



UNIVERSIDAD NACIONAL
AUTÓNOMA DE
MÉXICO

UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO

**PROGRAMA DE MAESTRIA Y DOCTORADO EN
INGENIERIA**

FACULTAD DE INGENIERÍA

**DETERMINACIÓN DE PARÁMETROS DINÁMICOS
A PARTIR DE UN SISTEMA NEURO-GENÉTICO**

T E S I S

QUE PARA OPTAR POR EL GRADO DE:

MAESTRO EN INGENIERIA

INGENIERÍA CIVIL - GEOTECNIA

P R E S E N T A :

FRANCISCO JAVIER CORREA GIRALDO

TUTOR:

Dr. MIGUEL P. ROMO O.

AÑO
2005



JURADO ASIGNADO:

Presidente: Dr. DANIEL RESENDIZ NUÑEZ
Secretario: Dr. RAÚL FLORES BERRONES
Vocal: Dr. MIGUEL P. ROMO ORGANISTA
1^{er.} Suplente: Dr. EFRAÍN OVANDO SHELLEY
2^{do.} Suplente: Dr. JESUS FIGUEROA NAZUNO

Lugar o lugares donde se realizó la tesis:

INSTITUTO DE INGENIERÍA - UNAM

TUTOR DE TESIS:

Dr. MIGUEL P. ROMO ORGANISTA

FIRMA

"...Tu la pronunciarás: es tu palabra: y tu palabra es la mía; palabra de honor: palabra de hombre: palabra de rueda: palabra de molino: imprecación, propósito, saludo, proyecto de vida, filiación, recuerdo, voz de los desesperados, liberación de los pobres, orden de los poderosos, invitación a la riña y al trabajo, epígrafe del amor, signo del nacimiento, amenaza y burla, verbo testigo, compañero de la fiesta y de la borrachera, espada del valor, trono de la fuerza, colmillo de la marrulería, blasón de la raza, salvavida de los límites, resumen de la historia: santo y seña de México: tu palabra:....."

La Muerte de Artemio Cruz

Carlos Fuentes, 1962

AGRADECIMIENTOS

A MÉXICO

Al Instituto de Ingeniería y a la Dirección de Estudios de Posgrado de la UNAM por el apoyo para la realización de este proyecto

Índice

Introducción	1
Capítulo 2	
Cómputo Aproximado	3
2.1 Redes Neuronales	4
2.1.1 Neurona biológica y artificial	6
2.1.2 Funcionamiento general	13
2.1.3 Aplicaciones en ingeniería	15
2.2 Algoritmos evolutivos	21
2.2.1 Algoritmos genéticos	23
2.3 Técnicas clásicas de optimación y AGs	30
2.3.1 Técnicas heurísticas	32
2.3.2 Características de los AGs	34
2.3.3 Diferencias de las técnicas evolutivas con respecto a las tradicionales	35
Capítulo 3	
Sistema de identificación	37
3.1 SI en ingeniería	38
3.2 SI geotécnico	49
Capítulo 4	
Resultado del sistema de identificación neuro-genético, SI-NG	56
4.1 Base de datos	56
4.1.1 Perfil estratigráfico del sitio CDAO	59
4.1.2 Descripción del arreglo acelerográfico vertical en CDAO	60
4.1.3 Registros acelerográficos en CDAO	62
4.2 Análisis de resultados	63
4.2.1 Descripción general del SI-NG	63
4.2.2 Funcionamiento del SI-NG	70
4.2.3 Descripción de las variables involucradas en el SI-NG	71
4.2.4 Algunas consideraciones sobre G y λ	72
4.2.5 Rangos dinámicos, atributos y representación numérica de las variables involucradas en el modelo neuronal	73

4.3 Ejemplo de aplicación	74
4.3.1 Depósito: 1 Estrato	74
4.3.2 Depósito: Caso CDAO	82
4.4 Resultados finales	92
4.4.1 Consideraciones prácticas para la estimación de la respuesta sísmica	99
Capítulo 5	
Conclusiones	109
Anexo A: Fundamentos teóricos	108
Anexo B: Ecuación unidimensional de onda de cortante	121
Anexo C: Solución de la ecuación unidimensional de onda de cortante	123
Anexo D: Función de transferencia	127
Apéndice I: Backpropagation	133
Referencias	142

INTRODUCCIÓN

Un depósito de suelo se considera como un sistema físico complejo debido a su conformación geológica, evolución de propiedades, configuración espacial e interacción con distintas obras civiles, haciendo difícil la construcción de modelos para estudiar su comportamiento. Esta exigencia obliga a generar modelos que simplifiquen el comportamiento físico observado.

