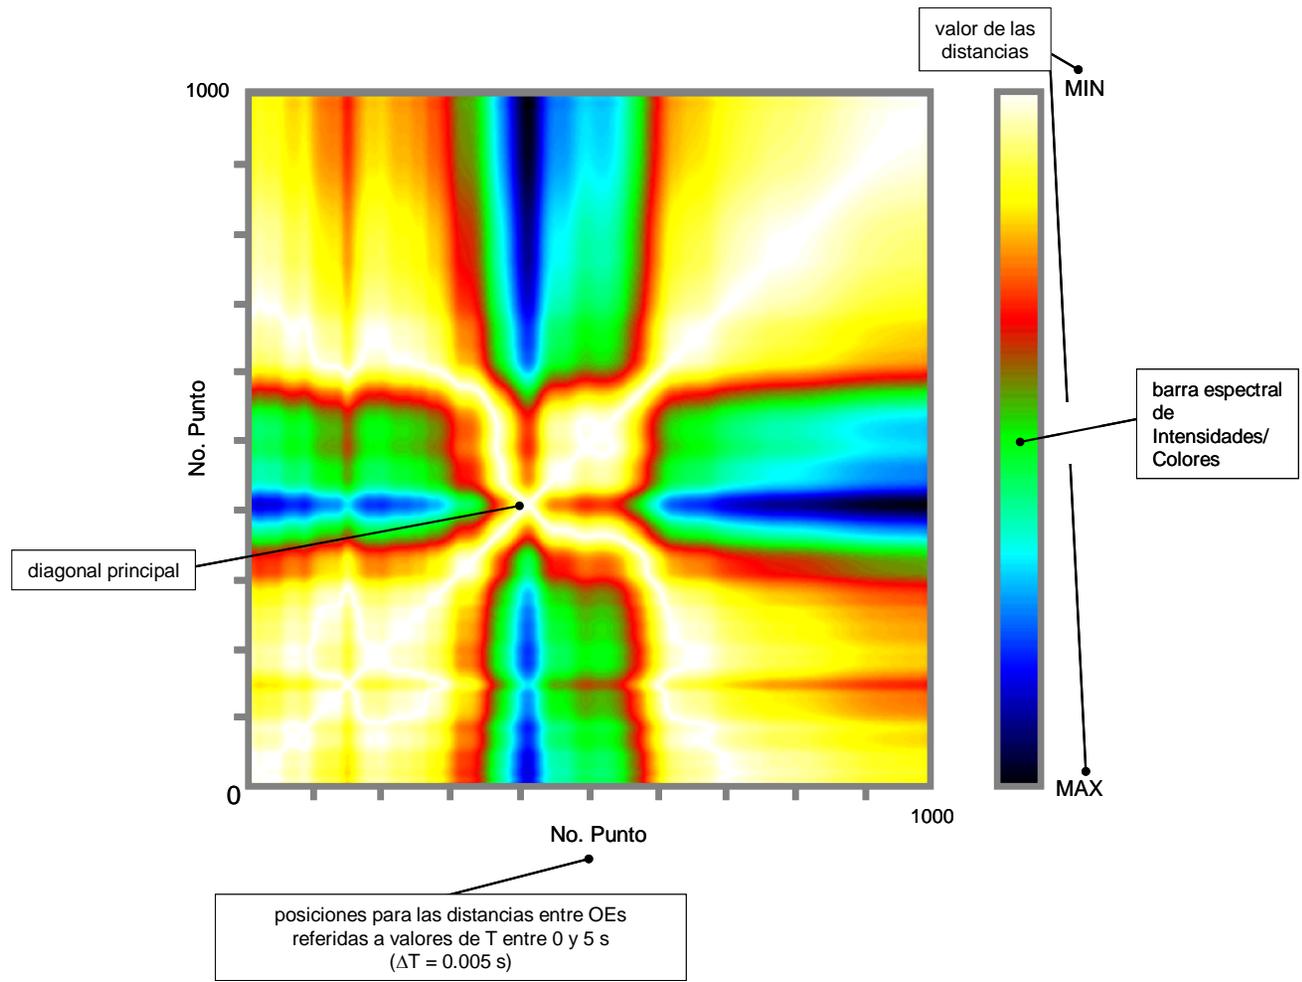


Figura 5.64 Componentes de un MR

Observe los MR mostrados en la Fig. 5.65. El MR en la posición (a.1) muestra un evento crítico definido por las amplias zonas claras que rodean una angosta banda bien localizada (línea oscura alrededor de la posición 250). Si transmutamos esta deducción hacia el significado de un ERA podemos decir que sólo un oscilador (con aproximadamente $T_s = 1$ s) responde de manera importante a la acción sísmica mientras que los otros estados (osciladores de otros periodos) no cambian o lo hacen muy lentamente.

En los MR mostrados en la Fig. 5.65 línea (b), se observan bandas oscuras (van del verde hacia el azul y negro) en las zonas donde el ERA presenta el máximo valor de OE.

Las bandas del MR en (b.1), centradas alrededor de la abscisa 900, representan la diferencia de comportamientos entre osciladores con periodo fundamental entre 1 y 3 s. En el caso (b.2) se pueden observar áreas blancas iniciales que indican poco movimiento de los osciladores con T_s menores a 2.5 s y un fuerte incremento de la respuesta para los osciladores con valores de T_s cercanos a los 4 s.

Activar las respuestas de osciladores con T_s altos generando una estructura en forma de “flecha” indica *tendencia* en el comportamiento que se ve acentuada por las áreas blancas en la esquina superior derecha (alrededor de la posición 750). Las bandas oscuras en el lado superior indican una posible desviación de los comportamientos de osciladores con $T_s > 5$ s.

El caso del mapa mostrado en la posición (c.1) muestra una banda fría (colores oscuros) delimitada por coordenadas horizontales [350-450] y rodeada de un área verde entre [300-500]. Esta *imagen* representa una fuerte diferencia entre las respuestas de los osciladores con periodos menores a 2 s y mayores a 2.5 s lo que puede llamarse un evento *severo* (sólo se observan mínimos cambios en los demás puntos).

Los mapas mostrados en la línea d, columnas 1, 2 y 3, muestran casos con grandes áreas blancas que significan periodos de estacionalidad, traducido a ERAs, amplios rangos de T_s donde no se aprecian cambios sustanciales en los patrones de respuesta, aunque debe apuntarse que las bandas oscuras en los extremos (fronteras del mapa) indican posibles desviaciones (pueden ser de importancia) del comportamiento promedio mostrado por los osciladores analizados.

Este tipo de MR muestra características especiales de ERAs, como fuertes *tendencias* (las flechas se marcan más sobre la diagonal principal, observe los colores claros) negativas (creciendo de izquierda a derecha), es decir, potentes máximos en los comportamientos de osciladores con periodos cercanos al origen y una tendencia a decrecer fuertemente hacia la zona extrema derecha, con el resto del mapa bastante homogéneo, lo que se traduce en estacionalidad.

Incluso los casos (d.2) y (d.3) asemejan el MR de una función *logarítmica* decreciente con signos de periodicidad enmascarados por el ruido entre las respuestas de todos los osciladores. En la Tabla 5.5 se presenta un resumen de las estructuras típicas y una interpretación física muy general.

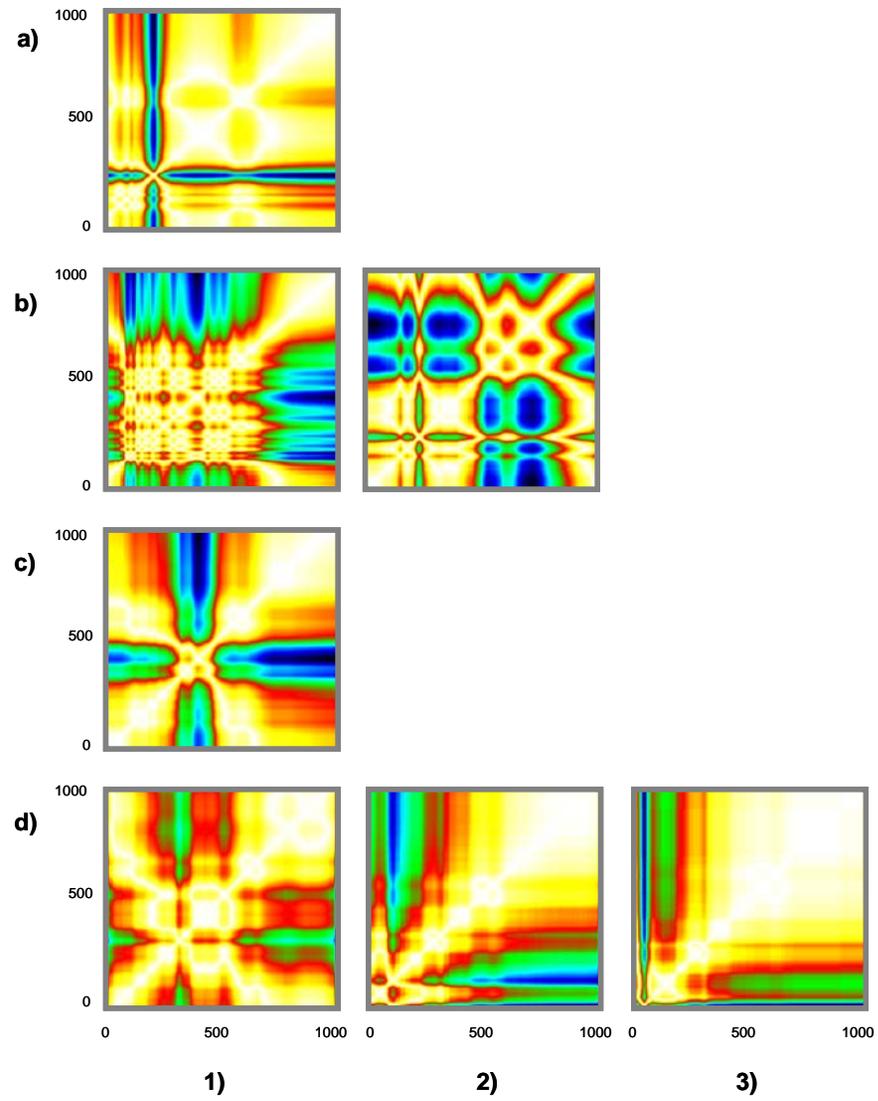


Figura 5.65 Ejemplos de estructuras de recurrencia mostradas por ERAs

Tabla 5.5 *Significado* general de un MR

CARACTERÍSTICA GEOMÉTRICA	INTERPRETACIÓN FÍSICA
Homogeneidad	Estacionalidad
Oscurecimiento desde las esquinas	No estacionalidad: desviaciones y tendencias
Bandas oscuras	No estacionalidad: algunos estados del sistema están lejos de la evolución media o pueden pertenecer a una transición
Patrones periódicos	Existen evoluciones cíclicas del sistema; la distancia entre patrones periódicos es el periodo
Puntos recurrentes aislados	Fluctuaciones rápidas del sistema que pueden ser aleatorias; de hecho el ruido blanco parece un conjunto de puntos aleatorios aislados
Líneas diagonales paralelas a la diagonal principal	La evolución del sistema es similar a diferentes tiempos; el sistema podría ser determinista
Líneas verticales u horizontales	Algunos estados del sistema no cambian o lo hacen muy lentamente

Entradas Sísmicas

Algunos ejemplos de los ERAs de entrada se muestran en las Figs. 5.66, 5.68 y 5.70. Para facilitar el manejo e interpretación de la información, los ERAs han sido separados de acuerdo con el valor de M generando las siguientes clases: sismos débiles ($M \leq 6$), sismos moderados ($6 < M \leq 7$) y sismos severos ($M > 7$). Los MR de estos movimientos de control (registros en CU) se presentan en las Figs. 5.67, 5.69 y 5.71. A continuación se presentan las consideraciones topológicas descubiertas a través de la expansión 2D y su relación con la noción básica de un vector ERA.

I. MR de sismos débiles (Figs. 5.66 y 5.67):

Sobre las estructuras y comportamiento de los estados (osciladores):

Común en todos los mapas es la presencia de bandas frías (verdes a azules) que parten de la esquina inferior izquierda indicando que algunos de los estados del sistema (osciladores con periodos menores a 1.2 s aproximadamente) están lejos de la evolución promedio o pueden corresponder a una transición. Las grandes áreas blancas en las esquinas superiores derechas pueden corresponder a periodos estacionarios (en un ERA significa que existen diferencias mínimas entre respuestas de osciladores con $T_s > 1.2$ s).

Las bandas azulosas en el inicio del MR (coordenada [0,0]) son típicas de desviaciones importantes entre estados por lo que se puede decir que durante sismos débiles, el comportamiento en CU es extremo en osciladores de periodos naturales muy cercanos a la unidad.

En los cinco MR, el área rojiza acotada por $Y = 200$, $Y = 250$ corresponde a mínimos muy profundos para osciladores de aproximadamente 2 s. Después de estos mínimos las OEs aumentan un poco pero los máximos ubicados en periodos menores a la unidad generan una flecha de tendencia (fuerte descenso del gradiente entre las respuestas conforme avanza el periodo) que se dibuja sobre la diagonal principal moviéndose hacia la esquina superior conforme la magnitud del sismo aumenta.

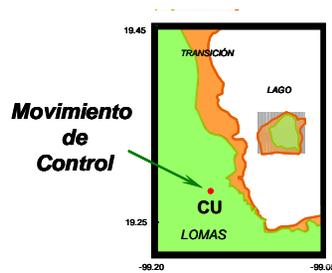
Sobre las características de los suelos y los sismos:

De acuerdo con la ubicación de los epicentros y la similitud de las estructuras mostradas en los MR de sismos débiles ($M \leq 6$) se puede asumir que los estados representados en estos movimientos de control son independientes de la sismogénesis.

El rango de las P_f y de aceleraciones máximas (A_{max}) en los acelerogramas del sitio CU cubiertos en este análisis, complementan la aseveración de que ERAs con intensidades bajas conforman sistemas con estados que siguen una especie de función logarítmica descendiente con una zona extrema localizada en periodos menores a los 1.5s. Esto es, los movimientos débiles en el sitio en roca afectan a los osciladores con T_s cercanos a 1s ($\pm 0.25s$) y los demás estados permanecen inalterados si se comparan con las respuestas máximas obtenidas para $T_s = 0$ s.

Si el sitio es el mismo (léase mismo depósito de suelo) y las magnitudes (interprete intensidades) entre los sismos son muy cercanas, entonces las diferencias estructurales de los MR ponen de manifiesto condiciones frecuenciales que afectan a la respuesta de los osciladores y que son muy difíciles de detectar a través de expresiones numéricas como los ERAs vistos en el plano XY.

Las descripciones anteriores y la información mostrada en la Fig. 5.66 permiten concluir que la escasa representación de un ERA podría ocasionar fuertes contradicciones en las respuestas estimadas si se reconoce que los modelos convencionales fundamentalmente modifican punto a punto el movimiento en la base a través de alguna simulación numérica.



A

930729
 P_F : <5 km
 D_E : 266 km
 M_s = 5.0
 A_{max} : 0.7 g

Periodo en s

B

900511
 P_F : 117 km
 D_E : 308 km
 M_s = 5.1
 A_{max} : 1.6 g

Periodo en s

C

880208
 P_F : 19.2 km
 D_E : 291 km
 M_s = 5.5
 A_{max} : 2.2 g

Periodo en s

D

940523
 P_F : 23 km
 D_E : 205 km
 M_s = 5.6
 A_{max} : 4.5 g

Periodo en s

E

930515
 P_F : <5 km
 D_E : 326 km
 M_s = 5.8
 A_{max} : 1.44 g

Periodo en s

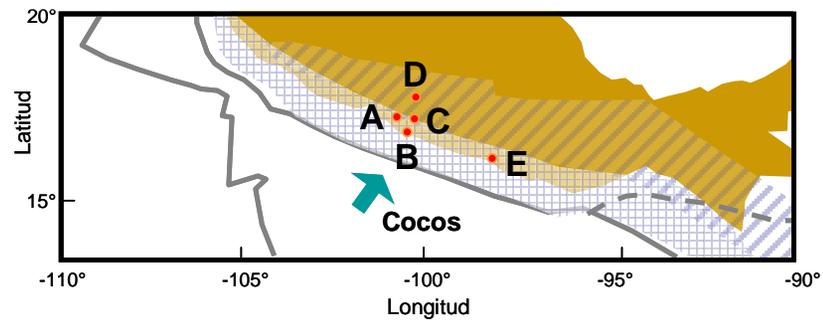


Figura 5.66 Ejemplos de ERAs en CU, sismos débiles

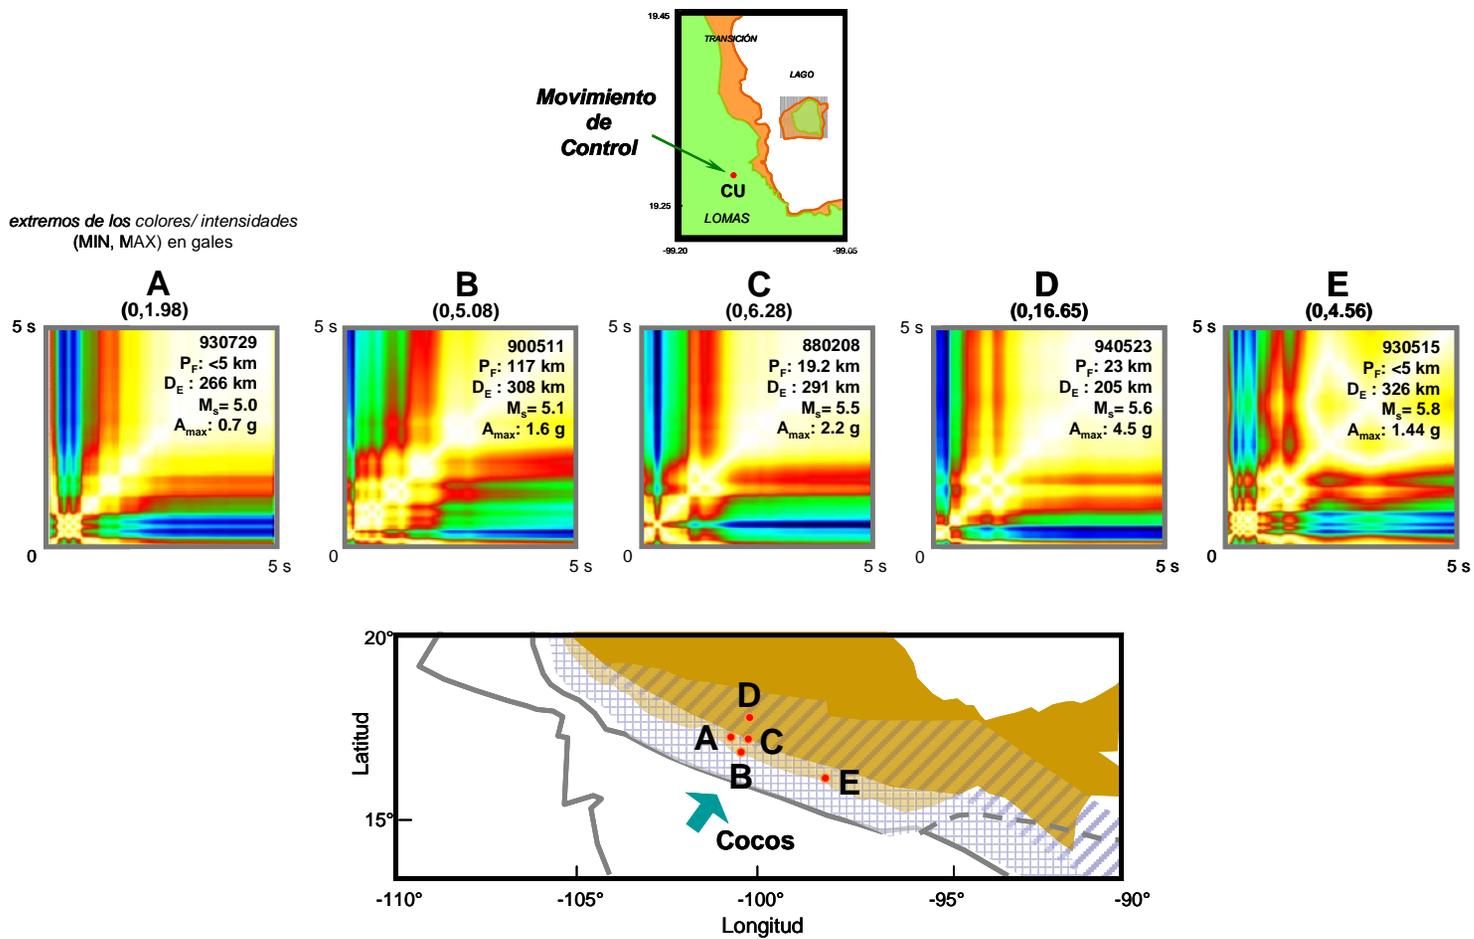


Figura 5.67 Ejemplos de MR en CU, sismos débiles

II. MR de sismos *moderados* (Figs. 5.68 y 5.69):

Sobre las estructuras y comportamiento de los estados (osciladores):

Los estados representados en estos MR apuntan hacia la activación de un mayor número de osciladores para cada evento. Las bandas frías (verdes a azules) se localizan ahora desde $T=1$ s y hasta $T=3$ s. El ancho de las bandas indica el rango de periodos fundamentales donde el comportamiento se dispara del que se presenta en $T_s = 0$.

Las transiciones entre estados son menos abruptas y ahora los cambios de colores fríos a cálidos muestran mayor importancia de los tonos rojizos. Las zonas de mínimos profundos no pueden ser localizadas fácilmente como en el caso de los MR de sismos *débiles*, la mayor parte de las zonas “claras” se concentran sobre la diagonal principal.

No hay tendencias (*flechas*) ni se presentan bandas de desviación de comportamientos, los mapas lucen más homogéneos que los de los sismos *débiles*. Los MR de los sismos A, B y D exhiben una cierta periodicidad local (observe la trama de cuadros en el extremo inferior izquierdo) lo que puede traducirse como evoluciones de comportamiento sin extremos y con amplios rangos de T (estados) donde las respuestas difieren poco entre ellas, haciendo sólo evidente el cambio respecto a la respuesta del oscilador en $T=0$ s.

Sobre las características de los suelos y los sismos:

Las estructuras en los MR con magnitudes *moderadas* difieren claramente de las obtenidas en sismos *débiles*, incluso para sismos con epicentros muy cercanos (compare MR *débil*-B con MR *moderado*-E) lo que permite concluir que el efecto de la *intensidad* en la respuesta monitoreada en el sitio de *control* CU es más evidente que el de la sismogénesis.

Los periodos donde se ubican las OEs más altas en los espectros deben coincidir con las zonas o líneas más oscuras en cada mapa, entonces para este sitio en roca no se puede hablar de un periodo fundamental en el sentido estricto del término ya que los sismos con intensidades *bajas* dibujan estados con el evento extremo en $T < 1.5$ s mientras que para los sismos *moderados* las OEs máximas se localizan entre 1.25 s y 2.5 s.

Ya no se pueden encontrar relaciones entre los MR a simple vista, el incremento de la intensidad parece complicar las geometrías y su relación con los parámetros sísmicos reconocidos. Si esto se acepta, se puede decir entonces que conforme la intensidad y por tanto la complejidad de los comportamientos crecen, la posibilidad de predecir la respuesta de los osciladores ante eventos “distintos” a través de relaciones “directas” entre vectores ERAs, disminuye.

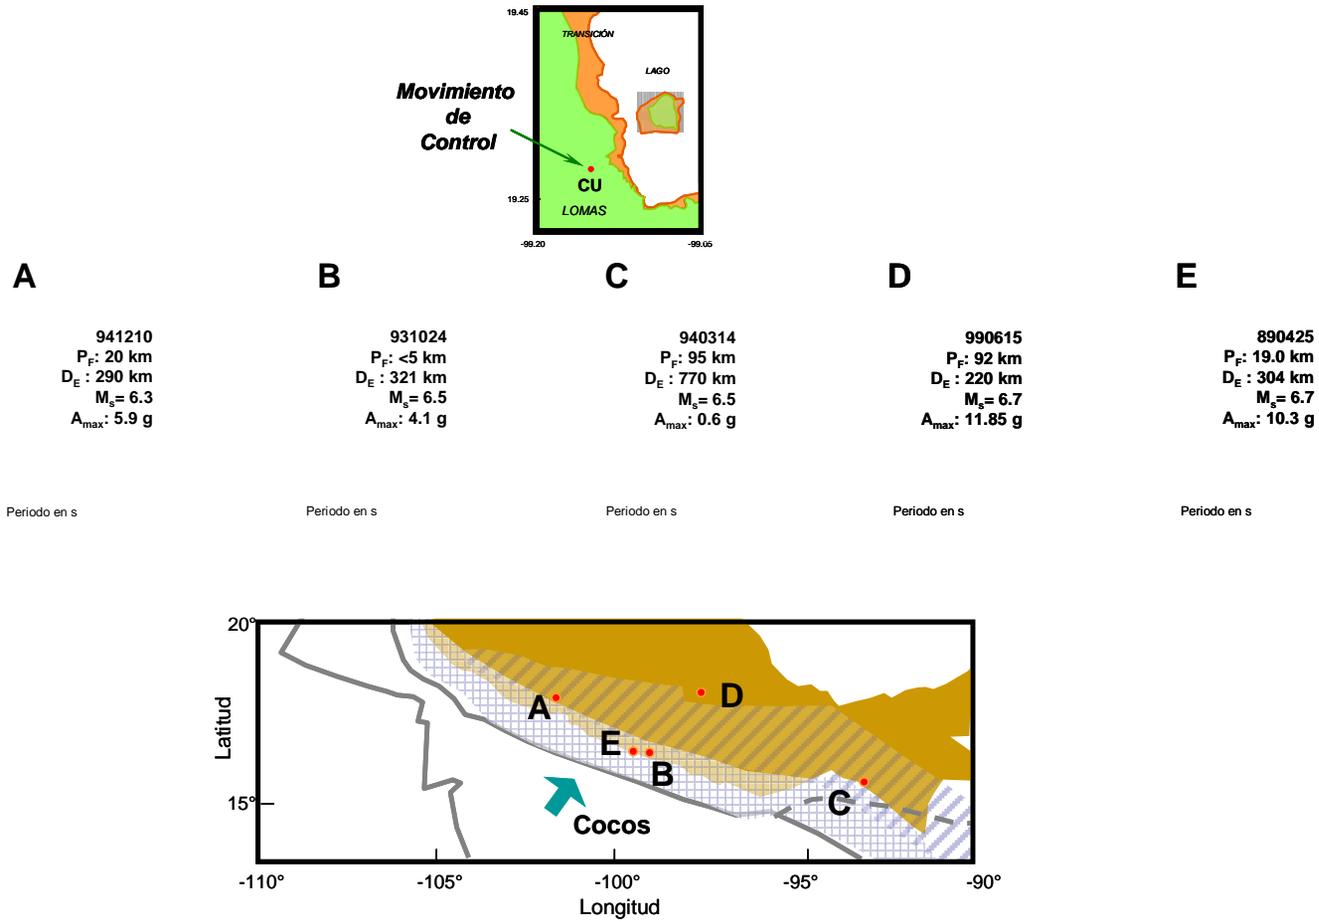


Figura 5.68 Ejemplos de ERAs en CU, sismos *moderados*

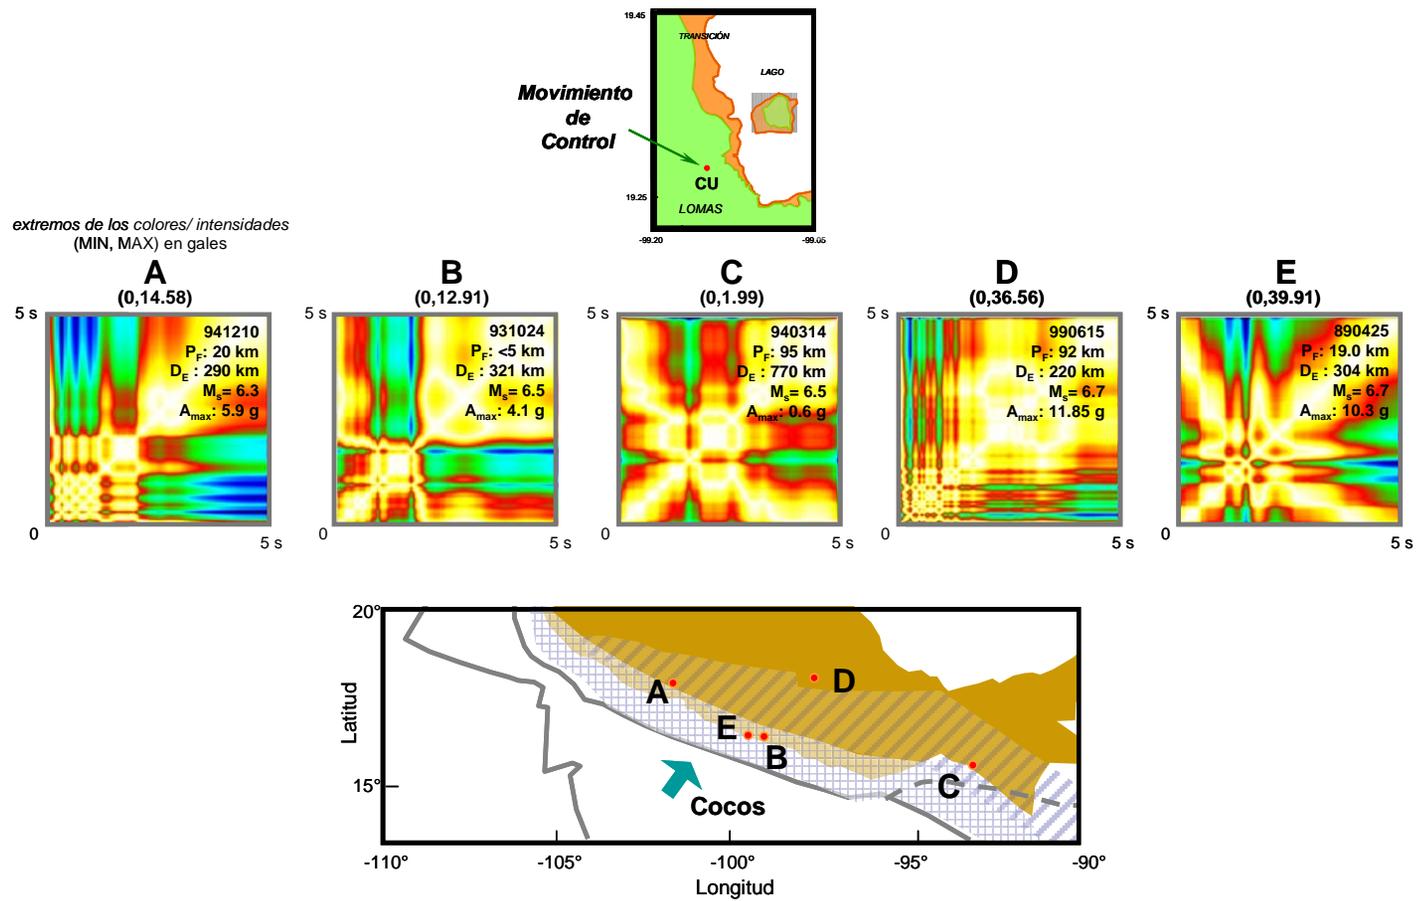


Figura 5.69 Ejemplos de MR en CU, sismos moderados

II. MR de sismos *severos* (Figs. 5.70 y 5.71):

Sobre las estructuras y comportamiento de los estados (osciladores):

Las transiciones ya no son abruptas y no existen zonas de mínimos, las zonas “claras” se concentran sólo en la diagonal principal.

Sin la presencia de bandas de desviación de comportamientos los mapas lucen homogéneos. En periodos menores a 2.5 s se distinguen tramas de cuadros que se traducen como periodicidad local.

Los estados representados exhiben estructuras similares a las desplegadas en MR de eventos *moderados* con un ligero aumento del rango de periodos donde se localizan las bandas frías (verdes a azules). A simple vista no se distinguen diferencias importantes entre colores y geometrías entre sismos *moderados* y *severos*.

Sobre las características de los suelos y los sismos:

Debido a las similitudes entre las estructuras de los eventos *moderados* y *severos* no es posible abundar sobre detalles del comportamiento del sitio pero se pueden extraer algunas particularidades sobre los sismos considerados *extremos*.

El ERA del 97/01/11, con casi la totalidad del MR en tonos blancos/amarillos, no muestra diferencias entre las respuestas de los osciladores. Es notoria la presencia de un máximo puntual (semejante a un pequeño pulso), abrupto y carente de sentido si se le compara con los MR B,C y D. Un mapa como el A se relaciona con un ERA-línea horizontal, lo que resulta especialmente importante si este sismo es usado para el cálculo de funciones de transferencia o relaciones de amplificación.

Las estructuras en C y D, semejantes a algunas obtenidas para sismos *moderados*, están constituidas por una especie de *meseta* contaminada por ruido. Se observan amplias zonas verdes con intercalaciones delgadas de tonos rojizos que significan un conjunto de osciladores con el mismo nivel de respuesta y ligeras diferencias entre valores intercalados de T , diferencias que pueden adjudicarse a una componente ruidosa más evidente en sismos *severos*.

Hablando de la unicidad del sismo del 19 de septiembre de 1985, en la literatura se ha señalado que éste tuvo características de intensidad y temporo-frecuenciales *extremas* o muy distintas a las registradas en la historia reciente del valle de México. El nivel de respuesta en el MR-1985, en términos de amplitudes espectrales, marca el *extremo* numérico de la base de entradas (OE_{maxima} alrededor de 130 gales) con valores promedio de 7 gales para sismos *bajos*, 20 gales en *moderados* y del orden de 30 gales en los demás sismos *severos*.

Sin embargo el MR de la respuesta registrada en CU (entrada o movimiento de control), que debiera describir geoméricamente la hipótesis de unicidad, es similar (en términos de respuestas o estados) al de un sismo *moderado* de la zona de subducción alejado del epicentro del sismo de Michoacán por varios kilómetros (Fig. 5.72).

En los dos MR mostrados en la Figura 5.72, se mantienen activados los mismos osciladores (desde 1 s hasta más allá de 2.5 s) y las franjas rojizas aparecen con similar participación. La única condición *extrema* que se observa es la intensidad. Esta similitud señala que el ERA del sismo del 85 muestra efectos sobre *estados* que ya se habían, y se siguen presentando, bajo la acción de sismos de magnitud *moderada*.

La única distinción topológica de este sismo es su *tendencia*, el MR del 85 presenta una *flecha* positiva ($X= 1s/ X= 2.5s$). Las OEs de este mapa son las únicas con *tendencia* de crecimiento, el resto de los sismos en la base de datos dibujan máximos por debajo de los 2 s y decrecen con una ley muy similar a una logarítmica descendiente.

La emisión de energía anormalmente alta desde la fuente, los efectos de trayectoria y la mínima atenuación que sufrieron las ondas sísmicas propagadas hasta la Ciudad de México son aspectos que no se pueden estudiar únicamente bajo las características del MR en CU, así que lo particularmente importante a tomar en cuenta dentro de este modelo es que el MR del 850919 expresa características geométricas contenidas en la historia sísmica en CU y la variante extraordinaria es únicamente la *intensidad*, las respuestas obtenidas debido a la *modificación* de esta entrada deberán ser explicadas bajo esta perspectiva.

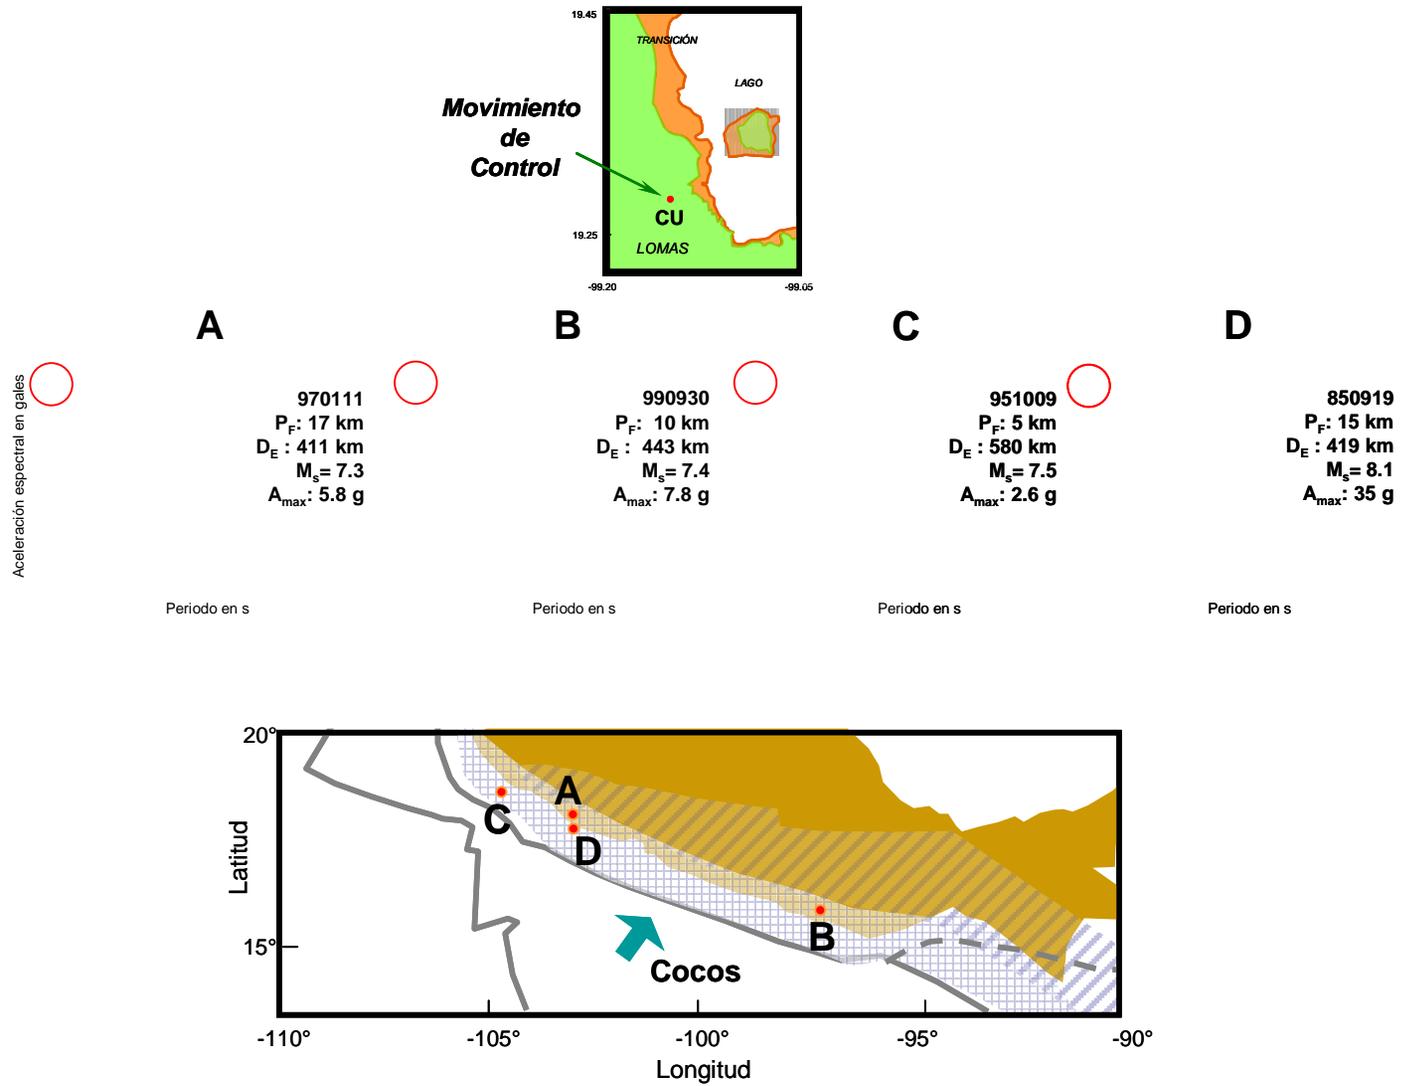
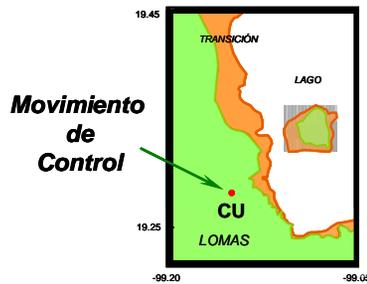


Figura 5.70 Ejemplos de ERAs en CU, sismos *severos*



extremos de los colores/ intensidades
(MIN, MAX) en gales

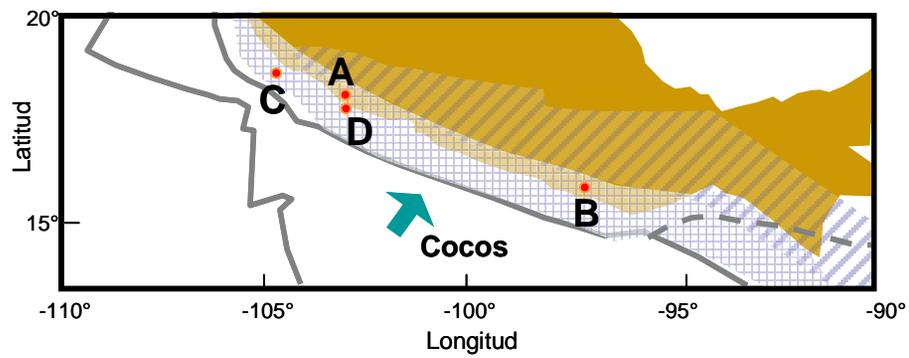
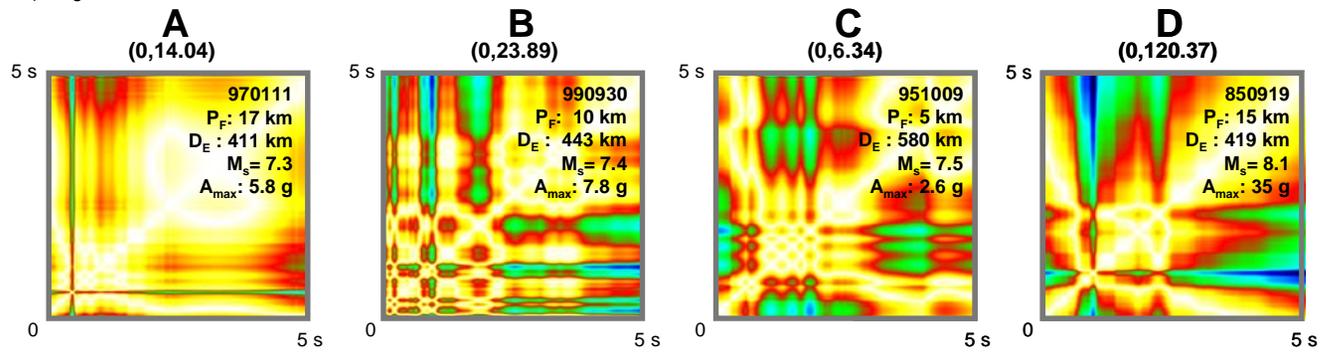


Figura 5.71 Ejemplos de MR en CU, sismos *severos*

extremos de los colores/ intensidades (MIN, MAX) en gales

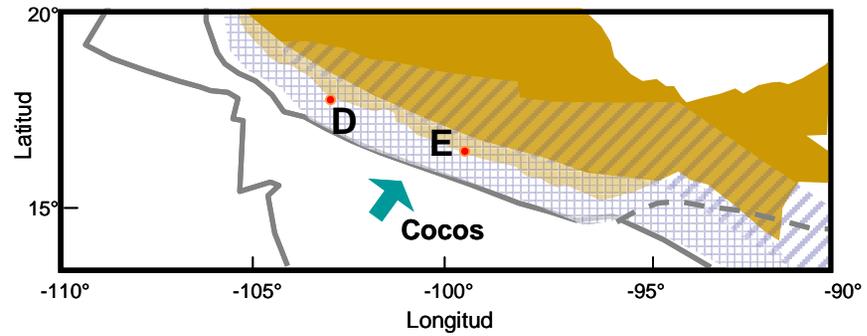
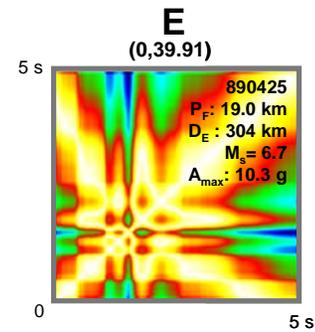
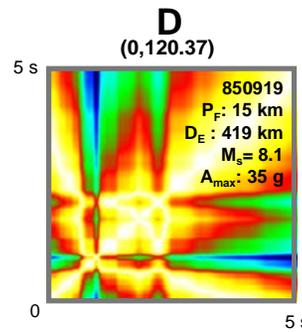
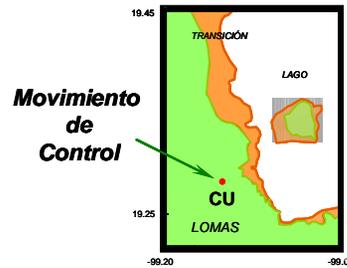


Figura 5.72

Comparación de geometrías en el MR de CU para el sismo más *severo*, 850919

Salidas: Respuesta en sitio

Los ERAs de los sitios estudiados (vea Tabla 5.2) han sido expandidos hacia sus MR de tal forma que se obtenga coherencia entre la información sobre los sismos y los comportamientos de los depósitos de suelo.

Las conocidas observaciones sobre los suelos de la Ciudad de México, como periodos dominantes del suelo de hasta 5 segundos, factores de amplificación hasta de 50 en espectros de amplitudes de Fourier y entre 10 y 15 en términos de aceleraciones espectrales (con 5 % de amortiguamiento) y un gran efecto de interacción suelo-estructura están contenidos en los MR que se obtuvieron.

Una tarea formidable resultaría desplegar en este trabajo de tesis el total de los MR de manera que quedaran descritas cada una de las particularidades de los suelos debajo de las 33 estaciones acelerográficas, por lo que sólo se eligieron algunos sitios que, de acuerdo con su periodo fundamental y ubicación, representen ejemplos gráficos de respuestas típicas.

Se recuerda que el papel de T_s en el modelo neuronal es de caracterización espacial. Se advierte al lector que su valor numérico no significa lo que en la teoría 1D de propagación de ondas. En esta investigación únicamente sirve para definir la situación de una estación. Por medio de un número reglamentado (curvas de isoperiodos publicadas en el Reglamento de Construcciones del Distrito Federal) y de amplio y fácil manejo en análisis y diseño, se relaciona la ubicación geográfica con las condiciones generales del depósito al tiempo que se genera un nodo espacial de extrema simpleza.

El mismo criterio de generación de conjuntos (valor de M) usado en los MR de entrada es empleado en la presentación de los eventos registrados en cada sitio. Las siguientes descripciones intentan abundar sobre las características de respuesta de los depósitos y cómo se identifican en las topologías desplegadas.

Sitio: **Secretaría de Comunicaciones y Transportes SCT**

T_s : 2.0 s

En la Fig. 5.73 se observan los MR construidos de registros con magnitud menor a 6 grados. Se distingue claramente el máximo valor de OE sobre la línea del T_s . Si se comparan las estructuras de los sismos *débiles* con las mostradas en la Fig. 5.74 para sismos de magnitud *moderada*, se reconoce que no hay cambio sustancial entre los osciladores activados en ambos rangos de intensidades.

Sobre la geometría global de los MR *moderados*, aparecen unas líneas verticales y horizontales alrededor de los 1.2 s que concuerdan con el segundo modo del sitio SCT. El ancho, pero sobre todo, la intensidad de estas líneas (banda verde con alma azul/negra) es mayor en el sismo de Tehuacán, Puebla (99/06/15) respuesta que difiere notablemente del patrón mostrado en los demás eventos.

Las condiciones geométricas para los sismos *severos* presentan diferencias más relevantes (Fig. 5.75). Las bandas delgadas de activación y las zonas amplias de estados (osciladores) con mínima respuesta se modifican y ahora la banda fría, aún con eje de simetría en 2 s, es más ancha y su dominio crece hasta casi 2 s (todos los osciladores dentro de una banda de 2 s –de 1.8 s hasta 2.8 s– tiene activación importante) en el MR del sismo del 85. Se minimiza la participación del segundo modo de vibrar dejando zonas amplias de mínima actividad antes y después del periodo fundamental.

La respuesta general en SCT, en términos geométricos, se puede considerar constante. El modelo neuronal en este caso debe generar multi-relaciones que dirijan el crecimiento de la banda fría en ancho (estados que se activan) y en intensidad de la respuesta (en gales) de acuerdo con la fuerza de la sacudida sísmica y en menor grado con la zona sismogénica, directividad y distancia fuente-sitio.

extremos de los colores/ intensidades
(MIN, MAX) en gales

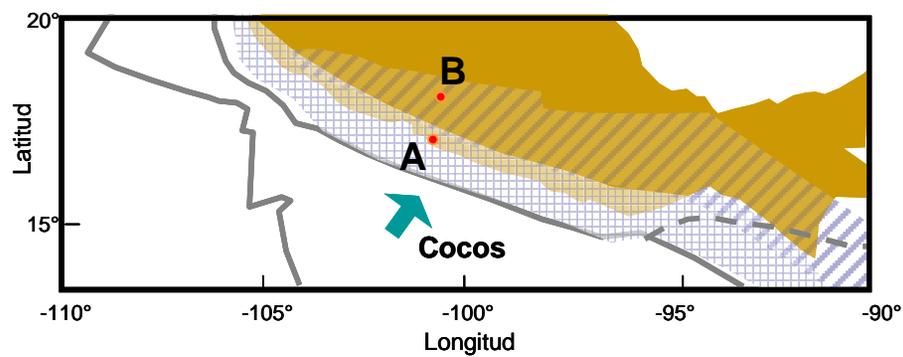
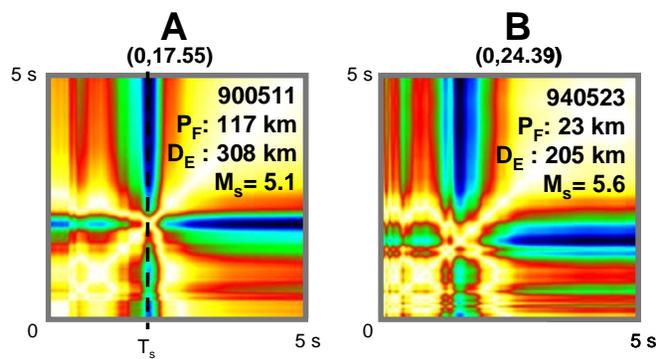
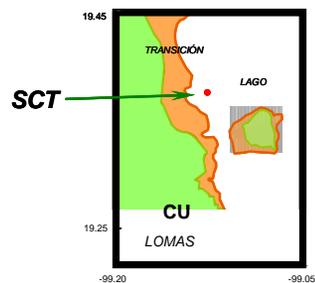


Figura 5.73 MR de SCT para sismos débiles

extremos de los colores/ intensidades
(MIN, MAX) en gales

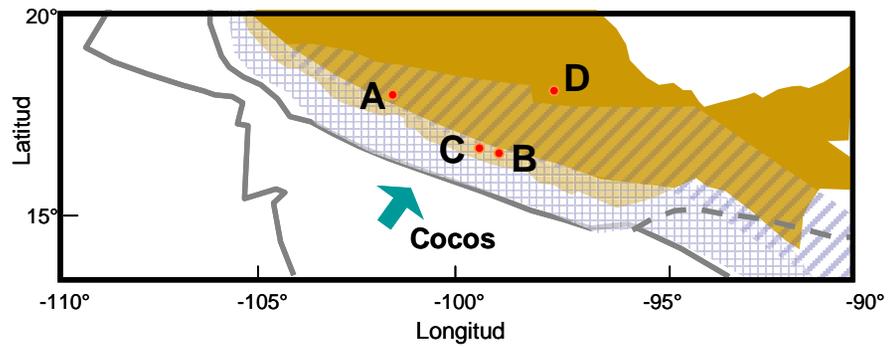
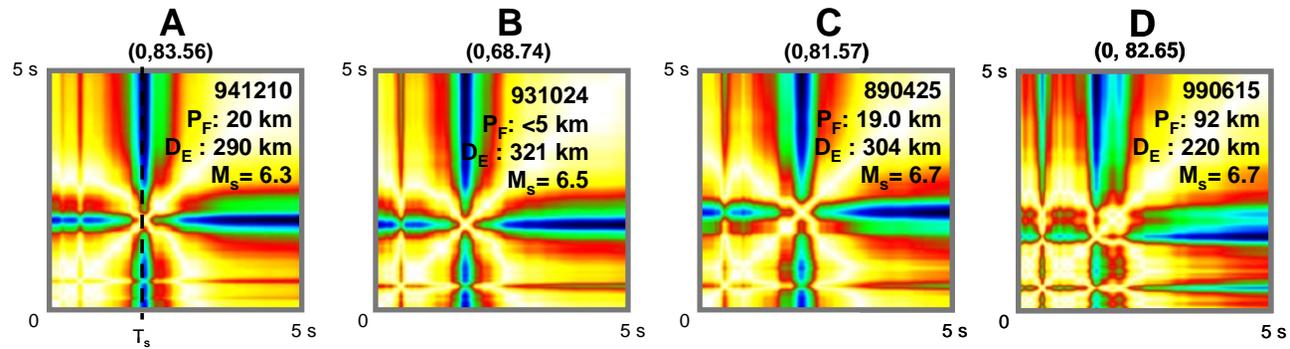
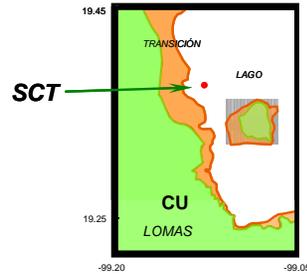


Figura 5.74 MR de SCT para sismos moderados

extremos de los colores/ intensidades
(MIN, MAX) en gales

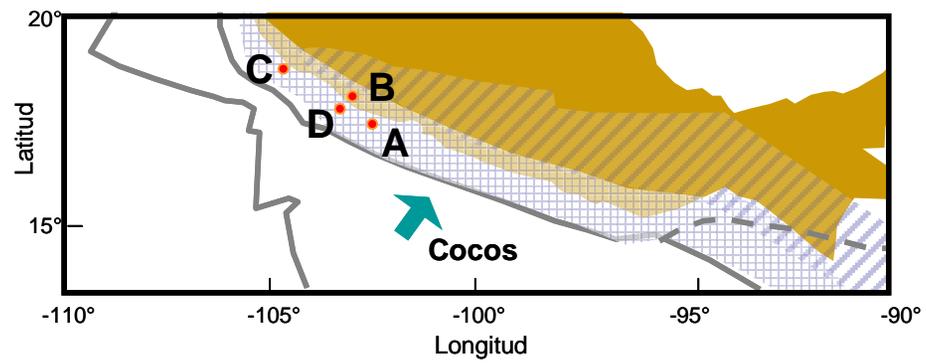
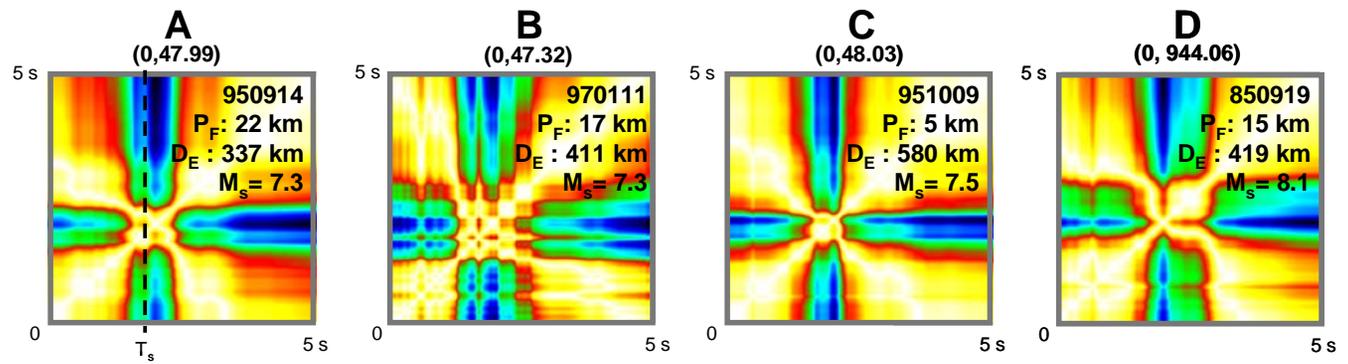
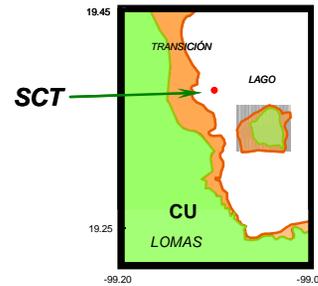


Figura 5-75 MR de SCT para sismos *severos*

- Sitio: **Garibaldi**

T_s : 2.24 s

Las Figs. 5.76, 5.77, y 5.78 muestran los MR para los registros de eventos *débiles*, *moderados* y *severos*, respectivamente. Las diferencias geométricas parecen evidentes entre los tres grupos pero es arriesgado concluir sobre las desplegadas en sismos con magnitudes *débiles* y *moderadas* debido a la componente ruidosa que se aprecia en las bandas *frías*. Lo claro en este rango de M ($M < 7$) es que las OEs máximas no se localizan sobre T_s y que las activaciones son importantes en una amplia zona de osciladores (*meseta*, similar a un ERA de diseño) con OE importantes desde $T = 0$ s y hasta 3 s.

La evidencia indica que conforme las amplitudes de la sacudida sísmica crecen, las componentes ruidosas se minimizan y se clarifica el periodo donde se concentran las máximas respuestas, las bandas *frías* se reducen y la estructura luce más homogénea. Una observación interesante es que la topología en los sismos *severos* es muy similar a las del sitio SCT para este rango de magnitudes, condición importante cuando se traduzcan los resultados neuronales que se obtengan para sitios distintos (caracterización espacial con T_s distinto).

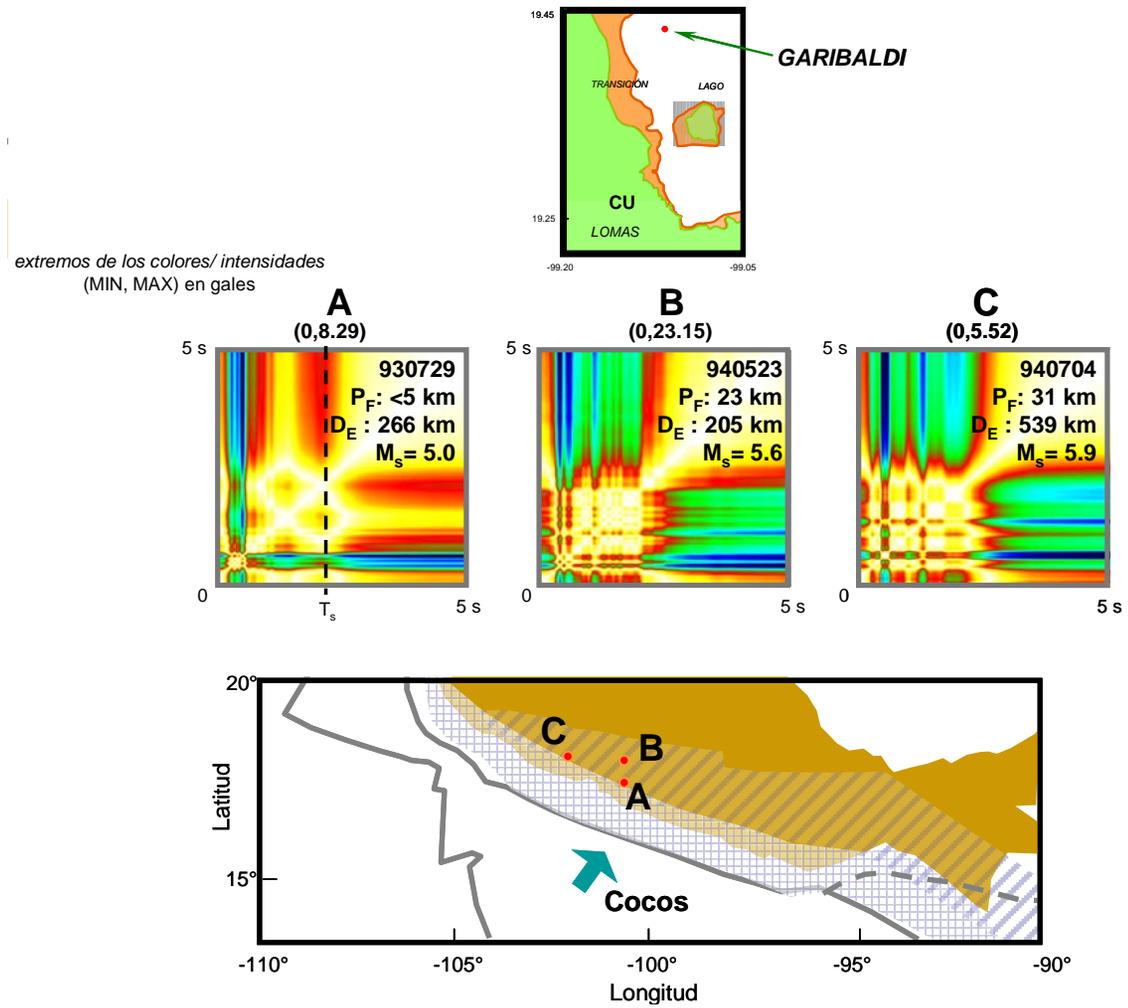


Figura 5.76 MR de Garibaldi para sismos débiles

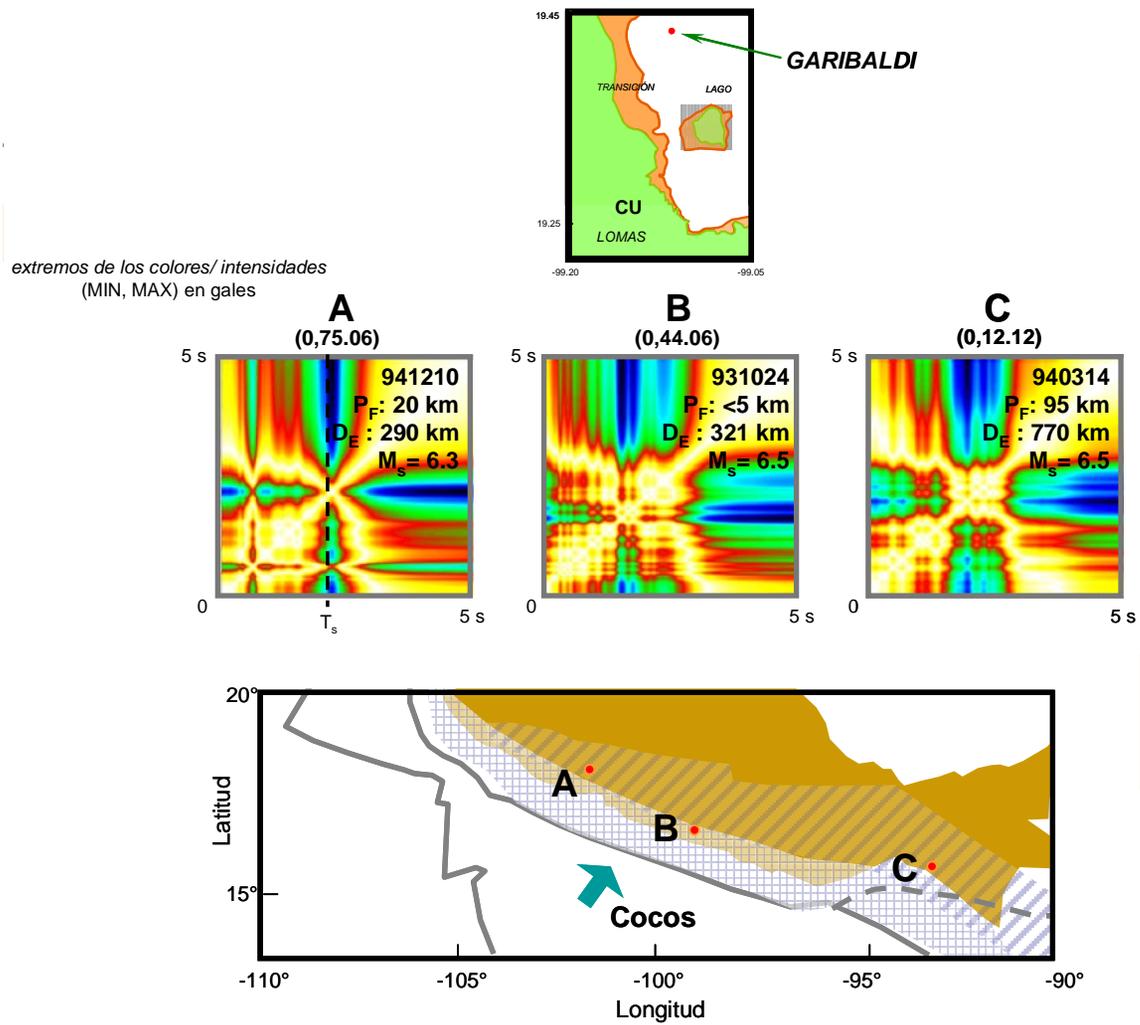


Figura 5.77 MR de Garibaldi para sismos moderados

extremos de los colores/ intensidades
(MIN, MAX) en gales

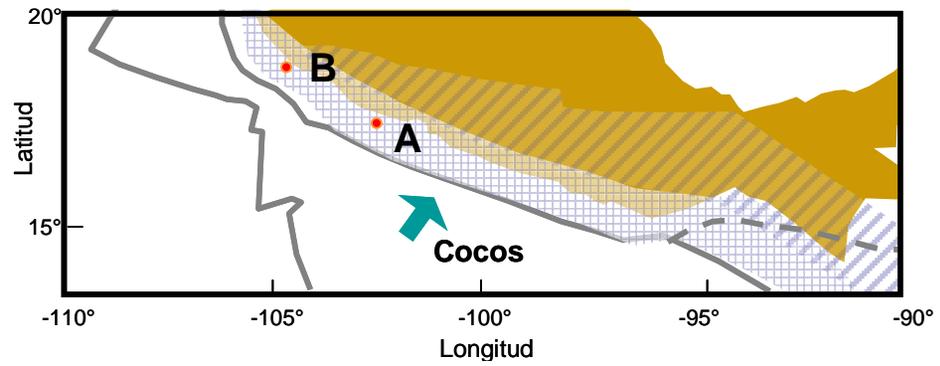
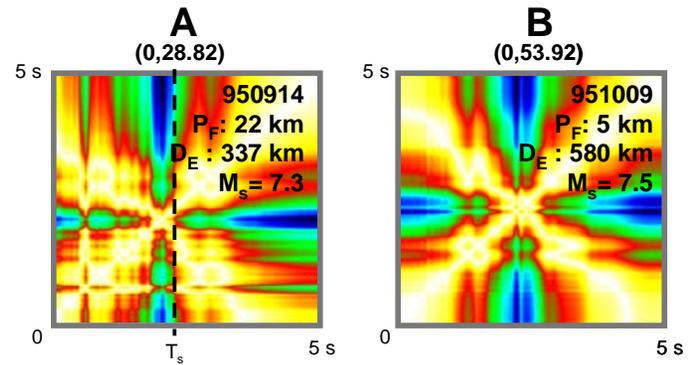
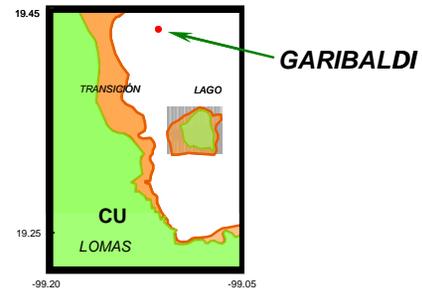


Figura 5.78 MR de Garibaldi para sismos *severos*

- Sitio: **Balderas**

T_s : 2.4 s

Las respuestas, en términos de MR, para sismos *débiles* parecen desvinculadas y se reconocen algunas geometrías muy similares a las registradas en terreno firme (Fig. 5.79). Las componentes ruidosas son altas y las OEs máximas no se localizan cerca del periodo fundamental. Cuando se analizan las topologías debidas a eventos *moderados* (Fig. 5.80) se verifican algunas estructuras comunes con un cuadro de comportamiento semi-periódico (entre 0.5 y 3.5 s) donde se podría localizar el máximo y éste podría caer en el T_s del sitio, pero es difícil de evaluar si la componente de ruido sigue siendo tan evidente (observe los “cortes” de las bandas *frías* en A, C y D).

Existen mejores argumentos para concluir sobre la posición de la OE máxima, pero sigue siendo aventurado concluir que para estas intensidades se localiza sobre el periodo fundamental del sitio.

Estructuras igualmente confusas se aprecian en la Fig. 5.81 para las sacudidas más *severas*. El sismo A presenta una gran meseta donde las respuestas máximas se localizan alrededor e incluso sobre T_s lo que ratifica el hecho de que las alteraciones ambientales que afectan a todos los registros obtenidos en el sitio Balderas no permiten elaborar juicios prudentes sobre la conducta del depósito de suelo.

La aparente mínima sensibilidad a la sismogénesis y a la directividad debería ponerse en duda cuando se analizan estas respuestas. La inserción de estos MR en la base de entrenamiento será cautelosa y en los procesos de aprendizaje y prueba los resultados neuronales serán analizados de la misma forma. Este tipo de patrones, aún con las alteraciones reconocidas por el entorno de la estación acelerográfica, en muchos sentidos son útiles para generar una mayor flexibilidad en modelos conexionistas (vea el Capítulo 3 Cómputo Aproximado).

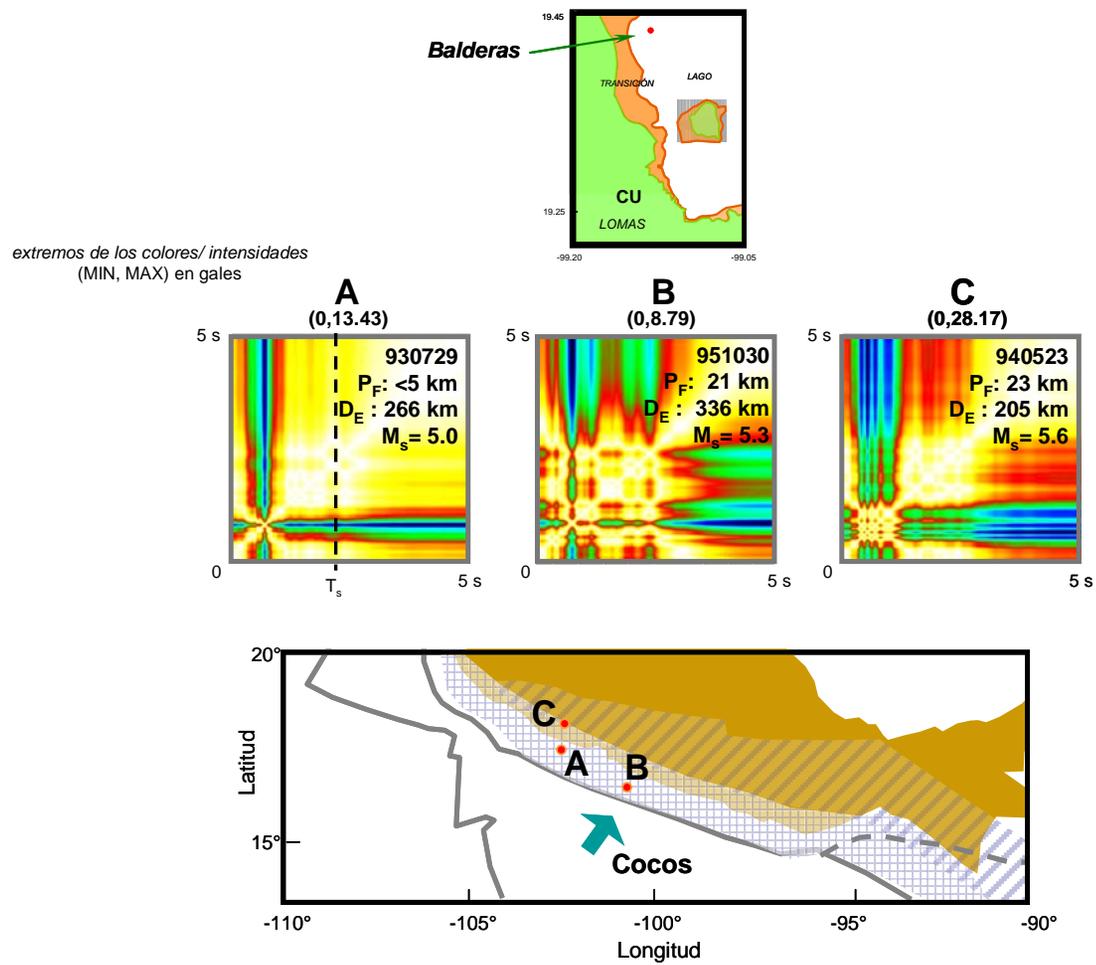


Figura 5.79 MR de Balderas para sismos débiles

extremos de los colores/ intensidades
(MIN, MAX) en gales

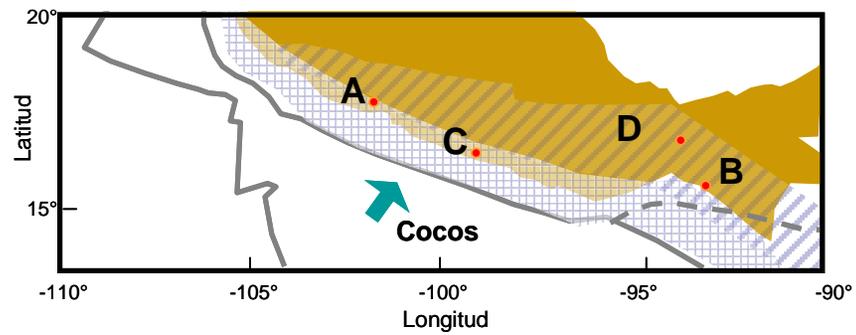
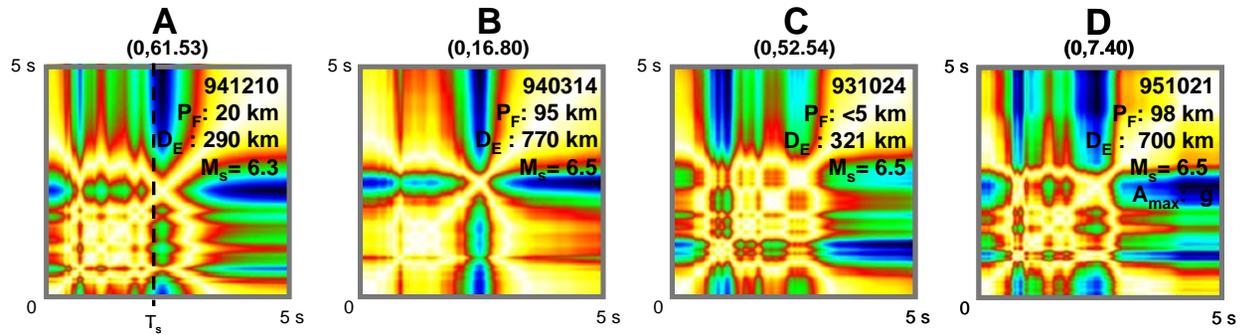
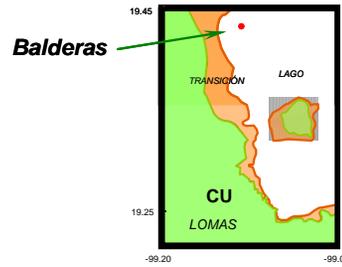


Figura 5.80 MR de Balderas para sismos *moderados*

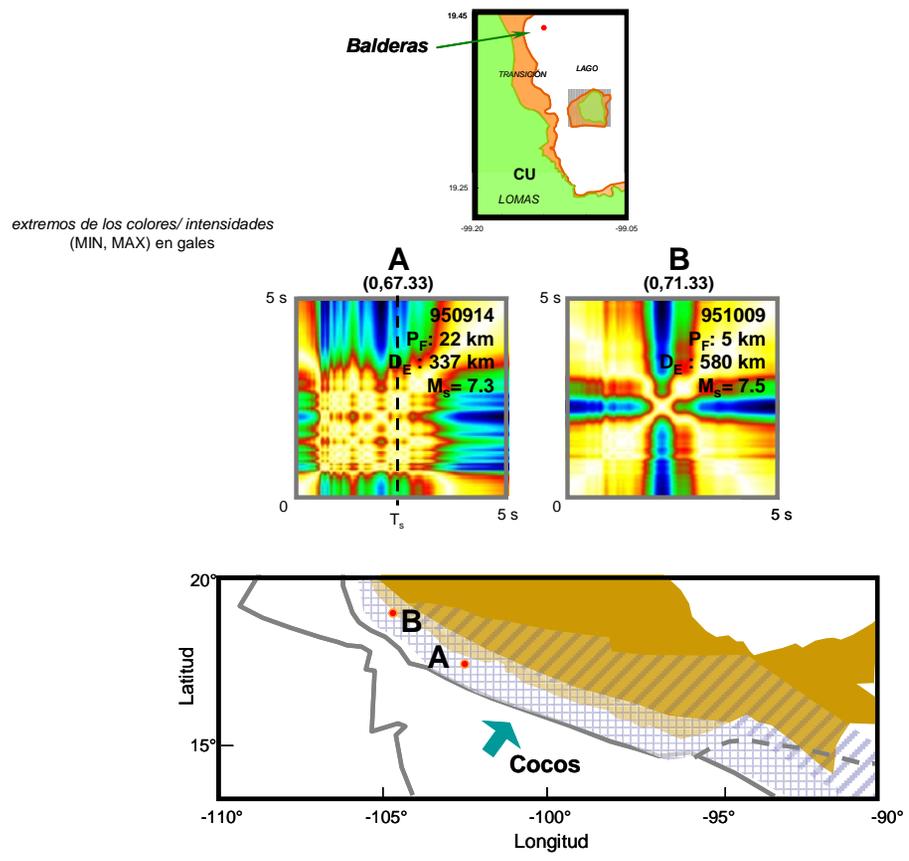


Figura 5.81 MR de Balderas para sismos *severos*

- Sitio: **Candelaria**

T_s : 3.0 s

Muy similar a las desligadas respuestas del sitio Balderas, los MR de la Fig. 5.82 correspondientes a sismos *débiles*, no presentan características comunes, ni en términos geométricos ni de intensidad. Registros de amplitudes muy bajas, debido a su relación aceleración/ruido, generan ERAs casi horizontales en grandes zonas de periodos. Esto se comprueba con la *especial* intensidad reportada para el sismo B que produce un MR con marcadas líneas verticales y horizontales y una OE máxima alrededor de 1 s.

Las mejores definiciones en las geometrías de sismos *moderados* (Fig. 5.83) comienzan a separarse de la tendencia topológica mostrada en SCT. Se muestra la participación igualmente importante de dos periodos (el fundamental y un segundo modo alrededor de los 1.2 s) y esto se conserva en lo reportado para sismos *severos* (Fig. 5.84). El depósito de alguna manera mantiene este patrón de comportamiento para amplitudes espectrales desde los 10 y hasta los 60 gales.

Evidente es la complejidad de las relaciones entre las geometrías, las intensidades y los aspectos sísmicos zona sísmica, distancia epicentral, directividad, profundidad focal e incluso el valor de la magnitud.

extremos de los colores/ intensidades
(MIN, MAX) en gales

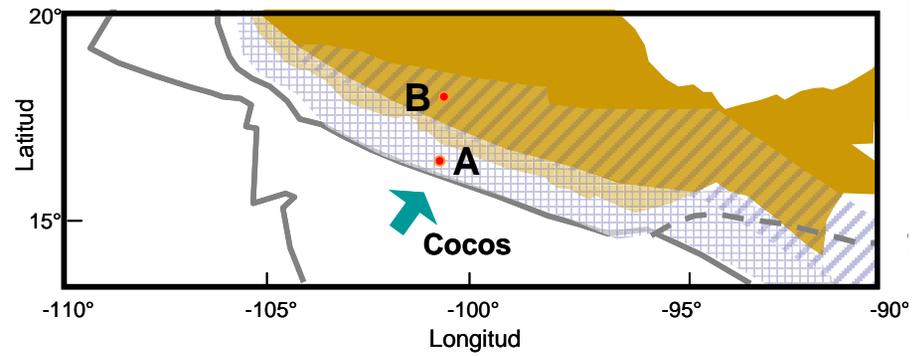
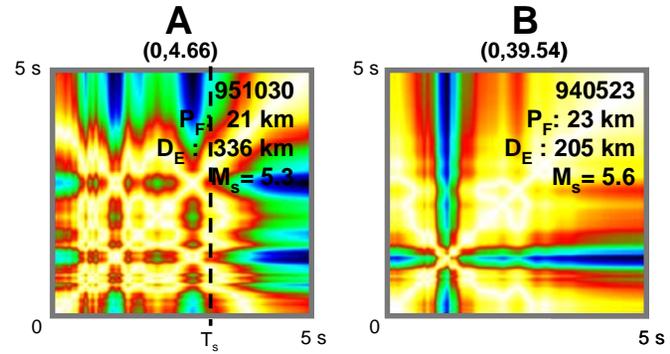
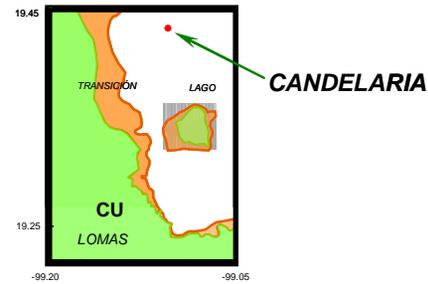


Figura 5.82 MR de Candelaria para sismos débiles

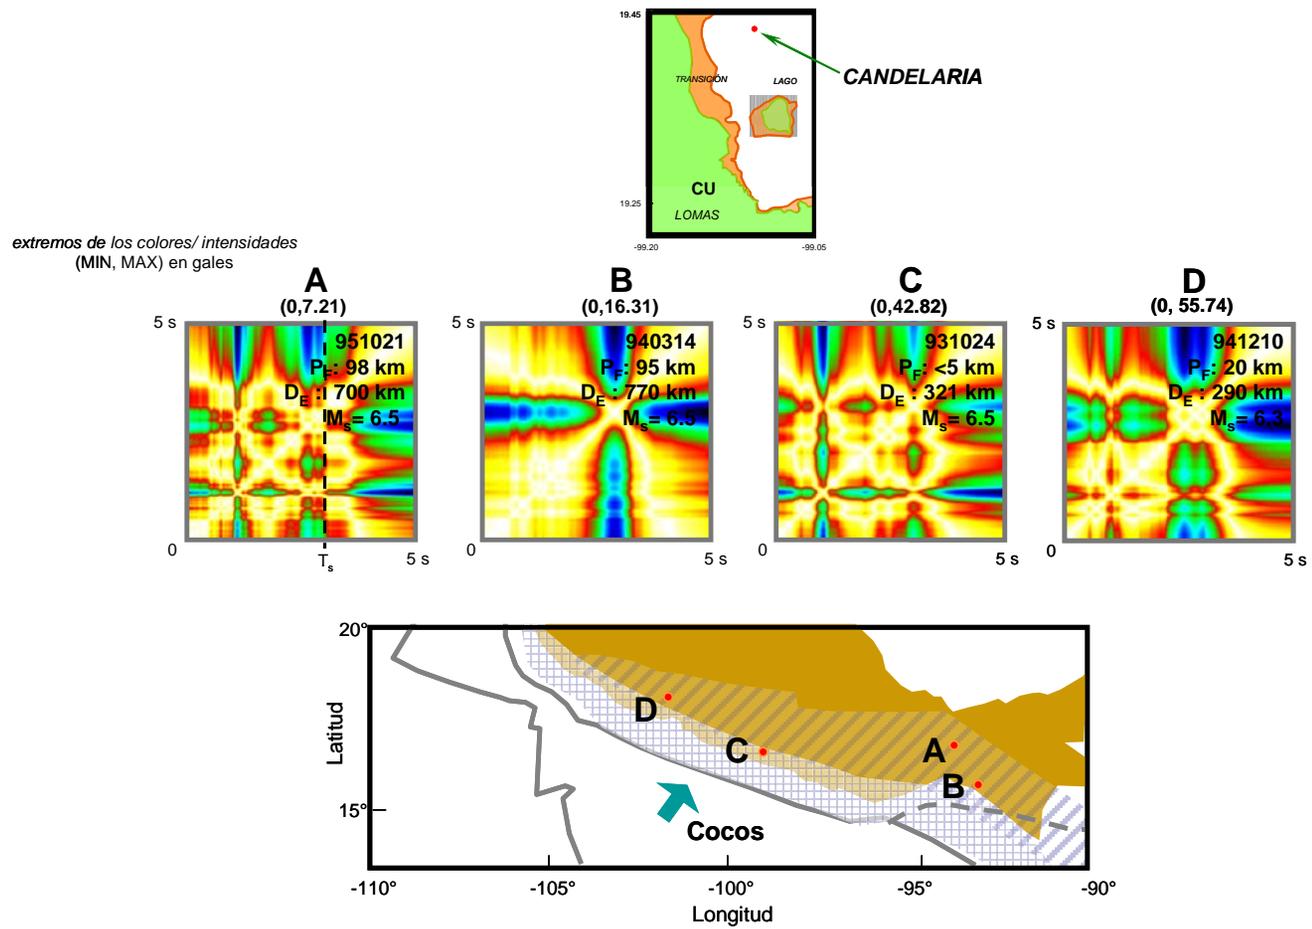


Figura 5.83 MR de Candelaria para sismos moderados

extremos de los colores/ intensidades
(MIN, MAX) en gales

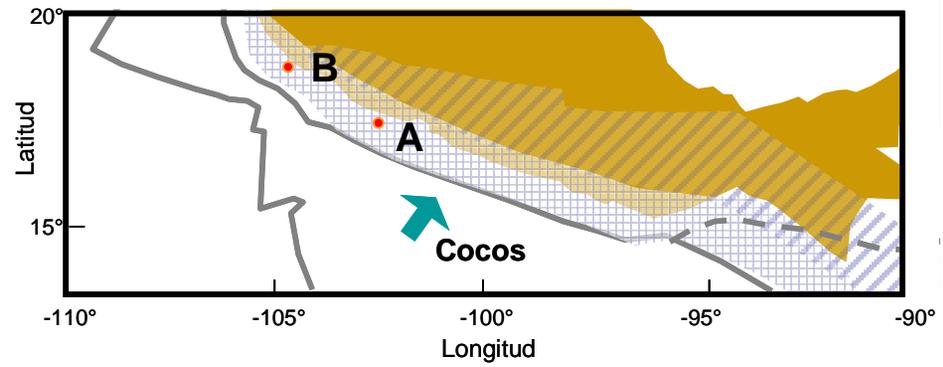
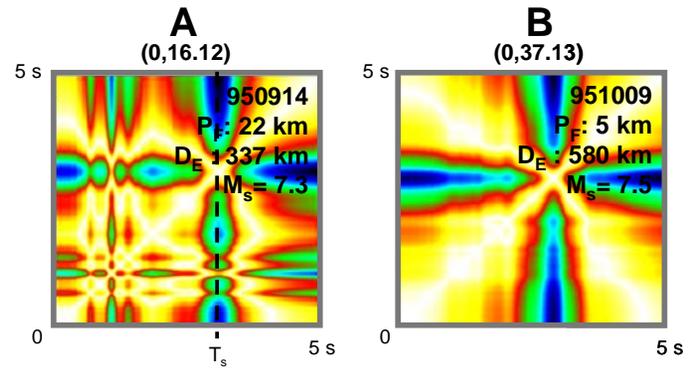
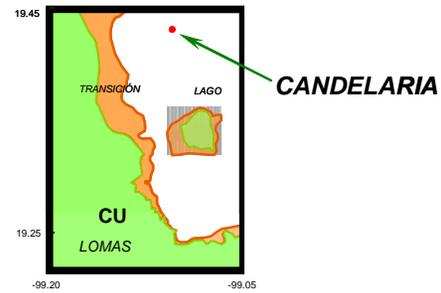


Figura 5.84 MR de Candelaria para sismos *severos*

- Sitio: Central de Abasto Oficinas CDAO

T_s : 3.5 s

El sitio CDAO es uno de los que, dentro de la base de datos, cuenta con menos información registrada. A pesar de esta escasez se distinguen tendencias interesantes en los MR analizados. En la Fig. 5.85 se presentan los dos MR construidos para sismos *débiles*. A partir de ellos se argumenta que las estructuras (geometrías) con mínima alteración para la mayoría de los osciladores (blancos y amarillos) y una puntual respuesta alrededor de 1s, se presentan en todos los sitios de acuerdo con un cierto nivel de sacudida pero la topología se mantiene a pesar de las diferencias en la condición espacial y por ende, estratigrafía.

El caso CDAO permite y obliga a combinar las observaciones hechas en sus MR de eventos *moderados* y *severos* (Figs. 5.86 y 5.87). Las respuestas máximas (0Es) se localizan en las cercanías del T_s y en su segundo modo de vibrar alrededor de los 1.2 s.

La ancha banda con eje sobre el periodo fundamental es más evidente conforme crecen las amplitudes espectrales. No se reconoce un máximo extremo y se puede hablar de una respuesta extrema de un conjunto de osciladores.

El depósito parece responder bajo un cierto patrón geométrico independiente de las zonas sismogénicas, las condiciones epicentrales y las profundidades focales.

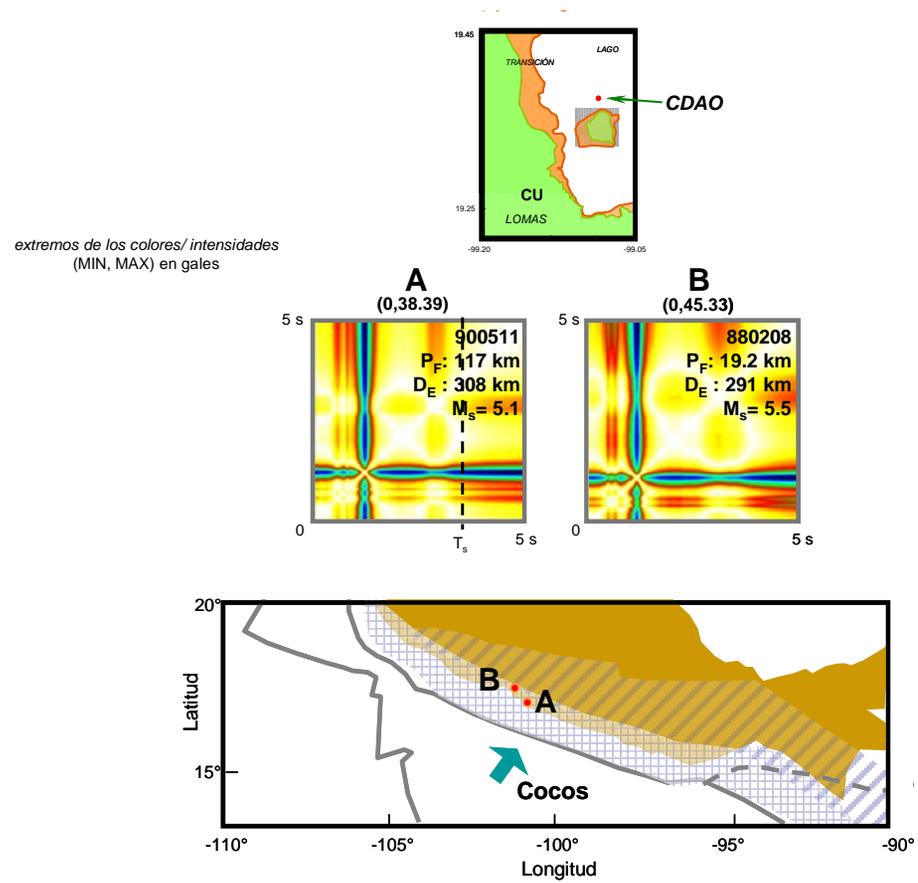


Figura 5.85 MR de CDAO para sismos débiles

extremos de los colores/ intensidades
(MIN, MAX) en gales

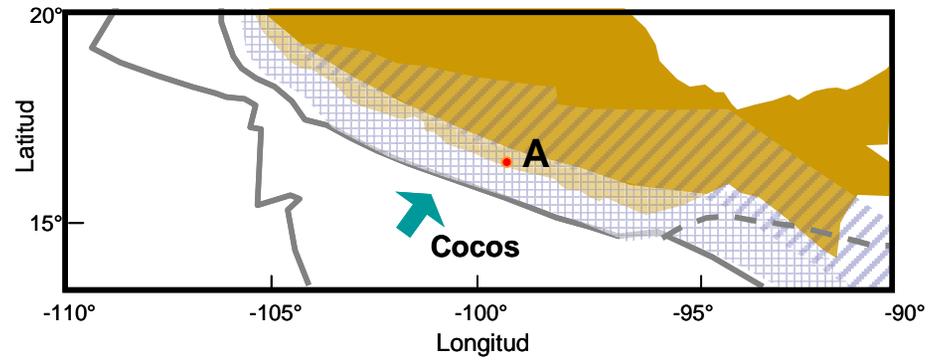
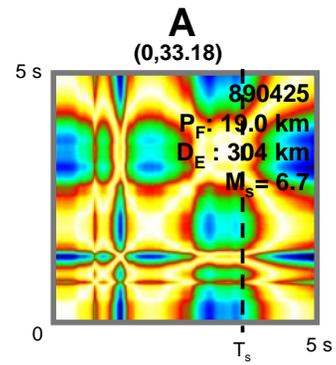
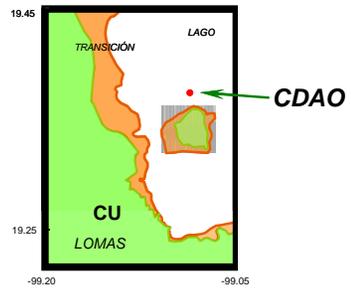


Figura 5.86 MR de CDAO para sismos *moderados*

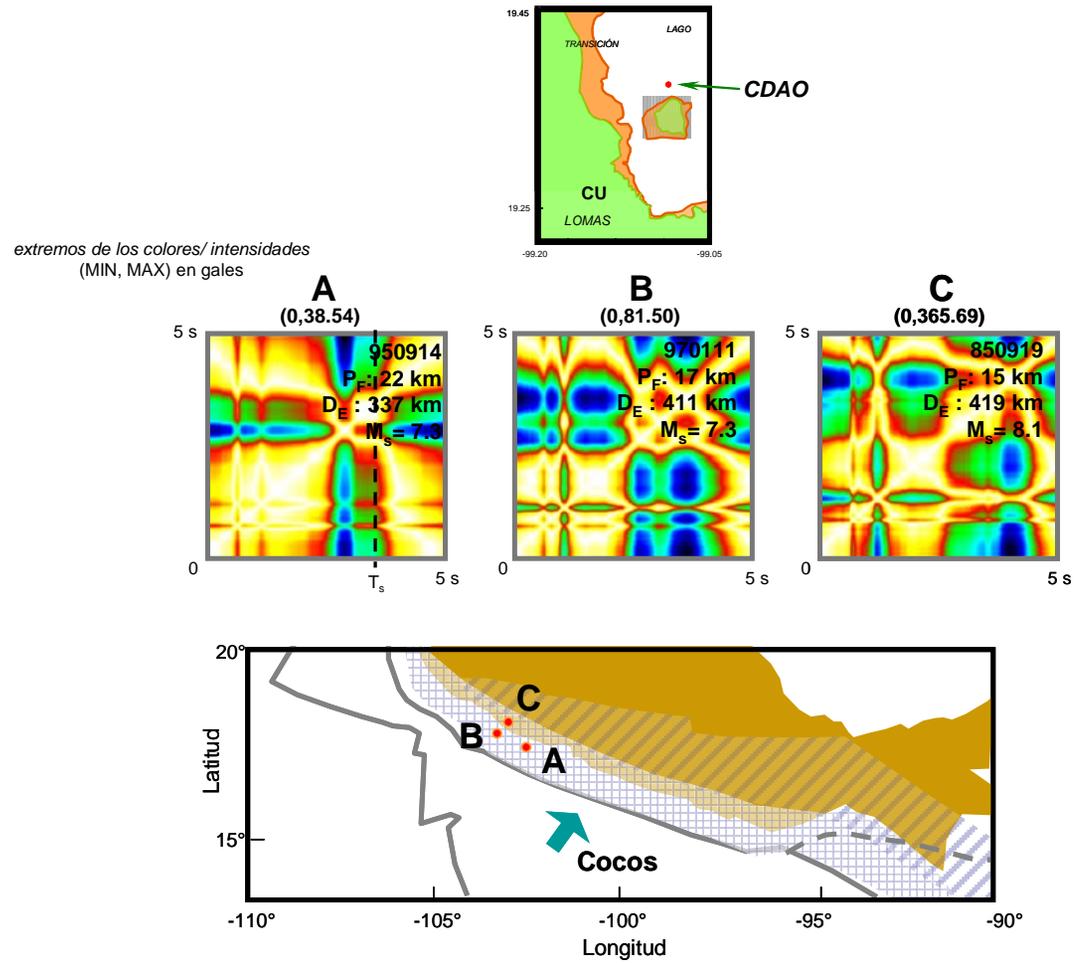


Figura 5.87 MR de CDAO para sismos *severos*

- Sitio: **Hangares**

T_s : 4.0 s

Las respuestas en este sitio, con periodo fundamental alto, verifican la hipótesis de la existencia de un mismo patrón de respuesta (geometría) en las Zonas de Lomas y Lago para sismos de intensidad menor (Fig. 5.88). Las bandas presentes de nueva cuenta presentan puntuales máximos en 1.2 s y 2.3 s, lejanos del valor de T_s para el sitio.

Los mismos periodos activados con las OE máximas en sismos *débiles* se repiten bajo la acción de algunos sismos *moderados* (Fig. 5.89) aunque no así la estructura general del mapa. Se puede apreciar que el incremento de fuerza sísmica origina un corrimiento hacia los periodos mayores de la zona de máximas OEs (banda verde).

En la Fig. 5.90 se presentan los dos MR de eventos *severos* registrados en el sitio. Esta información, similar a la desplegada en la Fig. 5.89, permite afianzar la deducción de que las estructuras de algunos sitios parecen no modificarse aún con el incremento de la intensidad en la sacudida (sin tomar en cuenta ningún evento *extremo*). Particularmente se distingue la participación importante de tres periodos, no coincidentes con el T_s del RCDF para Hangares.

Se recomienda precaución sobre estas conclusiones debido a la fuerte componente de ruido ambiental.

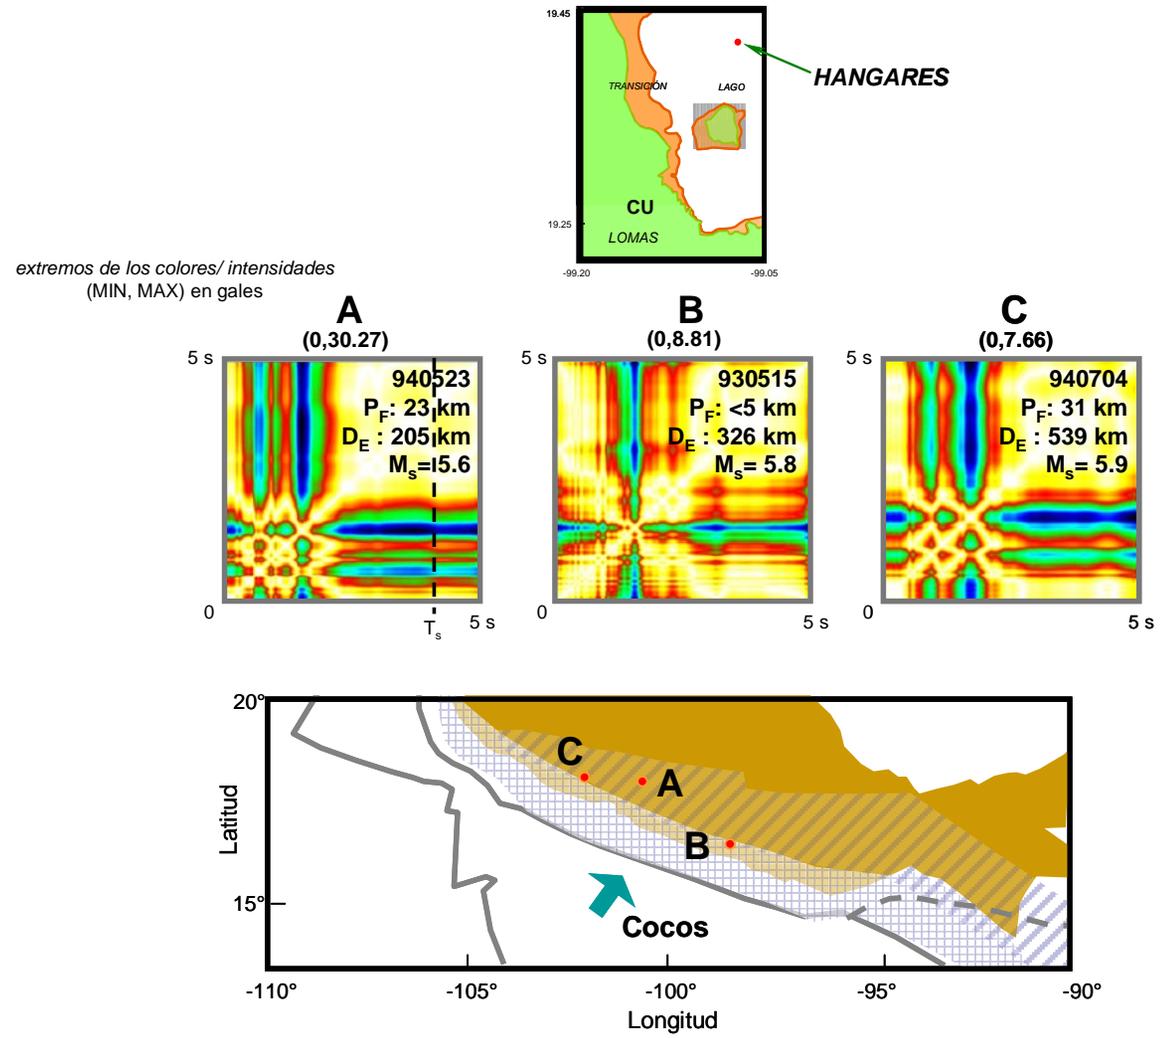


Figura 5.88 MR de Hangares para sismos débiles

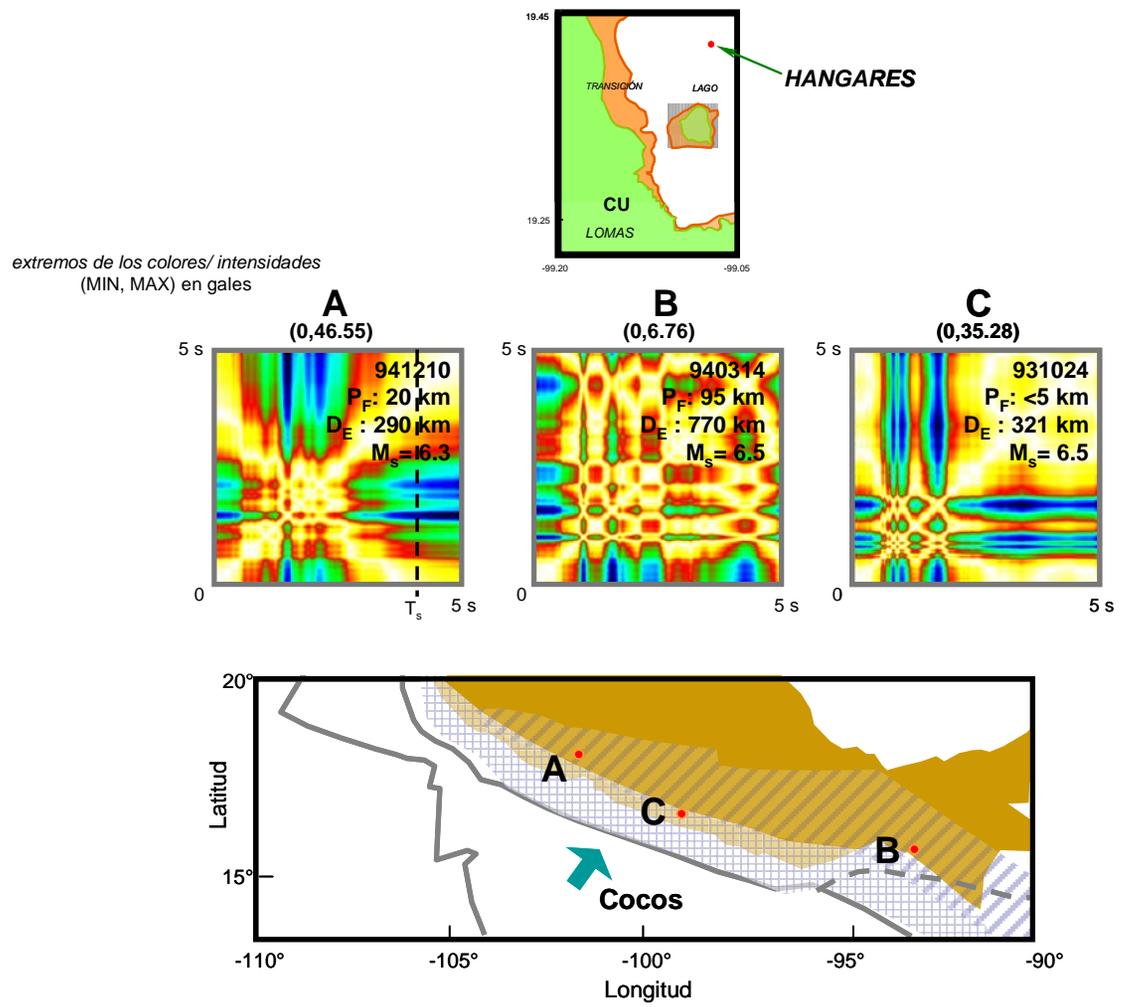


Figura 5.89 MR de Hangares para sismos *moderados*

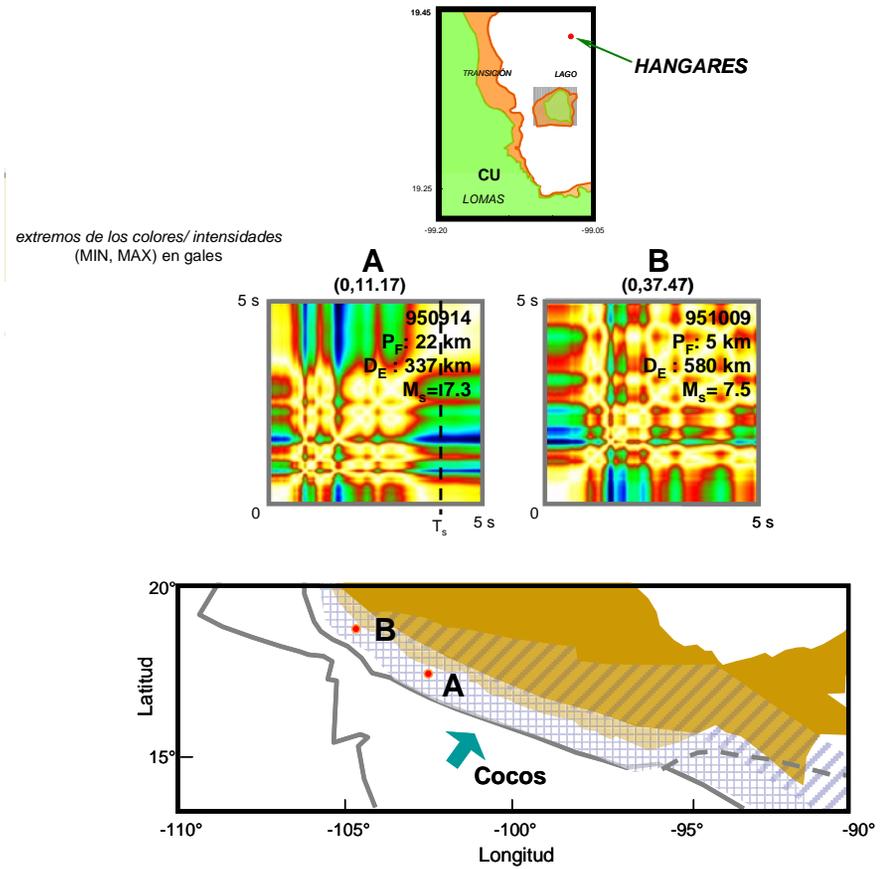


Figura 5.90 MR de Hangares para sismos *severos*

Algunas observaciones sobre los *Sismos* y los *Sítios*

El uso de los MR en el análisis de respuesta de sitio permite esclarecer algunos de los puntos que deben dirigir el comportamiento del modelo neuronal y que a su vez constituyen las estimaciones críticas y los puntos de divergencia teórica entre éste y los esquemas de cálculo convencionales. Es complejo y poco eficiente ejemplificar estas consideraciones usando toda la información disponible por lo que a continuación se presentan sólo ciertos esquemas comparativos que permitan al lector tener una idea general del tipo de mapeo que realizará el modelo conexionista propuesto en este trabajo de tesis.