Un ejemplo de esto, es el modelo unidimensional de ondas de corte (modelo 1D), con el que se realizan análisis de respuesta dinámica de depósitos de suelo con estratificación horizontal.

Uno de los elementos del modelo 1D con un importante efecto sobre la respuesta evaluada tiene que ver con las propiedades que caracterizan el comportamiento dinámico del suelo: módulo de rigidez G y relación de amortiguamiento λ . La medición (pruebas de campo y arreglos acelerográficos) y/o estimación (estudios de laboratorio) de G y λ junto con la interpretación de estos valores en condiciones particulares de campo, son actividades en muchos sentidos subjetivas e inciertas. Adicionalmente, uno de los aspectos poco estudiados sobre la variación de G y λ , es el hecho demostrado en ensayos de laboratorio sobre su dependencia con el valor de frecuencia.

En esta investigación se busca superar estos inconvenientes a partir de la combinación de técnicas avanzadas de cómputo y control. Empleando las ventajas del Cómputo Aproximado (CA) para el modelado de sistemas y fenómenos de alta complejidad, y combinándolo con conceptos de la teoría de control; se construye un Sistema de Identificación (SI) para establecer la estructura matemática (modelo de respuesta dinámica) y los parámetros asociados (G y λ) al comportamiento del depósito de suelo, a través de respuestas medidas en campo (arreglo acelerográfico del sitio Central de Abasto Oficinas). Este enfoque representa una atractiva alternativa a los análisis convencionales 1D, ya que la caracterización dinámica de los suelos que integran el depósito permite reproducir, con buena aproximación, el comportamiento observado en el sitio.

RESUMEN

En esta investigación se propone un sistema de identificación para: i) determinar los parámetros que dirigen el comportamiento dinámico de un depósito de suelo y ii) predecir la respuesta de dicho depósito ante eventos sísmicos futuros, a partir de la información contenida en mediciones realizadas sobre el depósito. El sistema de identificación compuesto de un módulo neuronal de respuesta de sitio y un optimizador genético de parámetros dinámicos, estima con una buena aproximación a lo medido la respuesta del sitio Central de Abasto Oficinas ubicado en la ciudad de México (Zona de Lago), a partir de parámetros dinámicos dependientes de la frecuencia y apoyado en el marco del modelo de respuesta unidimensional.

CAPITULO 2

Cómputo Aproximado, **CA**

El Cómputo Aproximado (CA), es un campo multidisciplinario donde se fusionan metodologías diseñadas para modelar y obtener la solución de problemas, cuya naturaleza y/o comportamiento los hacen muy difíciles de plantear analíticamente. El cómputo aproximado (Soft Computing; Zadeh, 1994) usa la mente humana como modelo, apuntando hacia la formalización de los procesos cognoscitivos que los humanos usamos en la realización de múltiples tareas. Su objetivo fundamental es desarrollar máquinas inteligentes para resolver problemas cuya no linealidad y alta dimensionalidad obliguen a planteamientos matemáticos más complejos (Zadeh 1993, 1996 y 1999).

Los principales constituyentes del CA son la Lógica Difusa **LD** (Zadeh, 1965; Zadeh, 1994), las Redes Neuronales **RNs** (Rosenblatt, 1959), el Computo Evolutivo **CE** (Holland, 1975) y el Razonamiento Probabilístico **RP** (Dempster, 1967; Shafer, 1976). La LD relacionada con la imprecisión, la RNs con el aprendizaje, el CE con la optimización y el RP con la incertidumbre, resultan técnicas complementarias; por lo que, su empleo de manera combinada para el diseño e implementación de sistemas inteligentes resulta ventajoso.