En la Fig. 5.91 se muestran similares MR obtenidos para los seis sitios analizados, a manera de ejemplo, de lo contenido en la base de datos. El Parámetro E común detrás de estas geometrías (una marcada línea vertical y horizontal con el valor máximo -color azul/negro- alrededor de $T=1$ s) es sólo la magnitud por debajo de los seis grados (evento *débil*). Los epicentros cubren una zona muy amplia y las profundidades focales van desde los 5 hasta más de 100 km.

Las condiciones de los depósitos en el área cubierta por los sitios elegidos son cambiantes y no pertenecen todos a la zona del Lago (potentes estratos de arcilla lacustre con altísimos contenidos de humedad). No es lógica la búsqueda de coincidencias en materiales, profundidades y espesores. Entonces existen condiciones sísmicas que hacen que una gran parte de la Zona de Lago genere movimientos semejantes y sean la *situación* (disposición) de los suelos quienes dirijan la intensidad de la respuesta.

Manteniendo fijo el evento y comparando las respuestas de los sitios, se puede argumentar que en sismos *débiles* (Fig. 5.92) es notable la tendencia a presentar los máximos por debajo del periodo fundamental del sitio y muy cerca del periodo del sitio en roca. La banda que contiene al valor máximo de OE está claramente definida y las zonas claras (mínima activación de los otros periodos) son muy extensas.

Si se refiere este comportamiento a la acción básica en la estimación de respuesta (modificación del movimiento en el afloramiento rocoso debido a la presencia del suelo) entonces todas las variantes en disposición y materiales en cada sitio no sugieren un cambio sustancial del artificio numérico con el cual se transforma la entrada. SCT es un caso excepcional. En toda la base de datos no se encuentra un depósito que presente respuestas tan constantes (en términos geométricos) y sólo parezca responder en diferentes niveles de intensidad a los valores de energía de entrada.

Conforme las magnitudes crecen las diferencias entre las respuestas son más claras en términos geométricos pero no en términos de intensidad (OEs) (Figs. 5.93 y 5.94). Los máximos valores espectrales comienzan a coincidir en posición con el T_s del sitio, siendo evidente que este concepto físico aplica de mejor manera para sismos *severos*.

Es importante señalar que el incremento de la fuerza sísmica activa un mayor número de *estados* en los MR y al minimizar los efectos del ruido ambiental permite analizar mejor los *estados* fundamentales, concepto propuesto en este trabajo de tesis y análogo al de *periodo* fundamental. Más adelante se retoma y analiza ampliamente esta idea.

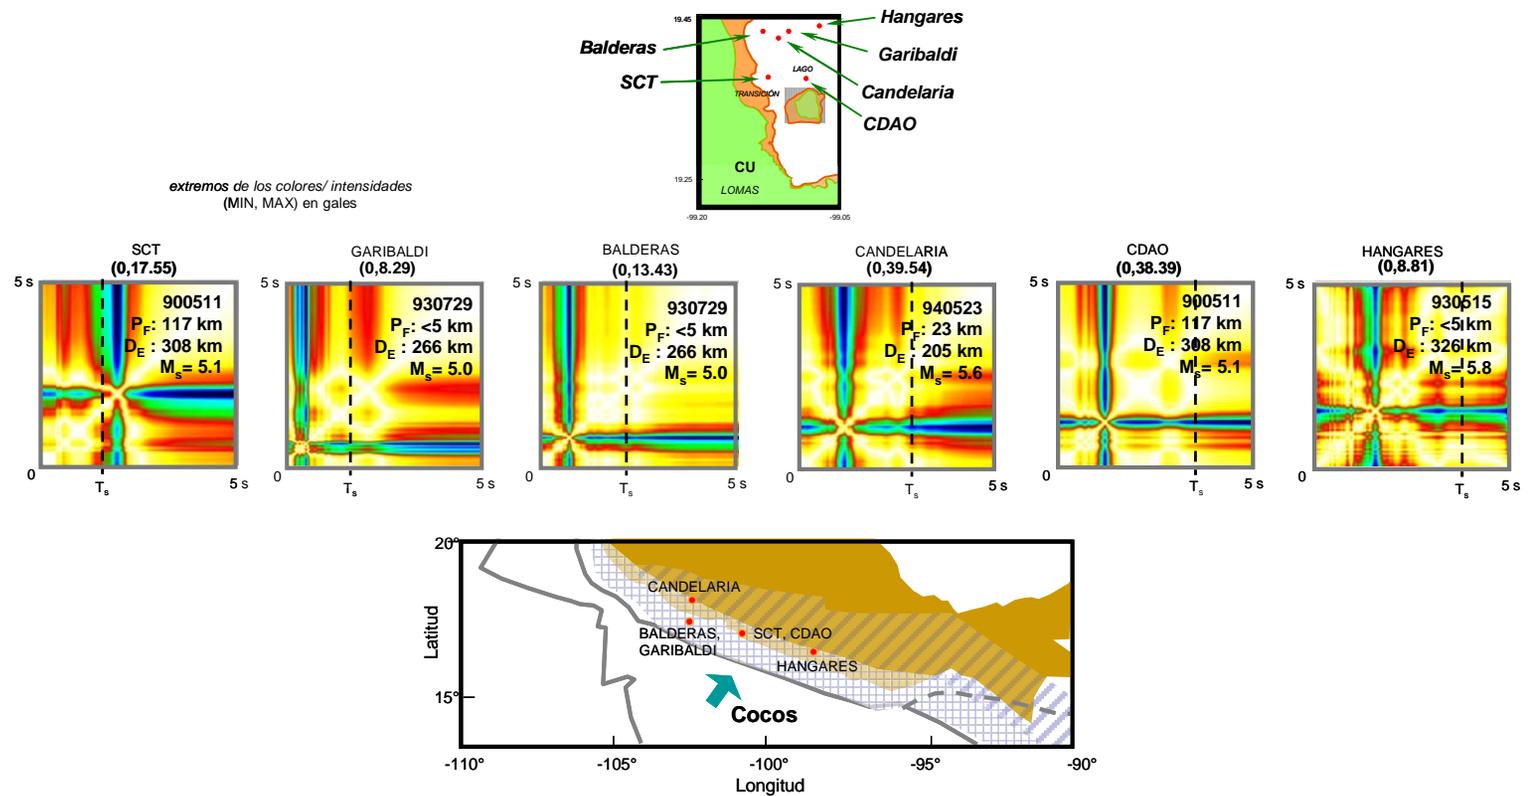


Figura 5.91 MR de depósitos de suelo distintos con geometrías similares

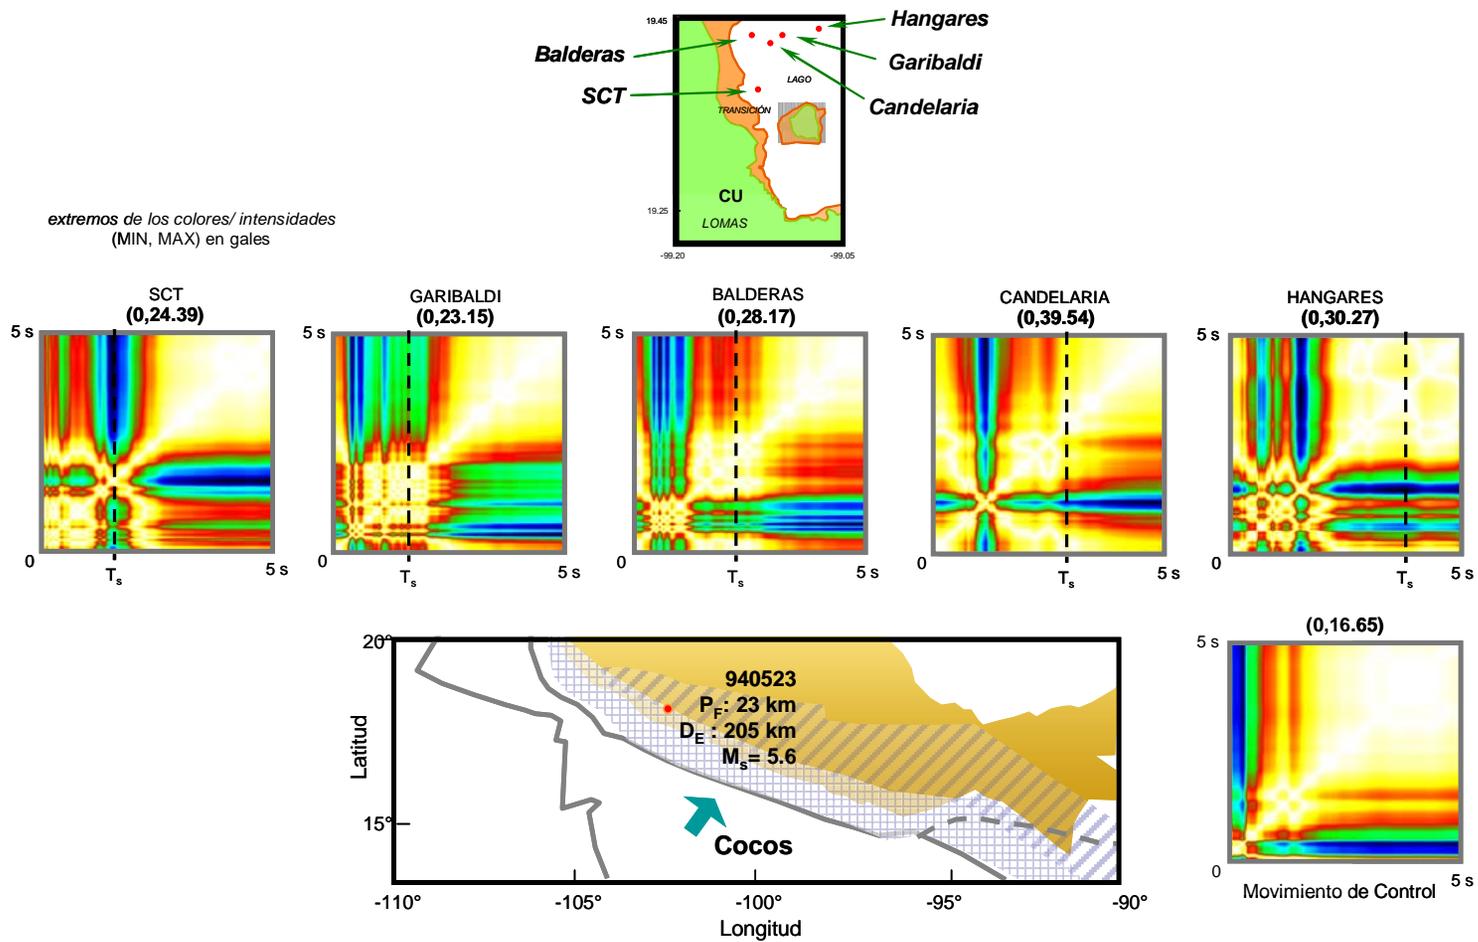


Figura 5.92 Ejemplos de MR de depósitos de suelo distintos, sismos débiles

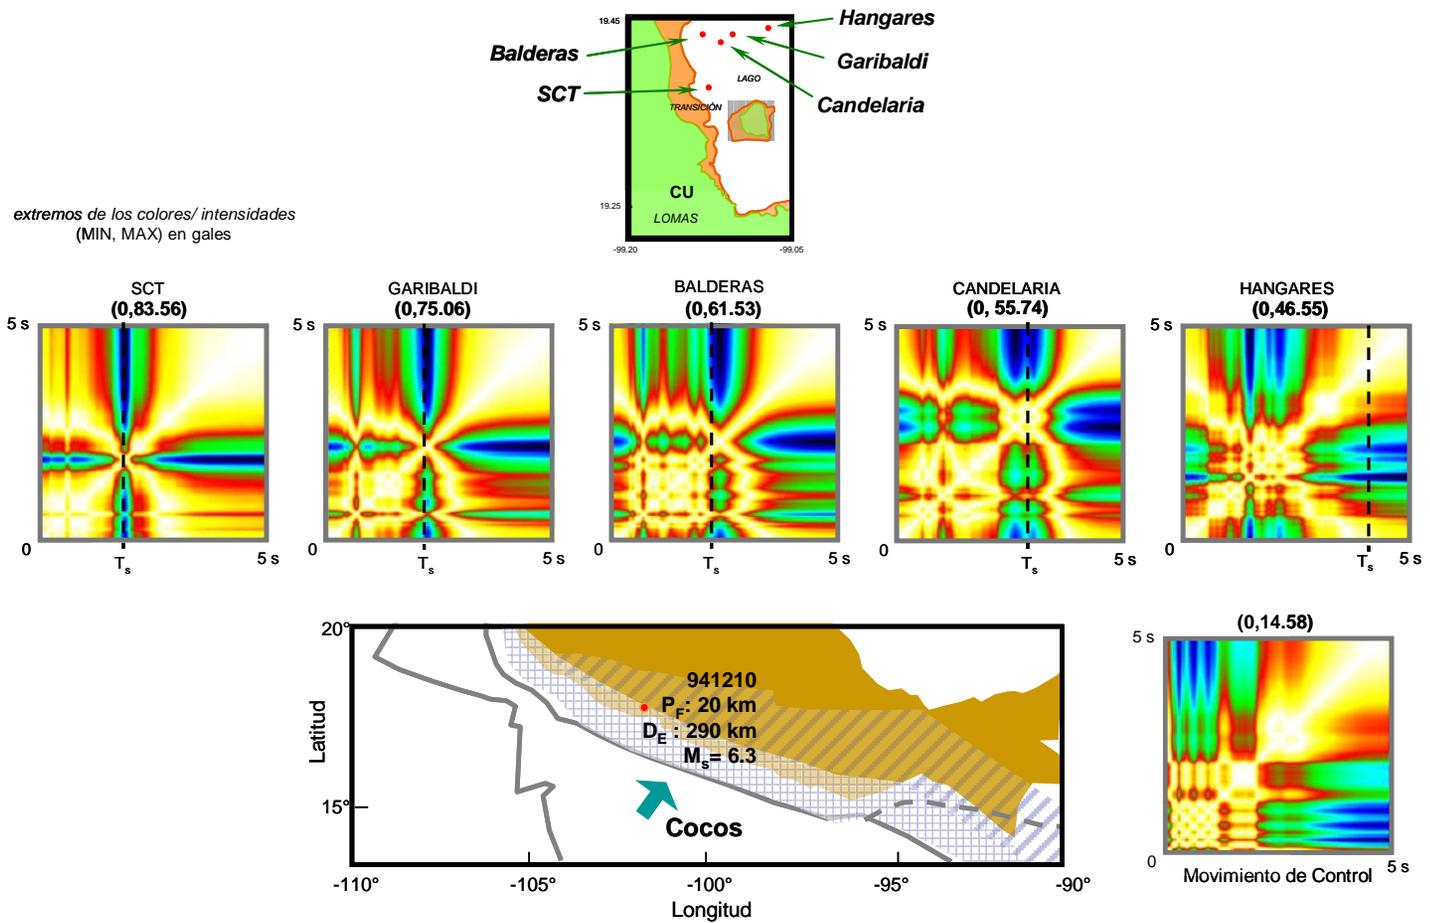


Figura 5.93 Ejemplos de MR de depósitos de suelo distintos, sismos *moderados*

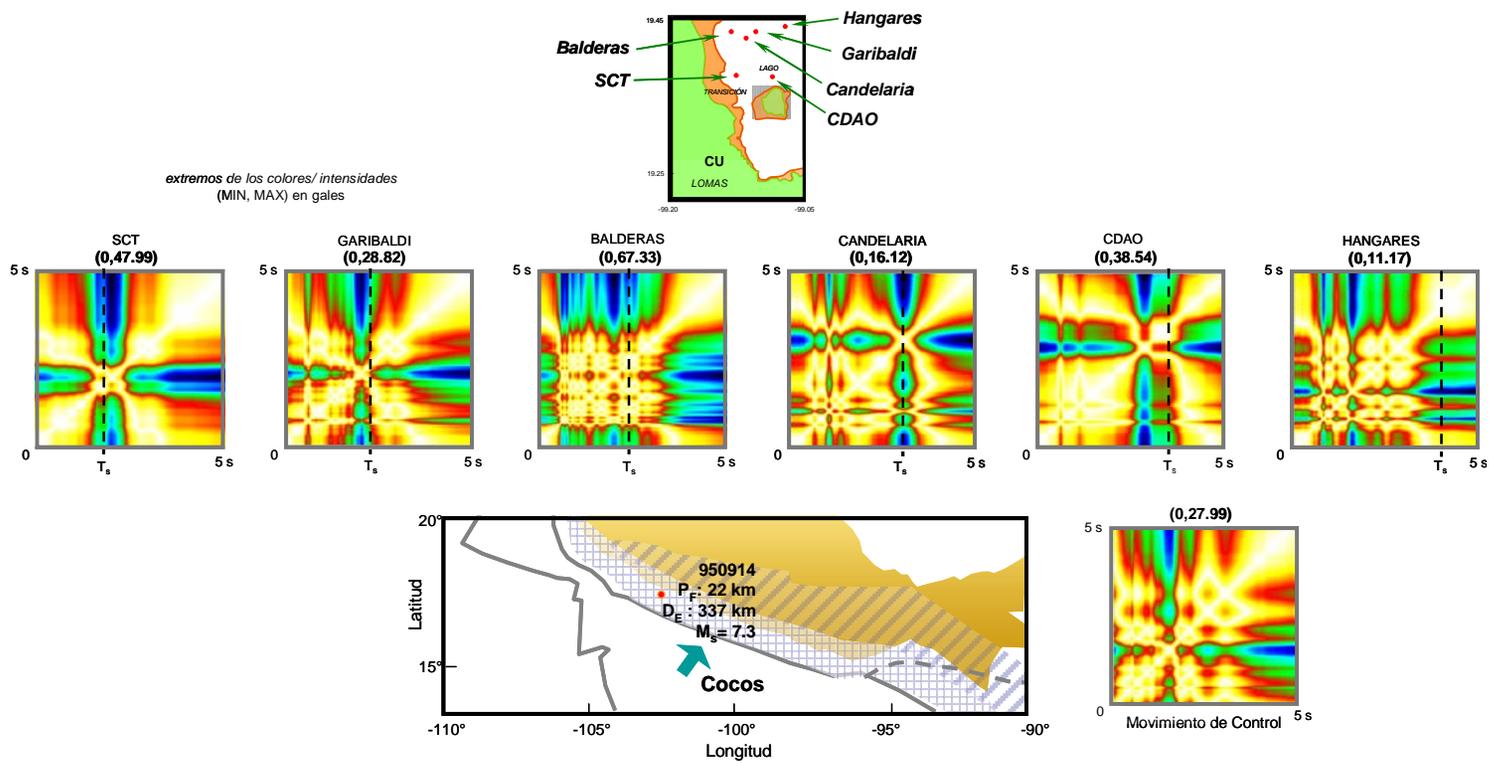


Figura 5.94 Ejemplos de MR de depósitos de suelo distintos, sismos *severos*

Entonces se puede hablar de una cota en las aceleraciones de entrada donde el Lago se comporta de manera muy similar, hablando de *estados*, y las diferencias entre las OE de los ERAs son sutiles. Más allá de este límite los estados que se activan comienzan a cambiar y se observan importantes diferencias de estructuras desplegadas en los sitios con $T_s < 2.5$ s y los que sobrepasan este valor. Las geometrías son más complejas para sitios con T_s altos y los comportamientos más constantes (líneas y zonas de máximos que se repiten en eventos *moderados* y *severos*). Se pueden generar conclusiones valiosas sobre las respuestas mínimas pero en el caso de eventos *extremos*, se cuentan con sólo tres registros del terremoto de 1985. Los MR de los dos sitios en Lago y el de control se muestran en la Fig. 5.95.

extremos de los colores/ intensidades
(MIN, MAX) en gales

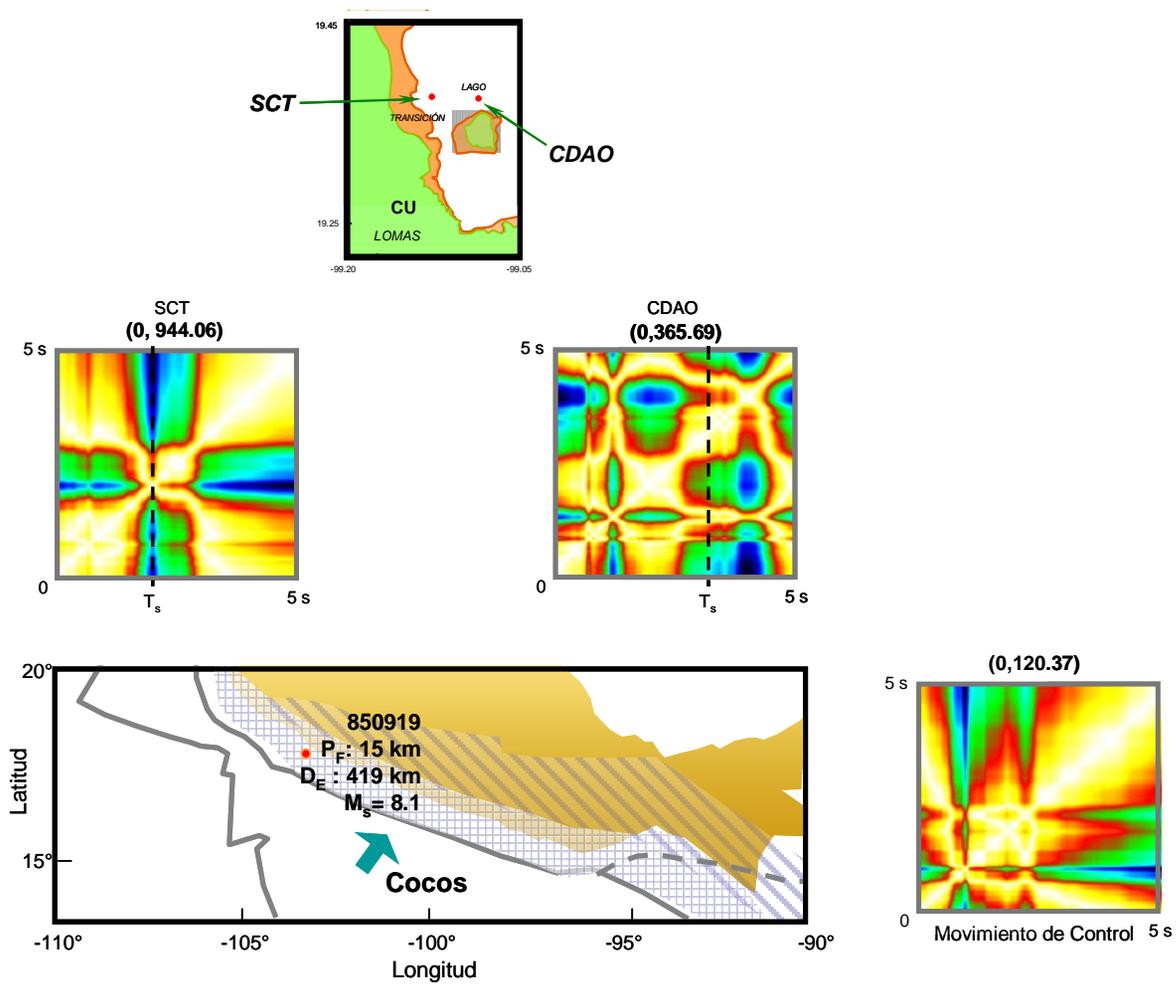


Figura 5.95 MR de los sitios SCT y CDAO para el sismo del 19 de septiembre de 1985

Como ya se apuntó, el movimiento de control muestra una geometría muy distinta a las registradas en toda la historia sísmica de la estación CU. OEs máximas alrededor de 1s con una zona de respuestas importantes (manchas verdes) desde los 0.5 s y más allá de los 2.5 s. El MR de este evento es incluso similar a algunos considerados típicos de sitios en la zona del Lago. Contrario a este anómalo comportamiento en CU, los sitios SCT y CDAO despliegan estructuras semejantes a las vistas en otros sismos de magnitud moderada. La típica presencia de franjas sobre el T_s para SCT y la sobresaliente participación de los dos modos de vibrar para CDAO son modificadas ligeramente durante el sismo del 85 en el primer caso, con el ensanchamiento de la banda fría creciendo hacia los 3 s (presencia de verdes hasta los 3.2 s) y en el caso CDAO con una disminución de la participación del primer modo de vibrar (referido a las OE en el segundo modo ≈ 1.2 s) que se desplaza hacia los 4 s.

La hipótesis de un umbral de intensidad sísmica debajo del cual la mayoría de los sitios responden de manera muy similar se refuerza si comparamos las Figs. 5.95 y 5.96. Las estructuras que caracterizan a un sitio aparecen cuando la sacudida es suficientemente fuerte pero no así cuando el evento es de menor importancia.

Es fundamental y conveniente a nuestro modelo conexionista que el movimiento de control contenga particularidades que lo separen del resto de los MR de entrada (geométricos y de fuerza) para lograr que la RN reconozca las condiciones especiales que generan las respuestas extremas (por lo menos en intensidad) en los sitios del Lago.

Resulta evidente que es una tarea muy compleja encontrar a simple vista las relaciones entre MRs o dilucidar sobre las geometrías desplegadas y su interpretación de acuerdo con las aceleraciones espectrales y los otros parámetros de entrada, por lo que no se pre-clasifican los mapas, no se añaden variables ligadas a las observaciones antes descritas ni se dirige de alguna otra manera el flujo de información/aprendizaje neuronal. Se obliga al modelo a comportarse como de reconocimiento y clasificación de patrones con fines de predicción numérica.

En la Fig.5.97 se muestra el nuevo esquema neuronal con la sustitución de los ERAs por el conjunto de sus MR. Como ya se ha mencionado y ejemplificado, la inclusión de los MR expande el *conocimiento* y aumenta la confianza en las *predicciones* neuronales, pero impone un importante reto: la eficiencia numérica. Si cada mapa ha sido construido con ERAs de 1000 puntos (mínimo suficiente para desarrollar análisis de recurrencia -identificación e interpretación de estructuras-) entonces las entradas y salidas neuronales se convierten en paquetes matriciales de dimensiones gigantescas.

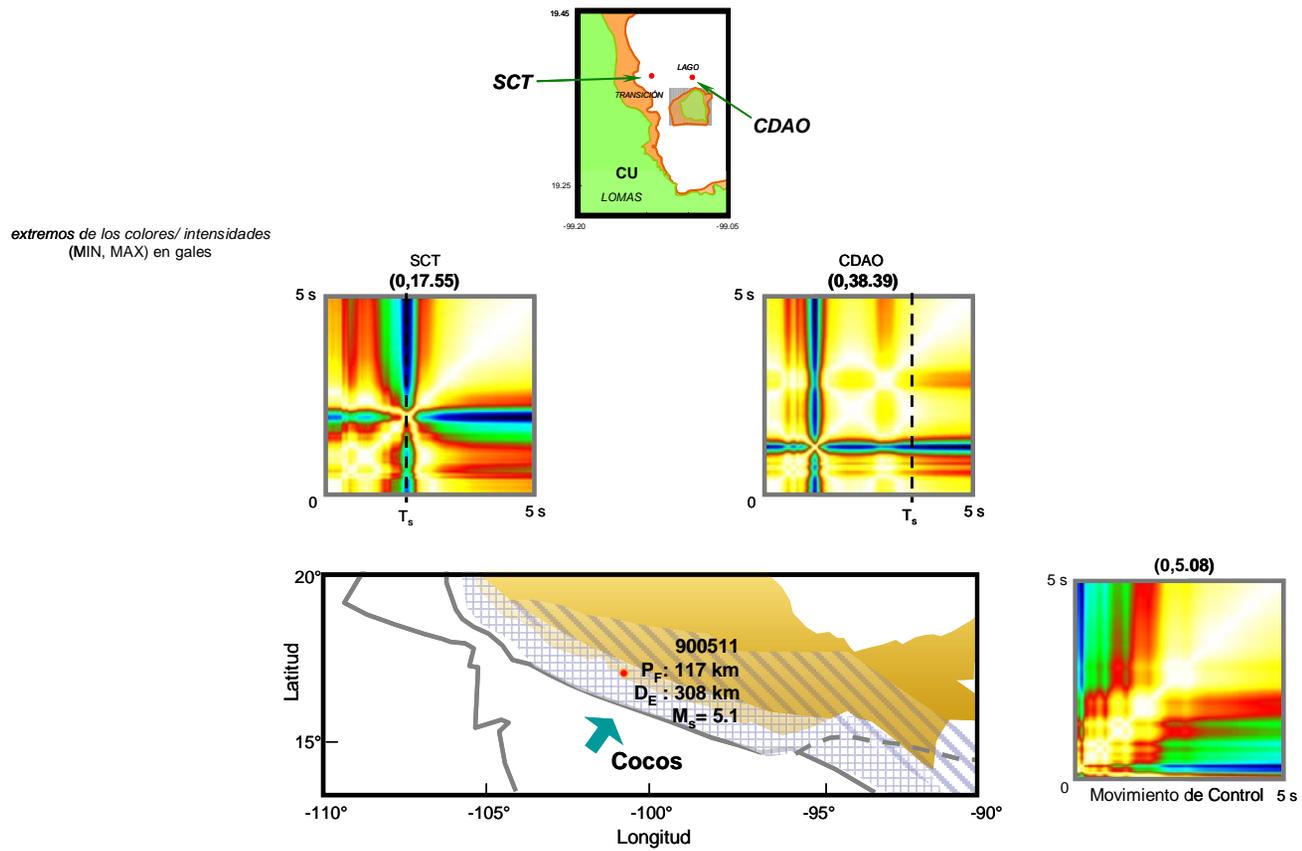


Figura 5.96 MR de los sitios SCT y CDAO para el sismo del 11 de mayo de 1990

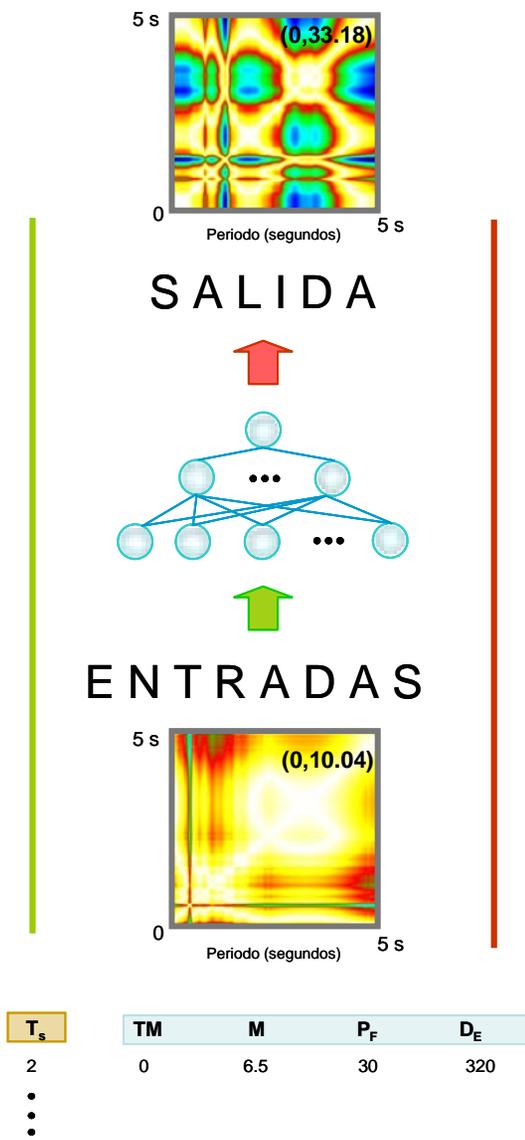


Figura 5.97 Sustitución de los ERAs por MR en el modelo neuronal

Involucrar de forma equilibrada a los cuatro Parámetros E con 1000 columnas y 1000 renglones (10,000 números que constituyen el MR de entrada -CU-) tal que se expresen correctamente las relaciones con el Parámetro S y las 10,000 salidas (1000 renglones y 1000 columnas del MR de salida -sitio-) para más de 150 patrones o ejemplos de comportamiento, es el problema por resolver. Es un hecho que las ventajas de los MR radican en sus características visuales y su actuación dentro del conjunto de manifestaciones del **Proceso**, así que en esta investigación se propone el uso de las Eigenfaces EFs, técnica de reconocimiento de rostros, para la inspección, almacenamiento y disposición eficiente de este enorme conjunto de MR.

La dupla MR-EFs, como mancuerna en el procesamiento de señales, permite expandir la información de un conjunto de vectores (1D) hacia la bidimensión con fines de categorización, almacenamiento (como miembros de un espacio) y compresión (versiones simplificadas de la expansión 2D), con el beneficio de la transformación inversa en cualquiera de sus etapas.

Análisis de Series de Tiempo a través de MR-EFs

La metodología presentada aquí puede ser aplicada al estudio de cualquier serie de tiempo. Las condiciones y procesos matemáticos para la construcción de MR y el análisis de imágenes a través de EFs se detallan en el Capítulo 4 de esta tesis por lo que en esta oportunidad sólo se describe la secuencia para su aplicación acoplada. De acuerdo con las operaciones generales de la Fig. 5.98, en pre-proceso,

- a) dado un conjunto de series de tiempo (en este caso vectores ERA),
- b) se calcula el MR de cada una de ellas y
- c) se encuentra el espacio de fase correspondiente al conjunto
- d) para expresar al MR como una combinación lineal de las eigenfaces y convertirlo en un punto,

y en post-proceso,

- a) conocido un punto
- b) se refiere a un espacio de fase conocido y
- c) a través de sus eigenfaces se calcula su MR
- d) para definir la serie original (en este caso vector ERA) correspondiente a ese MR.

El espacio de fase resulta de arreglar el conjunto de MR como matriz (cada columna es un MR expresado como vector) y calcular sus eigenvectores. Una vez construido el espacio de fase, cada MR puede ser expresado como una combinación lineal de las eigenfaces, convirtiendo un MR *completo* en un punto en el espacio de fase representado con unos pocos valores. Note que la dimensión de los vectores en el espacio de fase será igual al número de vectores usado como la base ortogonal del espacio de fase, es decir, el número de MR en la base de datos. Los eigenvalores más grandes representan la información sustancial de la imagen por lo que se puede usar un subconjunto de éstos para representar el elemento (MR) completo, abreviando el vector correspondiente.

Este proceso puede ser aplicado cuando: a) se requieran descripciones detalladas de señales que, en conjunto, expresan un mismo fenómeno y b) se necesite manipular grandes volúmenes de información numérica en esquemas de modelado con múltiples entradas y salidas.

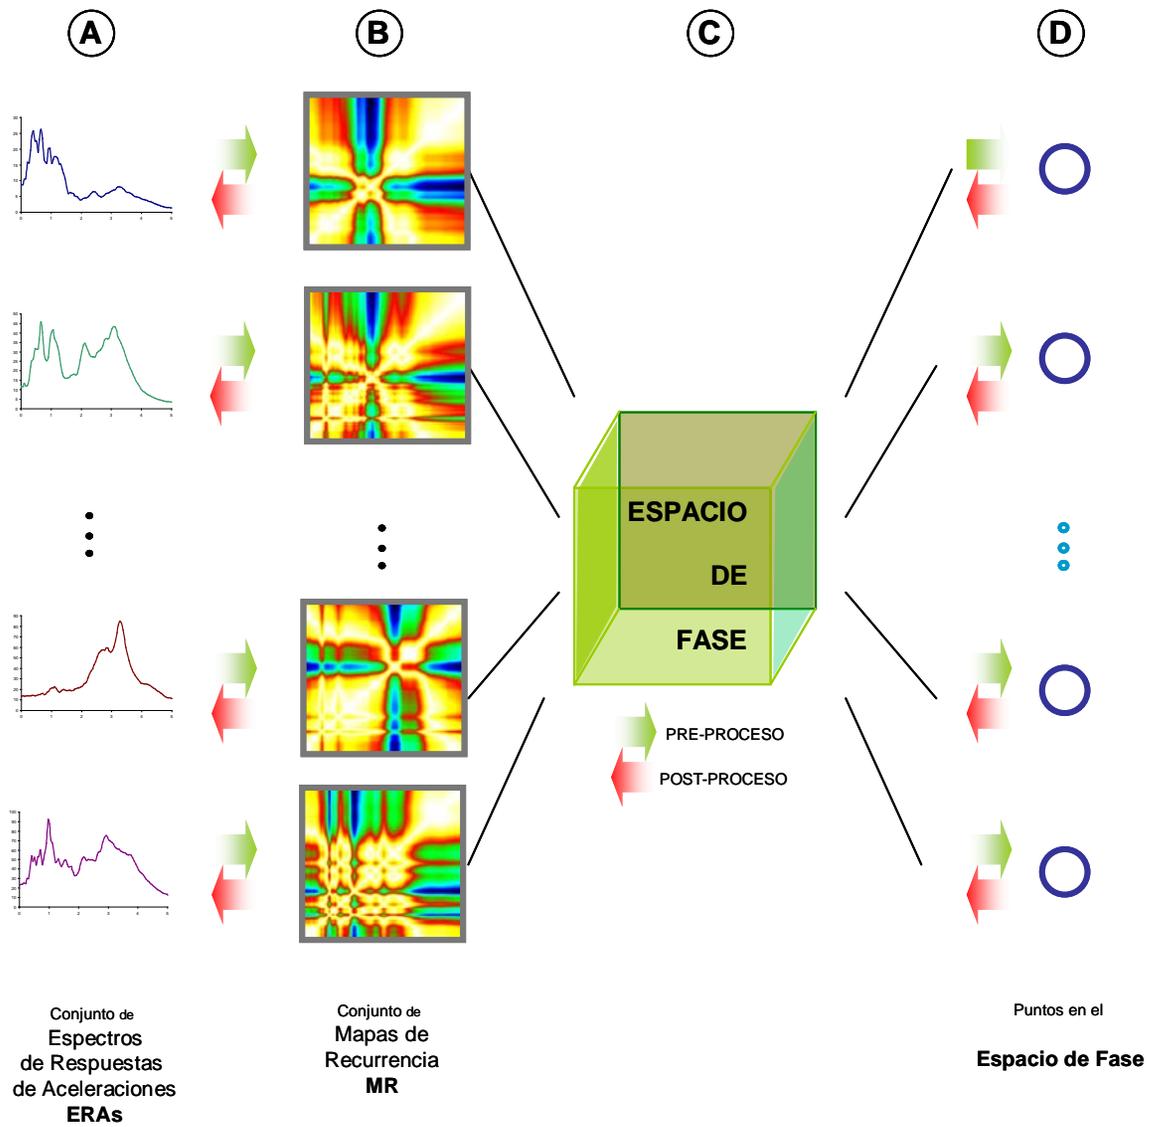


Figura 5.98

Proceso de análisis de ERAs usando la dupla MR-EFs

- Ejemplo de aplicación

Considere tres series de tiempo de entrada, cada una con 2000 valores, como las mostradas en la Fig. 5.99. El primer paso en la etapa de pre-procesamiento es calcular el MR de cada serie de tiempo de entrada.

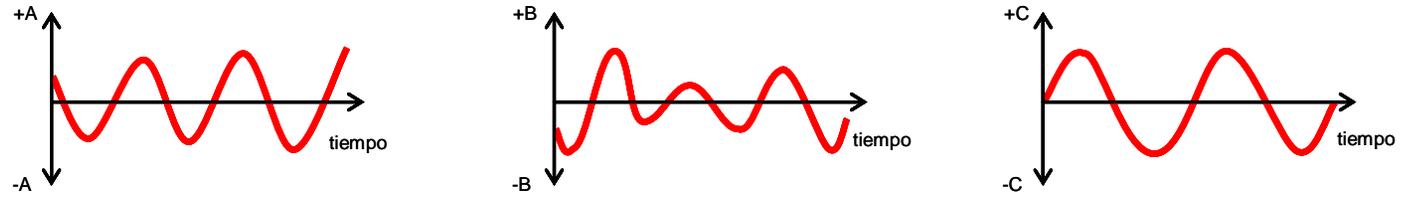


Figura 5.99 Ejemplos de Señales

Los MR resultantes se muestran en la Fig. 5.100. El siguiente paso es la generación del conjunto de eigenfaces de los MR mostrados anteriormente. Estos eigenfaces forman el espacio de fase y por lo tanto son tratados como una unidad. Un ejemplo de eigenface para un MR se muestra en la Fig. 5.101.

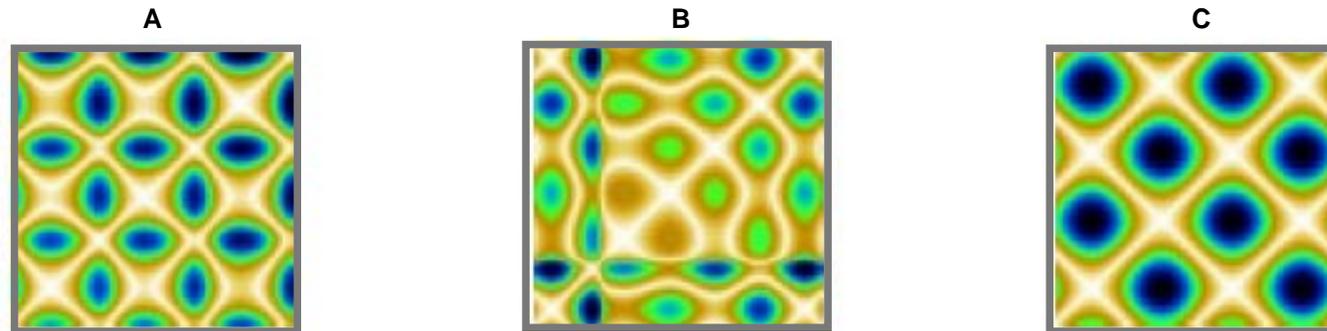


Figura 5.100 MR de las señales

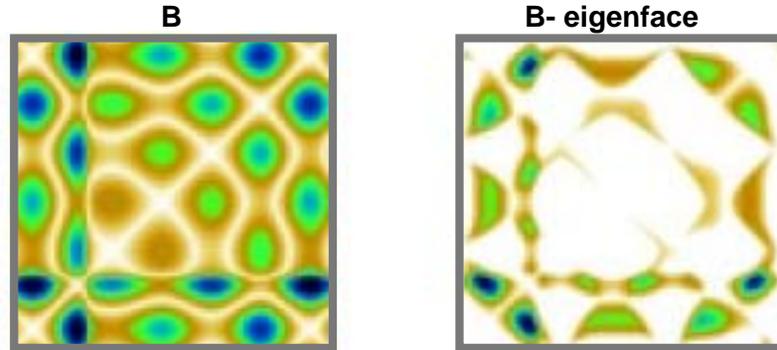


Figura 5.101 Ejemplo de MR-eigenface

Los vectores en el espacio de fase muestran el peso que cada eigenface tiene en el MR. Estos vectores no-normalizados se muestran a continuación (se mantiene el orden de los MR anteriores):

```
(777.1191573465204, -494.3188957993881, 12.325170500631794)
(1448.5151494857735, 268.12345386239616, 6.803736657263384)
(138.87833187137394, -30.50296638025993, -139.9314167509452)
```

Dados los vectores en el espacio de fase, los MR originales y las series de tiempo originales pueden ser recuperadas con gran precisión, como lo muestra la Fig. 5.102.

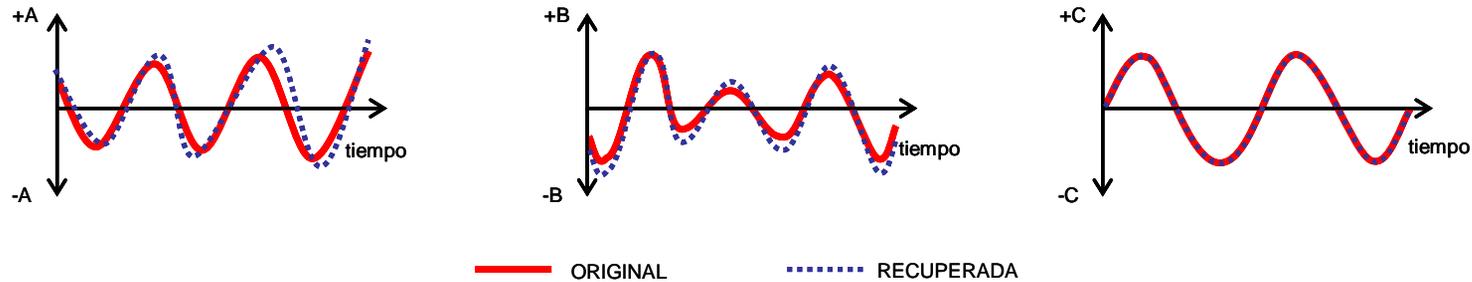


Figura 5.102 Señales recuperadas usando la dupla MR-EFs

Red Neuronal

Finalmente, el modelo neuronal se transforma en lo que se muestra en la Fig. 5.103. Este esquema exhibe las etapas de operación del sistema conexionista, donde la Dinámica No Lineal y el reconocimiento de imágenes forman parte de la presentación y manipulación de la información, pero la RN continúa siendo el cerebro funcional. Son 168 los patrones que conforman el conjunto de entrenamiento (de 198 ERAs en la base de datos, fueron separados 30 para la prueba del modelo) por lo que 168 es el número máximo de componentes vectoriales (longitud máxima de los eigenvectores).

Después de una serie de evaluaciones tipo “prueba y error” se decidió que la longitud óptima para reconstruir MR sin pérdidas que repercutieran en la calidad de los ERAs recuperados es 112 componentes vectoriales. Se tienen entonces 117 entradas y 112 salidas de 168 patrones de comportamiento. Comenzando con topologías *escasas* (mínimo número de nodos ocultos) se entrenaron redes monocapa con 150 y hasta 500 nodos ocultos (incrementos de 25 nodos en cada operación) generando resultados en etapa de entrenamiento muy por encima del criterio de terminación $(= ||\text{ERA}_{\text{medido}} - \text{ERA}_{\text{calculado}}|| \leq 10 \text{ gales})$.

Debido a la complejidad del problema es necesario realizar los ensayos con dos capas ocultas de tal forma que las conexiones eleven la dimensión del funcional neuronal. Las estructuras parten de 100×100 (no. de nodos_{1a.capa} x no. de nodos_{2da.capa}) y si el modelo no cumple con ϵ se aplica un incremento de 25 nodos en la primera capa y segunda capa en oportunidades diferentes. La estructura nodal más exitosa ($\epsilon \leq 7 \text{ gales}$) se detalla en la Fig. 5.104.

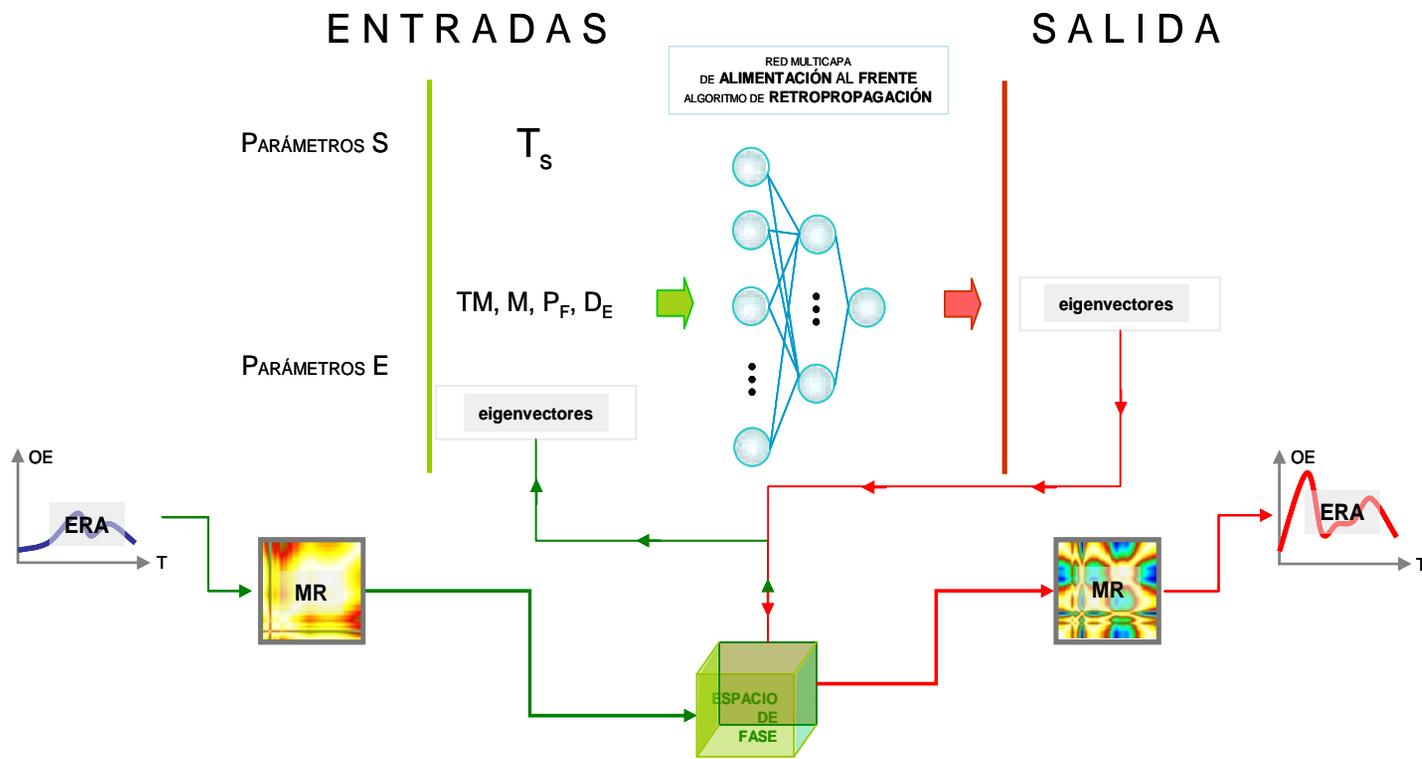


Figura 5.103 Señales recuperadas usando la dupla MR-EFs

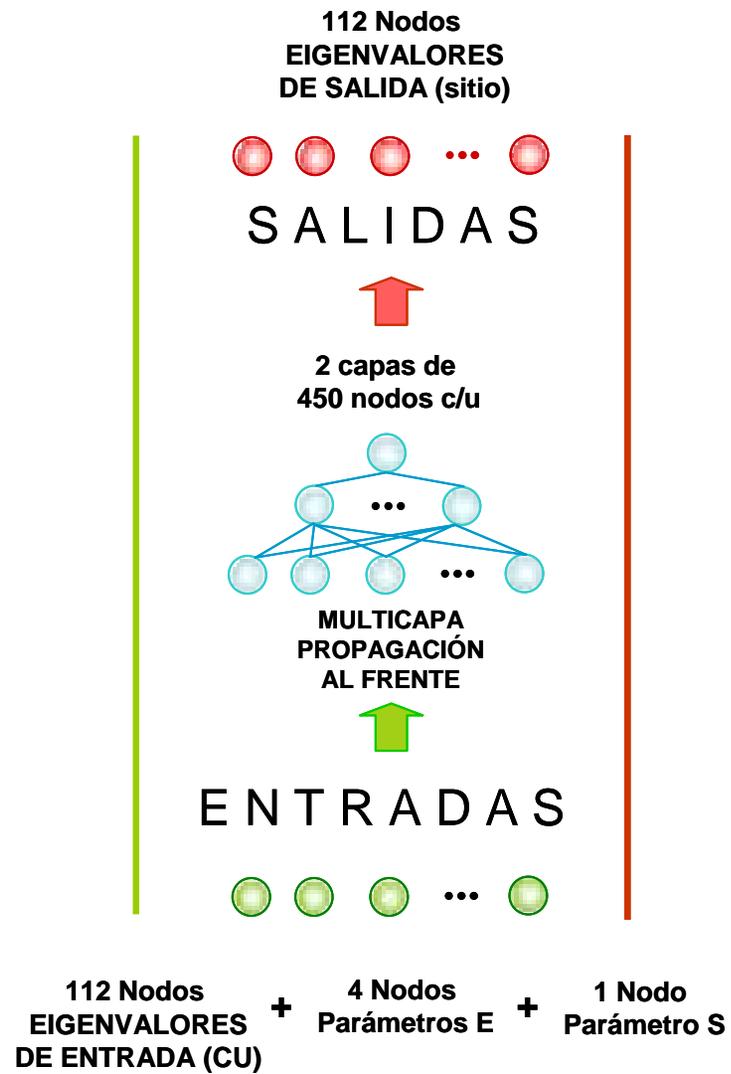


Figura 5.104 Estructura nodal del modelo neuronal

Entonces la RN mapea la información:

- de Entrada

Los eigenvalores de la historia sísmica de CU conforman el espacio de fase que contiene las posibles condiciones sismogénicas a través de características expuestas en los MR. Las condiciones de entrada se expanden de sólo parámetros sísmicos (como en el caso de una ley de atenuación) a una imagen que deberá ser *distorsionada* de acuerdo con un parámetro (T_S) que ubica y distingue al depósito de suelo.

Piense que los MR estudiados se comportan como puntales del espacio construido y entre estos soportes se encuentran condiciones sísmicas y de suelo no monitoreadas pero posibles. Como la información dentro de los mapas es compleja e incluso en algunos aspectos escapa de nuestra percepción del fenómeno, se adhieren *explícitamente* los factores que nuestra experiencia dicta como conductores de los efectos sísmicos para modificar las entradas, aún cuando se debe entender que en los MR están *implícitos* el efecto de la fuente, el de la trayectoria, el de la fuerza de la sacudida e incluso el de comportamiento del sitio de control.