Las principales características del cómputo tradicional (cómputo cerrado) son la precisión, la certeza y el rigor. En contraste, el CA resta importancia a la precisión y la certeza debido a que toma en cuenta que el cómputo, el razonamiento y la toma de decisiones deben considerar –hasta donde sea posible– la imprecisión y la incertidumbre inherentes a datos “reales” o naturales. La tarea: “estacionar un automóvil” ejemplifica claramente las ventajas del CA. La mayoría de las personas son capaces de estacionar un automóvil fácilmente porque la posición final y orientación del vehículo no se especifican de forma precisa. Si por el contrario, la precisión se incluyera como condición necesaria para cumplir debidamente esta acción, un ser humano difícilmente lograría realizarla. Lo que es importante recalcar aquí es que los humanos, en general, pueden resolver este problema debido a su formulación imprecisa; pero resulta muy difícil de solventar utilizando mecanismos de control y operación, debido a que estos métodos no manejan la indeterminación.

Por lo tanto, considerar la imprecisión y la incertidumbre es la base de la capacidad humana para entender un discurso distorsionado, descifrar la escritura, comprender matices del lenguaje, resumir un texto, reconocer y clasificar imágenes, manejar un vehículo en tráfico pesado y tomar decisiones racionales dentro de un ambiente indeterminado. Comprender los problemas del mundo real, asociados comúnmente a sistemas complejos y dinámicos con parámetros inciertos, involucra el desarrollo de modelos científicos que permitan modelar adecuadamente este tipo de fenómenos.

2.1 **Redes Neuronales, RNs**

El cerebro humano puede entenderse como una máquina capaz de interpretar información imprecisa suministrada por los sentidos a un ritmo veloz. Lo más destacable es que el cerebro aprende, sin instrucciones explícitas, a crear representaciones internas (patrones) que facilitan estas habilidades.

Las Redes Neuronales (RNs) son modelos que intentan reproducir el funcionamiento del cerebro a través de redes numéricas que identifican y simplifican los elementos relevantes de un sistema (fenómeno) y adquieren conocimiento (generalizar→aprender) a partir de comportamientos típicos (entrenamiento). Este conocimiento es adquirido durante el *proceso de aprendizaje* a través de la fuerza de interconexiones entre las neuronas (conocidas como *pesos sinápticos*), donde “almacena” por medio de símbolos este conocimiento. Por lo tanto, la tarea por

ejecutar no se programa, sino que se expresa con relaciones numéricas (datos entrada→salida).

El proceso de aprendizaje dirige a la red hacia la generalización; es decir, hacia la producción de resultados correctos para nuevos casos o condiciones de entrada no empleadas durante el proceso de aprendizaje. La elección adecuada de una topología neuronal, una estructura conveniente de datos (patrones) y un criterio de supervisión y terminación pertinente, permite construir redes de funcionamiento eficiente.

El primer modelo de red neuronal fue propuesto en 1943 por McCulloch y Pitts (1943) en términos de un modelo computacional de "actividad nerviosa", que sirvió de ejemplo para los modelos posteriores de Jhon Von Neumann, Marvin Minsky (Minsky y Papert, 1969), Frank Rosenblatt (Rosenblatt, 1962) y muchos otros. En la actualidad, las RNs constituyen una alternativa al cómputo clásico para abordar problemas en los que los métodos tradicionales no son capaces, a través de modelaciones algorítmicas (programación secuencial predefinida por instrucciones), de generar resultados convincentes.

A la definición de Robert Hecht-Nielsen (1990) de una RN como: *"un sistema computacional constituido por un gran número de elementos procesadores simples, altamente interconectados, que procesan la información por la respuesta en estado dinámico de entradas externas"*, puede agregarse que las RNs son una combinación de elementos simples (*neuronas*) interconectados, que permiten modelar datos, que capturan y representan relaciones complejas entrada/salida y que al operar de forma paralela, consiguen resolver problemas relacionados con el reconocimiento de formas o patrones, predicción, codificación, control y optimización.

El potencial de las RNs radica en su capacidad para representar relaciones lineales y no-lineales a partir de datos numéricos que describen los sistemas modelados.

Las RNs deben "aprender" cómo analizar la información de entrada y responder adecuadamente antes de que puedan utilizarse en aplicaciones prácticas. El ajuste de los pesos asociados a cada neurona (entrenamiento) realizado hasta que la salida de la red se aproxime lo suficiente al objetivo del cálculo, depende de los datos de entrada y las respuestas asociadas presentadas a la red. Cuando la red está entrenada, datos de

nuevas condiciones (entradas) son presentados al sistema neuronal, el cual "recuerda" la respuesta que "aprendió" y la modifica de acuerdo a las nuevas condiciones y al funcional neuronal generado por dicho entrenamiento.

En general, las RNs presentan las siguientes características:

- No linealidad: Dentro de la estructura básica de una red neuronal existen funciones que otorgan características de no linealidad. Esta propiedad permitirá el procesamiento y la simulación de sistemas no lineales y/o caóticos.
- Capacidad de establecer relaciones entrada-salida: Uno de los elementos de las RNs se conoce como aprendizaje supervisado, donde se le presentan a la red una serie de entradas junto a salidas asociadas para establecer relaciones entre ellas de manera que, ante entradas desconocidas, la red sea capaz de dar una respuesta "aproximada" a la salida deseada.
- Su desempeño no depende de hipótesis ni simplificaciones referidas a modelos o funcionales previamente establecidos.

La clase de problemas que las RNs resuelven eficientemente son la asociación, la evaluación, y el reconocimiento de patrones. Pueden encontrarse aplicaciones exitosas en el *análisis de inversión* (para predecir el movimiento bursátil); *análisis de firmas* (mecanismos para almacenar y estudiar bancos tipográficos); *procesos de control* (modelos no paramétricos para el control de sistemas dinámicos); *marketing* (mapeo predictivo de datos financieros de acuerdo a la actuación de los clientes), monitoreo, procesamiento de imágenes y voz, reconocimiento de patrones, planeación, interfaces adaptivas para sistemas hombre/máquina, filtrado de señales, entre otros.

2.1.1 Neurona biológica y artificial

Una **neurona** biológica consta de un cuerpo celular rodeado de ramificaciones o **dendritas** y una fibra larga llamada **axón** (Fig. 2.1). Las ramificaciones permiten la conexión entre una neurona y las que la rodean (**sinapsis**); el mecanismo de transmisión de información entre las neuronas responde a una combinación de señales eléctricas y químicas, la cual ocurre cuando al llegar de un impulso nervioso al axón de una neurona emisora se provoca la liberación de unas sustancias químicas (neurotransmisores) que alteran la permeabilidad de la membrana de la neurona a la que está conectada, produciendo una variación del potencial eléctrico de la neurona receptora (difusión de iones a través de la membrana celular). Cuando la diferencia de

potencial alcanza un cierto umbral, la neurona produce una descarga eléctrica seguida de un proceso de recuperación.




Figura 2.1 Neurona biológica

Dada la complejidad de este proceso y el escaso conocimiento que se tiene de él, matemáticamente se recurre a una versión simplificada en la que cada neurona integra, de forma continua, los impulsos (excitaciones e inhibiciones) de todas aquellas neuronas a las que está conectada generando un impulso de salida, siempre y cuando supere un umbral que se ha definido previamente. Una red de neuronas así constituida, funciona de forma asíncrona; es decir, cada neurona actúa como una unidad de procesamiento distribuido con múltiples entradas y salidas, de forma que realiza una operación individual elemental (Fig. 2.2).

Elementos de una Red Neuronal Artificial

Una RN se describe a partir de los siguientes elementos:

- a) Arquitectura o topología
- b) Unidades de procesamiento (neuronas)
- c) Conexiones
- d) Función de entrada
- e) Función de activación
- f) Regla de aprendizaje

Cada uno de estos elementos se describe brevemente a continuación, enfatizando en los tipos o clases involucrados en esta investigación. Los trabajos de Haykin (1994) y Shepherd (1997) representan excelentes guías teóricas en estos temas, por lo cual al lector no familiarizado con este tema se le recomienda una revisión de estos textos para una mejor comprensión de los puntos expuestos a continuación.




Figura 2.2 Simplificación de la neurona biológica

a) **Arquitectura o topología:** Consiste en la organización y disposición de las neuronas (nodos) formando capas distintas a las de entrada y salida de una red. La selección de la arquitectura es el primer paso en el diseño de una red neuronal; por lo tanto, de una elección apropiada, depende el entrenamiento eficiente de la red y su correcta relación con el fenómeno estudiado. Los parámetros básicos que se deben definir en la arquitectura de una red son: el *número de capas*, el *número de neuronas* por capa, el *grado de conectividad* y el *tipo de conexiones* entre neuronas. Cabe mencionar que no existe aún una técnica o metodología clara para determinar estos arreglos; la elección hasta el momento, se basa en la experiencia del diseñador.