Los cambios en los Parámetros E son fácilmente comprendidos por los ingenieros de la práctica, pero la modificación de las estructuras en los MR de CU deben ser dirigidos con otro esquema *inteligente*. En este trabajo de tesis, para estimar respuestas a eventos no incluidos en la base de datos, sólo se permite al usuario modificar los valores de [TM, MP_F, D_E] y escalar las intensidades de los MR. Fuera del alcance de esta investigación se encuentra la manipulación del movimiento de control en su expresión 2D.

Es importante señalar que la *experiencia* se genera a partir de efectos observados de donde se *inferen* las causas, los patrones y los esquemas de modelado. No existen condiciones bien conocidas para deducir universos específicos, así que la concepción hipotética de estar creando un espacio *completo de respuestas del valle* (del que no se pueden expresar numéricamente los límites ni las leyes que lo gobiernan) no resulta absurda y sí muy útil para plantear los *números* en las entradas y las salidas.

hacia la

- de Salida

Son los eigenvalores CU (abreviación de la información de ERAs en bi-dimensión) y los Parámetros E los que generan el patrón de cambio en los MR de respuesta (nivel de intensidad) y las relaciones entre estos vectores y T_S los que precisan las estructuras (*estados*) propias de cada depósito.

El *espacio de fase* contiene (o eventualmente puede contener) todas las respuestas a la acción sísmica que amenaza al valle. Para *navegar* en este *espacio* se utiliza al sistema conexionista. La entrada, como ya se explicó, es alimentación directa (en pre-proceso se calculan los eigenvectores y el usuario decide sobre los Parámetros E y S que más le convengan). La salida puede ser un eigenvector sin transfigurar (si la entrada es un MR y una combinación paramétrica *conocida*) o transfigurado (si los componentes

vectoriales son modificados por la RN para que respondan a una combinación MR-CU-Parámetros S/E distinta a las contenidas en el archivo de entrenamiento) y requiere de un post-proceso para trasladarlo a una expresión útil en ingeniería práctica. El *cerebro* (RN) es usado entonces como un *conductor* y *traductor* de información y el fenómeno y sus leyes quedan implícitos en el espacio de fase.

En este punto es notable la diferencia entre el sistema propuesto y los esquemas de reconocimiento de caras que utilizan la técnica de EFs. En el caso de las herramientas desarrolladas para ubicar personas la tarea se concentra en la *clasificación*: rostro conocido/no conocido. Cuando se trata de una cara que no está incluida en la base de datos (no conocido) simplemente se agrega como un nuevo individuo y se amplía el espacio de fase.

En el sistema conexionista cuando un MR-CU y combinación paramétrica son conocidos, entonces la respuesta pertenece a una de las codificadas en el espacio de fase. En el caso de predicción de respuestas, el *cerebro* modifica los eigenvectores bajo las relaciones que generó de acuerdo con la *experiencia* sísmica, los eigenvectores transfigurados se proyectan en el espacio de fase y se genera el MR del punto encontrado. El sistema puede ser re-alimentado periódicamente conforme sucedan más sismos, agregar nuevos ERAs incrementa la calidad del *espacio de respuestas* sin necesidad de modificar funciones, ajustar parámetros ni replantear teorías.

Los fundamentos básicos del modelo en su etapa de construcción y operación son: i) las hipótesis no sustentadas en la física del problema son excluidas y ii) las herramientas de otros campos de la ciencia (funciones y parámetros) sin empatía con las observaciones *naturales*, no son invocadas.

Salida (resultados)

ESPACIO DE FASE. Los ERAs de salida provienen del *espacio de respuestas* (composición del espacio de fase y la RN). El *espacio* (esquemáticamente mostrado en la Fig. 5.105) compuesto de respuestas en superficie caracterizadas espacialmente (referidas a su situación geográfica X-Y y materiales específicos en Z), un administrador de información (espacio de fase) y un cerebro de cálculo (RN), representa la solución global a la tarea planteada en este segundo inciso de análisis.

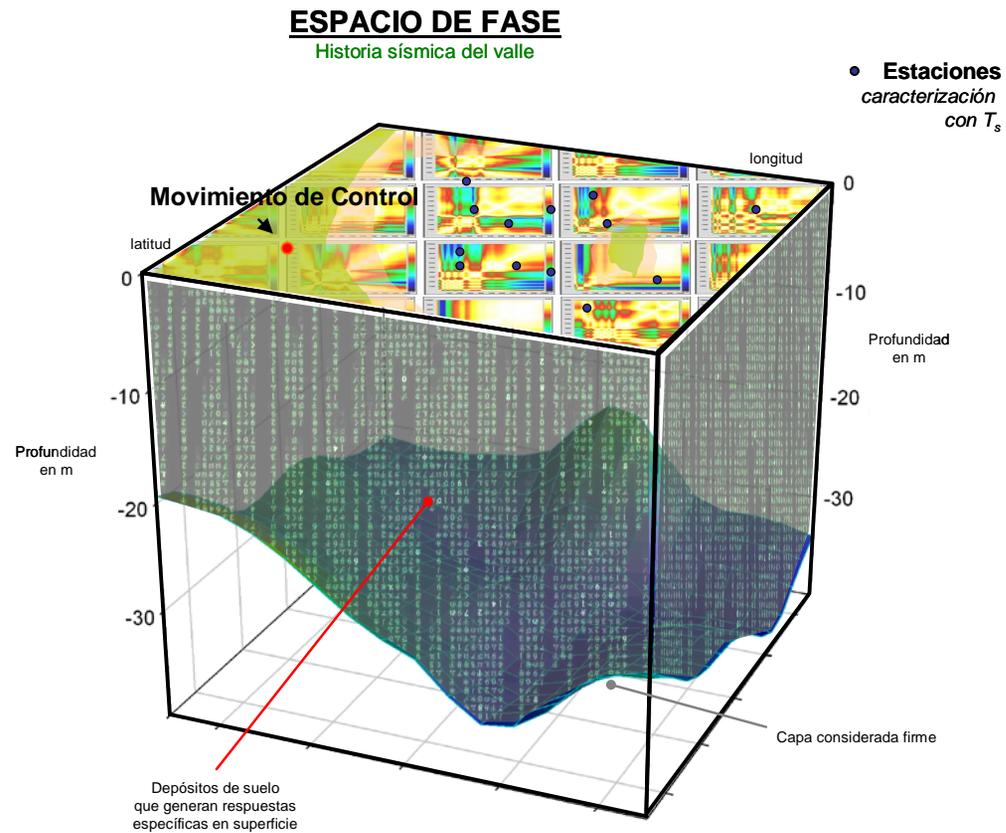


Figura 5.105

Espacio de respuestas: espacio de fase + RN (esquemización)

Los resultados que se presentan a continuación ejemplifican la competencia del modelo y fueron desarrollados sobre los sitios usados en la descripción de la metodología de análisis para darle sustento a las hipótesis expresadas sobre el **Sistema** y el **Proceso**.

- Sitio: **Secretaria de Comunicaciones y Transportes SCT**

T_s : 2.0 s

En la Fig. 5.106 se comparan las estimaciones neuronales y los ERAs calculados de las señales medidas en el sitio durante sismos *débiles*. Como se observa, las evaluaciones en prueba y entrenamiento son satisfactorias.

La RN *entendió* las OEs en intensidad y periodos (en el proceso de *aprendizaje* cuando nuestras respuestas son correctas se dice que hemos *entendido*).

La Fig. 5.107 contiene las respuestas que pertenecen a la categoría sismos *moderados*. Mientras que los ERAs de entrenamiento mantienen diferencias mínimas con los ERAs de señales *medidas*, el evento de prueba ya no es tan cercano al objetivo como en el caso de los sismos *débiles*.

No existen discrepancias importantes entre lo "real" y lo calculado, pero se debe señalar que debido a los invariantes MR de SCT (estructura que se repite en todos los eventos), el sistema aprendió una geometría básica y consideró que los cambios (más delgadas y en mayor número las bandas *frías*) no son la constante en el comportamiento estudiado.

Los sismos *severos* (Fig. 5.108) incluso son los casos donde se reporta el mejor comportamiento en modo de entrenamiento y prueba. Es remarcable la capacidad del modelo para distinguir clases ya que SCT es el único sitio con este comportamiento de entre los 33 sitios de la base de datos.

Todos estos atributos permiten señalar a SCT como uno de los sitios donde los modelos de análisis bien estructurados, deben llegar a respuestas muy cercanas a lo que se experimenta durante las sacudidas si se consigue una buena ley de amplificación. Sin que esto signifique que este depósito se comporta linealmente, el hecho es que el patrón geométrico (respuestas en términos de *estados*) es el mismo en sismos de cualquier intensidad y sismogénesis, incluso en el evento anómalo del 85/09/19 (año, mes día).

El sismo de Tehuacán, Puebla de 1999 (99/06/15) (Fig. 5.108), con elementos sismogénicos únicos en la historia sísmica de entrenamiento, se presenta como una buena prueba del comportamiento descrito.

La excelente predicción que el modelo ha hecho sobre un sismo de entrada con características tan distintas (en geometría) nos lleva a pensar que la RN reconoce la intensidad de entrada y genera un resultado más o menos intenso pero con modificaciones en cuanto a estructura. Los cambios topológicos se dan en la intensidad de las respuestas en el estado T_s y en el segundo modo de vibrar $T_s = 0.6 s$.

El ERA presentado en la Fig. 5.109 es la evaluación hecha para el sismo de Oaxaca del 30 de septiembre de 1999 (990930). La *doble joroba* que presenta el ERA medido no es reproducida totalmente por el modelo neuronal ya que no hay un comportamiento de ese tipo en la historia de entrenamiento de SCT.

Como el modelo está cerrado, se debe decidir sobre su inclusión como nuevo miembro del *espacio de respuestas* o calificar como adecuada la predicción de la RN por considerar que estas dos $OE_{máximas}$ no representan el comportamiento *natural* del sitio sino una desviación por las incertidumbres adheridas al proceso.

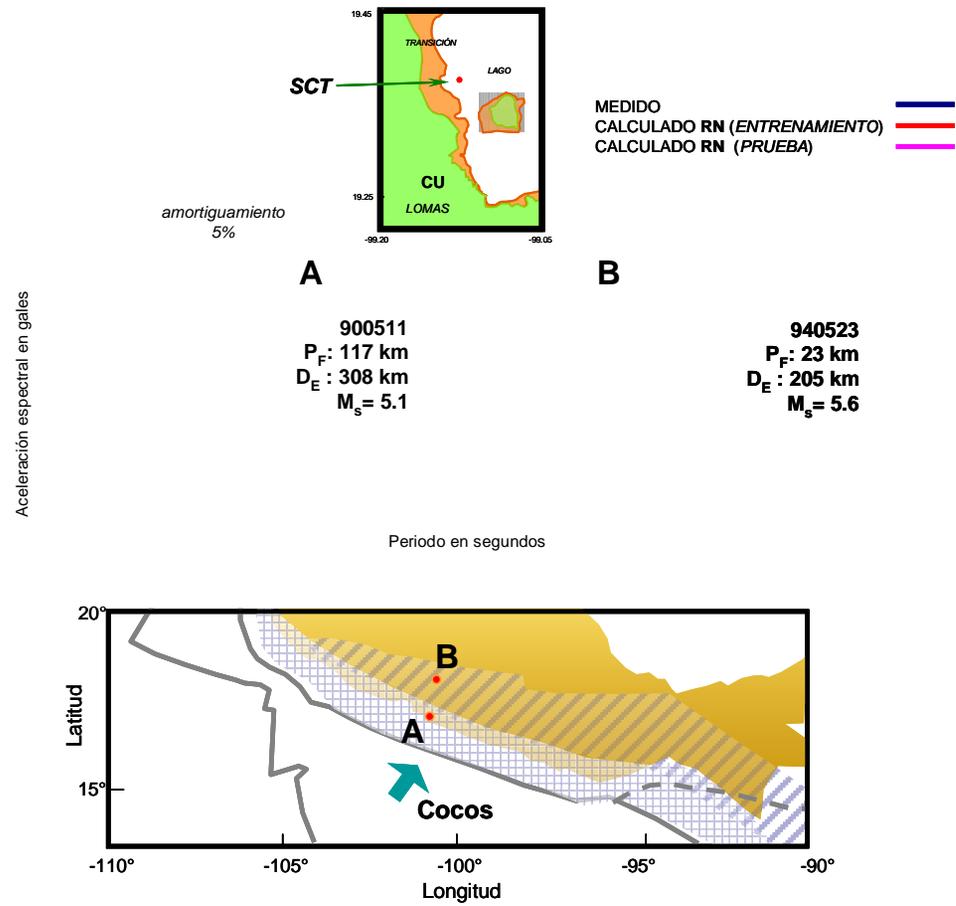


Figura 5.106 Respuestas en entrenamiento y prueba del modelo neuronal para SCT, sismos débiles

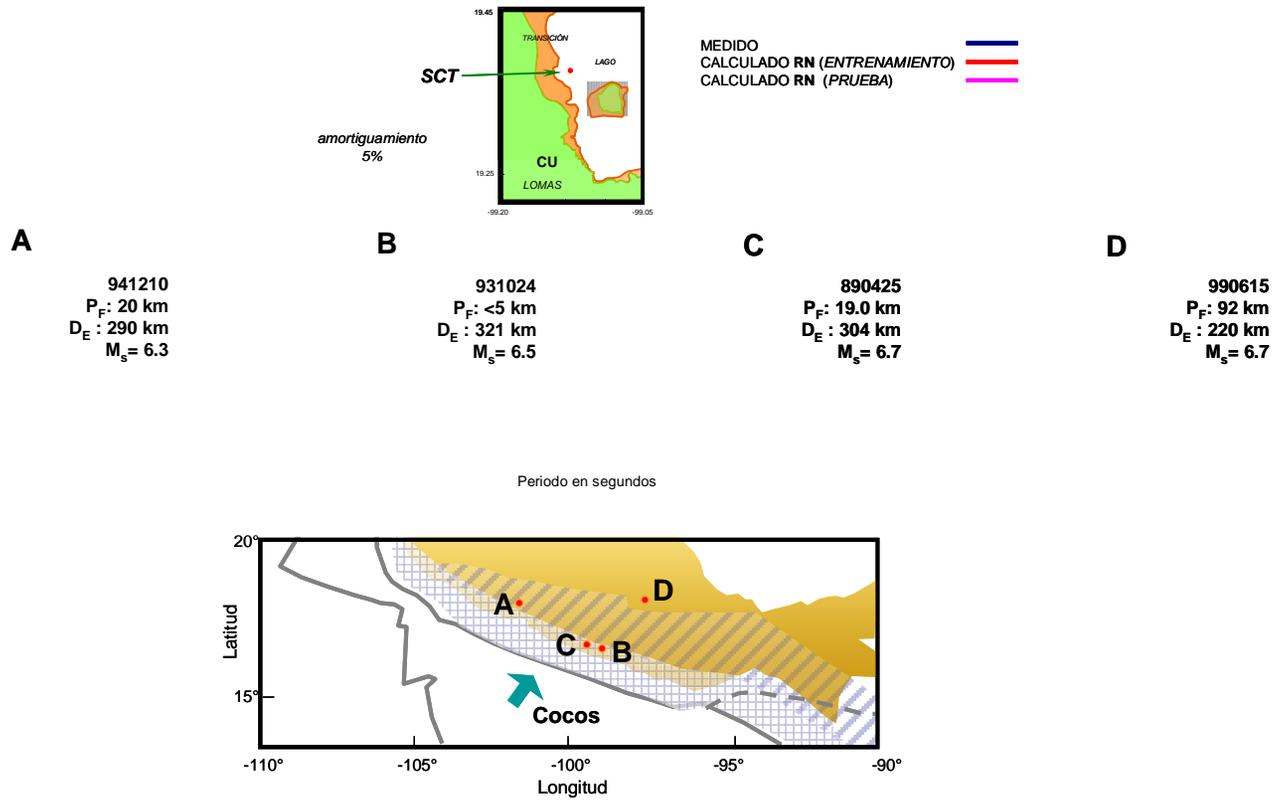


Figura 5.107 Respuestas en entrenamiento y prueba del modelo neuronal para SCT, sismos *moderados*

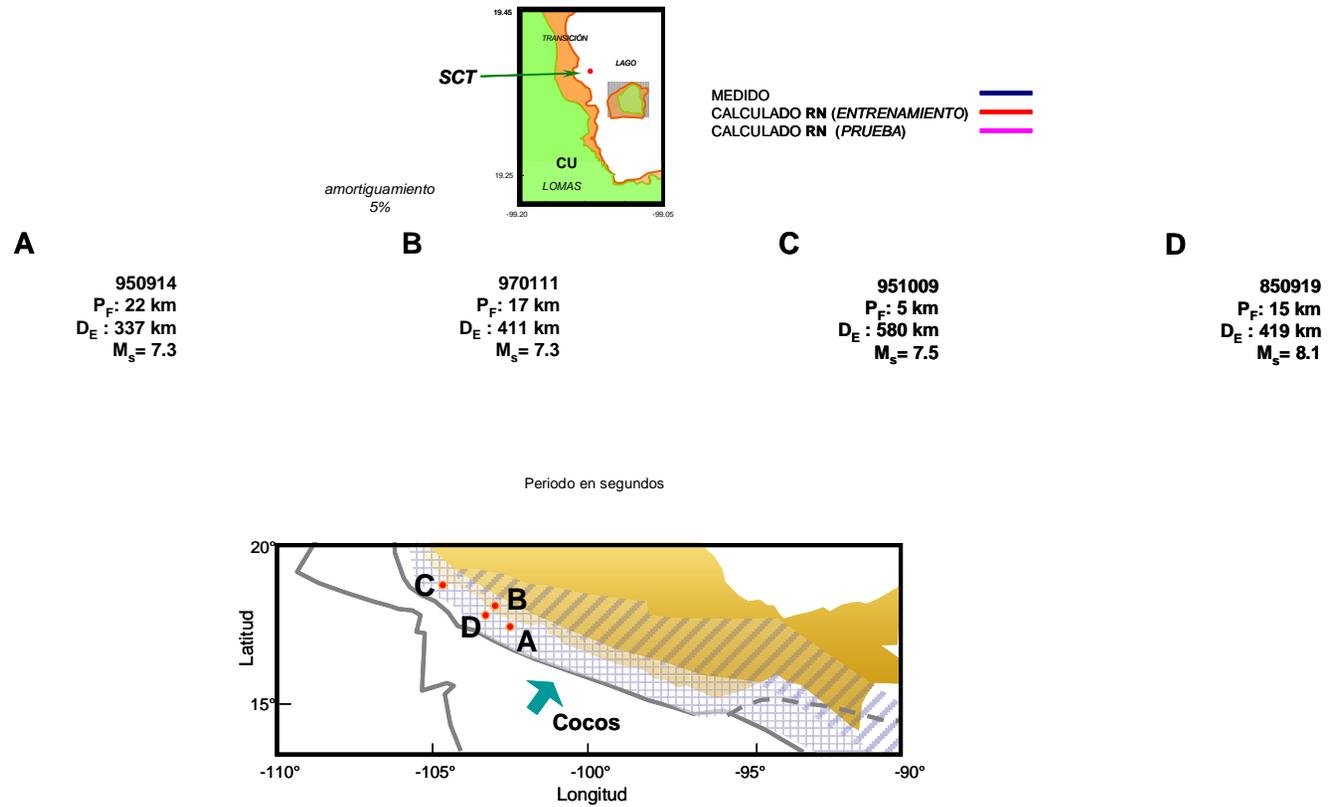


Figura 5.108 Respuestas en entrenamiento y prueba del modelo neuronal para SCT, sismos *severos*

Presentar los MR de las respuestas estimadas resulta un despliegue redundante. Sólo para mostrar los subproductos del procedimiento, en la Fig. 5.110 se incluye el MR obtenido al alimentar al modelo con el movimiento de control CU-97/01/11 y los parámetros S ($T_s = 2.0$ s) y E ($TM = 0, P_F = 17$ km, $D_E = 411$ km, $M = 7.3$). Se aprecia en la figura el inmejorable reconocimiento del modelo de la estructura básica del sitio SCT.

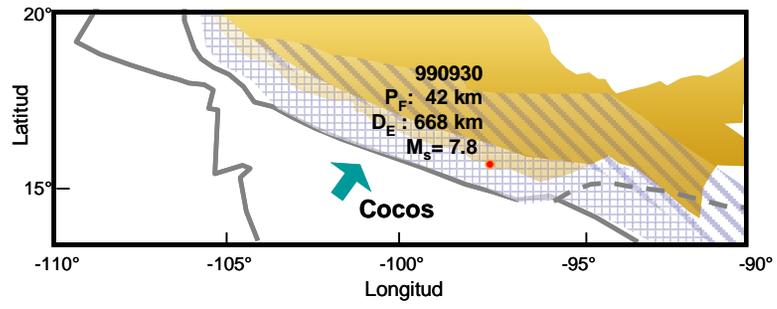
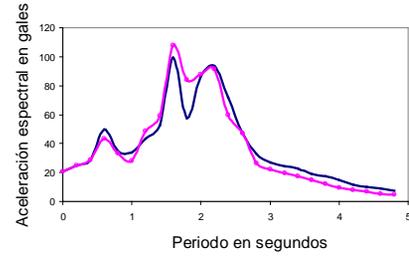
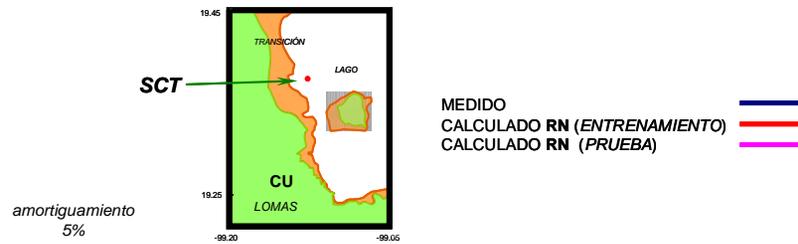


Figura 5.109 Predicción neuronal para SCT de un sismo *severos*

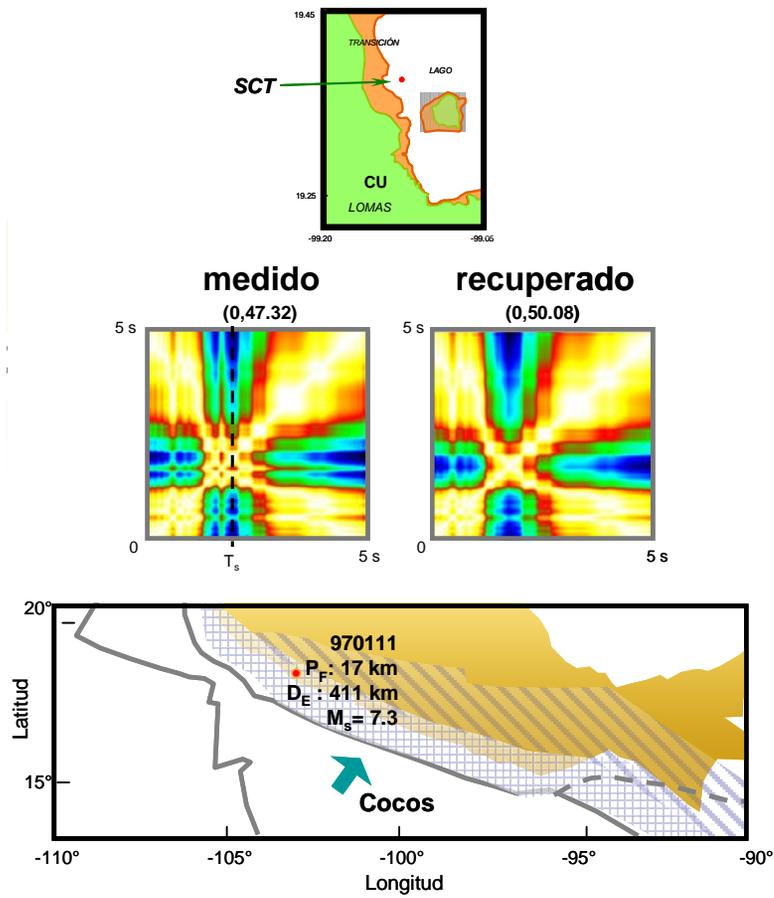


Figura 5.110 MR obtenido del eigenvector calculado por la RN para un sismo *severos*

- Sitio: Garibaldi

T_5 : 2.24 s

Las diferencias entre los ERAs de sismos *débiles* estimados por la RN y los ERAs medidos son más grandes de las alcanzadas en las respuestas en SCT. Sin embargo, como se aprecia en la Fig. 5.111, las estructuras fueron *entendidas* y las $OE_{máximas}$ ajustadas eficientemente en intensidad y periodo (Fig. 5.112). Las predicciones neuronales en entrenamiento y prueba para sacudidas más severas son mejores. El comportamiento general ratifica la hipótesis de que existe un grupo de estados que se activan en sacudidas *débiles* y otro conjunto de osciladores que lo hacen bajo la acción de eventos *fuertes* (Figs. 5.113 y 5.114). Particularmente para el sitio Garibaldi existe una marcada diferencia entre los patrones de respuesta a eventos *débiles* y los de *severos*.

Esta particularidad le da sentido a las recomendaciones *prácticas* de usar modelos específicos sólo para sismos *fuertes* (so pretexto de que son los que importan finalmente en diseño) y eliminar de las bases numéricas los sismos que no se ajustan a las tendencias pre-establecidas, es decir, los *débiles*.

La RN significa una mejora al modelado y sobre todo al conocimiento: la RN *entendió* que existe una relación y es capaz de manejar globalmente el fenómeno, sin calificar el comportamiento del depósito (lineal o no lineal), sin ajustar y discriminar patrones que no se ajusten a teorías o funcionales, y sin obligar a los *camino*s de información que se comporten como lo dicta nuestro nivel de conocimiento.

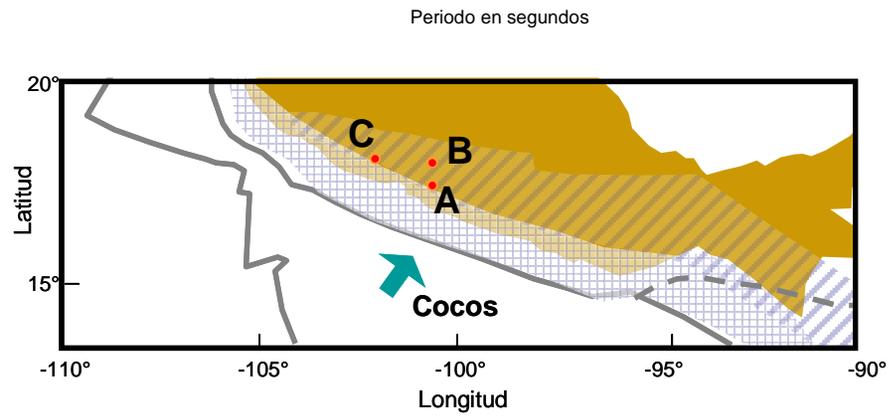
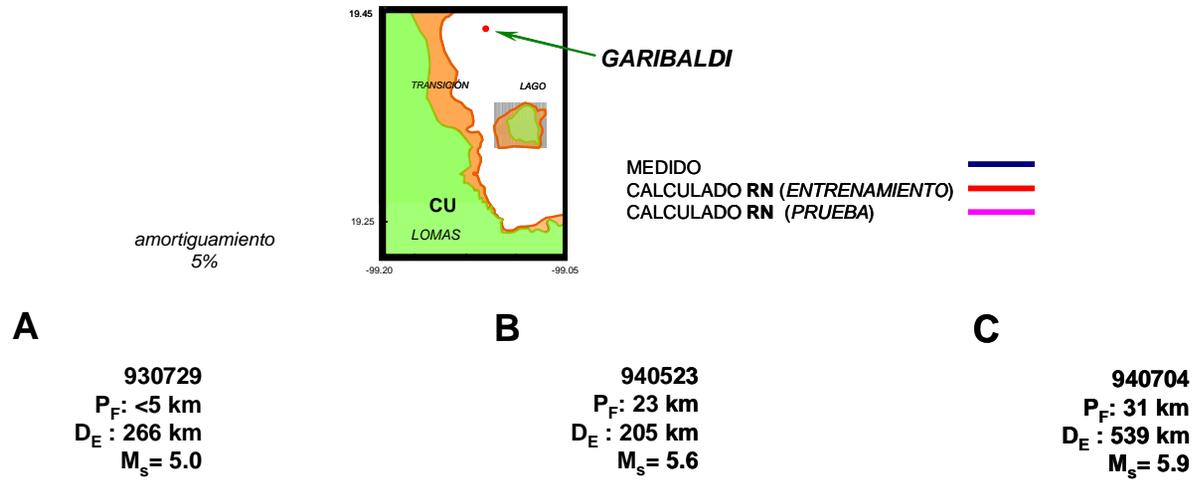


Figura 5.III Predicción neuronal para Garibaldi, sismos débiles

extremos de los colores/ intensidades
(MIN, MAX) en gales

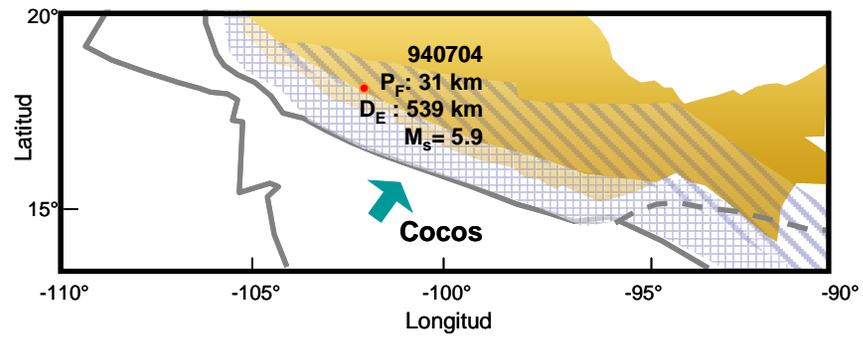
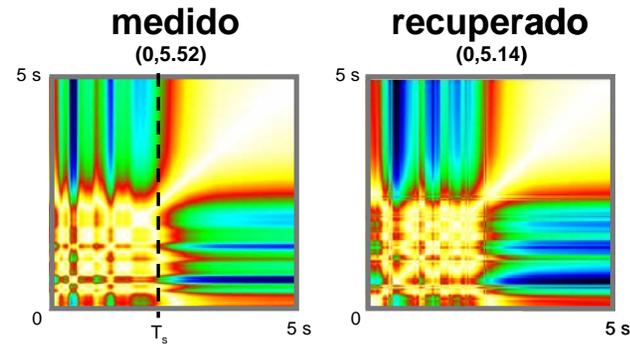
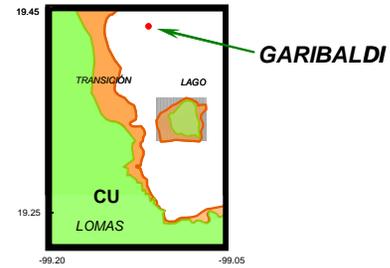


Figura 5.112 MR obtenido del eigenvector calculado por la RN para un sismo *débil*

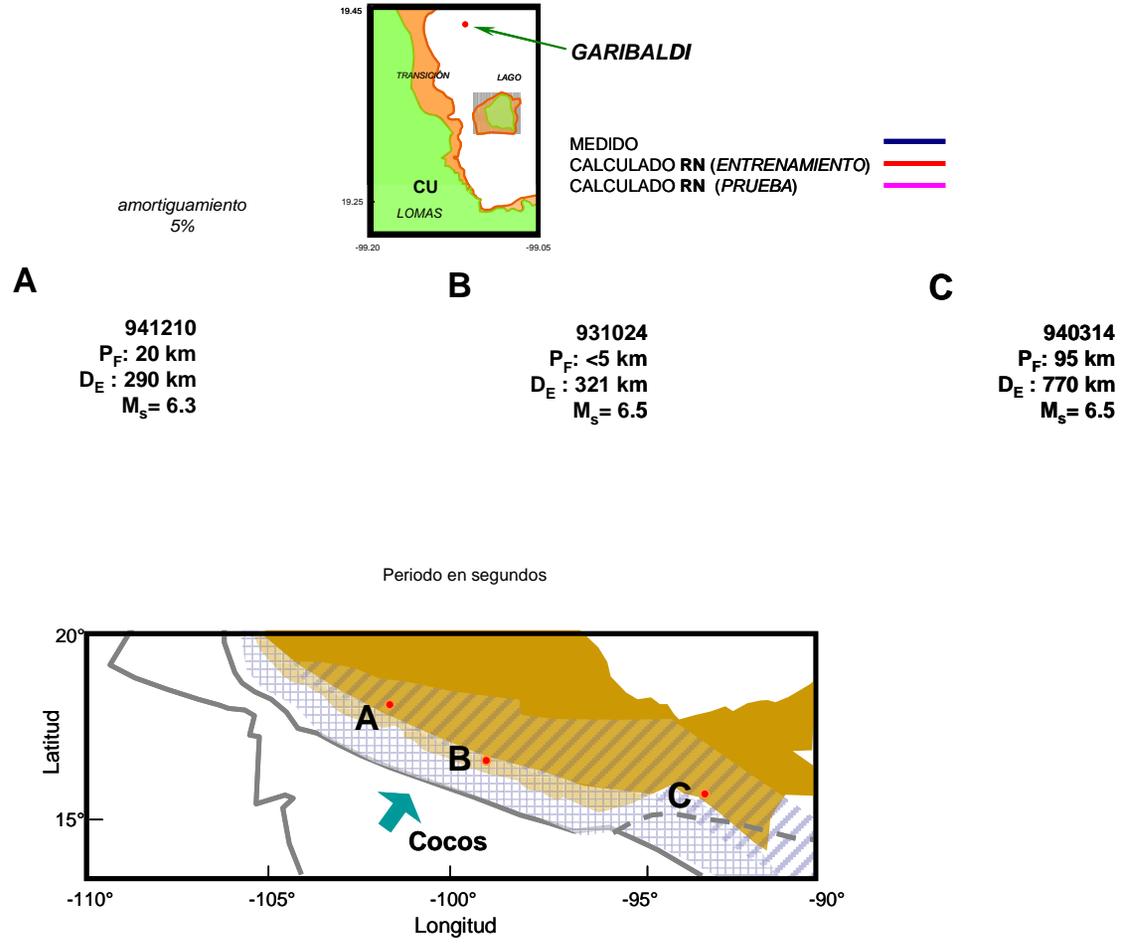


Figura 5.113 Predicción neuronal para Garibaldi, sismos moderados

Aceleración espectral en gales

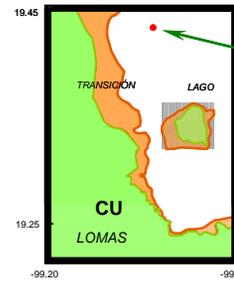
amortiguamiento
5%

A

950914
P_F: 22 km
D_E: 337 km
M_S = 7.3

B

951009
P_F: 5 km
D_E: 580 km
M_S = 7.5



GARIBALDI

MEDIDO
CALCULADO RN (ENTRENAMIENTO)
CALCULADO RN (PRUEBA)



Periodo en segundos

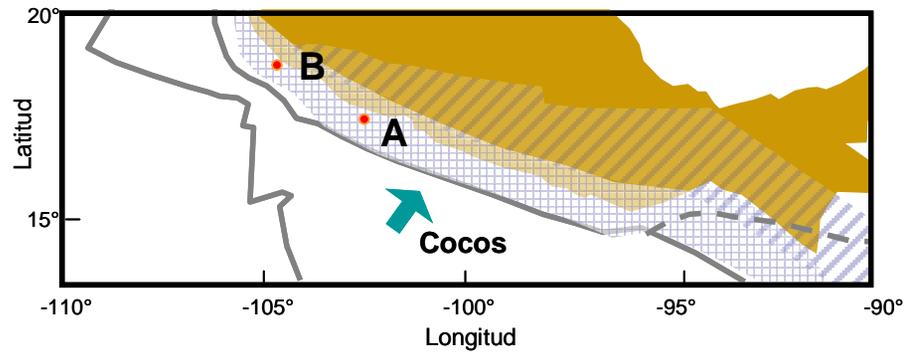


Figura 5.114

Predicción neuronal para Garibaldi, sismos *severos*

- Sitio: **Balderas**

T_S : 2.4 s

El caso del sitio Balderas resulta particularmente interesante por la aparente compleja estructuración de sus MR. En el apartado donde se describen las geometrías y sus relaciones con el conocimiento sísmico se calificó el comportamiento del depósito como *errático*. No se encontraron relaciones “claras” entre intensidades, sismogénesis, incluso se discurre sobre el efecto que el ambiente que rodea a la estación tiene sobre las señales registradas y sus componentes ruidosas. Los óptimos resultados presentados en las Figs. 5.115, 5.116, y 5.117 manifiestan: i) la individualidad del sitio dentro del espacio de fase, y ii) la habilidad de la RN para detectar los patrones geométricos (estados) que nuestra visión no advierte.

A pesar de que las predicciones en modo de trabajo directo no son tan cercanas como en otros sitios, el comportamiento para sismos importantes (*severos*) es bastante aceptable.

Note que las respuestas calculadas con RN se alejan más de las medidas conforme la intensidad del sismo crece lo que puede deberse a la mínima presencia de sacudidas fuertes en los datos que caracterizan a Balderas. Conforme se integre más información al espacio de fase se puede esperar una mejora en la generalización neuronal y definiciones más claras en el cambio de formas espectrales cuando se sujeta al depósito a distintos niveles de cargas dinámicas.

Aceleración espectral en gales

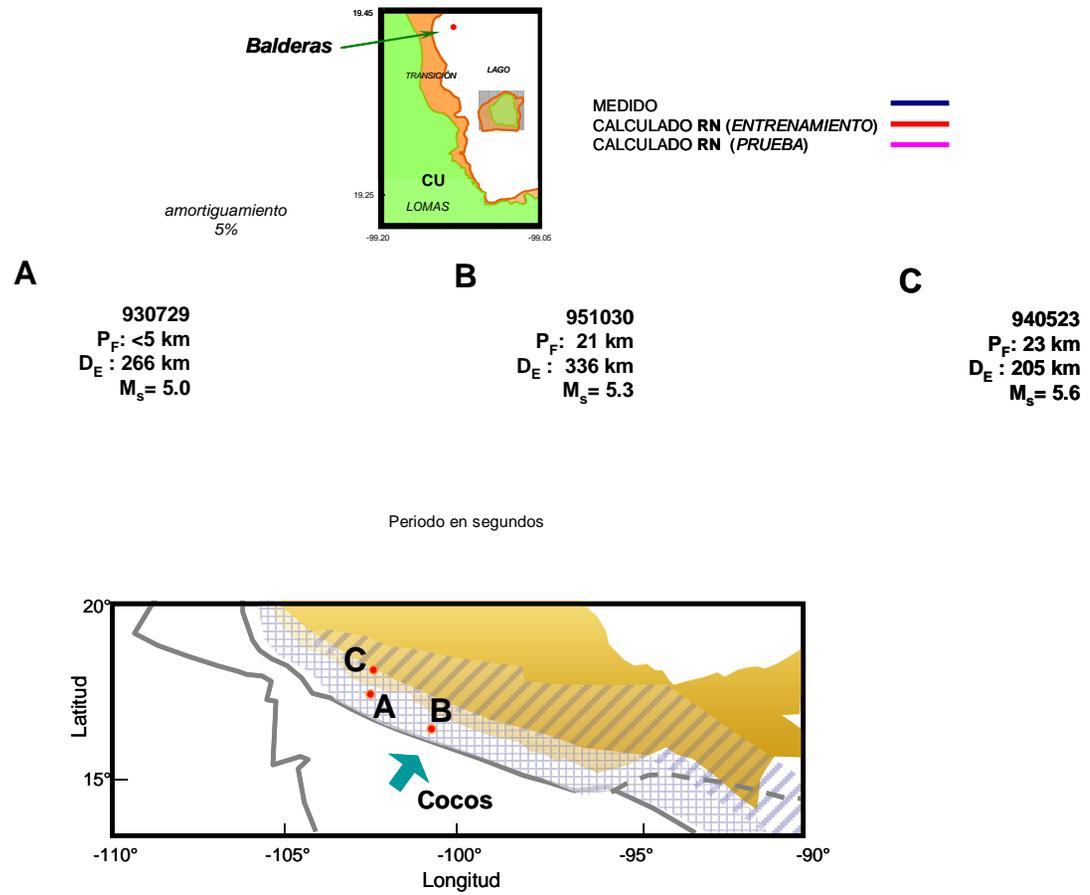


Figura 5.115 Predicción neuronal para Balderas, sismos débiles

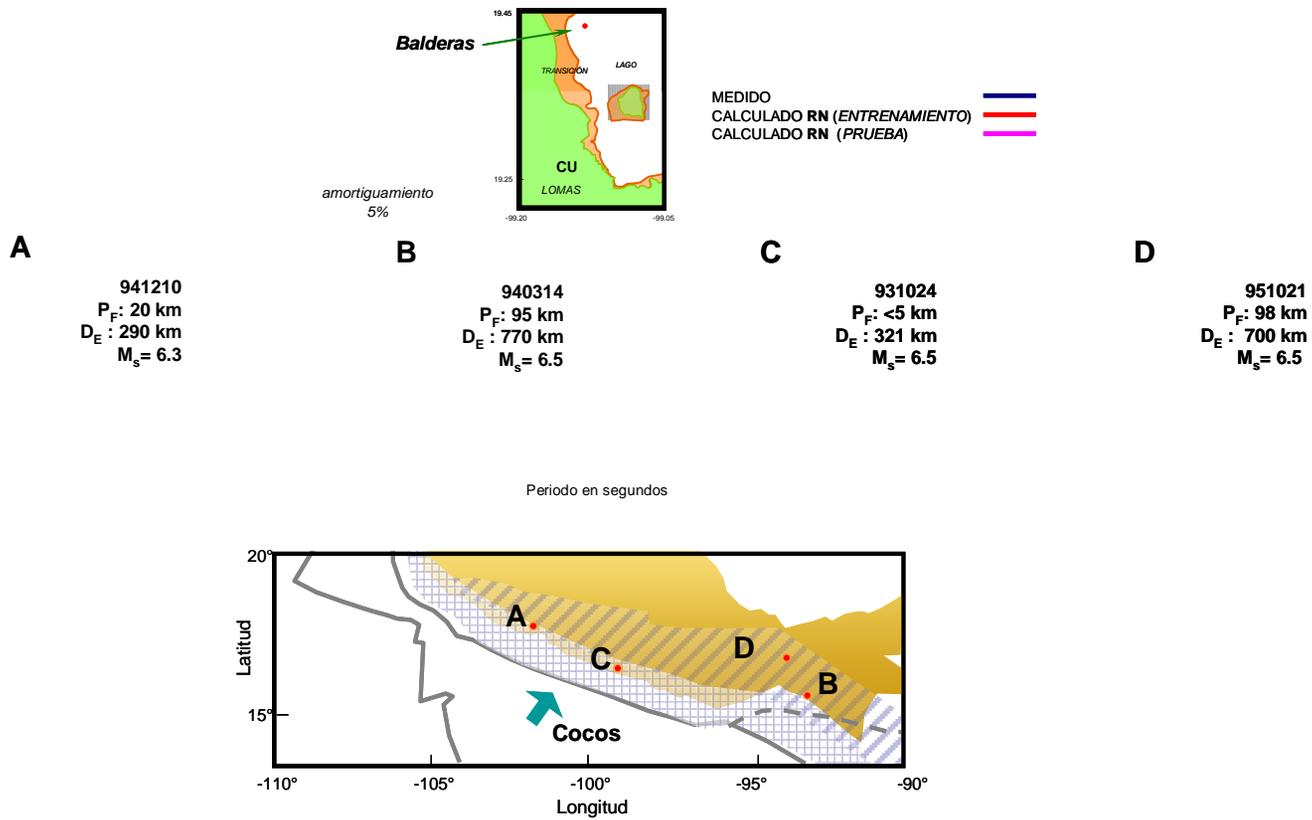


Figura 5.116 Predicción neuronal para Balderas, sismos *moderados*

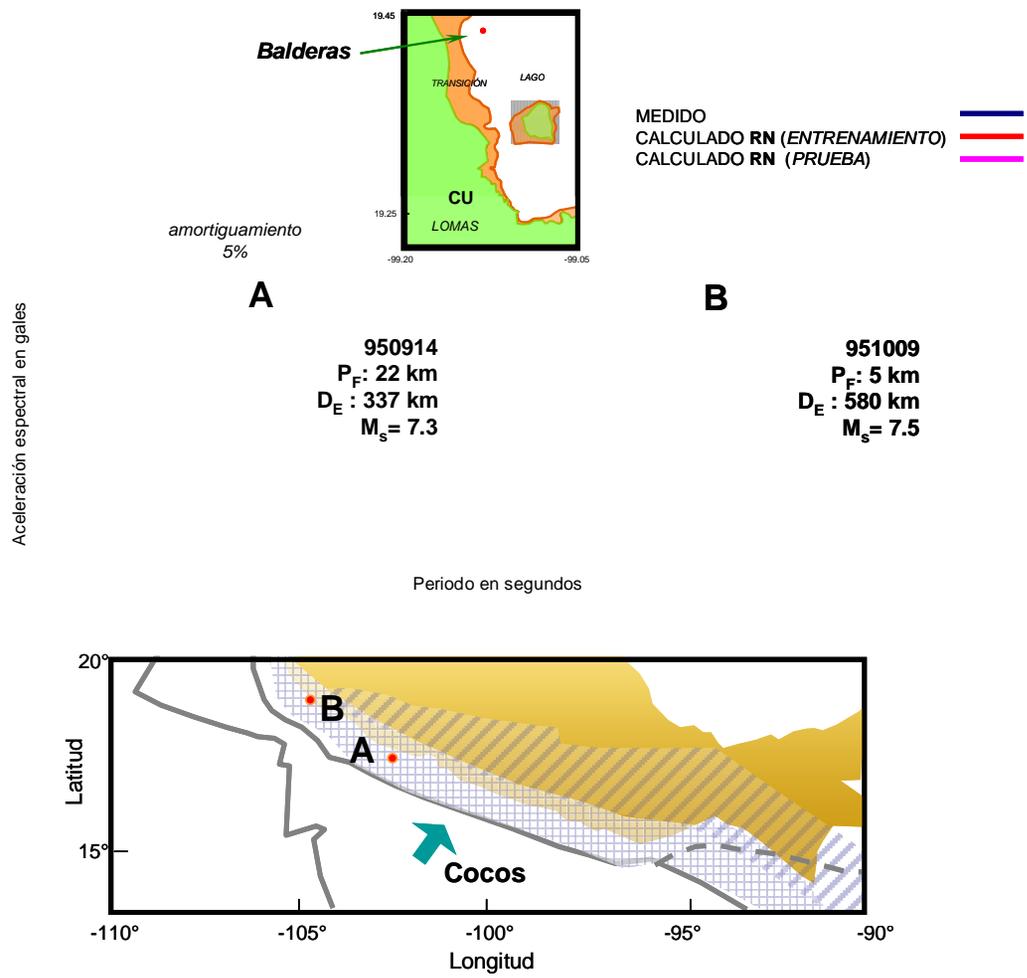


Figura 5.117 Predicción neuronal para Balderas, sismos *severos*

- Sitio: **Candelaria**

T_s : 3.0 s

En la Fig. 5.118 se muestran los resultados obtenidos en etapa de entrenamiento para sismos *débiles*. Las distancias entre los estados “reales” y los calculados son más grandes que en los depósitos anteriores, aunque la RN mantiene su buen comportamiento en la predicción de $OE_{máximas}$ y los periodos donde ocurren.

Como se observa en las Figs. 5.119 y 5.120 las predicciones en prueba y entrenamiento mejoran considerablemente conforme el sismo es más intenso. Las respuestas neuronales son más “suaves” que los ERAs medidos pero el ajuste promedio en el conjunto de las OEs es favorable.

Observe cómo las formas espectrales estimadas provienen de una geometría constante. En este depósito se reconocieron estados activados que cambian muy sutilmente en el rango de sacudidas estudiado. Al igual que el sitio SCT, las amplitudes son las que se modifican más drásticamente pero los estados (T) que se activan se mantienen en los ERAs presentados.

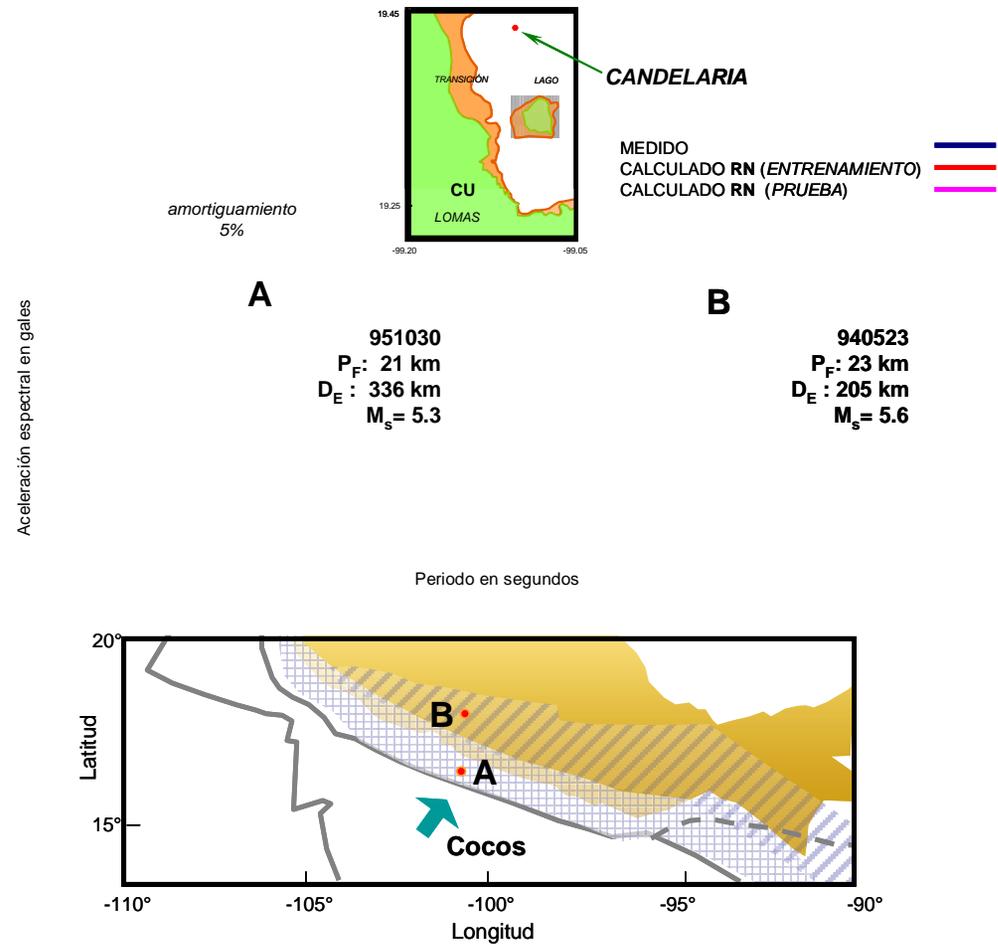


Figura 5.118 Predicción neuronal para Candelaria sismos débiles

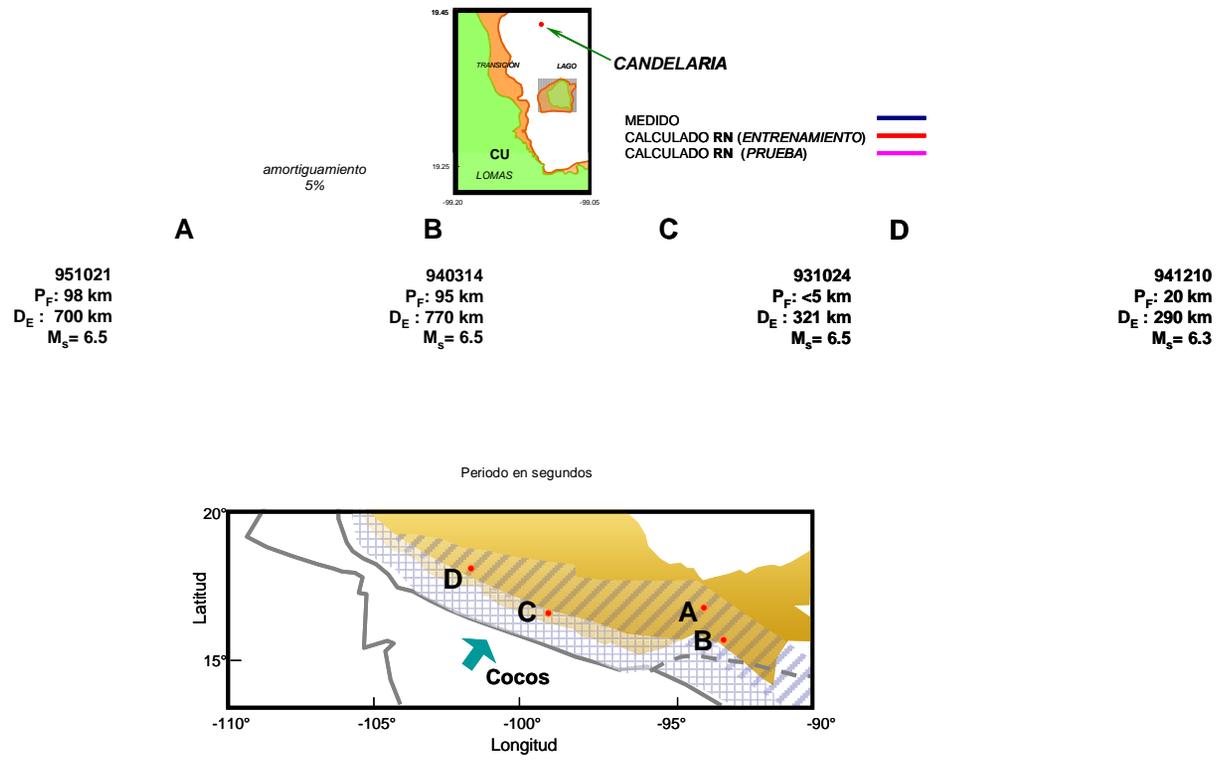


Figura 5.119 Predicción neuronal para Candelaria, sismos moderados

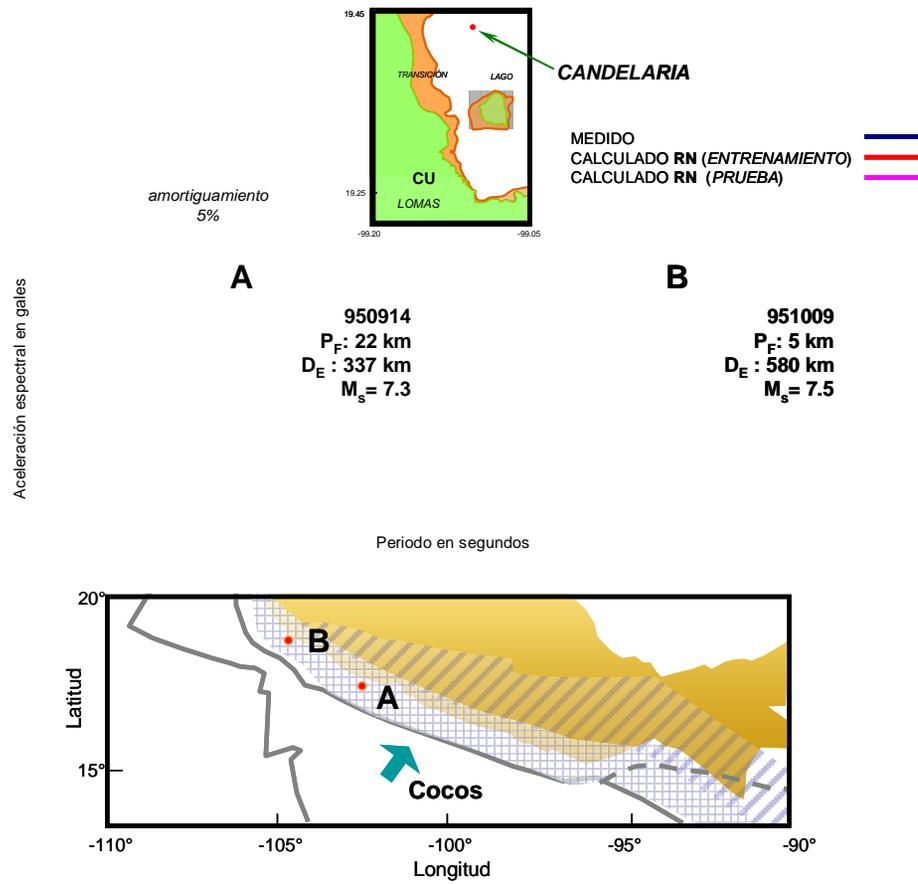


Figura 5.12o Predicción neuronal para Candelaria, sismos *severos*

- Sitio: Central de Abasto Oficinas CDAO

T_3 : 3.5 s

Este depósito ejemplifica la existencia de una frontera de comportamiento entre sismos *débiles* y *severos*. En las Figs. 5.121, 5.122 y 5.123 se muestran ambas tendencias de comportamiento. Si bien la información sobre el sitio es algo escasa, por lo menos se logra ubicar puntos sobre toda la base de la variable M y no es imprudente argumentar sobre la activación y desactivación de estados de acuerdo con la intensidad de entrada.

En la Fig. 5.121 se muestran las excelentes predicciones para las sacudidas menores durante el entrenamiento y la prueba de la RN. En la Fig. 5.122 se presenta el MR recuperado para el sismo de prueba (*débil*). Los detalles geométricos son reproducidos fielmente y no se observa ninguna desviación en la ubicación de las OEs máximas. Contrario a lo que se espera si pocos sismos débiles fueron presentados a la red durante el entrenamiento, las estimaciones neuronales alcanzan el agudo máximo en el segundo modo de vibrar y dibujan correctamente las zonas blancas de nula activación. ¿Por qué si no hay información al respecto, la RN ajusta asombrosamente los ERAs?, la respuesta puede ir de la mano con el argumento de un patrón único de respuesta en todo el valle para sismos menores. Este aspecto se tratará a detalle más adelante.

Cuando la demanda sísmica crece en intensidad, la meseta de máximos típica de este sitio ($3 < T < 4$) es bien reconocida por la RN y las relaciones que guardan estos valores con las ordenadas que se presentan en T_2 (segundo modo de vibrar) prácticamente son las mismas que las obtenidas en ERAs "reales". Es muy interesante el despliegue geométrico del depósito y cómo la RN es capaz de identificar, a través del parámetro de clase T , el cambio en el ancho de las bandas *frías*.

La respuesta de la RN en modo de trabajo directo para el sismo de Oaxaca de 1999 (Fig. 5.124) permite puntualizar el *pensamiento* del modelo propuesto: la entrada es *similar* (cercana en el espacio de fase) a la del sismo 95/09/14 por lo que, para un mismo T (el mismo punto sobre la superficie del valle) la respuesta a esta nueva demanda debe ser muy *parecida* a la anteriormente generada (observe que el estado de $OE_{máxima}$ durante el evento del '99 es el mismo que en el sismo del '95).

Entra la condición XY (T) y el modelo reconoce el sitio, lee la demanda sísmica (eigenvector CU y parámetros E) y la relaciona con la historia del depósito. A través de las formulaciones construidas en entrenamiento la RN modifica el eigenvector histórico de acuerdo con los nuevos requerimientos y ofrece un eigenvector *transfigurado* de salida. En post-proceso este vector se proyecta en el espacio y se obtiene el MR y ERA correspondientes. Siguiendo este procedimiento y para decirlo de manera muy simplista, el resultado nomotético para el ejemplo 99/09/30 es la salida *transfigurada* del sismo del '95 (cambio sutil referido a la intensidad del sismo).

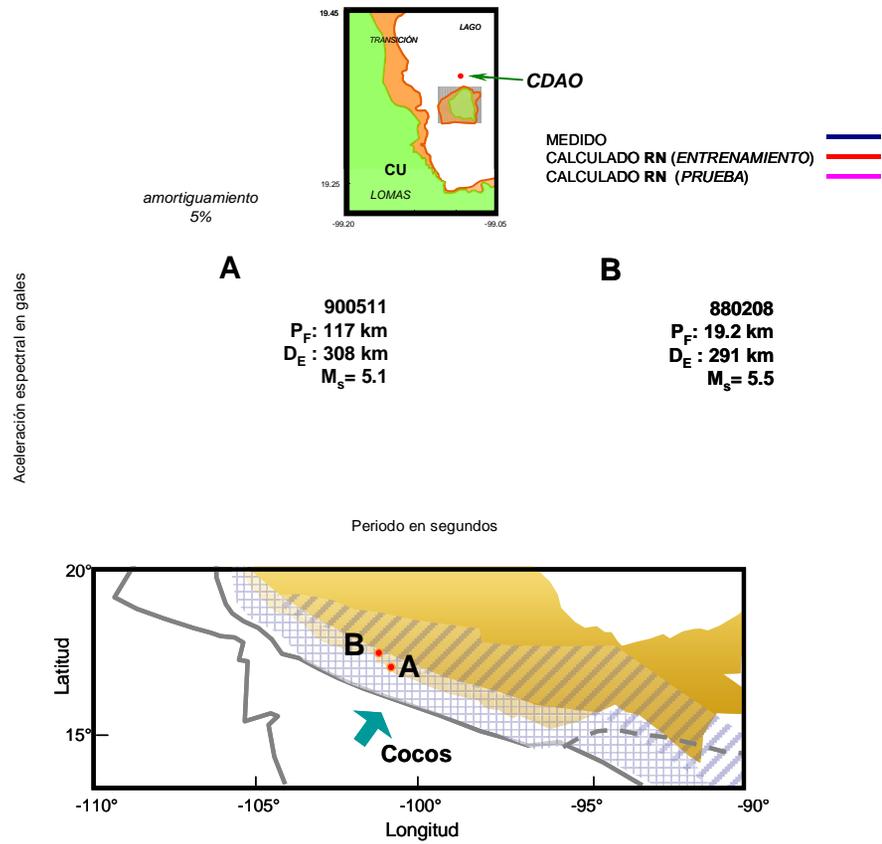


Figura 5.121 Predicción neuronal para Central de Abasto Oficinas, sismos débiles

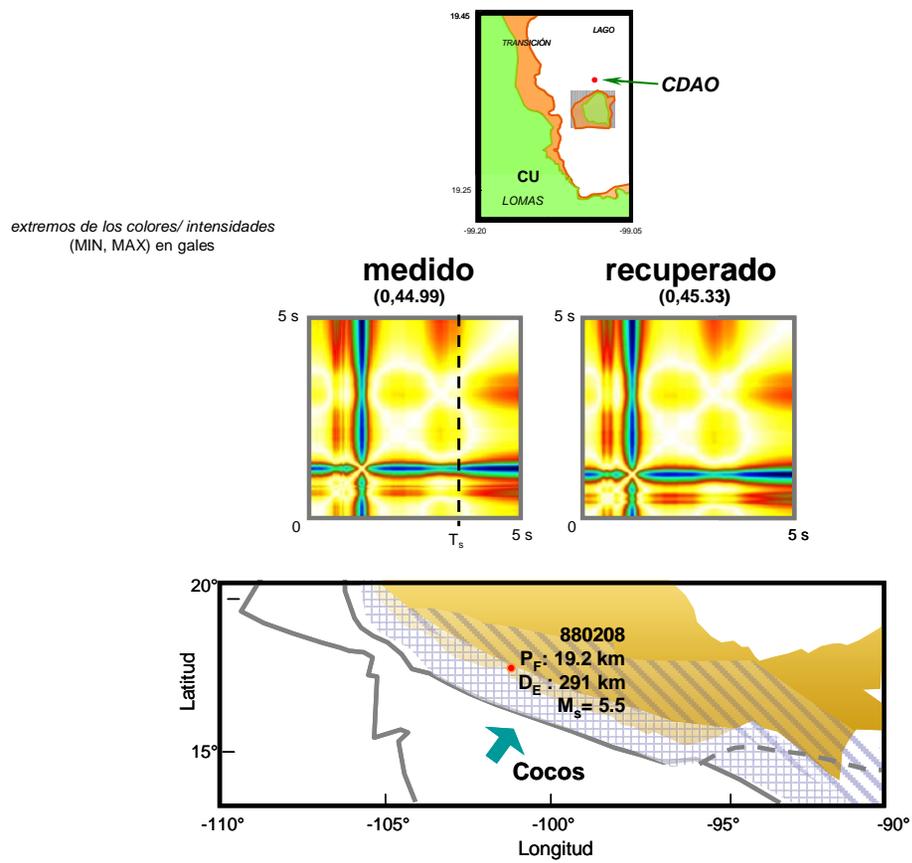


Figura 5.122 MR obtenido del eigenvector calculado por la RN para un sismo *débil*

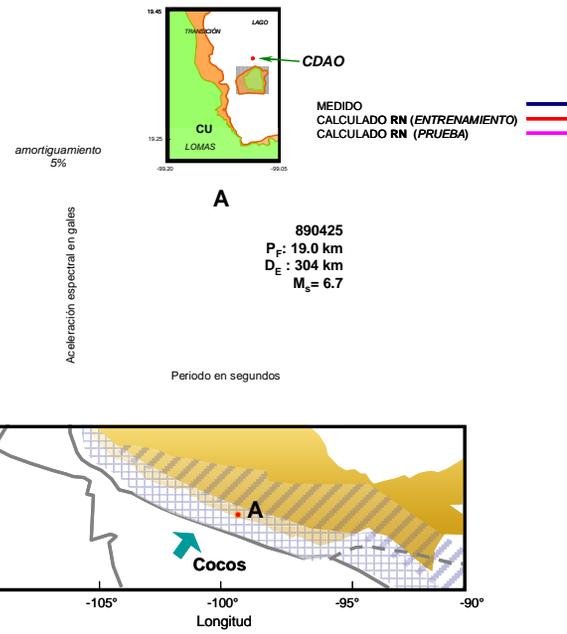


Figura 5.123 Predicción neuronal para Central de Abasto Oficinas, sismos *moderados*

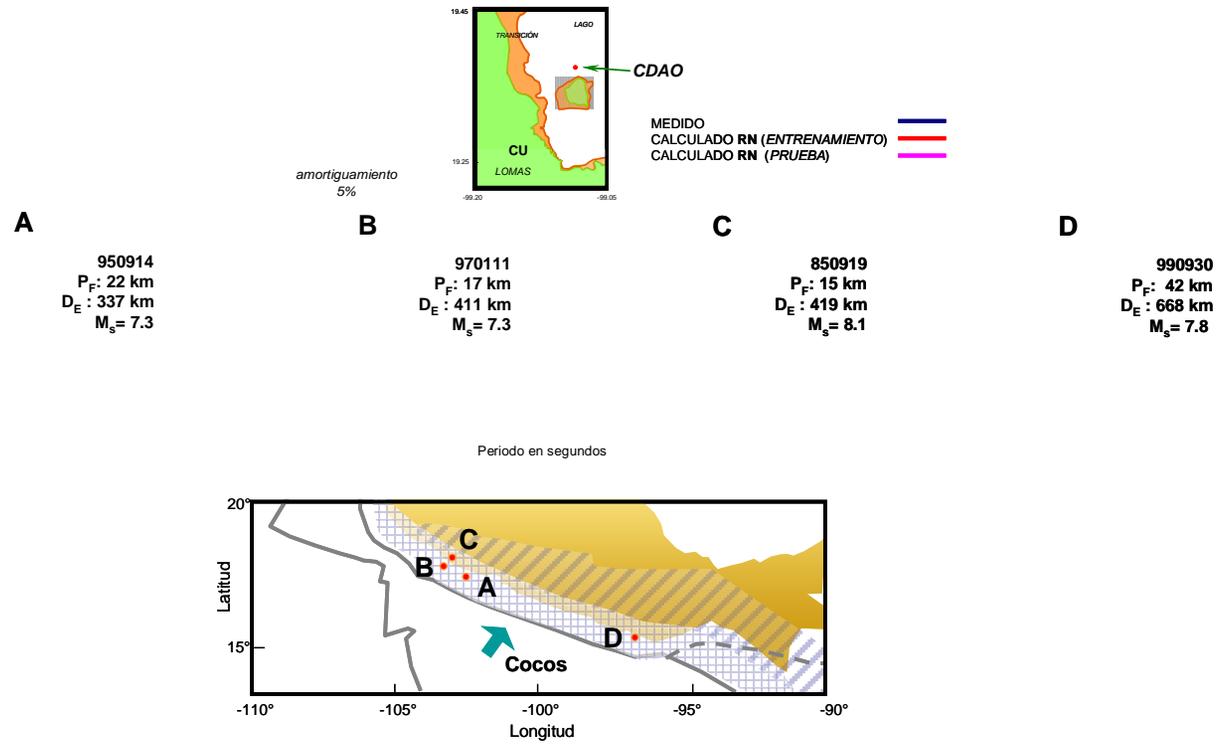


Figura 5.124 Predicción neuronal para Central de Abasto Oficinas, sismos severos

- Sitio: **Hangares**

T_s : 4.05 s

El argumento de que existe un patrón de respuesta común a todos los sitios para intensidades menores, se verifica con los resultados obtenidos para este sitio. Como se observa en la Fig. 5.125 el ajuste y la localización de máximas ordenadas, para sismos *débiles*, son bastante convenientes. La activación más importante vuelve a ser en estados por debajo de 1.0 s o alrededor de 1.6 s y más allá de esta localizada franja de respuestas máximas las OEs son mínimas.

De entre los sitios elegidos para mostrar las capacidades de la RN, este último es el que menor ajuste presenta entre los datos objetivo y los calculados. Si observa la Fig. 5.126 podrá verificar que el modelo sigue la tendencia marcada por el ERA "real" pero no logra alcanzar la eficiencia *estado a estado* logrado en los otros depósitos. A pesar de que los MR originales no parecen tan desestructurados, el modelo neuronal no alcanzó a otorgarle individualidad por lo que no fue capaz de revelar las leyes contenidas en los datos registrados.

Para los sismos más fuertes (Fig. 5.127) las predicciones se alejan más de las mediciones. En el MR construido a partir del eigenvector del caso prueba (Fig. 5.128) las diferencias geométricas son notables y eso se traduce como: i) no existe o la información recopilada no permite detectar la geometría característica del depósito ante sismos fuertes y ii) las oscilaciones entre estados (máximos y mínimos en el ERA) son demasiado pronunciadas y el modelo no reconoce este tipo de cambios.

Observe los detalles de los MR de la Fig. 5.128. El MR objetivo (medido) presenta bandas *frías* al igual que los otros sitios ejemplo, sin embargo es el único que tiene "zonas *frías*" ($1 < T < 3.5$) con cortes *cálidos* muy evidentes (oscilaciones fuertes, verdes y azules atravesados por delgados amarillos y naranjas). El MR calculado simula adecuadamente las zonas azules y verdes, pero no consigue cortar esta tendencia con líneas cálidas.

Bajo esta condición es necesario resolver si los ERAs son: *reales* (que expresan comportamiento *natural*) o *contaminados* (señales de baja calidad exhiben en el ERA aspectos *antinaturales*). Si resulta que el ERA es *real*, el patrón se mantiene como miembro del espacio y se debe re-entrenar a la RN con reproducciones del ejemplo estudiado.

En el caso de que los ERAs presentados estén *contaminados*, las estimaciones en predicción serán calificadas como adecuadas aunque los ERAs de respuesta luzcan más *suaves* que los medidos.

En el caso del sitio Hangares los resultados fueron conceptuados como *contaminados*. No forma parte del objetivo de este trabajo de tesis evaluar las incertidumbres adheridas a las señales sísmicas, pero ligando el significado de un ERA con los términos dinámicos de un MR, un depósito que active un oscilador con una amplitud considerable y a los inmediatos anterior y posterior (diferencia de 0.1 s en T_s) con amplitudes casi despreciables, es difícil de ubicar en el entorno de comportamiento de materiales "reales".

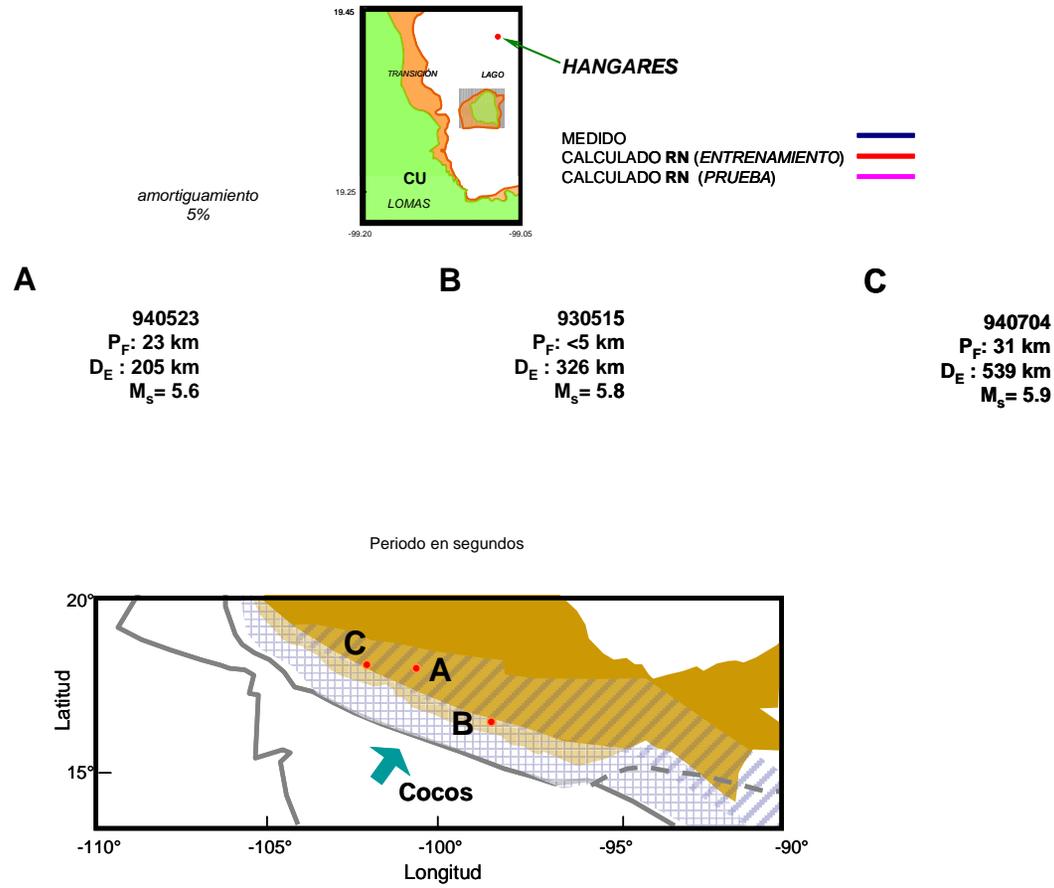


Figura 5.125 Predicción neuronal para Hangares, sismos débiles

Aceleración espectral en gales

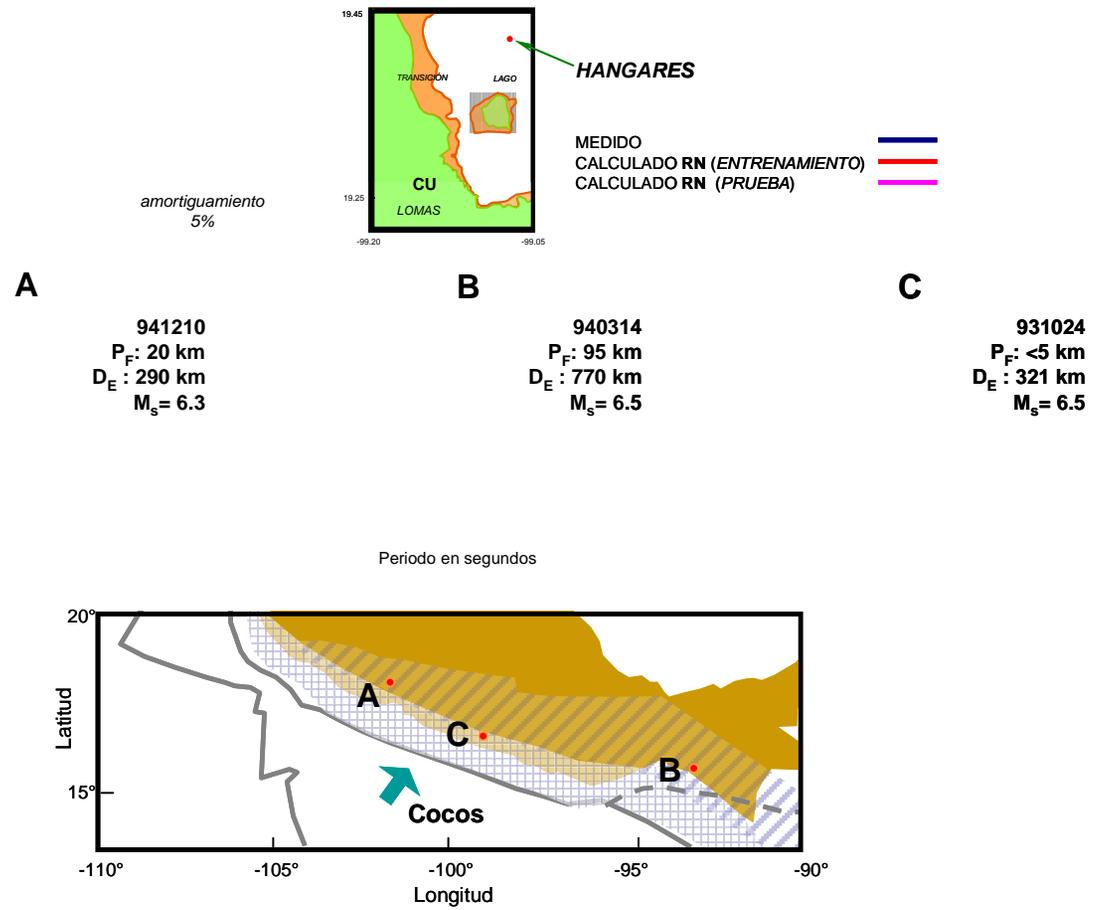


Figura 5.126 Predicción neuronal para Hangares, sismos moderados

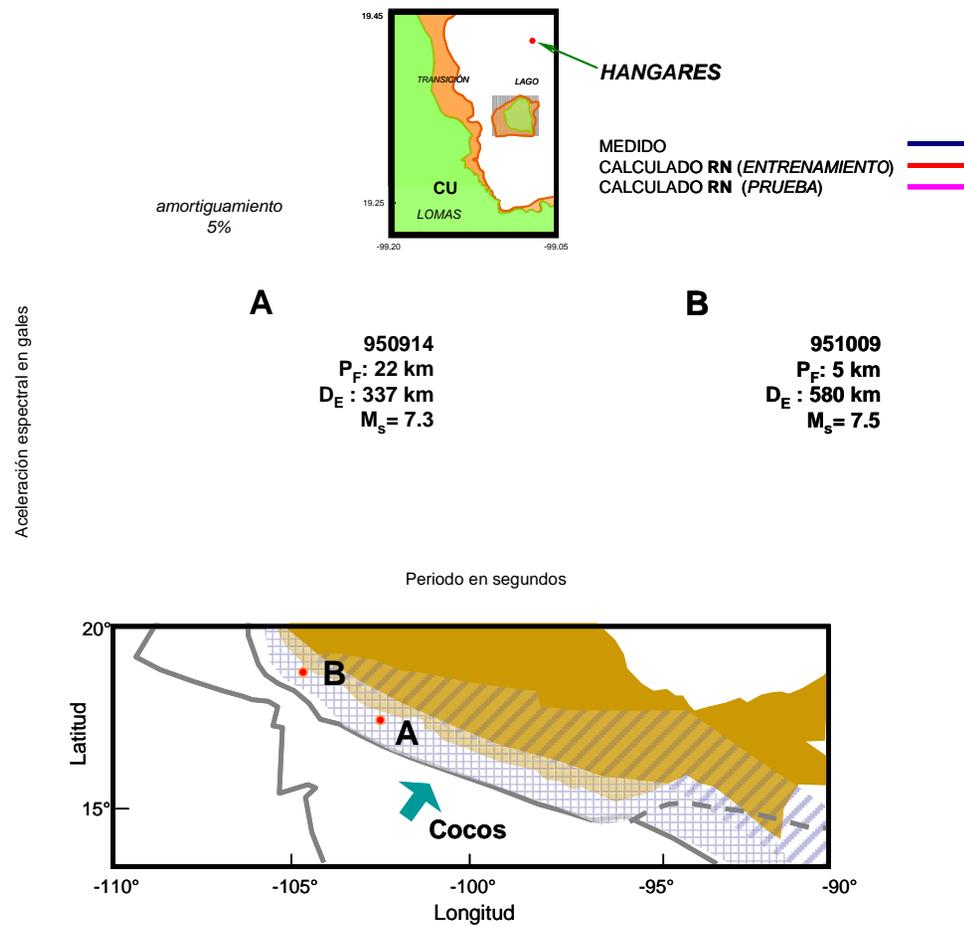


Figura 5.127 Predicción neuronal para Hangares, sismos *severos*

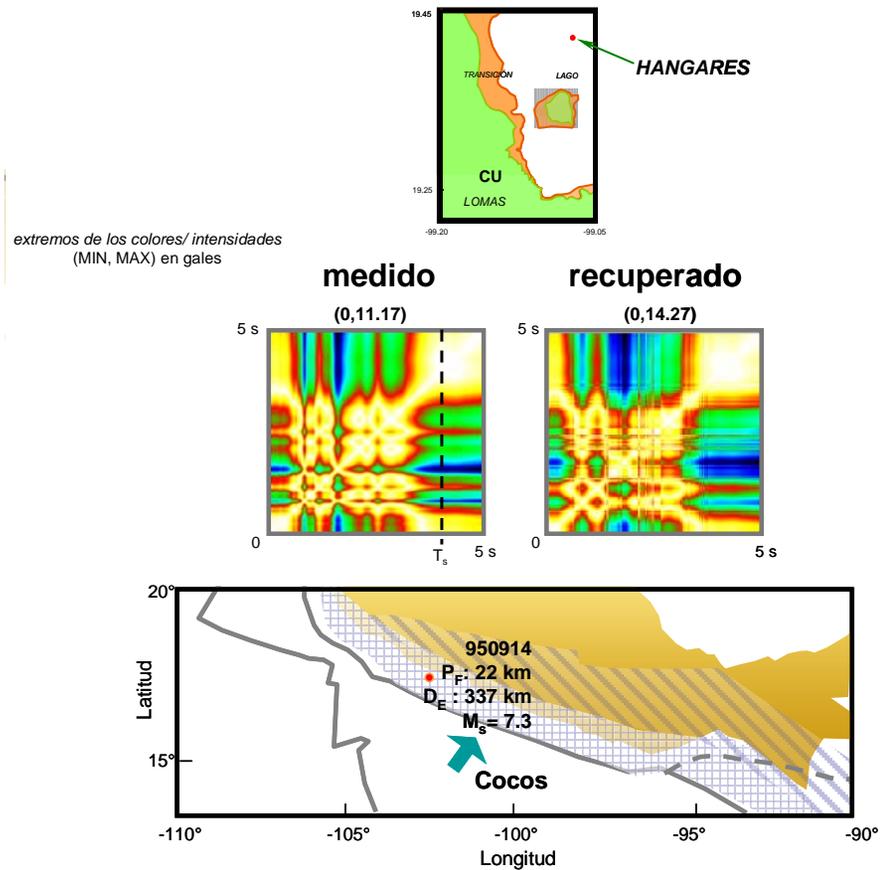


Figura 5.128 MR obtenido del eigenvector calculado por la RN para un sismo *severo*

Si hemos calificado anteriormente a la RN y al espacio de fase como una dupla de herramientas eficaces, estos resultados no deberían ser tomados como una deficiencia del modelo neuronal sino como una de las muchas *grietas* en nuestro entendimiento y representación del fenómeno sísmico.

A pesar de lo asombroso de estos primeros resultados, no se puede asumir que todo en el esquema funcionará bien. A la pregunta ¿éste es el modelo correcto para estimar las respuestas de los depósitos del valle?, la RN contesta con excelentes predicciones, sin embargo, el punto que define el valor del modelado se concentra en el equilibrio entre *ajuste* y *memorización*.

Los resultados indican ventajas prácticas pero advierten de carencias técnicas, ambas posiciones útiles para mejorar el propio modelo y dirigir futuras líneas de investigación.

La zona sur del valle, con un menor número de estaciones acelerográficas, se describe a través de los resultados en operación directa para los sitios Miramontes, Ibero y Culhuacán (Fig. 5.130). Su ubicación y por ende T_g , permite verificar la habilidad de la RN de reproducir las relaciones *naturales* observadas durante las sacudidas.

Si bien los periodos fundamentales en los tres sitios son muy cercanos, se verifica distinta geometría para el sitio más cercano a la zona de Lomas (Figs. 5.131-5.133). La respuesta de los sitios Ibero y Culhuacán, en términos de intensidad y osciladores activados es muy cercana y en intensidades severas las diferencias llegan a ser despreciables. La RN reproduce fielmente la aguda banda *fría* (máximos puntuales y descenso fuerte de las OEs en los otros periodos). El sitio Miramontes responde con menor intensidad, comparado con los sitios más cercanos al centro del Lago, y la RN no presenta problemas en el ajuste de los máximos pero genera formas espectrales con la tendencia de los ejemplos del Lago (bandas *frías* agudas) por lo que en varios eventos llega a equivocar la posición de la $OE_{máxima}$.

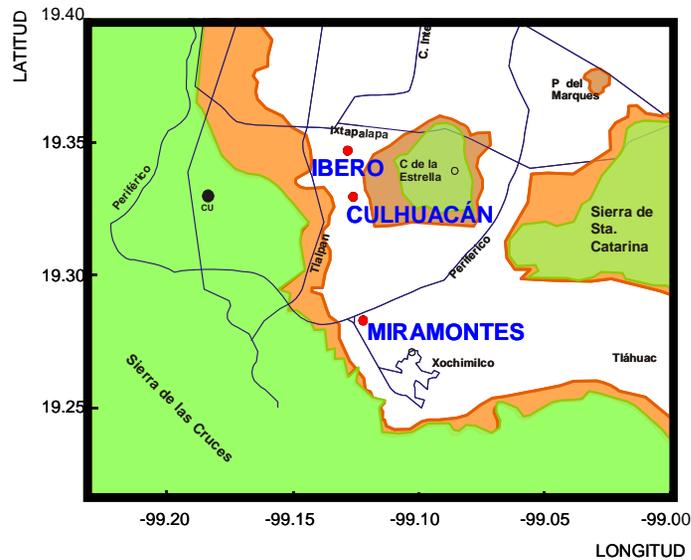


Figura 5.130 Sitios *lejos* del centro, periodos fundamentales alrededor de 1 segundo

Sitio : **Miramontes**
 $T_s : 1.3$ s

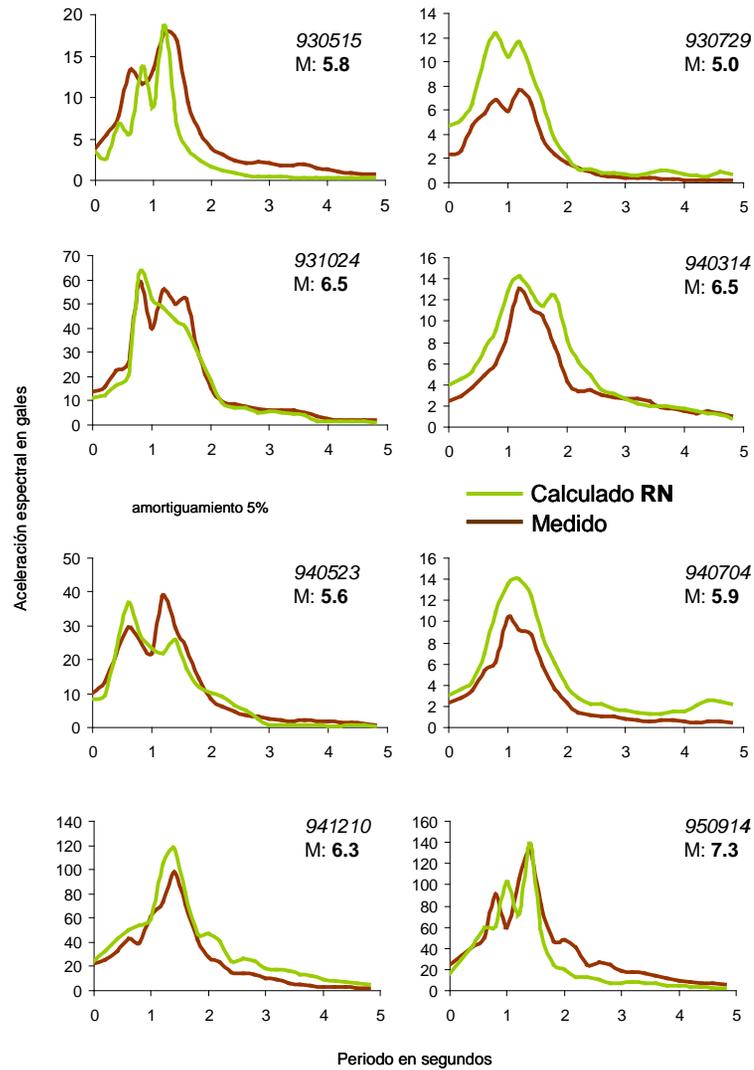


Figura 5.131 Sitio: Miramontes, predicciones en modo directo

Sitio : Ibero
 $T_s : 1.4 \text{ s}$

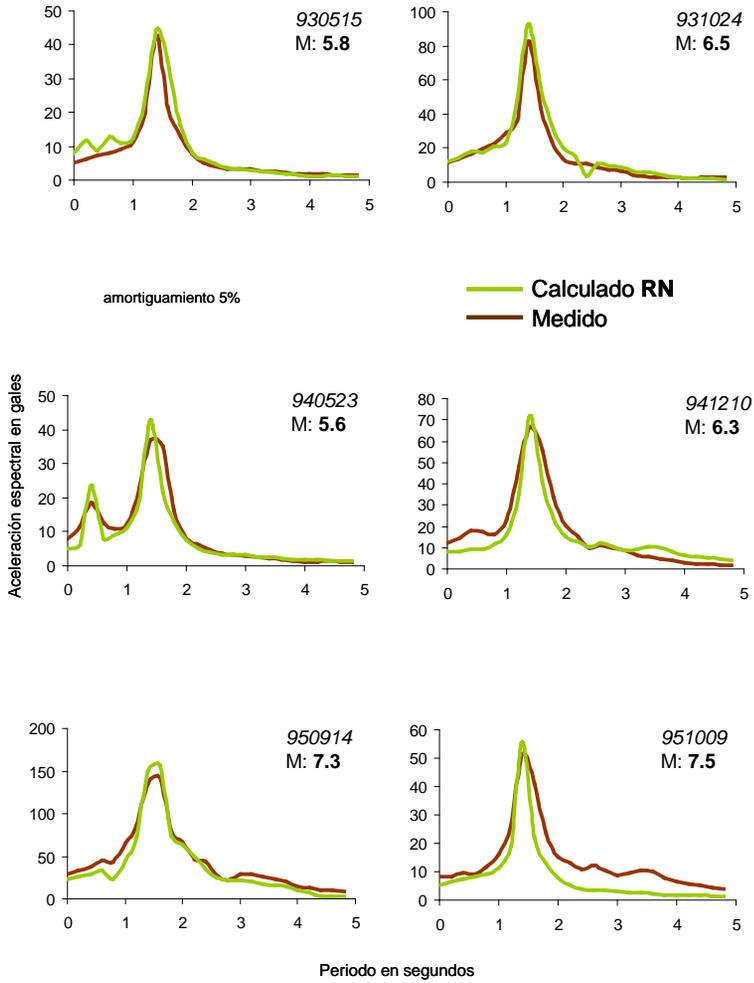


Figura 5.132 Sitio: Ibero, predicciones en modo directo

Sitio : Culhuacán
 T_s : 1.44 s

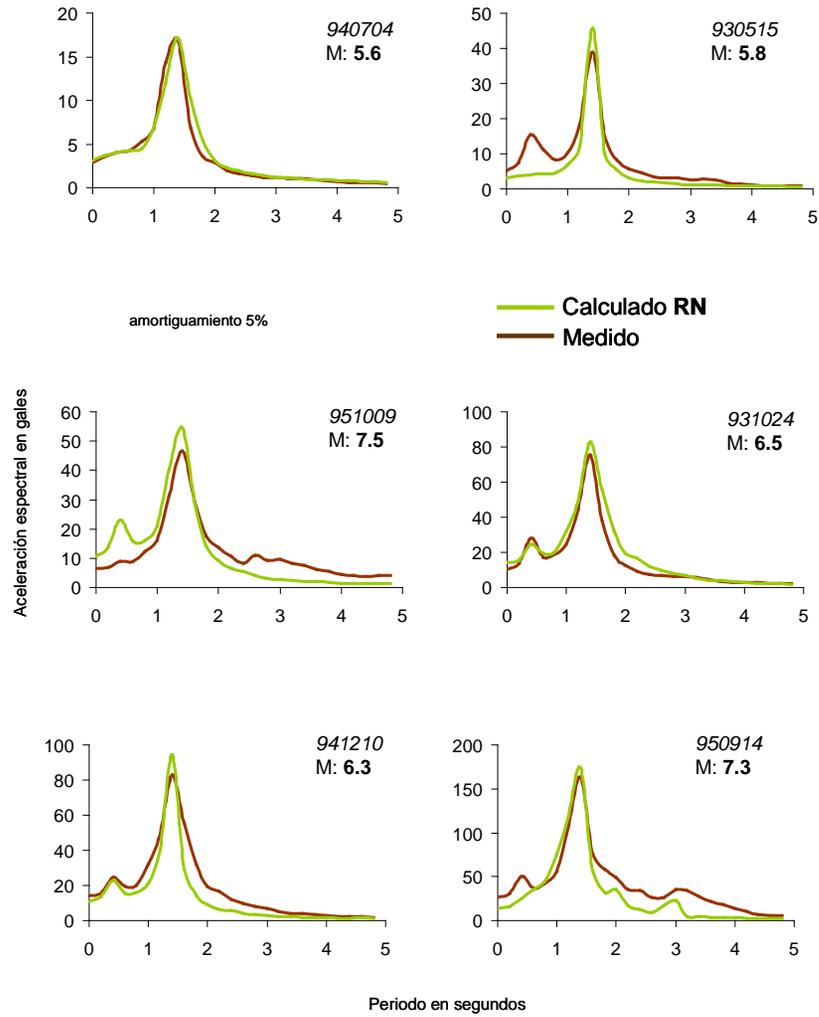


Figura 5.133 Sitio: Culhuacán, predicciones en modo directo

Conforme nos movemos hacia el norte (zona del aeropuerto de la Ciudad) y de acuerdo a lo expuesto por los sitios Apatlaco y Autódromo (Fig. 5.134) el número de estados que se activan durante los sismos de cualquier intensidad es mayor y comienzan a aparecer importantes OE en más de un periodo.

La presencia de dos bandas con máximas diferencias es bien *entendida* por la RN a pesar de no presentar el asombroso ajuste de los sitios anteriormente expuestos. Se reconoce la mayor capacidad de amplificación del sitio Apatlaco pero no se logra ajustar el máximo en el sismo de mayor respuesta, parece que la RN completa la tendencia de la zona de presentar las OEs máximas sobre el periodo (o la zona de periodos) fundamental(es) (Figs. 5.135 y 5.136). En Autódromo se observa la tendencia de los sitios con $T_s \geq 2.0$ s de clarificar la posición de las $OE_{máximas}$ conforme la intensidad de la sacudida crece. La RN lo reconoce y ofrece mejores predicciones conforme la magnitud del sismo es mayor.

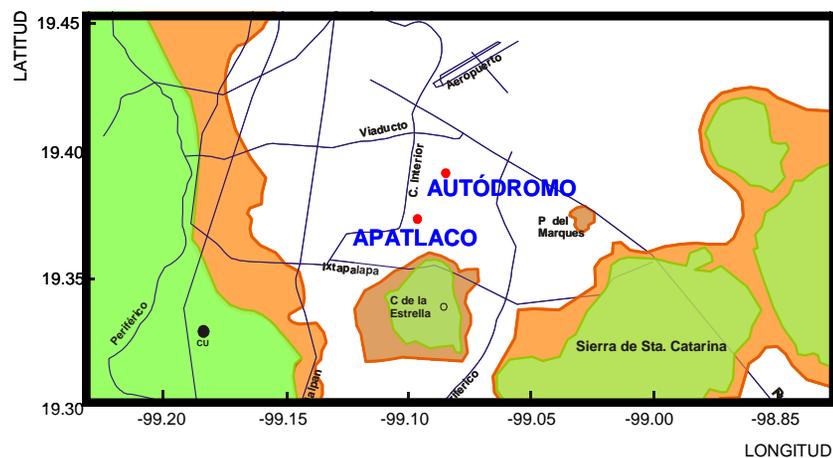


Figura 5.134 Sitios más cercanos al centro, periodos fundamentales alrededor de los 4 segundos

Sitio : Apatlaco
 $T_s : 3.1$ s

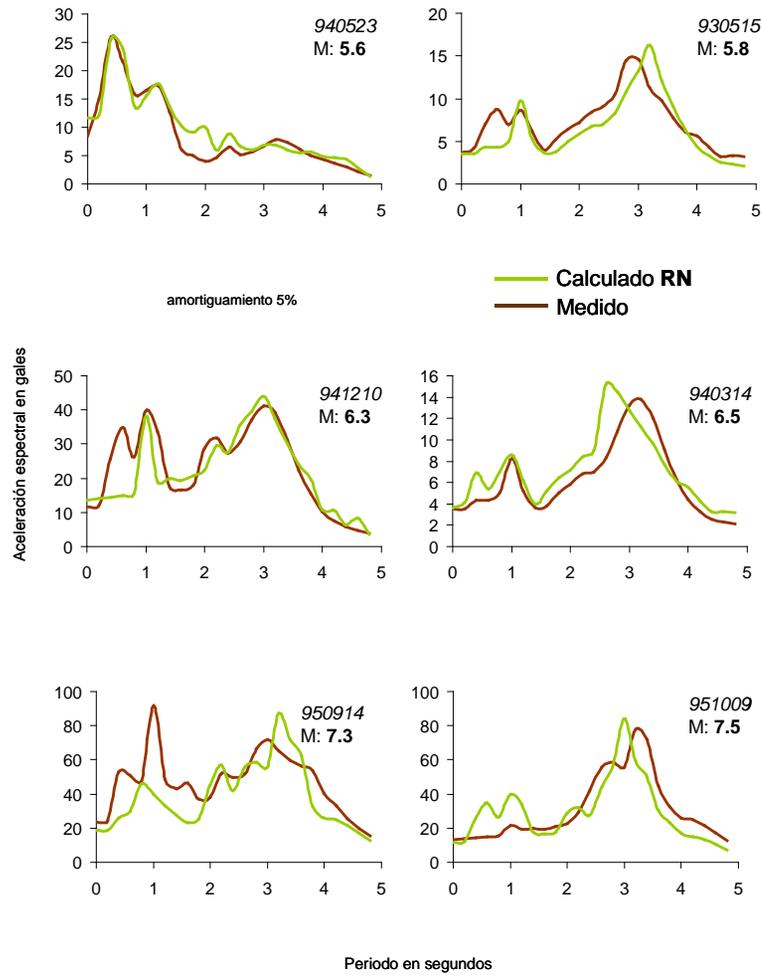


Figura 5.135 Sitio: Apatlaco, predicciones en modo directo

Sitio : Autódromo
 $T_s : 4.2 \text{ s}$

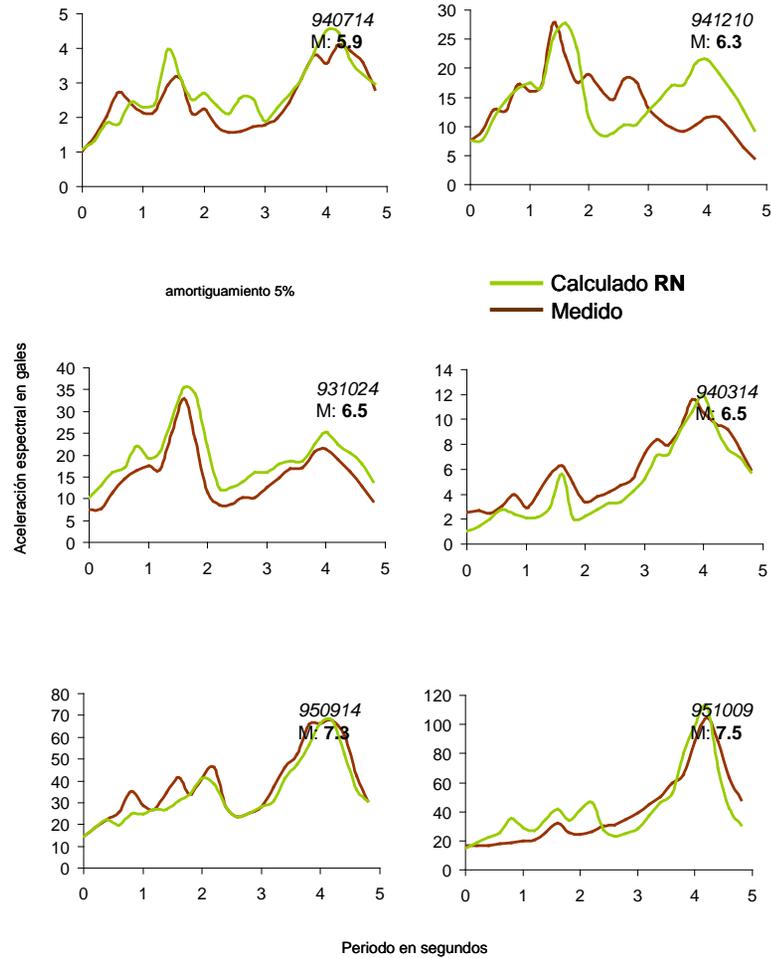


Figura 5.136 Sitio: Autódromo, predicciones en modo directo

Muy cerca del aeropuerto se encuentran los sitios Deportivo Moctezuma y Zaragoza (Fig. 5.137). Los resultados en predicción obtenidos en estos sitios son ejemplos de las zonas donde las diferencias entre lo medido y lo calculado son más evidentes (Figs. 5.138 y 5.139). La zona es conflictiva, observe la cercanía de los sitios y la gran diferencia entre las respuestas. Durante el entrenamiento la RN no logró generar relaciones eficientes para expresar las respuestas en ambos sitios y falla en la ubicación de los máximos, suaviza en demasía los ERAs y, de acuerdo con algunos ejercicios no incluidos en las figuras, llega a tener problemas de estabilidad numérica para sismos *severos* (del orden del sismo del '85).

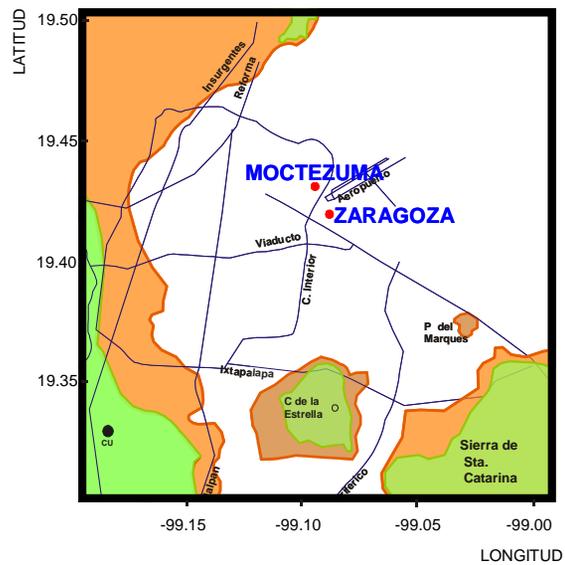


Figura 5.137 Sitios *hacia* el aeropuerto, periodos fundamentales alrededor de los 4 segundos

Sitio : **Deportivo Moctezuma**
 $T_s : 3.65 \text{ s}$

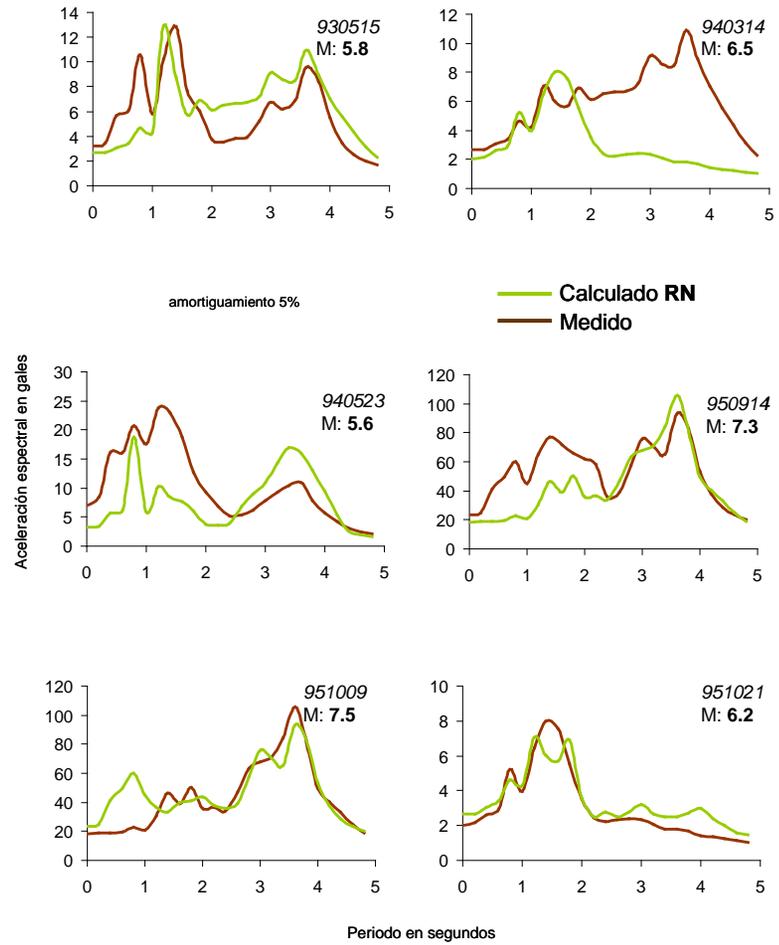


Figura 5.138 Sitio: Deportivo Moctezuma, predicciones en modo directo

Sitio : Zaragoza Superficie
 T_s : 4.0 s

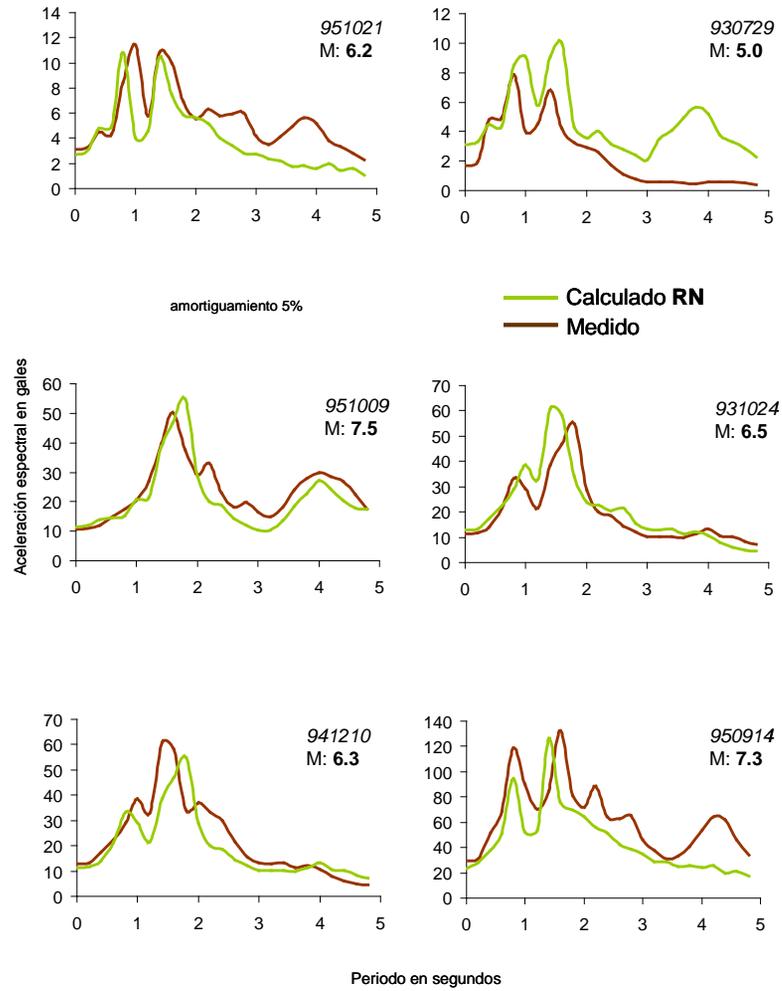


Figura 5.139 Sitio: Zaragoza superficie, predicciones en modo directo

A pesar de haber solucionado el efecto de las bandas *frías* con intercalaciones *cálidas* del sitio Zaragoza, la RN parece no haber encontrado un patrón de respuesta. Los máximos no se encuentran en la zona del T_s durante ningún evento aunque en algunos de ellos llega a haber una cierta activación alrededor de los 4 s. La RN no es capaz de captar este comportamiento.