Redes Monocapa: Establecen conexiones laterales, cruzadas o autorrecurrentes entre las neuronas que pertenecen a la única capa que constituye la red. Se utiliza en tareas relacionadas con la autoasociación (generar información – conclusiones- acerca de patrones que se presentan a la red de manera incompleta o distorsionada).

Redes Multicapa: Disponen de conjuntos de neuronas agrupadas en varios niveles o capas. Dentro de las más estudiadas y utilizadas en aplicaciones prácticas se encuentran las de multicapa de Propagación normal hacia adelante (*Multilayer Normal Feed Forward*). Cada capa recibe un vector de entrada que puede ser un vector de entrada externo o un vector de salida de una capa anterior. Las capas son ubicadas en orden; es decir, la entrada para la primera capa es la entrada externa, la entrada de la segunda capa, si existe, es la salida de la primera capa y así sucesivamente. Las capas siguientes reciben sus entradas de la capa anterior. Como consecuencia, la última capa es la de salida y el vector correspondiente representa la salida de la red (Fig. 2.3).

- b) Unidades de procesamiento: En una RN existen tres tipos de unidades que se encuentran agrupadas en capas (Fig. 2.3): i) *capa de entrada*, recibe las señales que intervienen en el comportamiento en estudio, ii) la *capa oculta*, donde se ejecutan los procesos fundamentales de la red neuronal y iii) la *capa de salida*, recibe la información de la capa oculta y transmite la respuesta al medio externo; esta capa contiene los parámetros objetivo.




Figura 2.3 Arquitectura de red multicapa: propagación normal hacia adelante

- c) Conexiones: Las conexiones entre las unidades de procesamiento tienen un peso asociado donde se *almacena* el conocimiento que adquiere la red. La magnitud de los pesos indican la fuerza que tiene la conexión entre neuronas o elementos procesadores, y funcionan como factor determinante en la definición de la excitación o inhibición de la neurona.

d) Función de entrada: Función con la que se calcula el valor total de las entradas recibidas en la capa oculta. Inicialmente, cada neurona recibe un vector de entrada \mathbf{X}_i (Fig. 2.3), con uno o más pesos asignados; este conjunto de pesos conforma el vector asociado al nodo \mathbf{W}_{ij} . Si \mathbf{W}_{ij} es positivo indica que la relación entre las neuronas es excitadora, es decir, siempre que la neurona j esté activada, la neurona i recibirá una señal que tenderá a activarla. Si \mathbf{W}_{ij} es negativo, la sinapsis será inhibitoria; es decir, si j está activada, enviará una señal que desactivará a i . Finalmente, si \mathbf{W}_{ij} es 0 se supone que no hay conexión entre ambas. Una *función de entrada* combina el vector de entrada \mathbf{X} con el vector de pesos \mathbf{W} con el propósito de obtener la *entrada neta* (Ec. 2.1) para el nodo correspondiente y equivale a la combinación de las señales excitadoras e inhibitorias de las neuronas biológicas.

$$E_j = \sum_{i=1} X_i W_{ij} \quad \text{[Ec. 2.1]}$$

e) Función de activación: Se considera el elemento clave en el funcionamiento de una red neuronal; se encarga de atribuir las características no lineales al procesamiento en los nodos, lo que se amplía su campo de aplicación y las ventajas sobre técnicas convencionales de regresión y análisis de datos (Ec. 2.2). La *función de activación* (f) actúa sobre el valor arrojado por la función de entrada limitando su crecimiento. Existen muchos tipos de funciones de activación; los más usuales son: sigmoide, tangente hiperbólica, función signo, escalón y lineal. En aplicaciones de RNs como aproximadores funcionales universales se ha probado el buen comportamiento de la función sigmoide y lineal en las capas ocultas y de salida respectivamente.

$$Y_j = f(E_j) \quad \text{[Ec. 2.2]}$$




Figura 2.4 Función de Activación Lineal

☞ Función de activación lineal: Función donde la salida es igual a la entrada (Fig. 2.4). Su ecuación está dada por la ecuación 2.3.