En búsqueda de la respuesta a esta deficiencia en el modelo se analizaron los sitios Aragón, Bondojito y Tlatelolco, más hacia el norte de la Ciudad (Fig. 5.140). Los resultados obtenidos (Figs. 5.141-5.143) muestran que la capacidad de predicción de la RN es mejor en sitios más cercanos al Lago, en términos geográficos y estratigráficos.

El sitio Aragón, cerca de los límites con el Estado de México es el que presenta mayores diferencias entre lo *medido* y lo *calculado* y ninguna de las formas espectrales estimadas logra seguir a las observadas. Por otro lado, los

comportamientos en Bondojito y Tlatelolco son mejor *entendidos* por el modelo y los resultados comienzan a ser mejores. Las formas espectrales neuronales, aunque suavizadas, son congruentes con las *naturales* y las máximas ordenadas coinciden en intensidad y oscilador activado.

Los sitios con mayor capacidad de amplificación, los que se acercan al centro del Lago, generan geometrías de menor complejidad si se comparan con las del sitio Aragón el cual amplifica menos las ordenadas de entrada.

Este efecto está incluido en las relaciones generadas por la red, sin embargo no se puede abundar sobre esta capacidad neuronal debido a las fuertes discrepancias entre los ERAS_{medidos} y ERAS_{calculados}, quizá esta observación se relacione más con las deficiencias del modelo que con una virtud en términos de predicción.

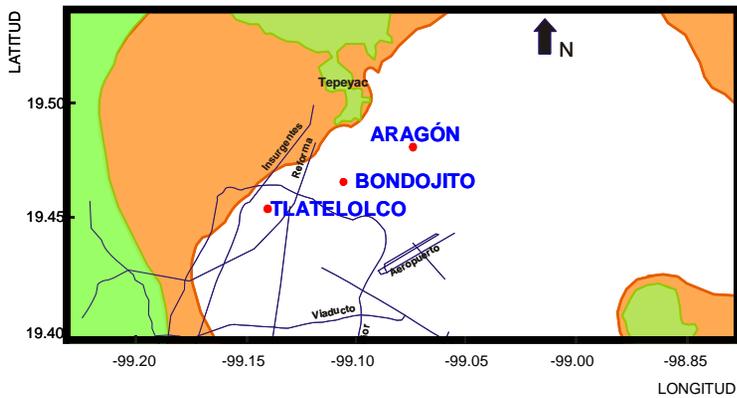


Figura 5.140 Sitios *hacia* el aeropuerto, periodos fundamentales entre 2 y 3,5 segundos aproximadamente

Sitio : Aragón
 $T_s : 3.4$ s

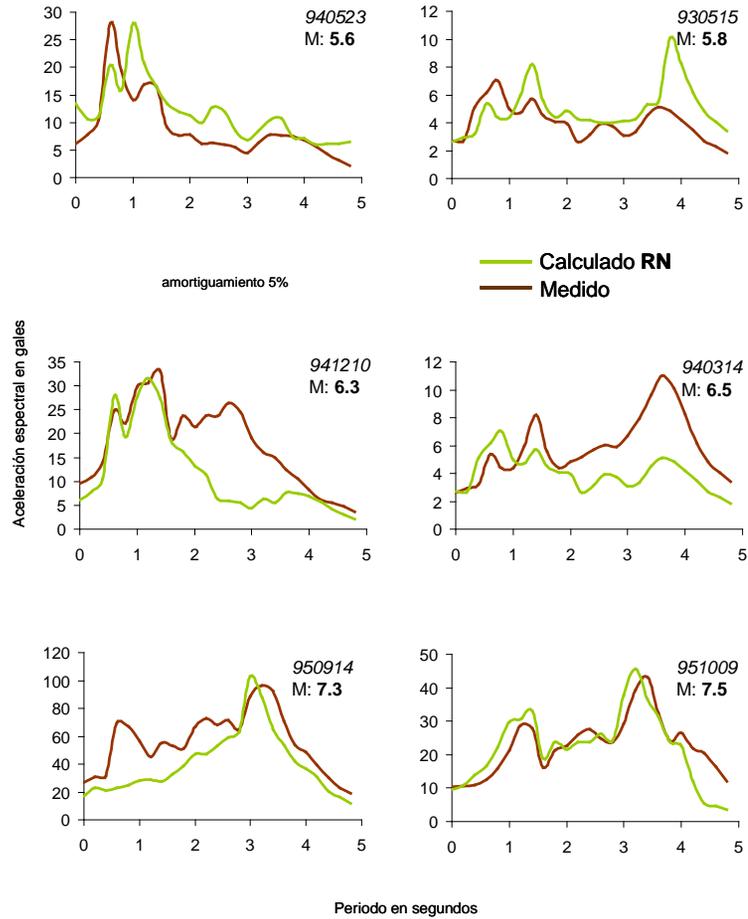


Figura 5.14I Sitio: Aragón, predicciones en modo directo

Sitio : **Bondojito**
 T_s : **2.7 s**

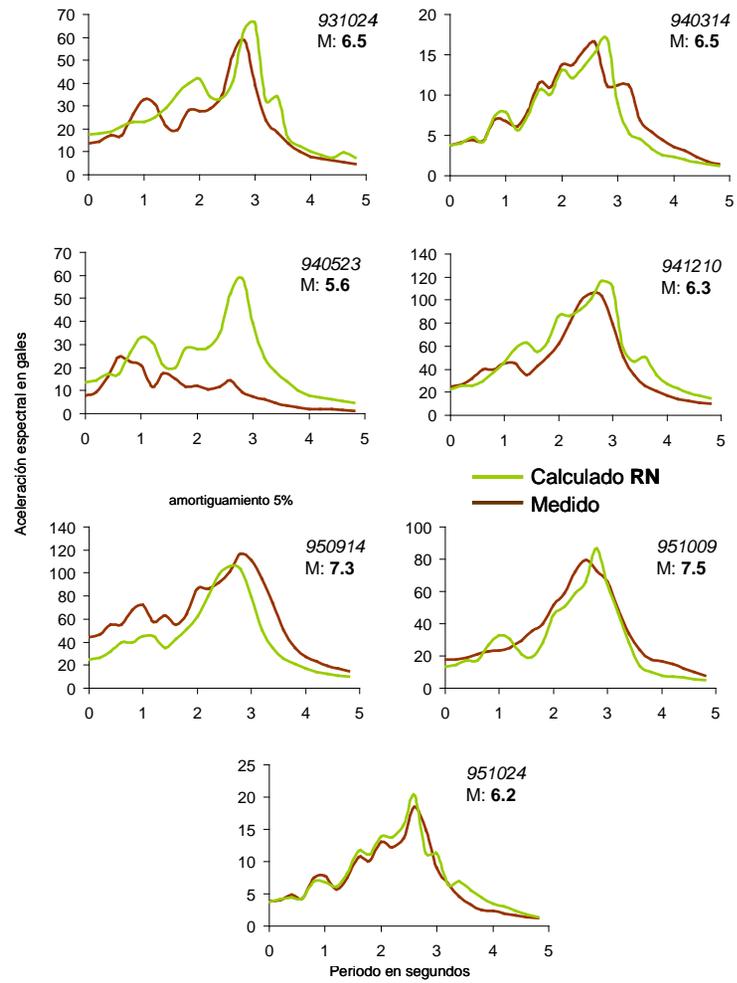


Figura 5.142 Sitio: Bondojito, predicciones en modo directo

Sitio : Tlatelolco
 $T_s : 2.1$ s

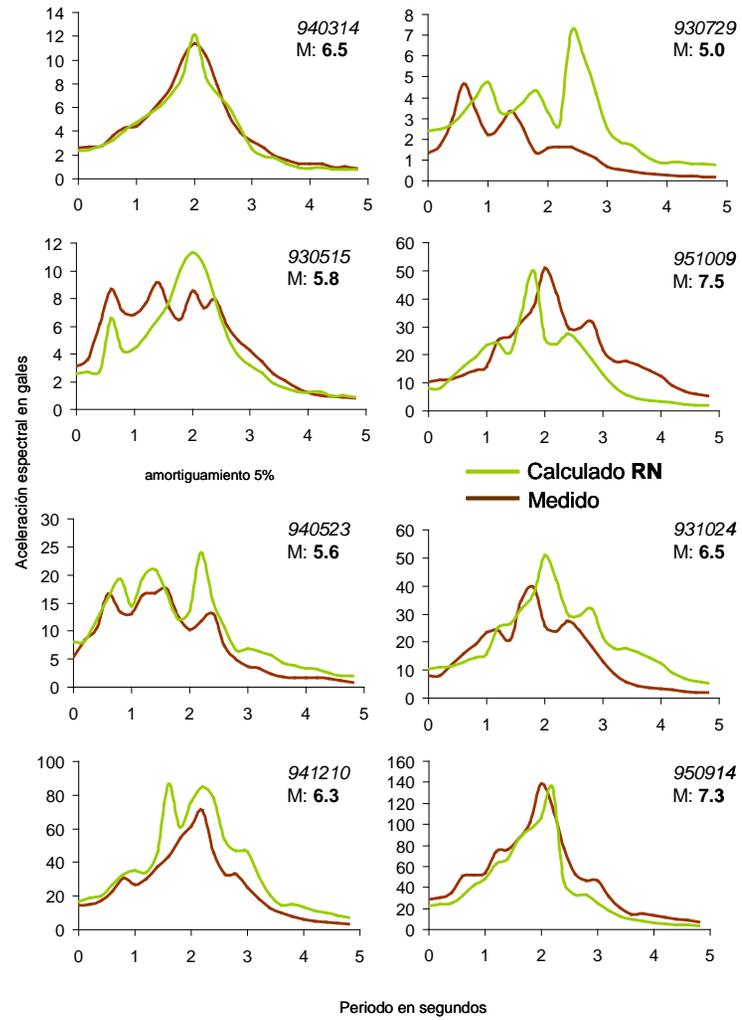


Figura 5.143 Sitio: Tlatelolco, predicciones en modo directo

Por último, se presentan los sitios Roma A Superficie y CU Juárez (Figs. 5.144-5.146), cercanos y dentro de la zona de Transición. Contrario a lo que se espera las predicciones en el sitio de Transición (CU Juárez) son más cercanas (tendencias y máximas ordenas correctamente dispuestas) que en el sitio en Lago (Roma A) donde son evidentes las diferencias entre las predicciones y las mediciones durante sismos menores. Los niveles de amplificación durante sacudidas ligeras son muy similares y sólo se presentan diferencias entre las respuestas de los depósitos cuando las amplitudes de entrada rebasan la etiqueta de *moderadas*. La hipótesis de un comportamiento único en el Lago durante las sacudidas menores parece abarcar también la zona de Transición.

Es importante señalar que en estos sitios, como en la mayoría de los cercanos a la Transición, no se puede hablar de un periodo donde se concentren las $OE_{máximas}$. Lo que se observa es la activación de estados en una zona de T (desde 1 y hasta 3 s) sin que sea posible (por lo menos a simple vista) decidir sobre el parámetro que dirige la ubicación de las máximas amplitudes.

Modelar esta condición con herramientas convencionales es una tarea muy difícil si no hay certeza del peso y la cualidad que debe otorgarse a cada parámetro de entrada para separar una serie de comportamientos que difícilmente podemos distinguir. Para la RN fue suficiente declarar como propios de un mismo depósito estos complejos patrones de respuesta para que se generara la *habilidad* y quedara implícita la ley que gobierna esta actuación.

Bajo una crítica parcial la característica neuronal de “caja oscura” puede acuñarse como deficiencia del modelo pues no es posible extraer una estructura numérica *simple* que sostenga los resultados. A favor de la actuación de la RN, se debe decir que no siempre obtener una estructura numérica que se *entienda* significa que *entendemos* los sucesos y somos capaces de explicarlos correctamente.

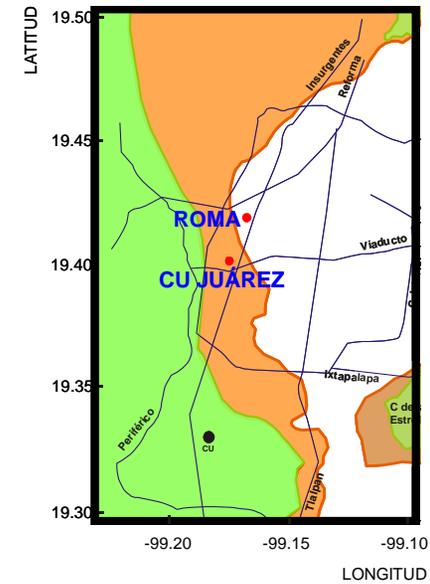


Figura 5.144 Sitios *hacia* la Transición, periodos fundamentales alrededor de los 2 segundos

Sitio : Roma A Superficie
 $T_s : 2.2$ s

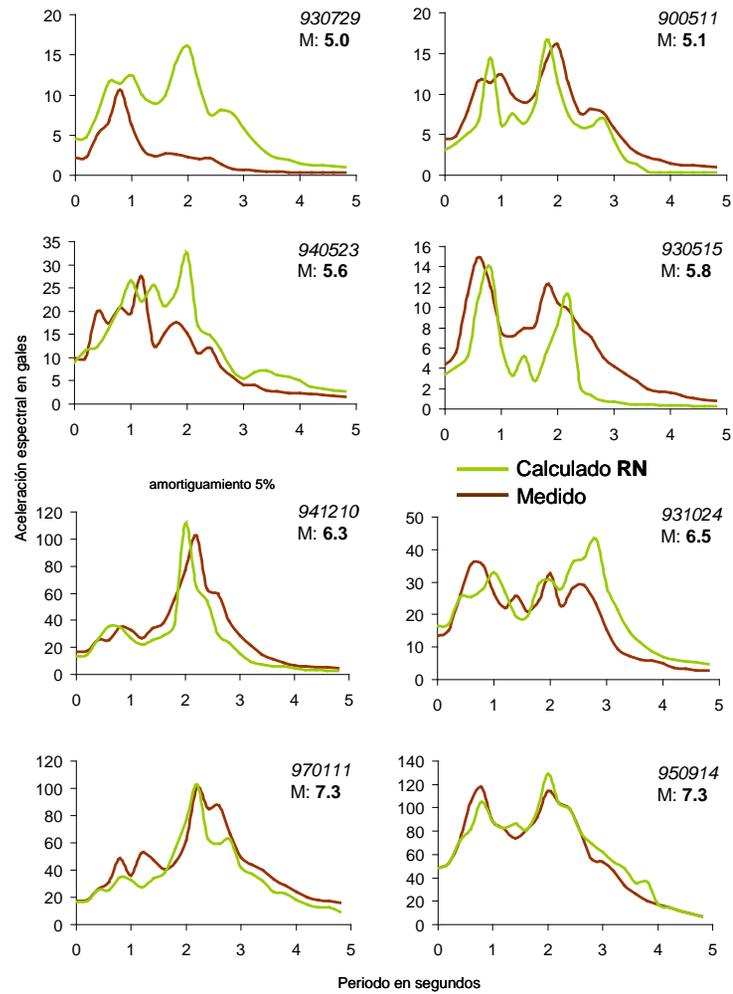


Figura 5.145 Sitio: Roma A superficie, predicciones en modo directo

Sitio : CU Juárez
 $T_s : 2.05$ s

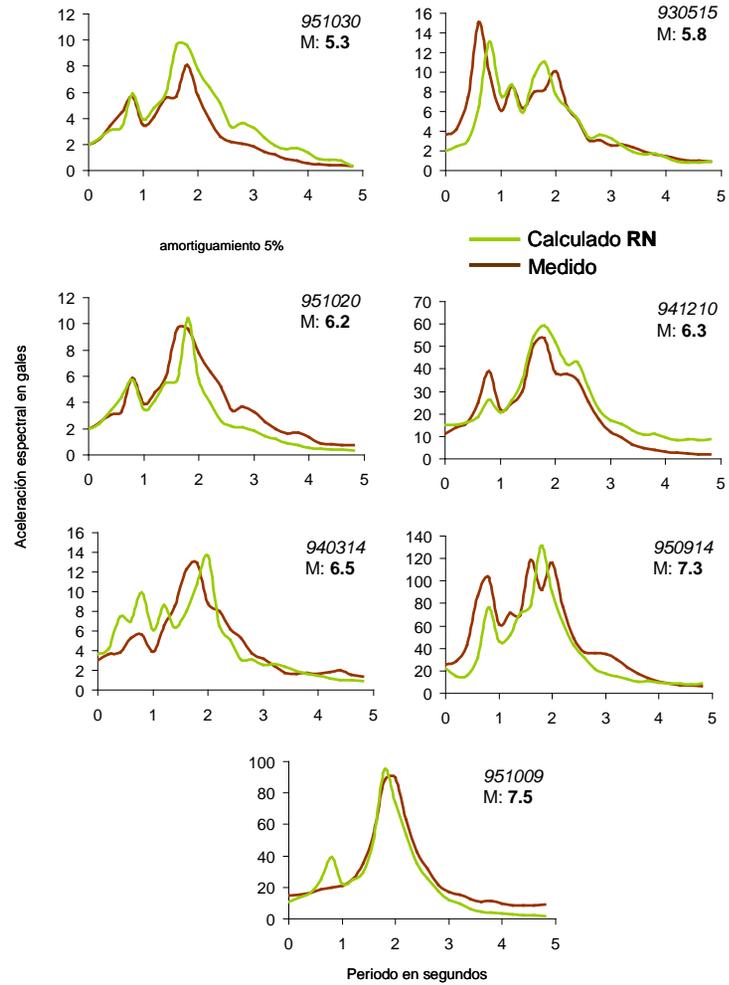


Figura 5.146 Sitio: CU Juárez (Transición), predicciones en modo directo

Operación del Modelo

Hasta este punto ha sido detallada la teoría detrás de: i) el procesamiento de señales (MR-EFs) y ii) el modelo neuronal. Resulta evidente que no es común en análisis o diseño sísmico el manejo de este tipo de esquemas conexionistas ni la visión dinámica no lineal con la que se construyó el modelo de estimación de respuesta de los depósitos del valle.

Al principio de este trabajo se argumentó sobre la necesidad de generar marcos de operación donde el ingeniero de la práctica pueda trabajar cómodamente a sabiendas de que el oportuno desarrollo científico le permite ese confort. A pesar de lo lejano que parece un esquema computacionalmente *avanzado* de las asignaturas básicas aprendidas por los graduados en el área, el producto final de esta propuesta (software) contiene una secuencia operativa muy cercana al pensamiento más básico (*natural*) en el planteamiento de la estimación de la respuesta sísmica (Fig. 5.147).

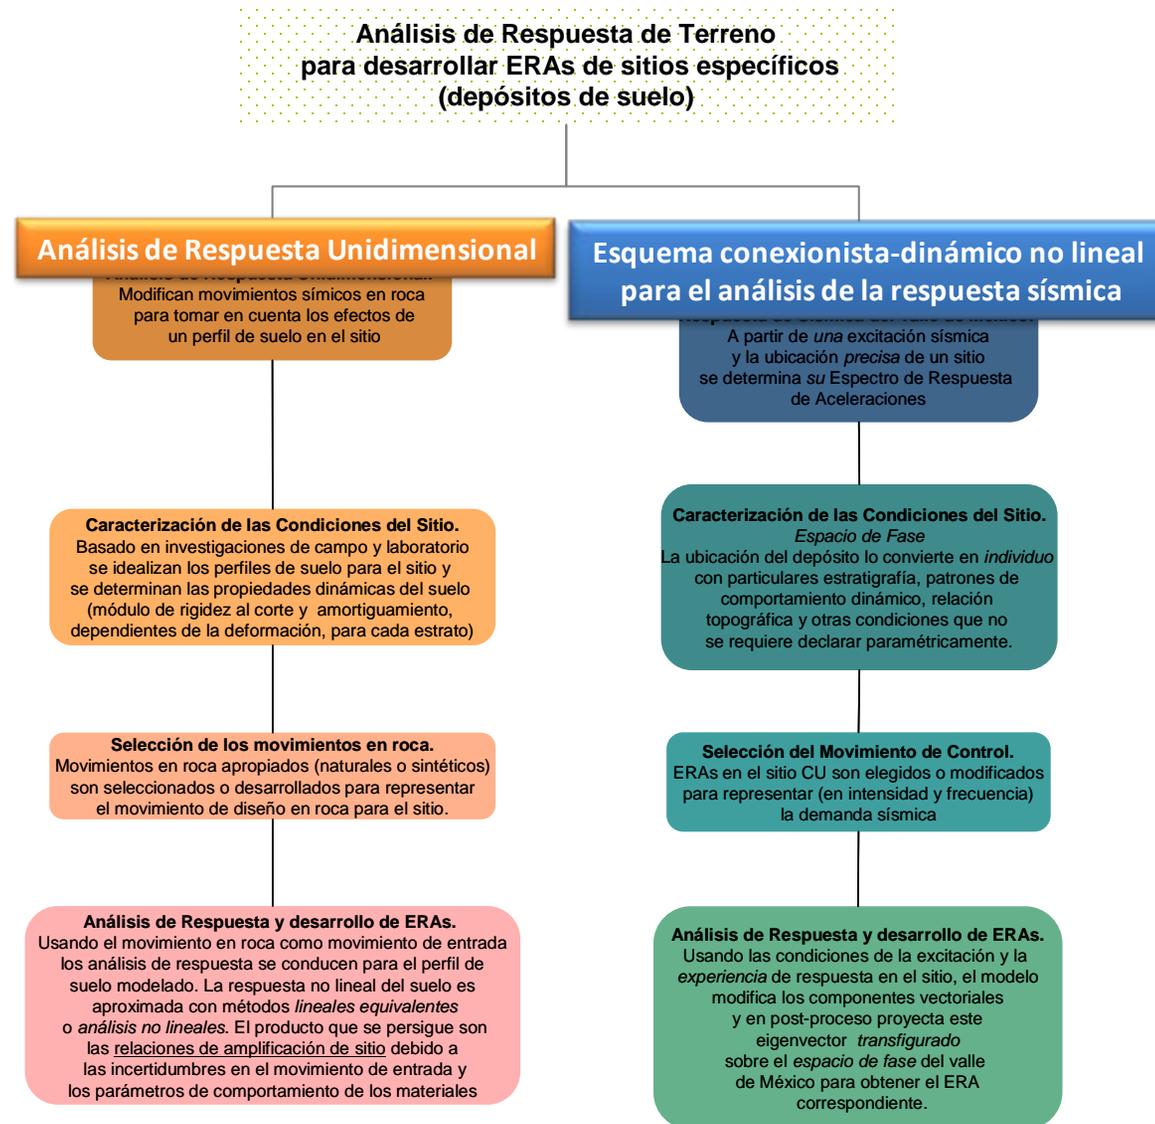


Figura 5.147 Comparación conceptual entre el ampliamente usado modelo 1D y el esquema conexionista propuesto en este trabajo de tesis

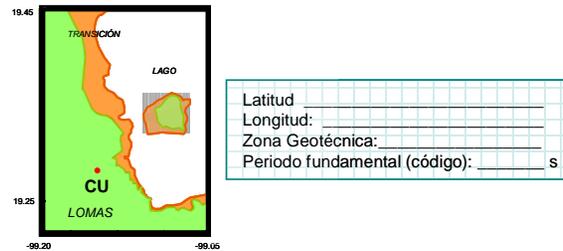
En el modelo MR-EFs/RN *cerrado* (la etapa de entrenamiento se declara *no-abierta*), sobre un mapa referenciado geográficamente se permite al usuario situar el punto que desea estudiar sobre la superficie del valle de México (Fig. 5.148). En esta tesis se presenta la parte del sistema que trabaja sobre sitios XY (caracterizados con T_s) específicos.

Señalar un punto distinto a los incluidos en el archivo de entrenamiento llama a una rutina adicional de interpolación de respuestas. El desarrollo y descripción de esta *conexión* paralela van más allá del alcance de esta

investigación y no serán presentados a detalle, pero se considera necesario aclarar que esta formulación forma parte del software final.

Cuando el usuario califica como válida su elección, el modelo despliega: i) las coordenadas geográficas del punto, ii) el periodo fundamental del sitio (de acuerdo con el RCDF y el criterio de modificación presentado al inicio de este apartado de **Resultados**) y iii) la zona geotécnica a la que pertenece el sitio.

UBICA EL SITIO :



SELECCIONA UNA OPERACIÓN :

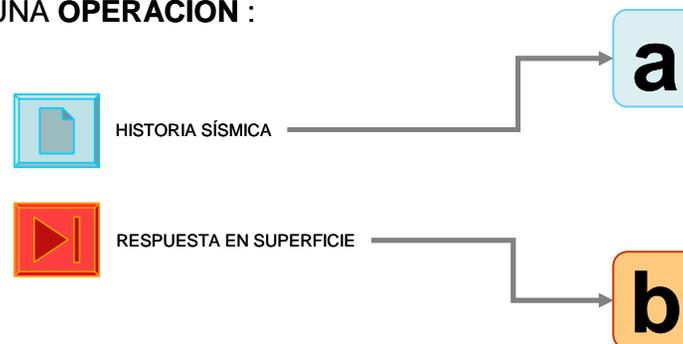


Figura 5.148 Primera etapa operativa del modelo

Posteriormente el sistema ofrece dos posibles operaciones. Se permite a) una revisión gráfica de la Historia Sísmica del sitio expresada en ERAs y MR con el evento de control adherido a cada respuesta (Figs. 5.149 y 5.150). Cualquiera de los eventos de control puede ser seleccionado como la alimentación de la segunda opción de operación: b) Respuesta en Superficie (Figs. 5.151 y 5.152).

Cuando un usuario pulsa la opción que calcula la Respuesta en el sitio de interés se le pregunta únicamente sobre los Parámetros E ya que el Parámetro S es determinado a través de la memoria codificada del propio sistema. El movimiento de control puede seleccionarse de alguno descrito en la Historia Sísmica aunque se permite la carga de un archivo de datos con las dos primeras columnas ocupadas por el vector de periodos y de OEs, respectivamente.

Existe la opción gráfica de modificar el ERA histórico con el arrastre del cursor para guardarlo como nuevo ERA y usarlo como demanda sísmica. Es importante recordar que si dentro de la relación entrada→salida, la *entrada* resulta demasiado ajena a la historia con la que se entrenó el modelo, la *salida* podría contener incongruencias numéricas.

Antes de presionar *Calcular* el usuario debe indicar los sub-productos que desea *guardar*: 1) Entrada (en ERA o en MR), 2) Eigenvector de entrada, 3) Salida (en ERA o en MR) y 4) Eigenvector de salida.

El resultado de la operación Respuesta en Superficie se despliega en pantalla y queda abierta la opción de más cálculos sobre el mismo sitio. Un cambio de posición implica cambio en la estratigrafía (mínimo o sustancial dependiendo de la distancia entre los puntos y la zona geotécnica donde se encuentren) y por tanto distintos patrones de comportamiento, por lo que cálculos en otro depósito requieren *restablecer* el sistema hacia el punto de arranque y una nueva selección XY sobre la superficie del valle.

Resumiendo, el usuario solamente: A) indica la posición del depósito, B) indica la demanda sísmica y C) indica los productos que desea que se *muestren o guarden*.



movimiento de control

respuesta monitoreada (ERA)

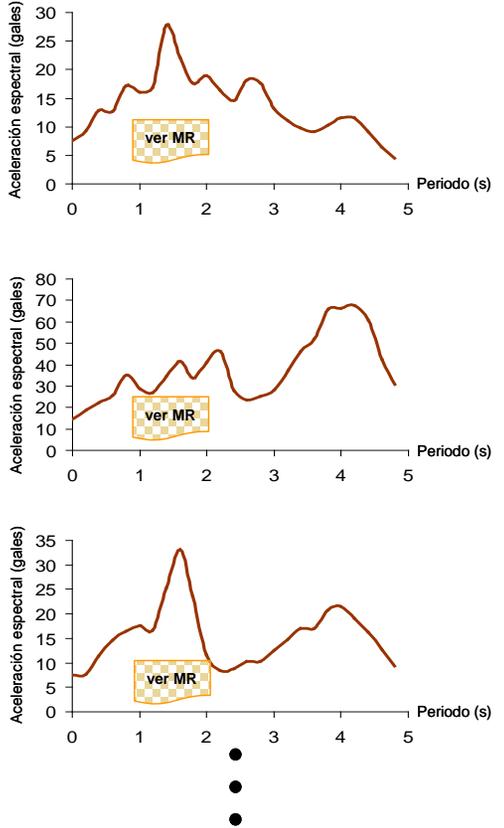
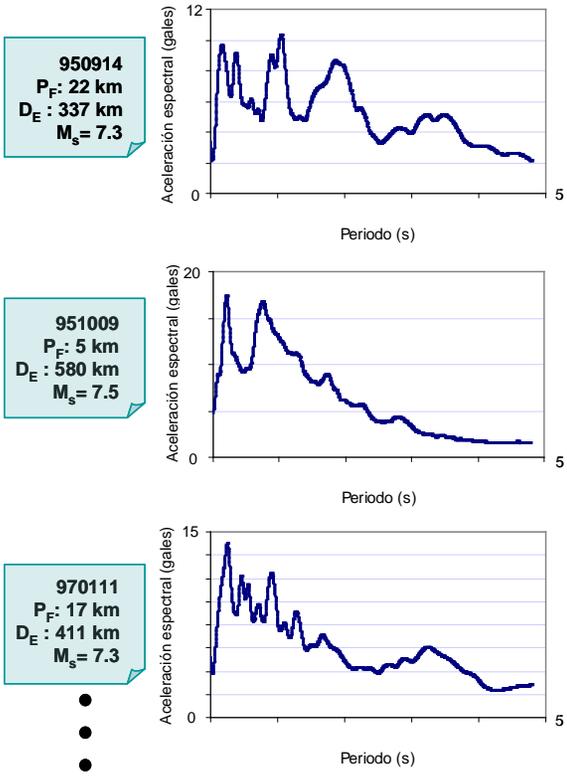


Figura 5.149 Primera opción operativa del modelo, opción *Historia Sísmica*



movimiento de control

respuesta monitoreada (ERA)

MR

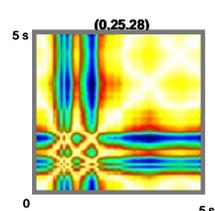
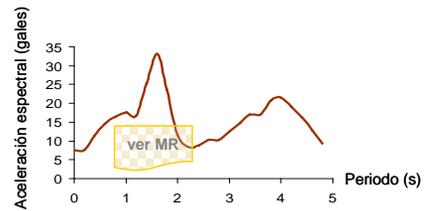
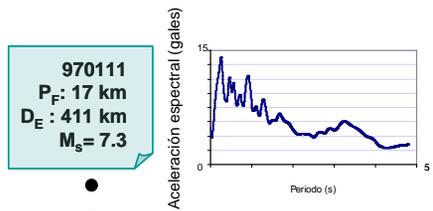
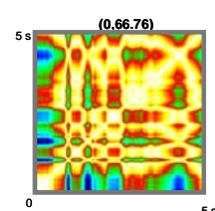
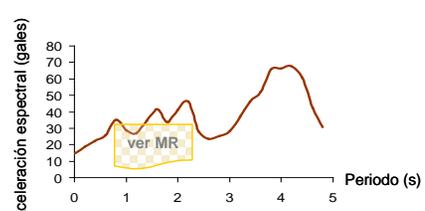
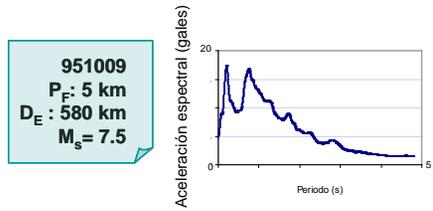
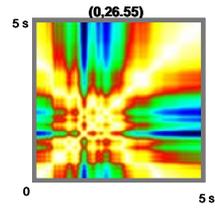
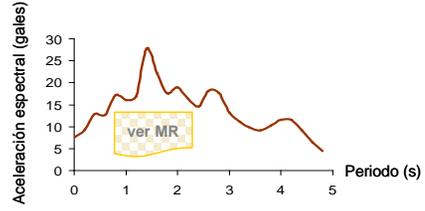
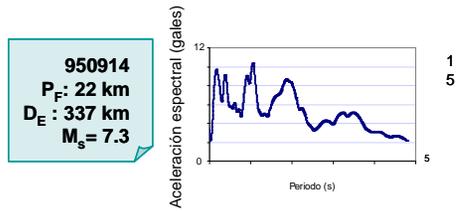


Figura 5.150 Primera opción operativa del modelo, opción Historia Sísmica

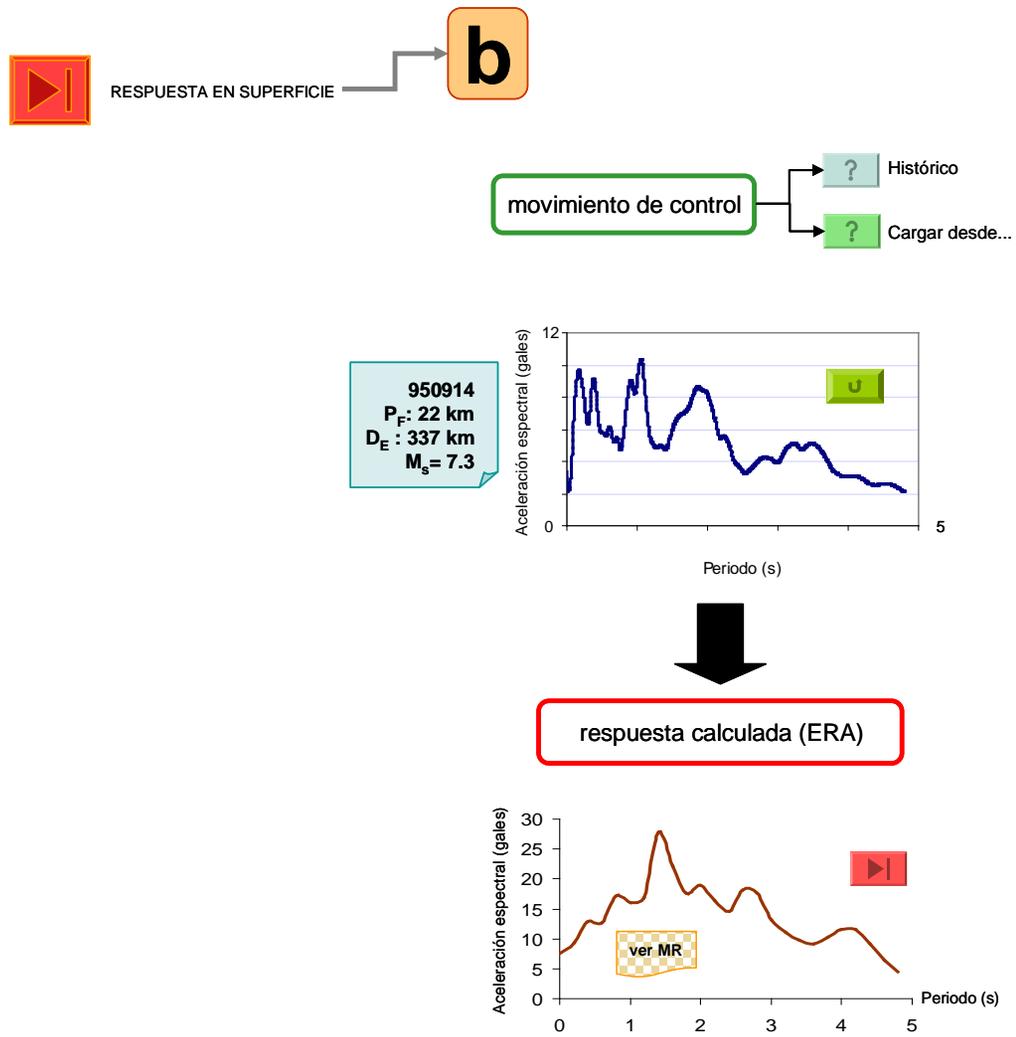


Figura 5.151 Segunda opción operativa del modelo, opción Respuesta en Superficie

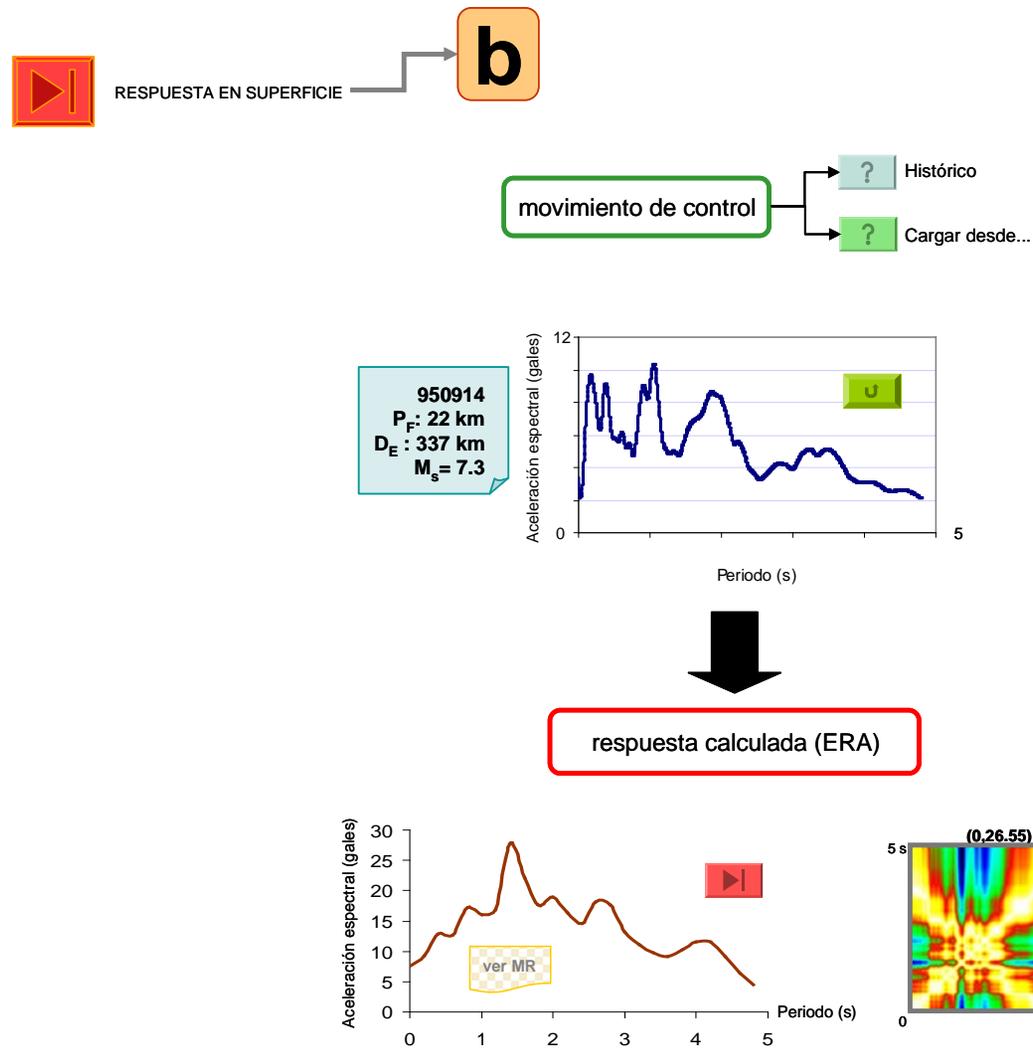


Figura 5.152 Segunda opción operativa del modelo, opción *Respuesta en Superficie*

Hacia la evolución del conocimiento

Algunos de los resultados presentados pueden significar evidencias útiles en la transformación de los actuales programas de análisis o, por lo menos, ideas sustancialmente poderosas para comprender el fenómeno sísmico explotando su manifestación en la superficie de los depósitos.

A continuación se presenta un condensado de estas observaciones.

- Sobre el movimiento de entrada

Si se dejan a un lado las hipótesis acerca de los movimientos en el afloramiento y el lecho rocoso, debemos reconocer que los acelerogramas que se colectan en el sitio en roca blanda (CU) contienen, de alguna manera, la propagación de las ondas sísmicas (génesis y viaje a través de cientos de kilómetros de roca) y el efecto de las condiciones del propio sitio.

Las estructuras generadas en CU, para los sismos incluidos en esta base de datos, van desde geometrías propias de funciones logarítmicas hasta, aunque parezca absurdo, bandas en periodos y amplitudes muy similares a las que se generan en sitios del Lago. Son claras las incongruencias entre magnitudes e intensidades espectrales.

La característica de respuesta más evidente es casi pulsos ($O_{E_{máxima}}$ alrededor de los 0.5 s) para sismos *débiles* y un gran número de osciladores activados (zona con $O_{E_{máximas}}$ entre 0.5 y 2.7 s) para la mayoría de los sismos de magnitud *moderada a severa* (aspecto importante para obtener relaciones de amplificación “convenientes”).

Esta condición podría ser la responsable de la recomendación de separar, de acuerdo con la intensidad sísmica, los modelos de análisis y de alguna manera podría estar ligada a la discusión obcecada sobre la linealidad de la respuesta de los suelos blandos.

Sin pretender descalificar los estudios que usan CU como entrada sísmica, conviene señalar que los MR de CU tienen una compleja activación de estados y que esto debería ser suficiente para que se apliquen con cautela las relaciones espectrales que deriven de sus ERAs.

El uso de los espectros, como *individuos*, para expresar la demanda sísmica es una restricción del marco teórico tradicional y, considerando las geometrías descubiertas para el sitio en roca blanda (CU), podría ser la responsable de algunas amplificaciones espurias entre sitios en terreno firme y depósitos de suelos blandos.

El sistema conexionista *flexibiliza* la definición de la sacudida a través de la ventajosa adición de los *Parámetros E* y el concepto *espacio de fase*, lo que al mismo tiempo *robustece* la estimación del eigenvector de salida *transfigurado*.

-

Sobre la respuesta de los depósitos

Las ubicaciones estudiadas permiten argumentar sobre el comportamiento de los depósitos del valle, un medio de arcillas plásticas, anisótropas y heterogéneas, en términos de sus trayectorias de respuesta.

Para eventos de intensidad *débil* se reconoce una misma estructura en el Lago y en la Transición, disímil a la mostrada por el sitio en roca (CU) en esos mismos eventos. Esto significa que, en términos muy simples, para M *menores* (< 6 grados) sería suficiente con un mapa *inteligente* de contornos de amplificación para definir los MR-ERAs escalados (si se parte de un MR *típico* con [0,1] en la barra de intensidades), mostrando un ligero aumento en la intensidad de las respuestas conforme se avanza hacia la zona central del viejo Lago y un notable decremento en el valor de las $O_{E_{máximas}}$ hacia el sureste de la Ciudad.

Es importante señalar que la ubicación del sitio es la variable explícita con más peso en el modelo mientras que la ubicación del epicentro y la P_F (mecanismo de falla) parecen no ser parámetros directores de este patrón de respuesta.

Estudiando los MR de sismos *moderados a severos* en los sitios en Lago y refiriéndoles a los correspondientes para el sitio de control se puede concluir que el nivel de energía contenida en el mapa de CU (el área total de los colores *fríos*) dirige la intensidad de la respuesta en los depósitos de suelos blandos.

Si se observan las ubicaciones de las máximas diferencias en CU (bandas o líneas azules/negras) y los periodos fundamentales en cada sitio no se pueden encontrar evidencias contundentes sobre el fenómeno de resonancia. Esto no indica su inexistencia, lo que hace es señalar la incapacidad del sitio de control para expresar completa y correctamente el contenido frecuencial de la sacudida.

Resulta una simplificación arriesgada y alejada de las *observaciones* tomar relaciones de amplificación (periodo a periodo) como válidas si se estudia el comportamiento de la superficie del valle. Esta posición de análisis resultaría válida sólo en modelos desarrollados para cada sitio, siempre y cuando sus trayectorias de respuesta sean *constantes* (vea las respuestas del sitio SCT, por ejemplo).

Durante los sismos de intensidad *mayor* se observan diferencias zonificadas entre las geometrías desplegadas en superficie. A pesar de la reconocida heterogeneidad en los depósitos que conforman el valle, en términos generales, los suelos parecen actuar como *filtros* de actividad bien delimitada.

Se encontró una separación *difusa* ($T_s \approx 2.5$ s) entre patrones de respuesta. Sitios cuyas máximas diferencias ($OE_{m\acute{a}xima}$) (bandas o líneas azules/negras) se localicen antes de esta frontera presentan ERAs agudos, bien definidos, y con máximas respuestas localizadas debajo de este T, incluso para sismos tan severos como el sismo del '85. Los depósitos con colores *fríos* máximos por encima de la frontera *difusa* presentan zonas de activación (espectros *anchos*) de entre 2 a 3 s que arrancan en $T_s \approx 2$ s. La aparición de importantes respuestas en un segundo modo de vibrar es característica de estas geometrías. Parece que es únicamente la ubicación del sitio (T_s) el parámetro director de esta separación de comportamientos.

6. Conclusiones

Sobre las aplicaciones

Han sido considerados dos importantes y complejos problemas geosísmicos. Se ha mostrado que las técnicas del cómputo aproximado ayudan a resolverlos exitosamente. La lógica difusa, la teoría del caos, el reconocimiento de imágenes, y las redes neuronales (en disposición híbrida) pueden ser considerados como herramientas convenientes en planteamientos geotécnicos e interpretaciones sísmicas. La consistencia y fusión computacional incrementaron la robustez y la utilidad práctica de conocidos planteamientos ingenieriles evolucionándoles hacia funcionales predictivos escalables, transparentes, interpretables, rápidos y económicos.

Estimación de la Velocidad de Ondas de Corte a partir de la Resistencia a la Penetración del Cono Eléctrico

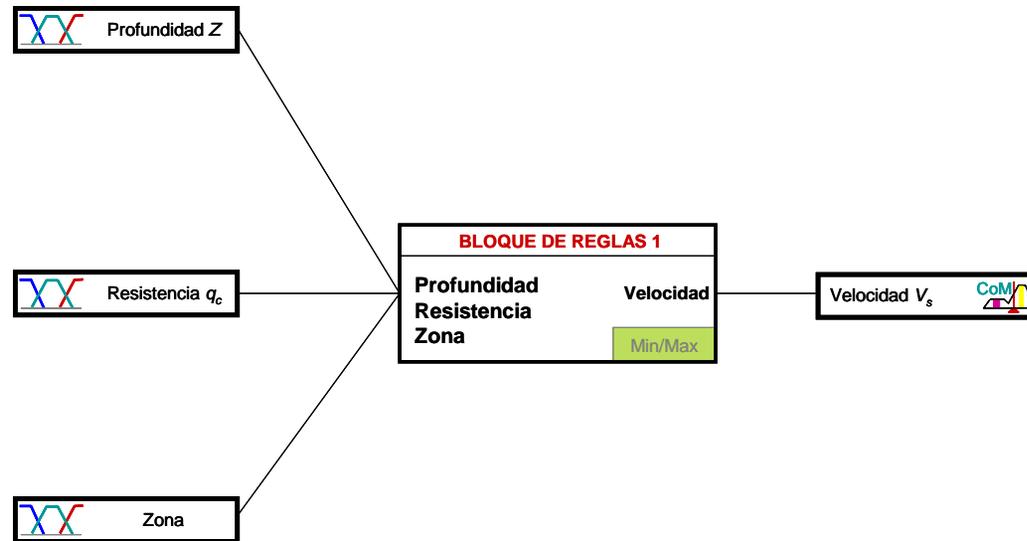


Figura 5.15 Estructura del Sistema de Lógica Difusa (viene del Capítulo 5)

- El modelo es *completo*, es decir, permite elaborar juicios y dictar sentencias sobre el comportamiento de la variable dependiente V_s . Se cubre un amplio rango de resistencias, profundidades y zonas geotécnicas para determinar velocidades desde *bajas* (suelos muy blandos) hasta *muy altas* (material considerado firme).
- Es posible identificar los parámetros de entrada del modelo por medio de un número pequeño de pruebas estándar realizadas sobre los materiales.
- El modelo está fundamentado en interpretaciones físicas de los comportamientos, no se decide *a priori* sobre las relaciones paramétricas ni las trayectorias de respuesta. Las predicciones, además de ser confiables, contienen *conocimiento* sobre los materiales y las propiedades.

Determinación del Módulo de Resistencia al Corte y el Amortiguamiento de acuerdo con la Plasticidad de los Suelos

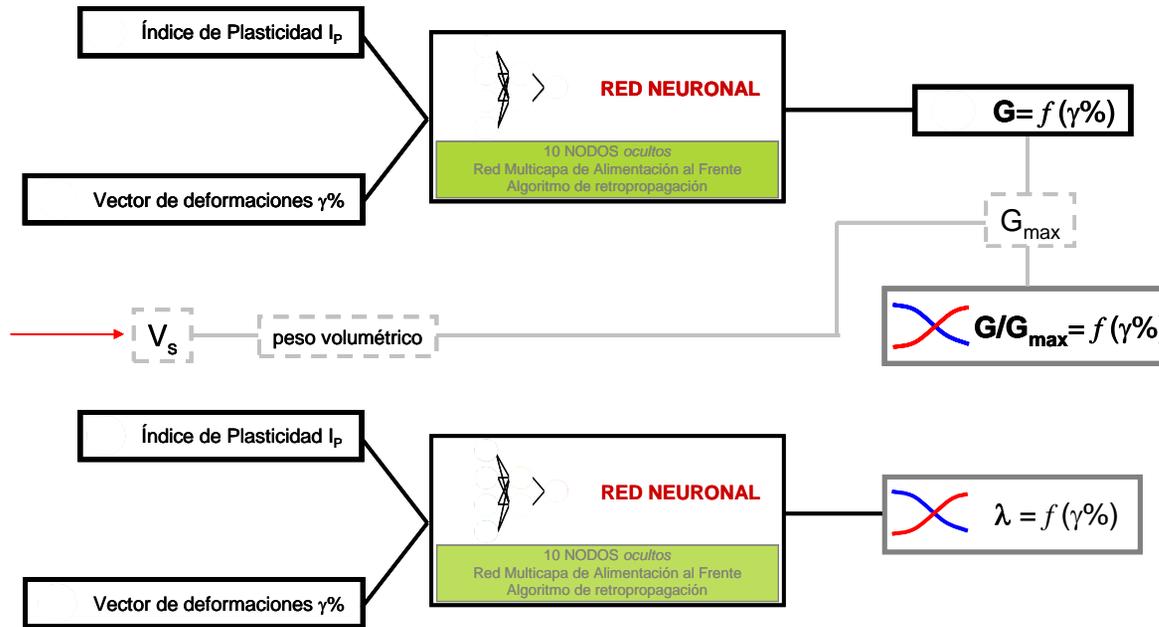


Figura 5.42 Topología más exitosa para modelar: $(G/G_{max}, \lambda) = f(I_p, \gamma\%)$ (viene del Capítulo 5)

- Esta relación neuronal es capaz de estimar los valores de G, λ por medio de una propiedad índice (I_p) obtenida de ensayos de laboratorio económicos y sencillos.
- Se encontró que, efectivamente, existe una relación *simple* entre la plasticidad y los parámetros dinámicos requeridos, lo que permitió la construcción de un módulo neuronal eficiente.
- La mayoría de las relaciones empíricas para obtener G, λ están muy lejos de la perfección y las incertidumbres asociadas difícilmente pueden ser cuantificadas. Esta herramienta *inteligente*-estándar, asequible y práctica- permite trabajar en los marcos de indeterminación paramétrica con suficiente confianza sobre el método y los resultados.

Estimación de Movimientos de Terreno en la Ciudad de México

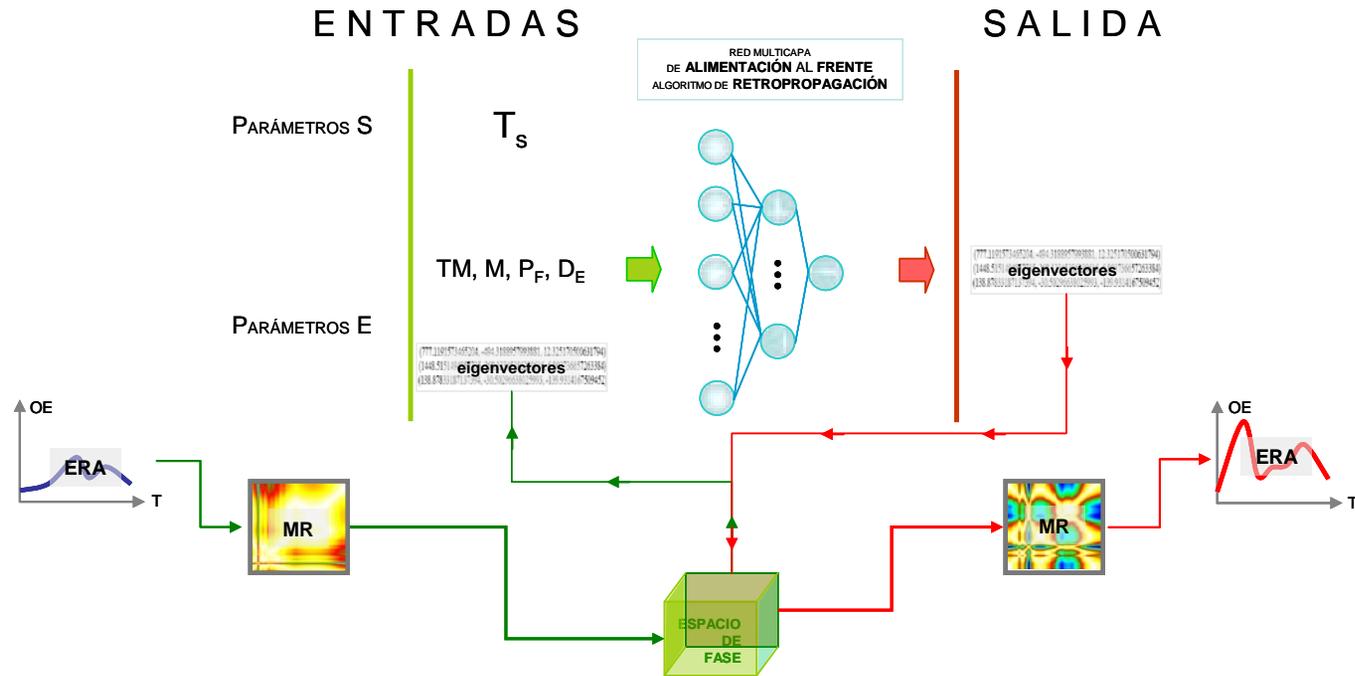


Figura 5.103 Señales recuperadas usando la dupla MR-EFs (viene del Capítulo 5)

- La poca practicidad de análisis *completos* de respuesta de terreno (aquellos que modelen el mecanismo de ruptura en la fuente, la propagación de las ondas de esfuerzo a través de la corteza terrestre hasta la parte superior del manto rocoso y la modificación de este movimiento en roca por efecto de los suelos depositados) dirige la tendencia del funcional RN-RPs/EFs de ser *muy simple*: únicamente se propone el movimiento que excita y se cuantifica su transformación de acuerdo con la situación geográfica y características de los materiales que conforman un depósito de suelo.
- Se evitan decisiones subjetivas (basadas en información *incierta o incompleta*) en la especificación de los movimientos de terreno. Se eliminan las afirmaciones poco científicas sobre el **Sistema** (depósitos del valle) y no se recurre a simplificaciones sobre la naturaleza del **Proceso** (propagación de ondas sísmicas).

- El *movimiento de control* facilita las decisiones de diseño y genera un procedimiento neuronal más robusto; la exclusión de propiedades dinámicas, índice y geométricas permite *dibujar* un espacio de respuestas de suelo (geo-referenciadas) sin incongruencias ni restricciones.
- La consistencia de los resultados dan confianza en los hallazgos sobre los comportamientos y los patrones que los rigen. Se avanza en *entender* el fenómeno a través de lo que observamos sin ajustar las observaciones a funciones matemáticas que *entendemos*.

Sobre el planteamiento

...Teoría es el lenguaje por medio del cual las lecciones de la experiencia pueden ser claramente expresadas. Cuando no hay teoría no existe una sabiduría colectiva, sino fragmentos meramente incompresibles...

[Fragmento del diario personal del Dr. K. Terzaghi, marzo 17, 1919]

...la Teoría es requerida para entrenar y desarrollar nuestra capacidad para interpretar correctamente lo que observamos; pero, al mismo tiempo, únicamente con *teorías* no podríamos entender casi nada en todo el campo de la ingeniería que trabaja con la tierra...

...yo siempre pierdo la paciencia con la gente que piensa que ha llegado a la *verdad* de los comportamientos¹ después de que han tenido cierto éxito en representar alguna fase de ellos², simplificada artificialmente, por medio de complicadas triples integrales, mientras al mismo tiempo, han olvidado cómo se manifiesta el suelo...

[Fragmento de una carta escrita por el Dr. K. Terzaghi, enero 21, 1926]

...nuestra experiencia práctica puede ser muy confusa a menos que se combine con una concepción razonablemente precisa de la mecánica del fenómeno bajo consideración...

[Fragmento de un reporte escrito por el Dr. K. Terzaghi, abril 9, 1939]

^(1,2) se refiere, dentro del texto en su idioma original, al comportamiento de los suelos

Ninguno de los planteamientos descritos en este trabajo desprecian las teorías ni postulados geotécnicos/sísmicos difundidos hasta el momento, al contrario, el desarrollo de los modelos requirieron de un profundo conocimiento acerca del significado de hipótesis, simplificaciones, parámetros y funcionales y de la interpretación de resultados provenientes de metodologías tradicionales. Las alternativas de análisis aglutinan de forma ventajosa las experiencias, los conceptos básicos y el cómputo aproximado para construir un ambiente que eventualmente contenga la *historia* y genere la *evolución* de la ingeniería geosísmica.

En esta tesis se intenta la expresión *correcta* de las manifestaciones del suelo a las acciones sísmicas para generar conocimiento ingenieril útil. Las novedosas tecnologías del CA evitan las simplificaciones y ayudan a entender *mejor* a través de lo que somos capaces de observar y expresar numérica y lingüísticamente. No se trata sólo de progresos computacionales a planteamientos rutinarios ni a juicios geosísmicos tradicionales. Se trata de establecer nuestra incapacidad para reconocer, analizar y modelar algunos aspectos del fenómeno geosísmico y nuestra invaluable experiencia y aciertos de interpretación del fenómeno, para dirigir lo más acertadamente posible la intuición del ingeniero sin alardear sobre los procedimientos matemáticos ni la tecnología que los sustentan.

Con la solución de los dos retos prácticos se puntualiza sobre algunos aspectos que podrían derivar en una nueva forma de pensamiento. Los modelos aquí propuestos requieren de hechos y conceptos *simples* (no de simplificaciones) para *aprender*. Conforme el ingeniero o especialista desarrolle observaciones más críticas, astutas e inteligentes podrá aprovechar, en la misma medida, las posibilidades que le brindan estas técnicas y metodologías.

Las formulaciones de esta investigación buscan la belleza, la armonía y la simpleza que, en sí mismas, puedan ser la dirección hacia la *verdad*. Los modelos hechos *visibles*, casi palpables, pierden su opacidad y acercan a la *realidad*. El soporte computacional posibilita visualizar los problemas, comprender cómo resolverles y, a veces, el descubrimiento (o la invención) de técnicas, métodos y algoritmos de formas inéditas.

7. Apéndices

7.1. Apéndice 2.3.A

Se presenta una lista de lecturas recomendadas para profundizar en aspectos importantes cuando se estudia el Análisis de Respuesta de Sitio.

Referencias Seleccionadas

- Efectos topográficos

Aki, K. (1988), "Local Site Effects on Strong Ground Motion", *Earthquake Engineering and Soil Dynamics II; Recent Advances in Ground Motion Evaluation, Geotechnical Special, Publication No. 20*, June, pp 103-155.

Aki, K. (1993), "Local site effects on weak and strong ground motions", *Tectonophysics*, 218, 1-3, pp93-111.

Athanasopoulos, G.A., Pelekis P.C. y Leonidou E.A. (1999), "Effects of surface topography on Seismic Ground Response in the Egion, Greece, 15 June 1995 earthquake", *Soil Dynamics and Earthquake Engineering*, Vol. 18, No.1, ISSN 0267-7261, pp. 135-149.

Deng, N. (1993), "FLUSHPLUSH: A computer program for approximate 3D analysis of soil -structure interaction problems", An enhanced PC version of the original FLUSH program published in 1975 by Lysmer, Udaka, Tsai y Seed, (program conversion and modification), University of California, Berkeley.

Faccioli, E. (1991), "Seismic Amplification in the presence of geological and topographic irregularities", *Proc. of the 2nd. Int. Conf. on Recent Advances in Geotechnical Engineering and Soil Dynamics*, St. Louis Missouri, Vol. 2, pp-1779-1797.

Geli, L., Bard P.Y., y Jullien B.(1988), "The effect of topography on earthquake ground: motion : a review and new results", *Bulletin of Seismological Society of America*, Vo. 78, No. 1, pp 42-63.

Reinoso, E., Wrobel, L.C. y Power H, (1997), "Three Dimensional Scattering of Seismic waves from Topographical Structures", *Soil Dynamics and Earthquake Engineering*, Vol. 16, pp. 41-61.

Sánchez-Sesma, F.J. (1983), "Diffraction of elastic waves by three-dimensional surface irregularities", *Bulletin of the Seismological Society of America*, 73, pp1621-1636.

Sánchez-Sesma, F. (1990), "Elementary solutions for response of a wedge-shaped médium to incident SH- and SV-waves", *Bulletin of the Seismological Society of America*, Vol. 80, pp. 737-742.

Sánchez-Sesma F. y Campillo M., (1993). "Topografic effects for incident P, SV and Rayleigh waves". *Tectonophysics*, Vol. 218, No.1-3, pp 113-125.

Sánchez-Sesma, F., Chávez-Pérez S., Aviles, J. (1994), "Scattering of elastic waves by three dimensional topographies", *Proc. of the 8th World Conference on Earthquake Engineering*, Sn. Francisco, Vol. II, pp. 639-646.

Trifunac, M.D. (1971), "Surface motion of a semi-cylindrical alluvial valley for incident plane SH waves", *Bulletin of the Seismological Society of America*, 61, pp1661-1667.

Trifunac, M.D: (1973), "Scattering of plane SH waves by a semi-cylindrical canyon", *Earthquake Engineering Structural Dynamics*, 1: 267-281.

Wong, H.L. y Trifunac, M.D. (1974), "Scattering of plane SH waves by a semi-elliptical canyon", *Earthquake Engineering Structural Dynamics*, 3: 157-169.

Todorovska M.I. y Lee, V.W. (1991), "A note on scattering of Rayleigh waves by shallow circular canyons: analytical approach", *Bull. Indian Soc. Earthquake Tech.*, 20:1-16.

- *Cuencas Aluviales:*

Bard, P.Y. y Gariel, J.C. (1986), "The seismic response of two dimensional sedimentary desopits with large vertical velocity gradients", *Bulletin of the Seismological Society of America*, Vol. 76, pp. 346-356.

Chávez-García, F.J., Ramos-Martínez J., y Romero-Jiménez E., (1995), "Surface Wave Dispersión Análisis in Mexico City", *Bulletin of the Seismological Society of America*, Vol. 85, pp. 1116-1126.

Graves,R.W. (1993), "Modeling three dimensional site response effects in Marina District Basin, San Francisco , California", *Bulletin of the Seismological Society of America*, Vol. 78, No.1, pp. 42-63.

Rial J.A., Saltzman, N.G. y Lingh, H. (1992), "Earthquake-induced resonance in sedimentary basin", *American Scientist*, Vol. 80, No. 6, pp. 565-578.

Somerville, P. (1998), "Emerging art: earthquake ground motion", *Geotechnical Earthquake Engineering and Soil Mechanics III*, Vol. I, ASCE, *Proc. of speciality conference*.

- *Geometría del valle y las no-homogeneidades del suelo*

Alterman, Z.S. and Karal, F.C. (1968), "Propagation of elastic waves in layered media by finite difference methods", *Bulletin of the Seismological Society of America*, 58, pp367-398.

Bielak, J., MacCamy, R.C., McGhee, D.S. and Barry, A. (1991), "Unified symmetric BEM-FEM of site effects on ground motions - SH waves", *Journal of Engineering Mechanics*, ASCE, 117 (10), pp2265-2285.

Lysmer, J. and Drake, L.A. (1971), "The propagation of Love waves across non horizontally layered structures", *Bulletin of the Seismological Society of America*, 61, pp1233-1252.

Sánchez-Sesma, F.J. (1983), "Diffraction of elastic waves by three-dimensional surface irregularities", *Bulletin of the Seismological Society of America*, 73, pp1621-1636.

TRISEE (1999), "3D site effects and soil-foundation interaction in earthquake and vibration risk evaluation", edited by Faccioli, E., Paolucci, R. And Vanini, M., European Commission, Directorate General XII for Science, Research and Development.

Romo , M.P.,(1977) "Soil-Structure Interaction in a Random Seismic Environment", Tesis Doctoral, Universidad de California , Berkeley.

Bárcena A. y Romo M., (1994), "RADSH: Un programa de computadora para analizar depósitos de suelo estratificados horizontalmente sujetos a excitaciones dinámicas aleatorias", Reporte Interno del Instituto de Ingeniería, UNAM.

Seed H.B. e Idriss I. (1969), "The Influence of Soil Conditions on Ground Motions during Earthquakes", *Journal of Soil Mechanics and Foundations Division, ASCE*, Vol. 94, No. SM1, pp. 120-137.

Martin, P.P. (1975), "Non-Linear Methods for Dynamic Analysis of Ground Response", PhD dissertation, University of California, Berkeley.

Lee, M.K.W. and Finn, W.D.L. (1991), "DESRA-2C: Dynamic effective stress response analysis of soil deposits with energy transmitting boundary including assessment of liquefaction potential", University of British Columbia, Faculty of Applied Science, p. 34.

Li, X.S., Wang, Z.L. and Shen, C.K. (1992), "SUMDES: A nonlinear procedure for response analysis of horizontally-layered sites subjected to multi-directional earthquake shaking", Dept. University of California, Davis, p. 81.

7.2.Apéndice 3.1.A

Breve historia del Conexionismo

La revolución conexionista

La investigación conexionista está firmemente establecida entre la comunidad científica [inteligencia artificial (Aizawa, 1992; Gallant,1993), neurociencia cognitiva (Mozer et al., 1997), economía (Zapranis y Refenes, 1994), lingüística (Plunkett, 1995), filosofía (Horgan y Tienson, 1996), y física (Hopfield, 1982), por nombrar algunos] especialmente en el campo multidisciplinario de la ciencia cognitiva (Thorndike , 1932; Bechtel y Abrahamsen, 1991; Dawson, 1988; Rumelhart et al., 1986; McClelland et al., 1986; Thagard, 1996).

El conexionismo tiene un pasado muy largo, el origen de las ideas conexionistas pueden atribuirse al gran filósofo griego Aristóteles y sus ideas sobre asociaciones mentales. Estas ideas fueron retomadas por los empíricos británicos y naturalmente extendidas por los fundadores de la psicología, siendo los neuropsicólogos quienes relacionan el proceso de aprendizaje y memoria a las propiedades cerebrales. Pero esto es sólo la mitad de la fotografía, la otra mitad la conforman los investigadores que alimentaron la investigación matemática y la temprana ciencia computacional y contribuyeron a la comprensión de los sistemas conexionistas.

La perspectiva ingenieril sobre los sistemas conexionistas dirige el diseño hacia redes tan eficientes como sean posibles (en términos de topología de red, respuestas correctas, y generalización) y el concepto general sobre estos mecanismos se ligó al cómputo neuronal, inspirado en la física e ingeniería y alejado de la biología (George et al., 1988).

Bajo la visión de la ciencia cognitiva, el conexionismo es usado para contestar preguntas concernientes al conocimiento humano desde la *percepción* hasta el más alto nivel llamado *atención* y *razonamiento*. Los científicos cognitivos-conexionistas se basan en la biología y no en la tecnología. Consecuentemente, los objetivos de la aproximación ingenieril no necesariamente aproximan a la ciencia cognitiva hacia el conexionismo.

Ciencia Cognitiva y Conexionismo

Raíces filosóficas

A pesar del considerable crecimiento de la investigación conexionista a partir de la década de los 80, éste no es un fenómeno nuevo. Aristóteles (ca. 400 B.C.) ha sido citado [Anderson et al., 1990] como el primer científico en proponer el concepto básico del conexionismo: "la memoria se compone de elementos individuales ligados o conectados entre sí a través de diferentes mecanismos como sucesión temporal, similitud de objetos, y proximidad espacial".

Mattie y Hobbes así como la escuela empírica británica encabezada por Berkeley, Locke y Hume extienden estas ideas y declaran que: i) los elementos mentales o ideas se asocian unas con otras a través de la experiencia, ii) que la experiencia consiste de contigüidad espacial, contigüidad temporal, similitud y disimilitud de ideas y iii) que estas ideas son muy complejas pero pueden ser reducidas a un conjunto de elementos simples (sensaciones) los cuales a través de sencillas reglas aditivas pueden ser convertidas en sujetos de predicción

Manifestaciones Psicológicas

Con el nacimiento de la psicología como un campo diferente de la filosofía, las ideas detrás del conexionismo se refinaron y concretaron su bases neurofisiológicas. Los trabajos de psicólogos como Spencer (1910) y James (1950) son ejemplos tempranos de redes conexionistas –redes que combinaron principios básicos de asociativismo con neurología.

a) Conexiones de Spencer

En *The Principles of Psychology*, Herbert Spencer (1910a,1910b) estableció que existe una conexión fundamental (básica) entre cambios nerviosos y estados físicos.

b) Memoria asociativa de James

William James (1950a, 1950b) postula que no existe modificación mental que no esté acompañada o seguida de un cambio en el cuerpo (primera referencia a los pesos entre neuronas).

c) Conexionismo de Thorndike

Edward Lee Thorndike trató a profundidad los estados de la mente (a partir del trabajo de Watson, 1913) y cómo cambian con la experiencia por lo que se le considera uno de los primeros conexionistas formales. En su libro, *The Fundamentals of Learning* (Thorndike, 1932) diferenció los principios del asociativismo británico del *nuevo conexionismo*. El conexionismo de Thorndike es un punto de giro donde las teorías de la asociación neuronal se hacen sub-simbólicas y graduadas en arquitecturas funcionales (Walter, 1990). En otras palabras, las conexiones neuronales se convierten en sustitutos para, en lugar de mecanismos de, procesos de ideas. Son sus leyes del *ejercicio* o *uso frecuente* y la del *efecto* los principios que subyacen a las actuales técnicas de entrenamiento supervisado (retropropagación, por ejemplo).

d) La regla de aprendizaje de Hull

Clark L. Hull (1943) describe varias propiedades funcionales de actividad neuronal que consideró importantes en los organismos vivos y fue el primero en desarrollar ecuaciones empíricas para describir el proceso de aprendizaje.

La influencia neurofisiológica

Siguiendo los trabajos pioneros de Sherrington y Cajal los esfuerzos en investigación se dirigieron al establecimiento de correlaciones entre el aprendizaje y la memoria. A partir de este paradigma dos grandes figuras en el conexionismo emergieron: Karl Lashley y Donald Hebb.

Aprendizaje Hebbiano

Quizá el trabajo más influyente en la historia del conexionismo es la contribución del neurofisiólogo Donald O. Hebb (estudiante de Lashley). En su libro, *The Organization of Behaviour* (Hebb, 1949) se describen (i) la existencia de propiedades de actividad cerebral continua y (ii) la naturaleza de la transmisión sináptica en el sistema nervioso central.

El concepto más importante que se desprende del trabajo de Hebb es su hipótesis formal de cómo ocurre el aprendizaje (postulado de Hebb),

“Cuando el axón de célula A está lo suficientemente cerca para excitar a la célula B y repetidamente o persistentemente toma parte en excitarla, algún tipo de crecimiento o cambio metabólico toma lugar en una o ambas células tal que la eficiencia de A, como una de las células excitadoras de B, sea incrementada”

La influencia matemática

La siguiente gran formulación de las teorías conexionistas puede atribuirse a McCulloch y Pitts (McCulloch y Pitts, 1943). En su trabajo *A logical calculus of the ideas immanent in nervous activity*, ellos simplificaron la actividad de las neuronas dentro de cinco estados funcionales:

1. La actividad de la neurona es un proceso “todo o nada”
2. Un número fijo de sinapsis debe ser excitado dentro del periodo de adición latente de manera que excite una neurona, este número es independiente de la actividad previa y la posición de la neurona.
3. El único retraso significativo entre el sistema nervioso es el retraso sináptico.
4. La actividad de una sinapsis inhibitoria previene completamente la excitación de la neurona en ese tiempo.
5. La estructura de la red no cambia con el tiempo.

Definición de Conexionismo

El Conexionismo es una teoría de procesamiento de información. A diferencia de los sistemas clásicos los cuales usan reglas explícitas, comúnmente lógicas, arregladas de manera jerárquica para manipular símbolos de manera serial, los sistemas conexionistas usan procesamiento paralelo de sub-símbolos con propiedades estadísticas en lugar de reglas lógicas para transformar la información.

La visión conexionista establece que los bloques de construcción básicos del cerebro son las neuronas y seis de sus propiedades funcionales (Dudai, 1989) son transportadas a las unidades artificiales:

- Es un dispositivo que recibe señales del ambiente o de otras neuronas.
- Es un dispositivo integrador y manipulador de entradas.
- Es un dispositivo conductor de la información integrada a distancia.
- Es un dispositivo de salida que envía información a otras neuronas o células.
- Es un dispositivo computacional que mapea un tipo de información a otro.
- Es un dispositivo que sub-ofrece la formación de representaciones internas.

Siguiendo estos puntos, Rumelhart, Hinton, y McClelland (Rumelhart et al., 1986) enlistan los 8 aspectos esenciales en los modelos neuronales, llamados PDP (Procesamiento Distribuido en Paralelo).

- Un conjunto de unidades de procesamiento
- Un estado de activación
- Una función de salida para cada unidad
- Un patrón de conectividad entre unidades
- Una regla de propagación para patrones de actividades propagándose a través de las conexiones de la red
- Una regla de activación para combinar las entradas con el estado actual de una unidad y producir un nuevo nivel de activación
- Una regla de aprendizaje por medio de la cual los patrones de conectividad son modificados por la experiencia.
- Un ambiente dentro del cual el sistema pueda operar.

Estas ocho propiedades de los modelos PDP se relacionan fácilmente en las seis propiedades funcionales de la neurona. La unidad de procesamiento es la neurona en sí. El estado de activación y la regla de activación son parte de la entrada y del dispositivo integrador de la neurona y la función de salida es simplemente la salida de la neurona. El patrón de conectividad y la regla de propagación se relacionan con la función conductiva de la neurona y la regla de aprendizaje y el ambiente operativo son parte de las funciones de representación y cómputo de la neurona (Fig. A.3.1.1).

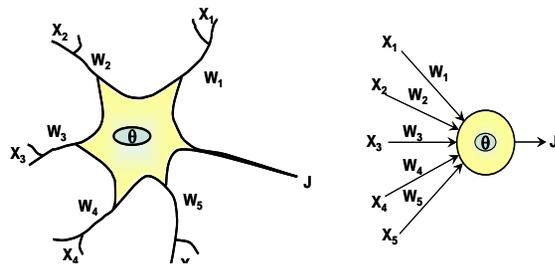


Figura A.3.1.1. Esquemas de una neurona biológica y una artificial

Primeros modelos computacionales de conexionismo

La influencia de la computadora en las teorías de aprendizaje puede verse como positiva y negativa cuando se trata del conexionismo. El *Pandemonium* de Selfridge (1959) y el *Perceptron* de Rosenblatt (1958, 1962) constituyen el esqueleto del conexionismo, pero las pruebas de las limitaciones de los perceptrones simples (Minsky y Papert, 1969), sin embargo, causaron el casi total abandono de este tipo de herramientas.

Pandemonium

Pandemonium (Selfridge, 1959) fue introducido como un modelo de aprendizaje que se auto-adaptaba para manejar problemas de clasificación de patrones sin especificaciones *a priori* a través de procesamiento en paralelo. El cambio hacia este tipo de procesamiento no fue arbitrario sino motivado por dos prominentes ventajas: (1) es más sencillo y *natural* manejar datos de forma paralela, y (2) es más fácil modificar un ensamble de módulos casi-independientes que una máquina cuyas partes interactúan secuencialmente de manera muy compleja.

Pandemonium consta de 4 capas o estratos cada una compuesta de *demonios* especializados en tareas específicas (Fig. A.3.1.2). El estrato del fondo contiene *demonios* de datos o imágenes que las almacenan y transmiten. El tercer estrato está compuesto de *demonios* computacionales que desarrollan cálculos complicados sobre los datos y después pasan los resultados al siguiente nivel. El segundo estrato está compuesto de *demonios* cognitivos quienes pesan la evidencia desde los *demonios* computacionales y "gritan" la evidencia hacia el estrato más alto de la red. Entre más evidencia se acumule, más fuerte será el grito. En el estrato más alto de la red está el *demonio* de decisión, quien simplemente escucha el grito más alto de los *demonios* cognitivos y decide qué fue presentado a la red.

La estructura de red inicial se determina *a priori* (de acuerdo con la tarea) excepto para el nivel computacional que se modifica por medio de dos diferentes mecanismos de aprendizaje. El primer mecanismo cambia los pesos de conexión entre los *demonios* cognitivos y los *demonios*

computacionales a través de aprendizaje supervisado (todas las otras conexiones entre la red permanecen fijas). Los pesos son entrenados usando un procedimiento de *gradiente ascendente* para optimizar el comportamiento de la red.

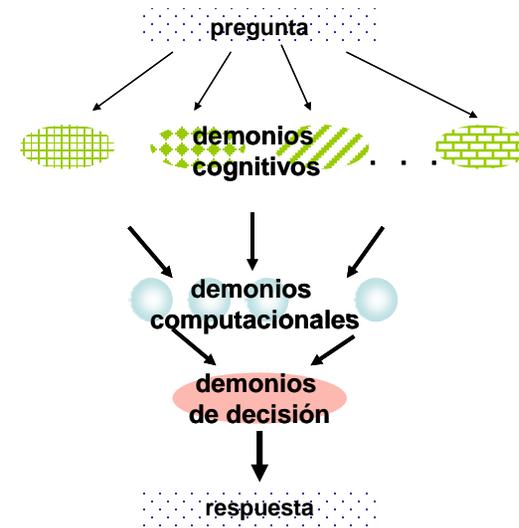


Figura A.3.1.2 *Pandemonium*

Después de que el aprendizaje supervisado se considera exitoso, un segundo mecanismo de aprendizaje es empleado. En este caso se seleccionan aquellos *demonios* computacionales importantes (basados en qué tanto influyen en la decisión), se eliminan aquellos con baja importancia y se generan nuevos *demonios* a partir de las características de los exitosos. Este segundo mecanismo es uno de los primeros algoritmos genéticos aplicados al aprendizaje-máquina.

Perceptrón

El *Perceptrón* (Rosenblatt, 1958) (o la teoría de la separabilidad estadística) alcanza más de los requerimientos funcionales del sistema nervioso que ningún otro sistema propuesto antes que él.

A pesar de que originalmente se intentó un modelo genotípico del funcionamiento de cerebro (Rosenblatt, 1958; Rosenblatt, 1962), el perceptrón representa la génesis de las máquinas de reconocimiento de patrones.

Básicamente se trata de un artefacto computacional en paralelo compuesto de (i) una capa de unidades sensoriales (S-unidades) las cuales transducen energía física (e.g. luz, sonido, etc.) a una señal, (ii) cualquier número de capas de unidades de asociación (A-unidades) las cuales tienen conexiones de entrada y de salida, y (iii) una capa final de unidades de respuesta (R-unidades) que emiten una señal para transmitir al mundo exterior (Fig. A.3.1.3).

En un perceptrón elemental las unidades-S están conectadas a las unidades A (no necesariamente masivamente conectadas) y todas las unidades-A están conectadas a una sola unidad-R, ninguna otra conexión es permitida. Debido a la importancia de este sistema, una exposición más detallada se presenta en una sección posterior de este mismo Apéndice.

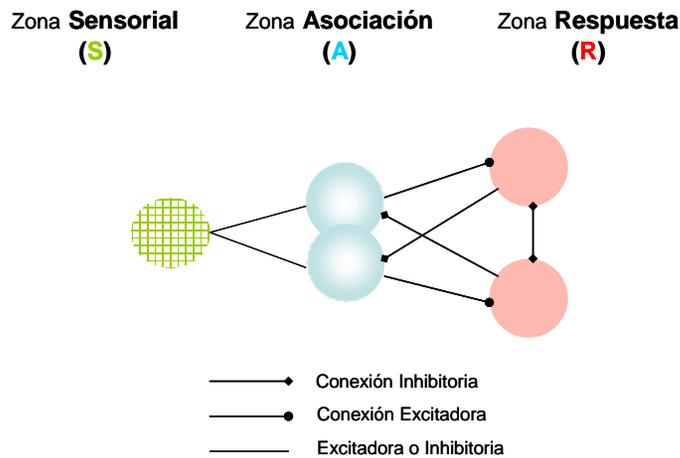


Figura A.3.1.3 *Perceptrón*

Adaline

La siguiente formulación en reglas de aprendizaje para redes se debe a Widrow y Hoff (Widrow y Hoff, 1960). Ellos desarrollaron *Adaline* (primero por *adaptive linear*, después *adaptive linear neuron* y posteriormente *adaptive linear element*) como una máquina de clasificación de patrones adaptativa. El procedimiento de aprendizaje se basó en un proceso iterativo de búsqueda que usa retroalimentación para guiar dicho proceso. El diseñador *entrena* al sistema por medio de ejemplos de entradas-salidas haciendo que la competencia de la red se relacione directa y cualitativamente con la cantidad de experiencia ofrecida al sistema.

La unidad *adaline* típica, también llamada “elemento neurona”, es un circuito lógico combinatorio que suma las señales a partir de las conexiones pesadas (ganancias), a_i , y luego envía una señal de salida si la señal interna excede algún umbral (una ganancia modificable, a_0). *Adaline* usa señales de entrada de -1 y +1 lo cual significa que una señal pasa siempre a lo largo de una conexión (a menos que la ganancia en la línea sea cero). Las ganancias en las conexiones se ajustan tal que las señales de salida sean exactamente -1 o +1; por lo tanto, la clasificación no puede ser *simplemente correcta*, sino *exactamente correcta*. Esta restricción en las salidas significa obligar al aprendizaje a continuar aún si la clasificación es *simplemente correcta* (resultado que no es *exactamente* -1 o +1).

Revisión de los Perceptrones

A pesar de que se sabía de las limitaciones de los perceptrones, no fue sino hasta el trabajo de Minsky y Papert, *Perceptrons* (1969), que estas dificultades fueron totalmente comprendidas. De hecho, fue con esta publicación que la ola conexionista se desaceleró (por lo menos durante algunos años). En lugar de preguntar si las redes neuronales eran buenas, Minsky y Papert se preguntaron “para qué son buenas las redes neuronales?”. Esto es claramente una pregunta a nivel computacional generada con el fin de identificar las limitaciones en las habilidades de representación de las redes tipo perceptrón.

Como Minsky y Papert apuntaron en su prólogo a la edición de 1988 de *Perceptrons*, “No hay máquina que pueda aprender a reconocer X a menos que ella posea, por lo menos potencialmente, algún esquema para representar X”. El estudio de las redes neuronales se basó en ejercicios prácticos de reconocimiento de patrones visuales que llevó a descubrir que algunos problemas (por ejemplo distinguir triángulos de cuadrados) fueron relativamente fáciles y podían ser calculados por redes simples (Papert, 1988). Algunos otros problemas (determinar si una cierta figura fue presentada o no, por ejemplo) resultaron extremadamente difíciles y requirieron redes muy grandes para resolverlos. La principal diferencia entre estos dos tipos de problemas no fue el tamaño del espacio de patrones, sino el orden (Minsky y Papert, 1969).

Las funciones que tienen un orden de 1, llamadas “linealmente separables”, pueden ser resueltas por medio de un perceptrón con una sola capa. Las tareas de reconocimiento que no pudieron ser resueltas por los perceptrones simples fueron aquellas cuyo orden fue mayor a 1. Este tipo de problemas, llamados “linealmente no-separables”, requieren de un estrato de unidades de procesamiento entre las unidades de entrada y las de salida y en aquel momento no existía un método formal para entrenar este nivel intermedio, así los perceptrones se limitaron a participar sólo en problemas linealmente separables.

A pesar de que los avances en la investigación sobre redes neuronales han producido métodos para entrenar múltiples capas de unidades (Rumelhart et al, 1986), muchas de las preocupaciones de Minsky y Papert continúan sin ser resueltas. Las redes que usan unidades de frontera lineales todavía violan la

restricción de orden límite cuando se enfrentan con problemas no separables linealmente. Más aún, el escalamiento de los pesos conforme el tamaño del espacio del problema se incrementa continúa siendo un punto a discutir (Feldman-Stewart y Mewhort, 1994).

Nuevo Conexionismo

Esta sección trata con la descripción de los sistemas conexionistas en la era post-perceptrón; esto es, redes del nuevo conexionismo. El nuevo conexionismo se caracteriza por redes poderosas computacionalmente que pueden ser entrenadas totalmente y han sido llamadas *mecanismos de aprendizaje universal* (Gallistel, 1995). Los algoritmos de aprendizaje involucrados en el nuevo conexionismo han generado procesadores de información muy poderosos –aproximadores funcionales universales (Cybenko, 1989) y clasificadores de patrones arbitrarios (Lippman, 1987).

Las *post-matemáticas* de la revolución de las redes neuronales han permitido que el número de arquitecturas conexionistas disponibles el día de hoy sea inmenso; la discusión de todas ellas está más allá del objetivo de este trabajo, pero es importante describir algunas arquitecturas básicas cuyos principios son comunes en la mayoría de las propuestas conexionistas actuales.

Arquitecturas Conexionistas Modernas

Interactive Activation and Competition (IAC) (McClelland, 1981), el primer ejemplo de conexionismo moderno, es un modelo de manejo de información a partir de conocimiento almacenado. Las primeras versiones de la arquitectura IAC no aprendían, pero desplegaban características del conocimiento humano que eran obviadas en los modelos simbólicos clásicos.

Siguiendo las bases de la red IAC surgieron las configuraciones de Grossberg (1974, 1976) (*instar* y *outstar*) y su red ART (de *Adaptive Resonance Theory*) y los mapas de auto-organización de Kohonen (1982) (redes Kohonen).

La **arquitectura genérica PDP** (procesamiento distribuido en paralelo) es una red multi-capas entrenada con el algoritmo de retropropagación (Rumelhart et al., 1986). La red PDP es probablemente la mejor conocida y más ampliamente usada arquitectura en la actualidad y se estima que cerca del 80% de las aplicaciones *reales* usan el algoritmo de retropropagación (Werbos, 1995) para tareas tanto de aproximación de funciones como de problemas de clasificación de patrones.

Una primera crítica a la arquitectura PDP fue su limitada capacidad de mapeo estático cuando el cerebro es un sistema dinámico no-lineal altamente dimensional (Doya, 1995). Para salvar esta desventaja, Hopfield (1982) presenta su arquitectura recurrente donde la activación de procesamiento (usualmente la salida) en el tiempo t es re-usada (usualmente como una entrada) en el tiempo $t+1$. Una red recurrente completamente conectada es potencialmente una arquitectura de procesamiento temporal; sin embargo, requiere de algoritmos muy poderosos para lograr un verdadero aprendizaje.

La red genérica PDP

Un perceptrón elemental tiene, en principio, el capacidad para resolver cualquier problema de clasificación de patrones expresado en notación binaria (separable linealmente), mientras que una red multicapa puede teóricamente cortar un espacio de patrones en un número arbitrario de regiones de decisión (Lippman, 1987). Se ha demostrado teóricamente que tales redes son aproximadores de funciones universales (esto es, capaces de resolver cualquier problema de aproximación de funciones de cualquier grado) (Cybenko, 1989; Hartman et al., 1990; Hornik et al., 1989).

Es fundamental entender que las pruebas de capacidad y eficiencia se concentran en arquitecturas, sin modificar las reglas de aprendizaje. Distinguir entre arquitectura y regla de aprendizaje permite (i) apuntar lo concerniente a “plausibilidad biológica” de ciertos algoritmos de aprendizaje sin comprometer la interpretación y resultados finales de una red entrenada y (ii) determinar si las diferencias en el desarrollo de las redes se deben a deficiencias de arquitectura o a modificaciones en el algoritmo de aprendizaje.

Referencias

- Aizawa, K. (1992). *Connectionism and artificial intelligence: History and philosophical interpretation*. *Journal of Experimental Artificial Intelligence*, 4:295-313.
- Anderson, J. A., Pellionisz, A. and Rosenfeld, E. editors. (1990). *Neurocomputing 2*. MIT Press, Cambridge, MA.
- Arbib, M. A. editor. (1995). *The Handbook of Brain Theory and Neural Networks*. MIT Press, Cambridge, MA.
- Bechtel, W. and Abrahamsen, A. (1991). *Connectionism and the Mind: An Introduction to Parallel Processing in Networks*. Blackwell, Cambridge, MA.
- Cybenko, G. (1989). *Approximation by superpositions of a sigmoidal function*. *Mathematics of Control, Signals, and Systems*, 2:303-314.
- Dawson, M.R.W. (1998). *Understanding Cognitive Science*. Blackwell, Oxford.
- Dawson, M.R.W., Medler, D.A. and I.S.N. Berkeley. (1997). *PDP networks can provide symbolic models that are not mere implementations of classical theories*. *Philosophical Psychology*, 10:25-40.
- Doya, K. *Recurrent networks: Supervised learning*. In Arbib, 1995, pages 796-800.
- Dudai, Y. (1989). *The Neurobiology of Memory*. Oxford University Press, Oxford.
- Feldman-Stewart, D. and Mewhort, D.J.K. (1994). *Learning in small connectionist networks does not generalize to large networks*. *Psychological Research*, 56:99-103.
- Gallant, S.I. (1993). *Neural Network Learning and Expert Systems*, MIT Press, Cambridge, MA.

- Gallistel, C.R. (1995). *The replacement of general-purpose theories with adaptive specializations*. In M. S. Gazzaniga, editor, *The Cognitive Neurosciences*, pages 1255-1267. MIT Press, Cambridge, MA.
- George, J., Reeke, N. and Edelman, G.M. (1988). *Real brains and artificial intelligence*. In S. R. Graubard, editor, *The Artificial Intelligence Debate*. MIT Press, Cambridge, MA.
- Grossberg, S. (1974). *Classical and instrumental learning by neural networks*. *Progress in Theoretical Biology*, 3:51-141.
- Grossberg, S. (1976). *Adaptive pattern classification and universal recoding: I. parallel development and coding of neural feature detectors*. *Biological Cybernetics*, 23:121-134.
- Hartman, E. J., Keeler, J. D. and J. Kowalski, M. (1990). *Layered neural networks with gaussian hidden units as universal approximations*. *Neural Computation*, 2:210-215.
- Hebb, D.O. (1949). *The Organization of Behaviour*. John Wiley & Sons, New York.
- Hinton, G.E. and Anderson, J.A. editors. (1981.) *Parallel Models of Associative Memory*. Lawrence Erlbaum Associates, Hillsdale, NJ.
- Hopfield, J.J. (1982). *Neural networks and physical systems with emergent collective computational abilities*. *Proceedings of the National Academy of Sciences*, 79:2554-2558.
- Horgan, T. and Tienson, J. (1996.) *Connectionism and the Philosophy of Psychology*. MIT Press, Cambridge, MA.
- Hornik, K., Stinchcombe, M. and White, H. (1989). *Multilayer feedforward networks are universal approximators*. *Neural Networks*, 2:359-366.
- Hull, C.L. (1943). *Principles of Behavior*. Appleton-Century-Crofts, New York.
- James, W. (1890/1950). *The Principles of Psychology*, volume 1. Dover, New York.
- James, W. (1890/1950). *The Principles of Psychology*, volume 2. Dover, New York.
- Kohonen, T. (1982). *Self-organized formation of topologically correct feature maps*. *Biological Cybernetics*, 43:59-69.
- Lippman, R.P. (1987). *An introduction of computing with neural nets*. *IEEE ASSP Magazine*, April:4-22.
- McClelland, J.L. (1981). *Retrieving general and specific information from stored knowledge of specifics*. In *Proceedings of the Third Annual Meeting of the Cognitive Science Society*, pages 170-172.
- McClelland, J.L., Rumelhart, D.E. and the PDP Research Group, editors. (1986). *Parallel Distributed Processing*, volume 2: *Psychological and Biological Models*. MIT Press, Cambridge, MA.
- McCulloch, W.S. and Pitts, W. (1943). *A logical calculus of the ideas immanent in nervous activity*. *Bulletin of Mathematical Biophysics*, 5:115-133.
- Minsky, M. and Papert, S.A. (1988/1969). *Perceptrons: An Introduction to Computational Geometry*. MIT Press, Cambridge, MA, expanded edition.
- Mozer, M.C., Halligan, P.W. and J. C. Marshall. (1997). *The end of the line for a brain-damaged model of unilateral neglect*. *Journal of Cognitive Neuroscience*, 9:171-190.
- Papert, S. (1988). *One AI or many?* *Daedalus*, 117:1-14.
- Plunkett, K. (1995). *Connectionist approaches to language acquisition*. In P. Fletcher and B. MacWhinney, editors, *The Handbook of Child Language*, pages 36-72. Blackwell, Oxford.
- Rosenblatt, F. (1958). *The perceptron: A probabilistic model for information storage and organization in the brain*. *Psychological Review*, 65:386-408.
- Rosenblatt, F. (1962). *Principles of Neurodynamics*. Spartan, Washington, DC.
- Rumelhart, D.E., Hinton, G.E. and McClelland, J.L. *A general framework for parallel distributed processing*. In Rumelhart et al. 1986 pages 45-76.
- Rumelhart, D.E., Hinton, G.E. and Williams, R. J. *Learning internal representations by error propagation*. In Rumelhart et al, 1986, pages 318-362.
- Rumelhart, D.E., Hinton, G.E. and Williams, R. J. (1986). *Learning representations by back-propagating errors*. *Nature*, 323:533-536.
- Rumelhart, D.E., McClelland, J.L. and the PDP Research Group, editors. (1986). *Parallel Distributed Processing*, volume 1: *Foundations*. MIT Press, Cambridge, MA.
- Rumelhart, D.E. and Norman, D.A. *Parallel associative models of memory: Where do they fit?* In Hinton and Anderson, 1981.
- Schneider, W. (1987). *Connectionism: Is it a paradigm shift for psychology?* *Behavior Research Methods, Instruments, and Computers*, 19:73-83.
- Selfridge, O.G. and Neisser, U. (1960). *Pattern recognition by machine*. *Scientific American*, 203:60-67.
- Selfridge, O.G. (1959). *Pandemonium: A paradigm for learning*. In D. V. Blake and A. M. Uttley, editors, *Proceedings of the Symposium on Mechanisation of Thought Processes*, pages 511-529, London. H. M. Stationary Office.
- Siegelmann, H.T. and Sontag, E.D. (1994). *Analog computation via neural networks*. *Theoretical Computing Science*, 131:331-360.

Skinner, B.F. (1938). *The Behavior of Organisms*. Appleton-Century-Crofts, New York.

Spencer, H. (1855/1910). *The Principles of Psychology, volume 1*. D. Appleton and Company, New York, 3rd edition.

Spencer, H. (1855/1910). *The Principles of Psychology, volume 2*. D. Appleton and Company, New York, 3rd edition.

Thagard, P. (1996). *Mind: Introduction to Cognitive Science*. MIT Press, Cambridge, MA.

Thorndike, E.L. (1932). *The Fundamentals of Learning*. Teachers College, Columbia University, New York.

Walker, S.F. (1990). A brief history of connectionism and its psychological implications. *AI & Society*, 4:17-38.

Watson, J. B. (1913). Psychology as the behaviorist views it. *Psychological Review*, 20:158-177.

Werbos, P.J. Backpropagation: Basics and new developments. In Arbib, 1995, pages 134-139.

White, H. (1988). Economic prediction using neural networks: The case of IBM daily stock returns. In *Proceedings of the IEEE International Conference on Neural Networks*, pages II-451-II-459, San Diego,

Widrow, B. and Hoff. (1960). M.E. Adaptive switching circuits. In *1960 IRE WESCON Convention Record*, pages 96-104, New York, IRE.

Zapranis, A.D. and Refenes, A.N. Investment management: Tactical asset allocation. In Arbib, 1995, pages 491-495.

7.3.Apéndice 3.1.B

Aprendizaje Neuronal – Teoría del Caos

Los paradigmas inspirados en la espontánea habilidad de los sistemas biológicos para adaptar su estructura y funciones a situaciones *problemáticas*, representan una ventajosa alternativa en el estudio y desarrollo de modelos sobre fenómenos naturales.

Las RNs son sistemas paralelos, dinámicos y adaptativos cuyo funcionamiento emula hechos generales propios de las redes biológicas. Una RN interactúa con los objetos y sus características estadísticas de formas similares a las que desarrollan los seres vivos.

Colectivamente las neuronas pueden llevar a cabo funciones tan complejas como identificación y corrección de errores, reconstrucción de información y análisis de patrones. Su fuerza paradigmática en aplicaciones prácticas (resolver problemas computacionales inflexibles o modelado adaptativo) reside en su habilidad para conseguir *síntesis funcional* (mapeo topológico) (Josin, 1988) y *abstracción espacial, funcional o temporal* de estos mapeos, a través del establecimiento de relaciones entrada→salida con base en ejemplos característicos.

Una vez que las invarianzas que están detrás de los datos presentados han sido aprendidas y codificadas en la topología y resistencias de las interconexiones sinápticas, la RN puede generalizar para resolver instancias de problemas arbitrarios. Además, las versiones operacionales de estas redes pueden ser “regularizadas” dinámicamente sin re-entrenamiento explícito (Barhen y Gulati, 1989) o reprogramación. Ya que los mapeos topológicos se alcanzan a partir de ejemplos *reales*, la funcionalidad de las redes no está limitada a hipótesis que observan la incertidumbre paramétrica o de ambiente, por lo que ofrecen una atractiva base para desarrollar algoritmos alternativos que resuelvan problemas con estrategias más poderosas que la tecnología existente.

Aprendizaje neuronal y la Teoría del Caos

Una red neuronal constituye un sistema dinámico no lineal disipativo cuyo flujo de información generalmente converge hacia un conector múltiple de baja dimensión en el espacio de fase. Tal sistema neuromórfico puede almacenar estados de memoria (o patrones) en puntos fijos de la dinámica de red, es decir, configuraciones de neuronas en alguna vecindad o cuenca de atracción hacia las que el estado de memoria será atraído. Para sustentar la competencia de las redes es muy importante conocer qué tan estables son estos atractores y, comenzando desde una configuración de red arbitraria, qué tan rápido pueden ser alcanzados. Sobre esta línea de análisis, un concepto de la teoría de sistemas dinámicos, los *atractores terminales*, permite formalizar la eficiencia de los algoritmos neuronales en términos de *aprendizaje*.

Atractores Terminales. Los atractores estáticos considerados en las simulaciones de sistemas dinámicos no lineales (como las redes neuronales) representan soluciones regulares a ecuaciones diferenciales de movimiento que nunca intersecan los estados transitorios (Fig. 1a). Teóricamente el tiempo de relajación del sistema a estos atractores “regulares” puede ser infinito y sufren de convergencia a mínimos locales o estados falsos. El concepto de atractor terminal en redes neuronales fue introducido por Zak (1988) para obviar algunas de las anteriores limitaciones y mejorar significativamente las características de comportamiento de los modelos neuronales de memoria asociativa.

La existencia de los atractores terminales fue establecida con el siguiente argumento: en equilibrio, los puntos fijos de un sistema dinámico disipativo

$$\dot{u}_n - f_n(u_1, u_2, \dots, u_N) = 0, \quad \text{para } n = 1, 2, \dots, N, \quad \text{se definen como sus soluciones constantes } u_n(\infty).$$

Si las partes reales de los eigenvalores μ_ξ de la matriz Jacobiana $M_{nm} = [\partial f_n / \partial u_m]$ en un punto fijo son todos negativos $\text{Re}\{\mu_\xi\} < 0$, entonces estos puntos son estables asintóticamente de manera local. Estos puntos son llamados atractores estáticos porque cada movimiento a lo largo

de la curva de fase consigue acercarse lo suficiente a $\bar{u}(\infty)$ (entra a la cuenca de atracción) y se aproxima al valor constante que corresponde a un cierto límite cuando t tiende a infinito.

Un punto de equilibrio representa un repulsor si por lo menos uno de los eigenvalores de la matriz M tiene una parte real positiva. Comúnmente las redes neuronales no lineales sólo generan sistemas que satisfacen la

condición de Lipschitz $|\partial f_n / \partial u_m| < \infty$. Esta condición garantiza la existencia de la solución única para cada configuración de espacio de fase inicial y explica porqué una solución transitoria no puede intersecar la solución constante correspondiente a la cual tiende, y por lo tanto, el tiempo teórico de aproximación a los atractores es siempre infinito. La evolución temporal del atractor se muestra en la Fig. B.3.1.1a.

En contraste, la noción del atractor terminal se basa en la violación de la condición de Lipschitz. Ahora un punto fijo se convierte en una solución singular (única) que cubre la familia de las soluciones regulares, mientras que cada solución regular se aproxima al atractor terminal en tiempo finito (Fig. B.3.1.1b).

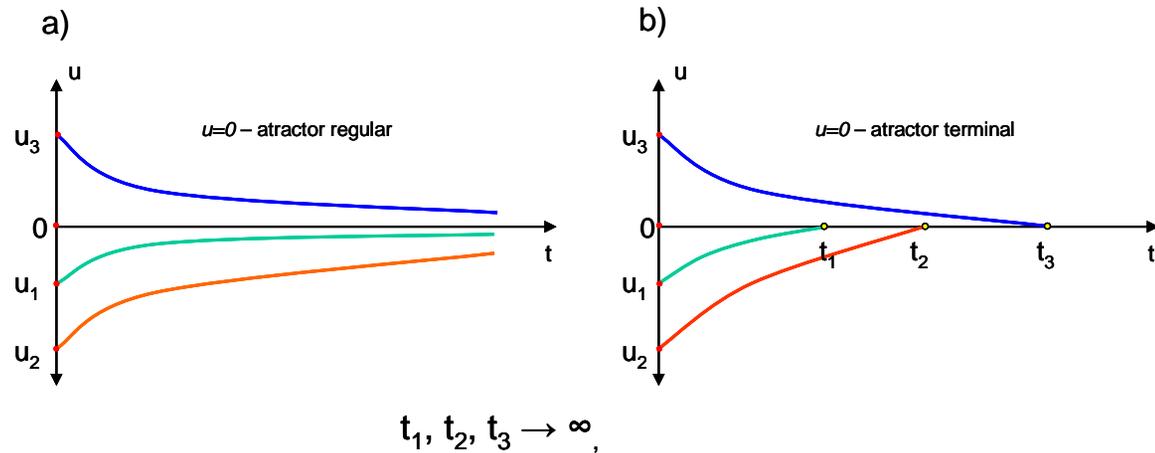


Figura B.3.1.1. a) Relajación asintótica de atractores regulares, b)atractor Terminal como solución única a un sistema dinámico

Para mostrar formalmente un atractor terminal considere el siguiente ejemplo unidimensional simple:

$$\dot{u} = -u^{1/3}$$

Esta ecuación tiene un punto de equilibrio $u = 0$ en el que la condición de Lipschitz no se cumple en

$$\frac{d\dot{u}}{du} = -\frac{1}{3}u^{-2/3}$$

$$\rightarrow -\infty \text{ en } u \rightarrow 0$$

Cuando $\text{Re}\{\mu\} \rightarrow -\infty$, este punto es un atractor con estabilidad local "infinita". Como una consecuencia, el sistema dinámico contiene "poder de atracción infinita". En una red neuronal codificada para mapeo, el fenómeno anterior implica inmediatamente relajación a las coordenadas del atractor deseadas, x_n y q_n .

De acuerdo con el ejemplo ilustrativo, el tiempo de relajación de la solución correspondiente a las condiciones iniciales $u = u_0$ hacia el atractor es finito y está dado por

$$t_u = - \int_{u_0}^{u \rightarrow 0} \frac{du}{u^{1/3}}$$

$$= \frac{3}{2} u_0^{2/3} < \infty$$

por lo que este atractor se convierte en atractor terminal y representa una solución singular (única) intersecada por todos los transeúntes atraídos.

Por lo tanto, si uno considera el caso más general $\dot{u} = \pm u^\beta, \beta > 0$ los atractores terminales estáticos ocurren para $\beta = (2i + 1)^{-1}$ y $i \geq 1$, mientras que en caso contrario todos los atractores son regulares. De esta manera ha sido demostrado que incorporar atractores terminales en las dinámicas neuronales pueden eliminar estados falsos (mínimos locales) (Zak, 1988).

Asegurar esta propiedad es un aspecto crítico para ofrecer confianza en la capacidad de generalización en operación de las redes propuestas en esta investigación. De esta manera se asegura que las interpolaciones (o extrapolaciones) de las configuraciones no están basadas en atractores falsos y sobre todo, en un marco neuromórfico, la dinámica de un atractor terminal ofrece el mecanismo para, implícitamente, explotar en tiempo restringido la “terminalidad” de las trayectorias de fase y la estabilidad infinita (localmente) permitiendo soluciones exactas y eficientes.

Aproximación universal y sus límites en SC

En 1900, en su memorable conferencia durante el Segundo Congreso Internacional de Matemáticas en París, Hilbert enlistó 23 hipótesis sobre problemas que él consideraba como los más importantes a resolver por los matemáticos del siglo XX. De acuerdo con la conjetura no. 13 existen funciones multivariadas continuas que no pueden ser descompuestas como una superposición finita de funciones continuas de pocas variables:

“existe por lo menos una función continua de tres variables, ejemplificada por $f^7 + xf^3 + yf^2 + zf + 1 = 0$ la cual podría no ser descompuesta como una superposición finita de una función continua bi-variable”

En 1957 Arnold desaprobó esta hipótesis (Arnold, 1957) y en el mismo año, Kolmogorov (1957) mostró un teorema de representación general con una prueba constructiva donde las funciones en la descomposición fueron unidimensionales.

El teorema de representación de Kolmogorov fue mejorado por varios autores como Sprecher (1965) y Lorentz (1966) siendo De Figueiredo (1980) quien mostró que este teorema puede ser generalizado para una red neuronal multicapa de propagación al frente y por lo tanto éstas podrían ser consideradas aproximadores universales (De Figueiredo, 1980; Blum y Li, 1991; Hornik et al., 1989; Kurkova, 1992).

Resultados similares fueron establecidos desde el comienzo de los 90 sobre lógica difusa (Castro, 1995; Kosko, 1992; Wang, 1992, por ejemplo) mostrando la capacidad de diferentes métodos de razonamiento difuso para aproximar cualquier función continua en un dominio compacto con cualquier exactitud específica.

Sin embargo, se ha demostrado que los modelos neuronales y difusos tienen una complejidad exponencial en términos del número de variables de la función original, esto significa que, (en el contexto de redes neuronales) el número de unidades en los estratos ocultos, o (en el contexto de lo difuso) el número de reglas o bloques de reglas, crece exponencialmente conforme el error de aproximación tiende a cero. Esta exponencialidad no puede ser eliminada por lo que la propiedad de aproximación universal de estos sistemas basados en la incertidumbre no puede ser explotada directamente para propósitos prácticos.