$$Y = X \quad \text{[Ec. 2.3]}$$

☞ Función de activación sigmoideal: Función que toma los valores de entrada y restringe las salidas entre cero y uno, de acuerdo con la ecuación 2.4 (Fig. 2.5). Por su cualidad diferenciable, esta función es comúnmente usada en redes multicapa con propagación de error hacia atrás.

$$Y = \frac{1}{1 + e^{-x}} \quad \text{[Ec. 2.4]}$$




Figura 2.5 Función de transferencia Sigmoideal

La activación de una red de propagación normal hacia adelante inicia con la alimentación de la entrada externa de la primera capa, aplicando la función de entrada para activar los nodos y acto seguido la función de activación (Fig. 2.6). El vector salida de esta capa alimenta la capa siguiente, que es activada de la misma manera, y de forma sucesiva hasta que la capa de salida es activada, produciendo el vector de salida de la red.

- f) Regla de Aprendizaje. Ecuación en función de las entradas y salidas que fija la forma de variación de los pesos; es decir, es el instrumento empleado para adaptar las conexiones a la información que se presenta, registrando, asociando y generando conocimiento. El proceso de aprendizaje implica la destrucción, modificación y creación de conexiones neuronales. Una conexión se crea cuando el peso de la conexión tiene un valor distinto de cero y se destruye cuando su peso se

igual a cero. El proceso de aprendizaje concluye cuando los valores de los pesos permanecen estables ($dw_{ij} / dt = 0$).




Figura 2.6 Proceso interno donde se involucra la función de activación (f)

Existen dos tipos básicos de aprendizaje: el *supervisado* y *no supervisado*. La diferencia fundamental entre ambos estriba en la existencia o no de un agente externo (supervisor) que controle el aprendizaje de la red.

Aprendizaje supervisado: Se presentan series de patrones de entrada y salida que ejemplifican comportamientos comunes del fenómeno estudiado. La red modifica los pesos de las neuronas tratando de minimizar el error de su salida, hasta que la salida calculada se aproxime a la deseada. A este grupo pertenece la regla empleada en este trabajo; que es una modificación del algoritmo de propagación del error hacia atrás (*BackPropagation* (BP), Apéndice I), denominada propagación rápida (*QuickPropagation* (QP)), que tiene como objetivo minimizar el tiempo requerido para encontrar un conjunto de pesos óptimo; este tiempo para problemas grandes y complejos es muy alto cuando se usa BP (Fahlman, 1988). QP es un algoritmo de aprendizaje basado en BP que propone una manera diferente de modificar los pesos, aproximando la curva error (error *versus* peso) para cada peso con una parábola que se construye a partir de la pendiente formada entre el valor de error actual y anterior.

Aprendizaje no supervisado: No requieren indicaciones sobre la salida para ajustar los pesos de las conexiones entre neuronas. A estas redes se les proporcionan únicamente los estímulos y ellas ajustan sus interconexiones basándose en sus estímulos y sus propias salidas.

Los atributos básicos de las RNs pueden clasificarse en atributos de arquitectura y neurodinámicos (Kartalopoulos, 1996). Los de arquitectura definen la estructura de la red, por ejemplo: número y topología de las neuronas y su interconexión. Los neurodinámicos, por su parte, definen la funcionalidad de la RN (función de entrada y función de activación).

2.1.2 Funcionamiento general

La operación de un modelo neuronal requiere de dos fases (*e.g.*, Ripley, 1996; Fausett, 1994; Zurada, 1992; Hecht-Nielsen, 1990; Maren *et al.*, 1990): 1) la de *aprendizaje o entrenamiento* y 2) la de *prueba*. En el entrenamiento se usa un conjunto de datos o patrones de entrenamiento para determinar los *pesos* (parámetros de diseño) de las interconexiones de las neuronas. Los pesos son modificados de acuerdo a la información contenida en los patrones de entrenamiento, generalmente, optimizando (minimizando o maximizando) alguna *función* (función de error), usando una *regla de aprendizaje*. Una vez entrenado, el modelo neuronal se somete a la *fase de prueba* o funcionamiento directo, donde se valida dicho modelo procesando patrones que representan entradas habituales del modelo entrenado, para determinar su actuación ante condiciones desconocidas.