Además, para algunos sistemas difusos especiales, por ejemplo controladores del tipo Takagi-Sugeno, (Moser, 1999; Tikk, 1999) se ha probado que si se limita el número de bloques de construcción (reglas), el conjunto de funciones resultante no puede ser “denso” en el espacio de las funciones aproximadas, es decir, se convierte en un *quasi*-conjunto discreto (Klement et al., 1999).

Estos resultados mutuamente contradictorios hacen surgir la pregunta: ¿en qué extensión la *aproximación* se cataloga como exacta?. Desde el punto de vista práctico es suficiente tener una “buena” aproximación y, de acuerdo con el problema por resolver, el modelador determine la aceptación en términos de exactitud. La tarea es encontrar un posible intercambio (equilibrio) entre la exactitud especificada y el número de unidades de construcción que permitan que sea factible (en términos de tiempo) dicha aproximación.

Pocos resultados han sido publicados en los campos teóricos de las RNs y la LD acerca de la determinación del número de bloques de construcción como función de la exactitud. En RNs, Blum y Li (1991) determinaron un límite superior para el número de unidades Mc-P (McCulloch-Pitts) para redes de tres capas (sólo una oculta). En el caso de redes de propagación al frente multicapa, Kurková (1995) fijó el límite superior para el número de unidades en capa ocultas con funciones de activación sigmoidales. Por su parte, en teoría difusa y para algunas aplicaciones prácticas de funciones de membresía específicas, Kóczy y Zorat (1997) determinaron el error de aproximación (el peor caso) y el costo parametrizado de la inexactitud en las funciones de aproximación. Para los controladores del tipo Takagi-Sugeno, Ding et al., (2000), Ying et al., (1998) y Zeng et al., (2000) determinaron las condiciones mínimas necesarias para la configuración del sistema en exactitud específica.

Es importante remarcar que el formalismo en topología es conveniente para probar sólo la existencia de la aproximación y no ofrece los medios para construir el aproximador por sí mismo. Para que el lector interesado en el proceso de construcción y su repercusión sobre la actuación final del sistema se recomienda (Haykin, 1999; Hellendoom et al., 1993; Jang et al., 1997).

Resultados positivos en aproximación universal.

Aproximación universal en RN

Los primeros resultados sobre RNs se basan en el teorema de representación de Kolmogorov (De Figueredo, 1980). Hecht-Nielsen (1987) reformularon el teorema de Sprecher estableciendo que cualquier función continua definida en I^n podría ser implementada (de manera exacta) por una red de tres estratos con $2n+1$ unidades en el estrato oculto y con funciones de transferencia $\lambda^{ps} \psi_q$ ($p=1, \dots, n; q=1, \dots, 2n+1$) -de la entrada a las unidades ocultas- y ϕ -desde las ocultas a la salida-. Con esto quedó demostrada la universalidad ya que ψ_q podría ser explotada para aproximar funciones de dimensión más alta usando el teorema de representación de Kolmogorov, esto es, cualquier función que satisfaga completamente las condiciones anteriores puede ser aproximada por medio de una red neuronal teniendo funciones Kolmogorov como funciones de activación.

Sin embargo, las funciones ϕ y ψ_q ($q=1, \dots, 2n+1$) pueden tener incluso gráficas fractales y están lejos de ser funciones de activación típicas. De acuerdo con Poggio y Girosi (1989) el resultado de Kolmogorov no es relevante para RN porque las unidades de red Kolmogorov tienen funciones complejas.

Los primeros resultados sobre una clase general de redes neuronales con funciones de activación "normales" y capacidad de aproximación universal fueron publicados por Hornik et al., (1989). Ellos probaron que cualquier función continua $f \in C(I^n)$ puede ser aproximada (con exactitud arbitraria) en la norma suprema por una red de alimentación al frente de tres estratos (entrada-oculto-salida) con unidades ocultas semi-lineales con función límite y una unidad de salida lineal, lo que se expresa formalmente como:

$$\left| f(x) - \sum_{i=1}^m w_i g \left(\sum_{j=1}^n a_{ij} x_j + c_i \right) \right| < \varepsilon$$

donde los número reales w_i y a_{ij} son los pesos y c_i los límites. Las unidades semi-lineales tienen la forma $g(L(x) - b)$ donde $L(x)$ es

lineal en x , y la función g es una función real monotónica con los límites $\lim_{x \rightarrow -\infty} g(x) = 0$ y $\lim_{x \rightarrow \infty} g(x) = 1$ usualmente llamada

limitante cerrado y g puede ser una función sigmoideal, por ejemplo $\sigma(z) = 1/(1 + e^{-z})$ o la función escalón

$$H(z) = \begin{cases} 1 & \text{si } z > 0 \\ 0 & \text{si } z \leq 0 \end{cases}$$

Adicionalmente, en (Hornik et al., 1989) se prueba que cualquier función $f \in L_2(I^n)$ (en el espacio de L_2 -funciones integrables) puede ser aproximada (con exactitud arbitraria) respecto a la norma L_2 por redes de tres estratos.

Resultados similares se han presentado en redes de retro-propagación (Cybenko, 1989; Funahashi, 1989; Castro et al., 2000) pero estos trabajos no fueron construidos de forma simple y las pruebas dependen de teoremas existenciales (revisar el de Stone-Weierstrass o el de Hahn-Banach en (Cybenko, 1989) por lo que no se presentarán en este trabajo de investigación.

Aproximación Universal en Sistemas Difusos.

Los primeros trabajos concernientes a las capacidades de los sistemas difusos tienen un planteamiento práctico y muestran experimentalmente cómo cualquier función no lineal continua, expresada dentro de un universo de discurso compacto, es posible aproximarla (con exactitud arbitraria) por medio de un sistema de control difuso (Kawamoto, 1992). Es a partir de estos lineamientos que se producen los postulados matemáticos que validaron los anteriores planteamientos y resultados.

Kosko (1992) probó que los controladores del tipo Mamdani (sistemas difusos aditivos que en términos de estructura y parámetros son similares al método Mamdani) podían aproximar uniformemente $f \in C(X)$ donde X es compacta. Aquí debe puntualizarse que a pesar de que el teorema es

presentado como válido para cualquier compacta $X \subset \mathfrak{R}^n$ la prueba fue aplicada sólo en espacios de entrada unidimensional.

El número de reglas puede estimarse por medio de la distancia mínima entre los centros de dos conjuntos adyacentes. Si estos conjuntos son denotados

por y_i y $y_i + 1$ entonces para ε -aproximación:

$$|y_i - y_{i+1}| < \frac{\varepsilon}{2p-1}$$

donde P es el número máximo de los antecedentes traslapados sobre X (2 para entrada unidimensional). A partir de esto, si la exactitud pre-establecida es ε , el número de reglas en la base debería ser

$$|\mathfrak{R}| \geq \frac{|X|}{\varepsilon}$$

A partir de la ecuación anterior se desprende que para una aproximación arbitraria el número de reglas es ilimitado, sin embargo, para una pre-escrita ε el número de reglas puede ser estimado usando dicha desigualdad.

Al mismo tiempo, los resultados de Wang (Wang y Mendel, 1991; Wang, 1992) mostraron que un tipo diferente de sistemas basados en reglas difusas tiene propiedades similares. En (Wang, 1992) investigó los sistemas con múltiples entradas y reglas de salida únicas, donde sea que se usaran funciones de membresía exponenciales positivas sobre todo el dominio de las entradas y por lo tanto de las reglas consecuentes, con el algoritmo de inferencia de Larsen y con el proceso difuso inverso del Centroide. Probó que un conjunto de estos controladores difusos podría aproximar cualquier función continua con exactitud arbitraria respecto a la norma suprema. También aplicó el teorema de Stone-Weierstrass, como lo hicieron Hornik et al. (1989) para mostrar que el conjunto de funciones entrada-salida de los

controladores anteriores es denso en $C(I^n)$. Desafortunadamente la misma dificultad técnica se mantiene como en el caso del teorema de Kosko: el número y los términos de las reglas en la base no están limitados.

Numerosos autores han contribuido en este tema mostrando que la propiedad de aproximación universal se mantiene para varios tipos de sistemas difusos (por ejemplo, Buckley, 1993;1995; Nguyen y Kreinovich, 1992). El trabajo más general fue publicado por Castro et al. (2000) y en él se ofrece una prueba para cada clase de lógicas difusas y por cada tipo fijo de función de membresía perteneciente a un amplio grupo de funciones de membresía. Las pruebas muestran que un sistema de control de lógica difusa es capaz de aproximar cualquier función real continua sobre un conjunto compacto con exactitud arbitraria. A pesar de esto, como se aclara en las conclusiones de Castro et al. (2000), ni el proceso de construcción ni el número de reglas requeridas se pre-definen y éstas últimas permanecen sin límite.

Recientemente ha sido demostrado que sistemas difusos más generales y que no están incluidos en el trabajo de Castro (por ejemplo los que usan inferencia t-norma y t-co-norma) poseen la propiedad de aproximación universal (Yager y Kreinovich, 2003).

En (Bauer et al., 1995; Ying, 1998a, 1988b; 1988c, Zeng et al., 2000) se trata con los controladores Takagi-Sugeno y concluyen que con sólo dos reglas y teniendo conjuntos difusos normalizados como antecedentes, cualquier función continua puede ser representada (en el caso multidimensional un número considerablemente más grande de reglas es requerido). A pesar de que esta sorprendente hipótesis usa sólo dos funciones de membresía el resultado tiene un punto débil: no se garantiza que los términos sean convexos a pesar de que la convexidad juega un papel central en el razonamiento natural (como la lingüística). Por lo tanto no se demuestra que con este método la reducción de la complejidad computacional, como la no

linealidad de f , es simplemente transferida a las funciones de membresía. Además, la función de membresía de los antecedentes debe ser construida

por medio de una transformación directa de la función f lo que significa que si no hay transformación exacta disponible en la función entrada-salida del sistema bajo control, como en la mayoría de los casos prácticos, estos postulados no ayudan en el diseño paramétrico de los controladores difusos

que aproximan una función desconocida f .

Referencias

Arnold, V.I. (1957). *On functions of three variables, Doklady Akademii Nauk USSR, 114:679-681.*

Bauer, P., Klement, E.P., Leikermoser, A. and Moser, B. (1995). "Modeling of control functions by fuzzy controllers". In H. Nguyen, M. Sugeno, R. Tong, and R.R. Yager Editors, *Theoretical Aspects of Fuzzy Control, 91-116, Wiley, New York.*

Barhen, J. y Gulati, S. (1989). "Theory for Neural Learning of Nonlinear Mappings". *Neural Networks.*

Blum, E.K. y Li, L.K. (1991). "Approximation Theory and Feedforward networks". *Neural Networks, 4(4):511-515.*

Buckley, J.J. (1993). "Sugeno type controllers are universal controllers". *Fuzzy Sets and Systems, 53:299-304.*

Buckley, J.J. (1995). "System stability and the fuzzy controller". In H. Nguyen, M. Sugeno, R. Tong, and R.R. Yager Editors, *Theoretical Aspects of Fuzzy Control, 51-63, Wiley, New York.*

Castro, J.L. (1995). "Fuzzy logic controllers are universal approximators". *IEEE Trans. On SMC, 25:629-635.*

Castro, J.L., Mantas, C.J. and Benitez, J.M. (2000). "Neural networks with a continuous squashing function in the output are universal approximators". *Neural Networks, 13:561-563.*

Cybenko, G. (1989). "Approximation by superposition of sigmoidal functions". *Mathematics of Control, Signal and Systems, 2:303-314.*

- De Figueiredo, R.J.P. (1980). *Implications and Applications of Kolmogorov's superposition theorem*. IEEE, Tr. Autom. Control, 1227-1230.
- Ding, Y.S., Ying, H. and Shao, S.H. (2000). "Necessary conditions on minimal system configuration for general miso mamdam fuzzy systems as universal approximators". IEEE Tr. Systems, Man and Cybernetics, Part B, 30(6):857-864.
- Funanashi, K.I. (1989). "On the approximate realization of continuous mapping by neural networks". Neural Networks, 2:183-192.
- Haykin, S. (1999). *Neural Networks: A Comprehensive Foundation*, Prentice Hall, Upper Saddle River, New Jersey, 2nd edition.
- Hecht-Nielsen, R., Kolmogorov's mapping neural network existence theorem. In Proc. Of the International Conference on Neural Networks, Vol. III, 11-14, New York, 1987.
- Hellendoorn, H., Driankov, D. and Reinfrank, M. (1993). *An introduction to fuzzy control*, Springer, Berlin.
- Hornik, K., Stinchcombe, M. and White, H. (1989). "Multilayer feed forward networks are universal approximators". Neural Networks, 6:359-366.
- Jang, J.S.R., Sun, C.T. and Mizutani, E. (1997). *Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence*. Prentice Hall, Upper Saddle River, New Jersey.
- Josin, G. (1988). "Neural-Space Generalization of a Topological Transformation". Biological Cybernetics, Vol. 59, pp. 283-290.
- Kawamoto, S., Tada, K., Onoe, N., Ishigame, A. and Taniguchi, T. (1992). "Construction of exact fuzzy systems for nonlinear systems and its stability analysis". In Proc. Of the 8th Fuzzy System Symposium, 517-520, Hiroshima.
- Klement, E.P., Kóczy, L.T. and Moser B. (1999). "Are fuzzy systems universal approximators?". Int. J. General Systems, 28 (2-3):259-282.
- Kóczy, L.T. and Zorat A. (1997). "Fuzzy systems and approximation". Fuzzy sets and Systems, 85:203-222.
- Kolmogorov, A.N. (1957). "On the representation of continuous functions of many variables by superpositions of continuous functions of one variable and addition". Dokl. Akad. USSR, 114:953-956. (In russian)
- Kosko, B. (1992). Fuzzy systems as universal approximators. In Proc. Of the IEEE Int. Conf. On Fuzzy Systems, 1153-1162, San Diego.
- Kurková, V. (1992). "Kolmogorov's theorem and multilayer neural networks". Neural Networks, 5, 501-506.
- Kurková, V. (1995). "Approximation of functions by perceptrons networks with bounded number of hidden units". Neural Networks, 8(5): 745-750.
- Lorentz, G.G. (1966). *Approximation of functions*. Holt. Reinhard and Winston, New York.
- Moser, B. (1999). Sugeno controllers with a bounded number of rules are nowhere dense. Fuzzy sets and Systems, 104(2),269-277.
- Nguyen, H.T. and Kreinovich, V. (1992). *On approximation of controls by fuzzy systems*. Technical Report TR 92-93/302, LIFE Chair of Fuzzy Theory, Tokyo Institute of Technology, Tokyo.
- Poggio, T. and Girosi, F. (1989). "Representation properties of networks: Kolmogorov's theorem is irrelevant". Neural Computation, 1(4):465-469.
- Sprecher, D.A. (1965). "On the structure of continuous functions of several variables". Trans. Amer. Math. Soc. 115:340-355.
- Tikk, D. (1999). "On nowhere denseness of certain fuzzy controllers containing prerestricted number of rules". Tatra Mountains Math. Publ. 16:369-377.
- Wang, L.X. (1992). "Fuzzy systems are universal approximators". In Proc. Of the IEEE Int. Conf. On Fuzzy Systems, 1163-1169, San Diego.
- Wang, L.X. and Mendel, J. (1991). "Generating fuzzy rules from numerical data with suplications". Technical Report TR USC-SIPI #169. Signal and Image Processing Institute, University of Southern California,
- Yager, R.R. and Kreinovich, V. (2003). "Universal approximation theorem for uninorm-based fuzzy systems modeling". FUZZY SETS AND SYSTEMS 140 (2): 331-339.
- Ying, H. (1998). "Sufficient conditions on uniform approximation of multivariable functions". by general Takagi-Sugeno fuzzy systems with linear rule consequents. IEEE Trans. On SMC, Part A, 28(4):515-520.
- Ying, H. (1998). fuzzy systems with linear rule consequents are universal approximators. General SISO Takagi-Sugeno IEEE Trans on FS, 6(4): 582-587.
- Ying H. (1998). "fuzzy systems with simplified linear rule consequents are universal approximators". General Takagi-Sugeno. Models and filters, J Inform. Sci., 108:91-107.
- Ying H., Sufficient conditions on uniform approximation of multivariate functions by general Takagi-Sugeno fuzzy systems with linear rule consequents. IEEE Trans. on SMC, Part A, 28(4):515-520, 1998.
- Zeng, K., Zhang N.Y. and Xu, W.L. (2000). A comparative study on sufficient conditions for Takagi-Sugeno fuzzy systems as universal approximators. IEEE Trans. On FS. 8(6):773-780.
- Zak, M., "Terminal attractors for adressable memory in neural networks", Physics Letters A, Vol. 133, 1988, pp. 218-222.

7.4. Apéndice 4.1.A

Lista de lecturas recomendadas para profundizar en la teoría, construcción e interpretación de los Mapas de Recurrencia.

Referencias Seleccionadas

A. Babloyantz, "Some remarks on nonlinear data analysis of physiological time series", (1989), In: *Measures of Complexity and Chaos*, Neal A. Abraham, Alsonso M. Albano, Anthony Passamante and Paul E. Rapp (eds.), pp. 51-62, Plenum Press, NATO ASI Series B: Physics Vol. 208, New York and London

A. Babloyantz, "Evidence for slow brain waves: a dynamical approach", (1991), *Electroencephalogr. Clin. Neurophysiol.*, vol. 78, pp. 402-405

M.C. Casdagli, "Recurrence plots revisited", *Physica D* 108 (199) 12-44

J.P. Eckmann, S. Oliffson Kamphorst and D. Ruelle, "Recurrence plots of dynamical systems", (1987), *Europhys. Lett.*, Vol. 4, No. 9, pp. 973-977

Claire G. Gilmore, "A new test for chaos", (1993), *J. Econ. Behav. Organ.*, Vol. 22, pp. 209-237

Claire G. Gilmore, "A new approach to testing for chaos, with applications in finance and economics", (1993), *Int. J. Bifurcation Chaos*, Vol. 3, No. 3, 583-587.

Pawel Kaluzny and Remigiusz Tarnecki, "Recurrence plots of neuronal spike trains", (1993), *Biol. Cybern.*, vol. 68, pp. 527-534

Keegan AP, Zbilut JP, Merritt SL, Mercer PJ, "Use of recurrence plots in the analysis of pupil diameter dynamics in narcoleptics", (1993) *SPIE Proceedings: Chaos in Biology and Medicine*, Vol 2036, pp 206-213.

M.C.K. Khoo (ed), "Approaches to Pulmonary Physiology and Medicine", Plenum Press, New York, 1996., Chapter 8, pp 137-148.

Matthew Koebbe and Gottfried Mayer-Kress, "Use of recurrence plots in the analysis of time-series data" (1992), In: *Nonlinear Modeling and Forecasting*, M. Casdagli and S. Eubank (eds.), pp. 163-188, *SFI Studies in the sciences of complexity*, Proc. Vol. XII, Addison-Wesley

Gottfried Mayer-Kress and Alfred Huebler, "Time evolution of local complexity measures and aperiodic perturbations of nonlinear dynamical systems", (1989), In: *Measures of Complexity and Chaos*, Neal A. Abraham, Alsonso M. Albano, Anthony Passamante and Paul E. Rapp (eds.), pp. 155-171, Plenum Press, NATO ASI Series B: Physics Vol. 208, New York and London

F. Takens, "Detecting strange attractors in turbulence", (1981), In: *Dynamical Systems and Turbulence* (Warwick 1980), *Lecture Notes in Mathematics*, No. 898, Springer-Verlag, Berlin

Trulla, L.L, A. Giuliani, J.P. Zbilut, and C.L. Webber, Jr., "Recurrence quantification analysis of the logistic equation with transients", *Phys. Lett. A* 223: pp 255-260, (1996).

M. Vihinen, "An algorithm for simultaneous comparison of several sequences", (1988), *CABIOS*, Vol. 4, No. 1, pp. 89-92.

C.L. Webber, Jr. and J.P. Zbilut, "The application of chaos theory to rhythmic breathing patterns", (1991), In: *Cardiorespiratory and motor coordination*, H.-P. Koepchen and T. Huopaniemi (eds.), pp. 239-247, Springer-Verlag, Berlin, Heidelberg, New York

C.L. Webber, Jr., "Rhythmogenesis of deterministic breathing patterns", (1991), In: *Rhythms in Physiological Systems*, H. Haken and H.P. Koepchen (eds.), pp. 177-191, Springer-Verlag, Springer Series in Synergetics, Berlin, Heidelberg, New York

Webber, C.L., Jr. and J.P. Zbilut, "Assessing deterministic structures in physiological systems using recurrence plot strategies. In: *Bioengineering*", Charles L Webber and Joseph P. Zbilut. *Dynamical assessment of physiological systems and states using recurrence plot strategies.* (1994), *J. Appl. Physiol.*, vol. 76, no. 2, pp. 965-973

Webber, C.L., Jr. and J.P. Zbilut, "Recurrent structuring of dynamical and spatial systems", In: *Complexity in the Living: A Modelistic Approach. A.*

J.P. Zbilut, M. Koebbe, H. Loeb and G. Mayer-Kress, "Use of recurrence plots in the analysis of heart beat intervals", (1991), In: *Proceedings IEEE Computers in Cardiology*, pp. 263-265, IEEE Computer Society Press, Washington, Brussels, Tokyo

J.P. Zbilut, "Power laws, transients, attractors, and entropy: possible implications for cardiovascular dynamics" (1991), In: *Rhythms in Physiological Systems*, H. Haken and H.P. Koepchen (eds.) pp. 139-151 Springer-Verlag Springer Series in Synergetics Berlin, Heidelberg, New York

Joseph P. Zbilut and Charles L Webber Jr., "Embeddings and delays as derived from quantification of recurrence plots", (1992), *Phys. Lett. A*, vol. 171, pp. 199-203

Webber, C.L., Jr. and J.P. Zbilut, "The applicability of methods from nonlinear dynamics in assessing physiological states of the respiratory system", *Proc. Eng. Med. Biol. Soc. 12*: 1863-1864, 1990.

Webber, C.L., Jr. and J.P. Zbilut, "The applicability of chaos theory to rhythmic breathing patterns." In: *Cardiorespiratory and Motor Coordination*. H.-P. Koepchen and T. Huopaniemi (eds.). Springer-Verlag, Berlin, Heidelberg, New York, pp 239-247, 1991.

Webber, C.L., Jr., "Rhythmogenesis of deterministic breathing patterns" In: *Rhythms in Physiological Systems*. H. Haken and H.P. Koepchen (eds.). Springer-Verlag, Berlin, Heidelberg, New York, pp 177-191, 1991.

Zbilut, J.P. and C.L. Webber, Jr., "Embeddings and delays as derived from quantification of recurrence plots", *Physics Letters A* 171: 199-203, 1992.

Webber, C.L., Jr. and J.P. Zbilut, "Dynamical assessment of physiological systems and states using recurrence plot strategies" *J. Appl. Physiol.* 76: 965-973, 1994.

Webber, C.L., Jr., Schmidt, M.A., and J.M. Walsh, "Influence of isometric loading on biceps EMG dynamics as assessed by linear and nonlinear tools." *J. Appl. Physiol.* 78: 814-822, 1995

Webber, C.L., Jr. and J.P. Zbilut, "Assessing deterministic structures in physiological systems using recurrence plot strategies", In: *Bioengineering Approaches to Pulmonary Physiology and Medicine*. M.C.K. Khoo (ed.). Plenum Press, New York, Chapter 8, pp 137-148, 1996.

Trulla, L.L., A. Giuliani, J.P. Zbilut, and C.L. Webber, Jr., "Recurrence quantification analysis of the logistic equation with transients", *Physics Lett. A* 223: 255-260, 1996.

Zbilut, J.P., A. Giuliani, C.L. Webber, Jr., "Recurrence quantification analysis and principle components in the detection of short complex signals", *Physics Lett. A* 237: 131-135, 1998.

Zbilut, J.P. and C.L. Webber, Jr., "Quantification of heart rate variability using methods derived from nonlinear dynamics", In: *Analysis and Assessment of Cardiovascular Function*. G. Drzewiecki and J.K.-J. Li (eds.). Springer Verlag, New York.

Webber, C.L., Jr. and J.P. Zbilut, "Recurrent structuring of dynamical and spatial systems", In: *Complexity in the Living: A Modelistic Approach*. *Interdisciplinary Science Rev.* Oxford Press, A. Colosimo and A. Lesk (eds.). (in press).

7. Referencias

Capítulo 2 Problemática Geosísmica

- Anderson, J. G. (2001). "Precautionary principle: Applications to seismic hazard analysis", *Seism. Res. Lett.* 72, 319- 322.
- Bendat, J.S. y Piersol, A.G. (1986). "*Random Data, Analysis and Measurement Procedures*". Wiley-Interscience, New York, 2nd edition, J. Soil Mech. Found. Div., ASCE, 98, 603-624.
- Campanella, R.G. y Kokan, M.A. (1993). "A new approach to measuring dilatancy in saturated sands". *Geotechnical Testing Journal, ASTM GTJODJ*, 16(4):485-495.
- Campanella, R.G., Stewart, W.P., Roy, D. y Davies, M.P. (1994). "Low strain characteristics of soils with the downhole seismic piezocone penetrometer". En *Proc. Symp. on Dynamic Geotechnical Testing II*, 73-87, San Francisco, CA.
- Campanella, R.G. (1994). "Field methods for dynamic geotechnical testing: An overview of capabilities and needs". En *Proc. Symp. on Dynamic Geotechnical Testing II*, 3-23, San Francisco, CA.
- Davis, P.M., Rubinstein, J.L., Liu, K.H., Gao, S. S. y Knopoff, L. (2000). "Northridge earthquake damage caused by geologic focusing of seismic waves", *Science* 289, 1746-1750.
- Day, S.M. (1998). "Efficient simulation of constant Q using coarse-grained memory variables", *Bull. Seism. Soc. Am.* 88, 1051-1062.
- Dobry, R. Ladd, R.S., Yokel, F.Y., Chung, R.M. y Powell, D. (1982). "Prediction of Pore Water Pressure Buildup and Liquefaction of Sands during Earthquakes by the Cyclic Strain Method", Report NBS Building Science Series 138, U.S. Department of Commerce, Washington.
- Dobry, R. y Vucetic, M., (1987). "Dynamic properties and seismic response of soft clay deposits", *Proc. International Symposium on Geotechnical Engineering of Soft Soils, Mexico City*, Vol. 2, pp. 51-87.
- Douglas, B.J. y Olsen, R.S. (1981). "Soil Classification Using the Electric Cone Penetrometer", *Proceedings of the Cone Penetration Testing and Experience Session, ASCE National Convention, St. Louis, Oct 1981, American Society of Civil Engineers, New York, NY*.
- Erdik, M., (1987). "Site response analysis", *Strong Ground Motion Seismology*, edited by M. Erdik and M. Toksoz, D. Reidel Publishing Company, Dordrecht, 479-543.
- FUGRO Ltd, (1996). "Cone Penetration Testing CPT: Simplified Description of the Use and Design Methods for CPTs in Ground Engineering", *HANDBOOK*, United Kingdom.
- Harder, H. y von Bloh, G. (1988)., "Determination of representative CPT-parameters", En *Proc. Geotechn. Conf. Penetration Testing in the UK*, 237-240, Birmingham, Inst. of Civil Engineers.
- Hardin, B. O. y Drnevich, V. P. (1972a)., "Shear modulus and damping in soils, Design equation and curves measurement and parameter effects", *J. Soil Mech. Found. Div., ASCE*, 98, 667-692.
- Hardin, B. O. y Drnevich, V. P. (1972b). "Shear modulus and damping in soils: Measurement, *J. Soil Mech. Found. Div., ASCE*, 98, 667-692.
- Harris, R.A. y Day, S.M. (1993). "Dynamics of fault interaction: Parallel strike-slip faults", *J. Geophys. Res.* 98, 4461-4472.
- Harris, R.A. y Day, S.M. (1999). "Dynamic 3D simulations of earthquakes on echelon faults", *Geophys.Res. Lett.* 26, 2089-2092.
- Hegazy, Y.A. y Mayne, P.W. (1995). "Statistical correlations between Vs and cone penetration data for different soil types". En *Proceedings of the International Symposium on Cone Penetration Testing (CPT'95)*, Linkoping, Sweden, 4-5 October 1995. Swedish Geotechnical Society, Linkoping, Sweden, Report 3-95, Vol. 2, 173-178.
- Jaime, A. y Romo, M.P. (1988). "Correlations between dynamic and static properties of Mexico City clay", *Earthquake Spectra, EERI*, Vol. 4, No. 4, 787-804, November.
- Jefferies, M.G. y Davies, M.P. (1993). "Use of CPTu to estimate equivalent SPT N_{60} ". *Geotechnical Testing Journal*, 16(4):458-468.
- Kokusho, T., Yoshida, Y. y Esashi, Y. (1982). "Dynamic properties of soft clay for wide strain range", *Soils and Foundations*, Vol. 22, No.4, 1-18.

- Magistrale, H. y Day, S. (1999). "3D simulations of multi-segment thrust fault rupture", *Geophys. Res. Lett.* 26, 2093-2096.
- Martin, P.P. y Seed, H.B. (1982). "One-dimensional dynamic ground response analyses." *Journal of Geotechnical Engineering Division, ASCE*, 108(7), 935-952.
- O'Connell, D. R. H. y Ake, J.P. (2000), *Earthquake Ground Motion Estimation*, "Hazards and Disasters" series, to commemorate the International Decade of Natural Disaster Reduction, published by Routledge, Ltd.
- Oreskes, N., Shrader-Frechette, K. y Belitz, K. (1994). "Verification, validation, and confirmation of numerical models in the Earth sciences", *Science*, 264, 641-646.
- Ovando, E. y Romo, M.P. (1991). "Shear wave velocity estimation of Mexico City clay from cone tests", *Sismodinámica*, Vol. 2, No. 2-3, 107-123, June-September
- Popescu, R. y Prévost, J.H. (1995). "Reliability assessment of centrifuge soil test results", *Soil Dynamics and Earthquake Eng.*, 14(2):93-101.
- Prévost, J.H. y Popescu, R. (1996). "Constitutive Relations for Soil Materials", *EJGE*, Paper no. 9609.
- Romo, M.P. y Ovando, E. (1996). "Modelling the dynamic behaviour of Mexican clays", 11th World Conference on Earthquake Engineering, Acapulco, Mexico, Paper # 1028, Proceedings in CD ROM, June. NOTA: SUSTITUIR POR ROMO (1990)
- Silva, W., Li, S., Darragh, B. y Gregor, N. (1999). "Surface geology based motion amplification factors for the San Francisco Bay and Los Angeles areas", PEARL report to PG&E/CEC/Caltrans.
- Stewart, W.P. y Campanella, R.G. (1993). "Practical aspects of in-situ measurements of material damping with the SCPT". *Canadian Geotechnical Journal*, 30(2):211-219.
- Sun, J.I., Galesorkhi, R. y Seed, H.B. (1988). "Dynamic moduli and damping ratios for cohesive soils", Report No. EERC-88/15, Earthquake Engineering Research Center, University of California, Berkeley.
- Terzaghi, K., (1925), „Erdbaumechanik auf bodenphysikalischer Grundlage“: Franz Deuticke, Leipzig und Wein, 399.
- Terzaghi, K. (1943). "*Theoretical Soil Mechanics*"; John Wiley and Sons, N.Y.
- Toro, G.R., Abrahamson, N.A. y Schneider, J.F. (1997). "Model of strong ground motions from earthquakes in Central and Eastern North America: Best estimates of uncertainties", *Seism. Res. Lett.* 68, 41-57.
- Vucetic, M. y Dobry, R. (1991). "Effect of soil plasticity on cyclic response", *J. Geotech. Eng.* 117, 89-107.
- Yung-Mook, Na., Victor, Choa., Cee-Ing, Teh. y Ming-Fang, Chang. (2005). "Geotechnical parameters of reclaimed sandfill from the cone penetration test". *Can. Geotech. J.* 42: 91-109
- Zen, K., Umehara, Y. y Hamada, K. (1978). "Laboratory tests and in-situ seismic survey on vibratory shear modulus of clayey soils with different plasticities", *Proceedings, 5th Japan Earthquake Engineering Symposium, Tokyo*, 721-728.

Capítulo 3 Cómputo Aproximado

Bonissone, P.P. (1997). "Soft Computing: The convergence of emerging reasoning technologies", *Soft Computing*, 1:6-18

Hajek, P. (1995). "Fuzzy logic as logic". En: *Mathematical Model for Handling Partial Knowledge in Artificial Intelligence*, G. Coletti, D. Dubois, R. Scozzafava, eds., Plenum Press, New York, 21-30

Holland, J.H. (1975). "Adaptation in Natural and Artificial Systems", MIT Press, Cambridge, MA.

Mendel, J. (1995). "Fuzzy logic systems for engineering: A tutorial", *Proc IEEE* 83:345-377

Novak, V. (1996). "Paradigm, formal properties and limits of fuzzy logic". *Int J of General Systems*, 24:377-406

Rosenbaltt, F. (1959). "Two theorems of statistical separability in the perceptron", En: *Mechanization of Thought Processes*, 421-456, Symposium held at the National Physical Laboratory, HM Stationary Office, London, England.

Vopenka, P. (1989). Introduction to the mathematics in the alternative set theory. Alfa Bratislava (in Slovak).

Vopenka, P. (1979). *Mathematics in the alternative set theory*. Teubner, Leipzig.

Widrow, B. and Hoff, M.E. (1960). "Adaptive switching circuits", En: *IRE Western Electric Show and Convention Record*, Part 4. 96-104.

Zadeh, L.A. (1965). "Fuzzy Sets", *Inf. Control* 8, 338-353.

Zadeh, L.A. (1994). "Fuzzy Logic and Soft Computing: Issues", *Contentions and Perspectives*. En *IIZUKA'94: 3rd International Conference on Fuzzy Logic, Neural Nets and Soft Computing*, 1-2, Iizuka, Japan.

Zadeh, L.A. (1997). "What is soft computing?", *Soft Computing*, 1(1):1

Redes Neuronales

Ahmad, R. y Salam, F. (1992). "Error back propagation learning using the polynomial energy function," en *Proceedings of the International Joint Conference on Neural Networks*, Iizuka, Japan.

Anand, R., Mehrotra, K., Mohan, C. y Ranka S. (1993). "An improved algorithm for neural network classification of imbalanced training sets," *IEEE Transactions on Neural Networks*, vol. 4, no. 6, 962-969.

Blum, M. (1962). "Properties of a neuron with many inputs". In *Principles of Self-organization*, H. von Foerster and G.W. Zopf, eds., 95-120; Pergamon Press: Oxford.

Cajal, S.R. (1904). "Histologie du système nerveux de l'homme et des vertébrés", Dunod, Paris.

Carpenter, G.A. y Grossberg, S. (1988). "The ART of adaptive pattern recognition by a self-organizing neural network". *Computer*, 21, 77-88.

Chen X.H., (1997). "Efficient backpropagation learning using optimal learning rate and momentum," *Neural Networks*, vol. 10, no. 3, 517-527.

Cherkassky, V. y Shepherd, R. (1998). "Regularization effect of weight initialisation in back propagation networks," en *1998 IEEE International Joint Conference of Neural Networks (IJCNN'98)*, (Anchorage, Alaska), 2258-2261, IEEE.

Denoeux, T. y Lengelle, R. (1993). "Initialising back propagation networks using prototypes," *Neural Networks*, vol. 6, no. 3, 351-363.

Eaton, H. y Oliver, T. (1992). "Improving the convergence of the back propagation algorithm," *Neural Networks*, vol. 5, 283-288,

Fahlman, S.E. y Hinton, G.E. (1987). "Connectionist Architectures for Artificial Intelligence". *IEEE Computer* 20(1):100-109.

Fukushima, K. (1975). "Cognitron: A self-organizing multi-layered neural network". *Biological Cybernetics*, 20:121-136.

Fukushima, K. y Miyake, S. (1982). "Neocognitron: A new algorithm for pattern recognition tolerant of deformations and shifts in position," *Pattern Recognition* 15(6), 455-469.

Gori M. y Tesi, A. (1992). "On the problem of local minima in backpropagation," *IEEE Transactions on PAMI*, vol. 14, no. 1, 76-86.

Holt, M. y Semnani, S. (1990). "Convergence of back-propagation in neural networks using a log-likelihood cost function," *Electronics Letters*, vol. 26, no. 23, 1964-1965.

Haykin, S. (1994). "Neural Networks: A Comprehensive Foundation", New York 10022: IEEE Society Press, Macmillan College Publishing.

- Hirose, Y., Yamashita, K. y Hijiya, S. (1991). "Back propagation algorithm which varies the number of hidden units," *Neural Networks*, vol. 4, no. 1, 61-66.
- Hopfield, J.J. y Tank, D.W. (1986). "Computing with neural circuits", *Model Science*, v.233, 3088-3092.
- Hopfield, J.J. y Tank, D.W. (1988). "Computación conjunta en circuitos neuromorfos". *Investigación y Ciencia*, 137:44-52.
- Jacobs, R. (1989). "Increased rates of convergence through learning rate adaptation," *Neural Networks*, vol. 1, no. 1, 295-307.
- Joost, M. y Schiffmann, W. (1998). "Speeding up backpropagation algorithms by using crossentropy combined with pattern normalization," *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems (IJUFKS)*, vol. 6, no. 2, 117-126.
- Kohonen, T. (1988). *Self-Organization and Associative Memory*. Springer, second edition.
- Kruschke, J. y Movellan, J. (1991). "Benefits of gain: Speeded learning and minimal hidden layers in back propagation networks," *IEEE Transactions on Systems, Man and Cybernetics.*, vol. 21, no. 1, 273-280.
- Kwon, T. M. y Cheng, H. (1996). "Contrast enhancement for backpropagation," *IEEE Transactions on Neural Networks*, vol. 7, no. 1, 515-524.
- Linsker, R. (1988). "Self-organization in a perceptual network". *En Computer*, 21.
- McCulloch, W.S. y Pitts, W. (1943). "A Logical Calculus of the Ideas Immanent in Nervous Activity" *Bulletin of Mathematical Biophysics*, vol. 5, 115-133.
- Minsky, M.L. y Papert, S.A. (1969). "Perceptrons: An Introduction to Computational Geometry" ,Cambridge, Massachusetts:MIT Press.
- Ooyen, A. y Nienhuis, B. (1992). "Improving the convergence of the back propagation algorithm," *Neural Networks*, vol. 5, 465-471,
- Riedmiller, M. y Braun, H. (1993). "A direct method for faster backpropagation learning: The RPROP Algorithm," *En IEEE International Conference on Neural Networks 1993(ICNN93)*, San Francisco, 586-591.
- Riedmiller, M. (1994). "Advanced supervised learning in multi-layer perceptrons from backpropagation to adaptive learning algorithms," *Computer Standards and Interfaces Special Issue on Neural Networks*, vol. 16, no. 3, 265-275.
- Rumelhart, D.E. y McClelland, J.L. (1986). "Parallel Distributed Processing: Explorations in the Microstructure of Cognition", MIT Press, Cambridge, MA, London, England.
- Sarkar, D. (1995). "Methods to speed up error back propagation learning algorithm," *ACM Computing Surveys*, vol. 27, no. 4, 519-542.
- Schiffmann, W., Joost, M. y Werner, R. (1993). "Application of genetic algorithms to the construction of topologies for multilayer perceptrons," *en Proceedings of International Conference on Neural Networks and Genetic Algorithms (ICNNGA)*, (University of Innsbruck, Austria), 675-682.
- Schittenkopf, C., Deco, G. y Brauer, W. (1997). "Two strategies to avoid overfitting in feedforward neural networks," *Neural Networks*, vol. 10, no. 3, 505-516.
- Shannon, C.E. y McCarthy, J. (Eds). (1956). "Automata Studies", Princeton U. Press, Princeton, N. J.
- Silva, F. y Almeida, L. (1990). "Speeding up back-propagation," *in Advanced Neural Computers (R. Eckmiller, ed.)*, (Amsterdam), 151-158, Elsevier Science Publishers,
- Solla, S., Levin, E. y Fleisher, M. (1988). "Accelerated learning in layered neural networks," *Complex System*, vol. 2, 625-640.
- Steinbuch, K. (1963). "Die Lernmatrix", *Kibernetik Vol. 1*, 1961, Versión ampliada de este trabajo por el mismo autor en "Automat und Mensch", Springer Verlag
- Tollenaere, T. (1990). "Super SUB: Fast adaptive back propagation with good scaling properties," *Neural Networks*, vol. 3, no. 5, 561-573.
- Vitthal, R. P. Rao, Sunthar, y Durgaprasada, C. (1995). "The generalized proportional-integral-derivative (PID) gradient descent back propagation algorithm," *Neural Networks*, vol. 8, no. 4, 563-569.

Vogl, T., Mangis, J., Rigler, A., Zink, W. y Alkon, D. (1988). "Accelerating the convergence of the backpropagation method," *Biological Cybernetics*, vol. 59, 257-263, September.

Weir, M. (1991). "A method for self determination of adaptive learning rate in back propagation," *Neural Networks*, vol. 4, 371-379.

Wessels, L. y Barnard, E. (1992). "Avoiding false local minima by proper initialisation of connections," *IEEE Transactions on Neural Networks*, vol. 3, no. 6, 899-905.

Wiener, N. y Schade J.P. (1969). "Sobre modelos de los nervios, el cerebro y la memoria". Ed. Tecnos, Madrid,

Widrow, B. (1962). "Generalization and Information Storage in Networks of Adaline Neurons".

Yovits, M.C., Jacobi, G.T. y Goldstein, G.D. (1962). "Principles of Neurodynamics" (New York:Spartan) Washington, Spartan, 435. Rosenblatt, F.

Zhang, B.-T. (1994). "Accelerated learning by active example selection," *International Journal of Neural Systems*, vol. 5, no. 1, 67-75.

Lógica Difusa

Abraham, A. y Nath, B. (2000). "Evolutionary Design of Neuro-Fuzzy Systems - A Generic Framework", en *Proceedings of the 4th Japan - Australia joint Workshop on Intelligent and Evolutionary Systems*, Japan.

Abraham, A. (2001). "Neurofuzzy systems: State-of-the-Art modeling techniques", in *Proceedings of the Sixth International Conference on Artificial and Natural Neural Networks*, IWANN 2001, Granada, Springer-Verlag, June, <http://ajith.softcomputing.net>

Agrawal, G. Chaneau, J.L.A. y Bordeau, P.L. (1997). "Assessing the liquefaction susceptibility at a site based on information from penetration testing", In *Artificial Neural Networks for Civil Engineers: Fundamentals and Applications*, New York, ASCE, 185-214

Bezdek, J.C. (1981). "Pattern recognition with fuzzy objective function algorithm", Plenum Press

Bherenji, H.R. y Khedkar, P. (1992). "Learning and Tuning Fuzzy Logic Controllers through Reinforcements", *IEEE Transactions on Neural Networks*, Vol (3), 724-740,

García, S., Romo, M.P. y Figueroa-Nazuno, J. (2006). "Soil dynamic properties determination: A neurofuzzy system approach", *Control and Intelligent Systems*, Volume 34, Issue 1, 1-11, ISSN:1480-1752

Ghaboussi, J., Garret, J.H. y Wu, X. (1991). "Knowledge based modeling of material behavior with neural networks", *Journal of the Engineering Mechanics Division, ASCE*, Vol. 117, No. 2, 132-153

Hoppner, F., Klawonn, F., Kruse, R. y Runkler, T. (1999). "Fuzzy cluster analysis", John Wiley and Sons, New York, ISBN 0-471-98864-2

Jang et al. Jang, J.S., Sun, C.T. y Mizutani, E. (1997). "Neuro-Fuzzy and Soft Computing". Prentice-Hall, Englewood Cliffs, NJ

Kandel, A. (editor). (1992). "Fuzzy expert systems", CRC Press, Inc. Boca Ratón, FL

Kasabov, N. y Qun, Song. (1999). "Dynamic Evolving Fuzzy Neural Networks with 'm-out-of-n' Activation Nodes for On-line Adaptive Systems", Technical Report TR99/04, Department of information science, University of Otago,

Kosko N, (1992), "Neural networks, Fuzzy systems: Dynamical systems approach to machine intelligence", Englewood Cliffs, N.J., Prentice Hall

Kosko, B. (1992). "Neural networks and fuzzy systems: A dynamical systems approach to machine intelligence", Prentice-Hall, London, ISBN 0-13-611435-0

Jang, R. (1992). "Neuro-Fuzzy Modeling: Architectures, Analyses and Applications", PhD Thesis, University of California, Berkeley.

Juang Chia, Feng. y Lin Chin, Teng. (1998). "An Online Self Constructing Neural Fuzzy Inference Network and its Applications", *IEEE Transactions on Fuzzy Systems*, Vol 6, No.1, 12-32,.

Lin, C.T. y Lee, C.S.G. (1991). "Neural Network based Fuzzy Logic Control and Decision System", *IEEE Transactions on Comput.* (40(12): 1320-1336,

Menger, K. "Statistical metrics", *Proc. Nat. Acad. of Sci., U.S.A.*, 28 (1942), 535-537.

Munukata, T. y Jani, Y. (1994). "Fuzzy Sets: An Overview", *Communications of the ACM*, 7(3), pp. 69-76.

Nauck, D. y Kruse, R. (1996a). "Designing neuro-fuzzy systems through backpropagation", en W Pedrycz (ed): *Fuzzy modeling: Paradigms and Practice*, 203-228, Kluwer, Boston

Nauck, D. y Kruse, R. (1996b). "Neuro-fuzzy classification with NEFCLASS", en P. Kleinshmidt, A. Backem, U. Derigs, D. Fisher, U. Leopold-Wildburger y R. Möhring (eds): *Operations Research Proceedings 1995*, 294-299, Springer-Verlag, Berlin

Nauck, D. y Kruse, R. (1997). "Neuro-Fuzzy Systems for Function Approximation", 4th International Workshop Fuzzy-Neuro Systems,

Reiter, R. (1980). "A logic for default reasoning. *Artificial Intelligence*", vol. 13, 81-132.

Romo, M.P. y García, S.R. (2003). "Neurofuzzy mapping of CPT values into soil dynamics properties", *International Journal of Soil Dynamics and Earthquake Engineering*, Vol. 23, Num. 6, August, 473-482

Romo, M.P. (2004). "System-identification: From analytic to neurogenetic methods", Keynote Lecture, 3er Congreso Internacional de Computación, Instituto Politécnico Nacional, Mexico City, October.

Sulzberger, S.M., Tschichol-Gurman, N.N. y Vestli, S.J. (1993). "FUN: Optimization of Fuzzy RuleBased Systems Using Neural Networks", en *Proceedings of IEEE Conference on Neural Networks*, San Francisco, 312-316.

Takagi, T. y Sugeno, M. (1985). "Fuzzy Identification of Systems and its applications to Modeling and Control", *IEEE Transactions on Systems, Man and Cybernetics*, SMC-15 (1), 116-132.

Tano, S., Oyama, T. y Arnould, T. (1996). "Deep combination of Fuzzy Inference and Neural Network in Fuzzy Inference", *Fuzzy Sets and Systems*, 82(2), 151-160,

Yager, S., Ovchinnikov, R.M. y Tong, H.T. Nguyen (eds), *Fuzzy Sets and Applications*, Wiley, New York, 293-329.

Yager, R.R. (1982). "Measuring tranquillity and anxiety in decision making: An application of fuzzy sets", *Inter. Journal of General Systems* 8, 139-146

Yager, R.R. y Filev, D.P. (1993). "SLIDE: A simple adaptive defuzzification method", *IEEE Transactions on Fuzzy Systems*, Vol. 1, No. 1, 69-78

Zadeh, L.A. (1965). *Fuzzy sets*, *Information and Control*, 8, 338-353

Zadeh, L.A., (1987), "A theory of approximate reasoning", en: R.R. Yager, S. Ovchinnikov, R.M. Tong, H.T. Nguyen (Eds.), *Fuzzy Sets and Applications: The selected papers by L.A. Zadeh*, Wiley, New York, 1987, 367-411.

Capítulo 4 Análisis de Series de Tiempo

- Bendat, J. S., (1990) "Nonlinear System Analysis and Identification from Random Data". Wiley Interscience, 267.
- Davis, P.J. (1994), "Chaos and the New Understanding". SIAM NEWS 27: 6.
- De Jong, A.J. (1990), "Reclaiming a Mission; New Direction for the Church-Related College". Grand Rapids, MI: William B. Erdmans.
- Earman, J. (1986), "A Primer on Determinism". Dordrecht: D. Reidel,
- Kantz, H., y T. Schreiber, (1999), "Nonlinear Time Series Analysis". Cambridge University Press, 304.
- Kellert, S. H. (1993), "In the Wake of Chaos". Chicago, IL: University of Chicago Press.
- May, R. M. y Oster, G. F. (1976), "Bifurcations and Dynamic Complexity in Simple Ecological Models." American Naturalist 110: 573-599.
- Priestley, M. B., (1988), "Nonlinear and Nonstationary Time Series Analysis". Academic Press, 237.
- Stewart, I. (1989), "Does God Play Dice? The Mathematics of Chaos". Cambridge, MA: Basil Blackwell.
- Tong, H., (1990), "Nonlinear Time Series Analysis". Oxford University Press, 564.

Mapas de Recurrencia

- H. D. I. Abarbanel, (1995), "Analysis of Observed Chaotic Data". Springer.
- J.-P. Eckman, O.S. Kamphorst, y D. Ruelle, (1987), "Recurrence Plots of Dynamical Systems". Europhysics Letters 5, 973-977.
- U. Feudel y C. Grebogi, (1997), "Multistability and the control of complexity", CHAOS. V.7, 597.
- Fraser A. M. y Swinney H. L., (1986), "Independent coordinates for strange attractors from mutual information", Phys. Rev. A 33, 1134.
- García S.R., Botero E. y Romo M., (2003), "Chaotic Analysis and Neural Modeling of Seismic Time Series", International Conference

on Adaptive Modeling and Simulation ADMOS 2003, N.-E Wiberg and P. Díez, Eds, CIMNE, Barcelona,.

Hegger R., Kantz H. y Schreiber T., (1999), "Practical implementation of nonlinear time series methods: The TISEAN package", CHAOS 9, 413.

J. Huang y D.L. Turcotte, (1990a), "Are Earthquakes an Example of Deterministic Chaos?", Geophys.Res.Lett.,17, 223-226.

J. Huang y D.L.Turcotte, (1990b), "Evidence for Chaotic Fault Interactions in the Seismicity of the San Andreas Fault and Nakai Trough", Nature, 348, 234- 236.

Kennel M. B., Brown R. y Abarbanel H. D. I., (1992), "Determining embedding dimension for phase-space reconstruction using a geometrical construction", Phys. Rev. A 45, 3403.

D.G. Luchinsky, P.V.E. McClintock y M.I. Dykman. (1998), "Analogue studies of nonlinear systems". Reports on Progress in Physics, V.61. 889.

N. Packard, J. Crutchfield, J. Farmer, y R. Shaw, (1980), "Geometry from a time series". Physical Review Letters, 45:712.

Paluš M., (1995), "Testing for nonlinearity using redundancies: Quantitative and qualitative aspects", Physica D 80, 186.

Sauer, T.; Yorke J. y Casdagli M., (1991), "Embedology", J. Stat. Phys. 65, 579.

Takens, F. (1981), "Detecting strange attractors in fluid turbulence". En D. Rand and L.- S. Young, editors, Dynamical Systems and Turbulence, Springer, Berlin, 366-381.

Eigenfaces

González, R. C., y Tou, J. T., (1974), "Pattern recognition principles", Addison-Wesley Publishing Company.

Kirby, M., and Sirovich, L., (1990), "Application of the Karhunen-Loeve procedure for the characterization of human faces", IEEE PAMI, Vol. 12, 103-108.

Lau Technologies. (1999). "Facial recognition technology". Retrieved September 25, 1999, from the World Wide Web: <http://www.lautechnologies.com/Pages/FacialRecognition.htm>.

Press, W. H., Flannery, B. P., Teukolsky, S. A., y Vetterling, W. T., (1988), "Numerical recipes in C", Cambridge University Press, 353-380.

Sirovich, L., y Kirby, M., (1987), "Low-dimensional procedure for the characterization of human faces", J. Opt. Soc. Am. A, 4, 3, 519-524.

Turk, M. y Pentland, A. (1991). "Eigenfaces for recognition". Journal of Cognitive Neuroscience, 3, 71-86.

Velasco, J. (1998). "Teaching a computer to recognize a friendly face", The New York Times, G7.

Yuille, A. L., Cohen, D. S., y Hallinan, P. W., (1989), "Feature extraction from faces using deformable templates", Proc. of CVPR.

Capítulo 5 Resultados

Díaz-Rodríguez, J. A., Lozano-Santa Cruz, R., Dávila-Alcocer, V.M., Vallejo, E. y Girón, P. (1998). "Physical, chemical, and mineralogical properties of Mexico City: a geotechnical perspective", *Canadian Geotechnical Journal*, Vol. 35, No. 4, 600-610.

Gomez-Looh, B. (1987). "Análisis por difracción de rayos X de las arcillas del subsuelo de la Ciudad de México". Tesis de licenciatura, Facultad de Química, UNAM, México.

Lo, K.Y. (1962). "Shear strength properties of a sample of volcanic material of the valley of Mexico". *Géotechnique*, Vol. 12, No. 4, 303-318.

Marsal, R.J. y Mazari, M. (1959). "The Subsoil of Mexico City". Contribution to the First Panamerican Conference on Soil Mechanics and Foundation Engineering, Ciudad de México, México.

Mesri, G. Rokhsar, A., y Bohor, B.F. (1975). "Composition and compressibility of typical samples of Mexico City clay", *Geotechnique*, Vol. 25, No. 3, 527-554.

Peralta y Fabi, R. (1989). "Sobre el origen de algunas propiedades mecánicas de la formación arcillosa superior del valle de México". Simposio Tópicos Geológicos de la cuenca del valle de México, SMMS, México.

Zeevaert, L. (1949). "An investigation of the engineering characteristics of the volcanic lacustrine clay deposit beneath Mexico City". *Ph.D. Thesis*, University of Illinois, Urbana, Illinois.