Ventajas de las RN

- a) **Aprendizaje Adaptativo**: Las RNs adquieren conocimiento a través del entrenamiento o "experiencia" que es "almacenada" en los pesos de las conexiones neuronales. Una RN no necesita un algoritmo para resolver un problema, genera su propia distribución de pesos durante el proceso de aprendizaje.
- b) **Autorganización**: A partir de su cualidad adaptativa, una RN organiza la información que recibe durante el aprendizaje creando su propia representación de la información y con este conocimiento organizado, responde a los datos o situaciones de nueva exposición.

- c) Tolerancia a falla numérica: Contrario a los sistemas computacionales tradicionales, que pierden funcionalidad en cuanto sufren un pequeño error de memoria, las RNs no sufren caída repentina si se produce una falla en un pequeño número de neuronas. La tolerancia a fallas se reconoce porque: i) las redes pueden aprender a reconocer patrones con ruido, distorsionados, o incompletos y ii) pueden seguir funcionando (con cierta degradación) aunque se destruyan ciertas partes de la red. La razón por la que las RNs poseen esta ventaja es debido a que tienen su información distribuida en las conexiones neuronales que produce redundancia en el almacenamiento de la información. A diferencia de la mayoría de los ordenadores algorítmicos y sistemas de recuperación de datos en los que se almacena cada pieza de información en un estado único, localizado y direccionable.
- d) Operación en tiempo real: Los computadores neuronales operados en paralelo, se diseñan y fabrican como *hardware* idóneo en procesos que requieren operación en tiempo real.
- e) Fácil inserción dentro de tecnología existente. Una RN se entrena, comprueba, verifica y traslada a una implementación *hardware* a relativo bajo costo. Las subrutinas neuronales mejoran el desempeño de herramientas de cómputo existentes de forma incremental.

Las RNs son preferibles a otros métodos matemáticos cuando:

1. Es difícil encontrar las reglas que definen la variable a modelar en relación con las variables independientes consideradas para el modelo.
2. Los datos son imprecisos o contienen perturbaciones estadísticas (ruido).
3. El problema necesita para ser definido un gran número de variables dependientes (presenta una alta dimensionalidad).
4. El modelo a resolver es no lineal.
5. Se dispone de un gran número de datos.
6. El entorno de trabajo es variable.

Aplicaciones de la RN

Las aplicaciones neuronales se clasifican como sistemas neuronales de:

- Clasificación: Decidir a que clase, de una serie dada, se asigna un dato de entrada de la red.

- Asociación: La red funciona como un proceso de recuperación de un dato a partir de una entrada relacionada con el dato almacenado. La entrada puede ser una versión incompleta o deformada del dato buscado.
- Agrupamiento: Utilizada cuando no se conoce una clasificación de los datos de entrada y se espera que la red genere esta clasificación.
- Optimización: Permite solucionar problemas de naturaleza complicada, que involucran toma de decisiones y actuaciones dependientes de procesos.
- Predicción y control: En tareas de predicción para anticipar el estado futuro de un sistema y en tarea de control de sistemas dinámicos complejos

2.1.3 Aplicaciones en ingeniería

A la fecha, las RNs han sido ampliamente usadas en problemas ingenieriles, aprovechando las características que las aventajan sobre otras técnicas de modelado de sistemas. Entre otras áreas de aplicación pueden encontrarse (aplicaciones adicionales pueden también encontrarse en Romo, 1999; García y Romo, 2003; Romo *et al.*, 1998):

Ingeniería de costas: Se han construido modelos neuronales para el pronóstico de mareas y el estudio de olas que inducen inestabilidad en el fondo marino, lo cual es importante en el diseño de estructuras marinas (plataformas marinas). En general, cuando las olas se propagan sobre el océano, generan una presión dinámica en el piso marino. La constante fluctuación de las olas causa fuertes cambios en el esfuerzo efectivo y exceso de presión de poro dentro del suelo, que puede generar una parcial licuación (pérdida de resistencia) de los sedimentos del suelo marino. Modelos neuronales (Jeng *et al.*, 2003) han sido construidos para la evaluación del potencial de licuación por causa de dicho fenómeno.

Ingeniería estructural: Se han construido modelos neuronales para la detección del período natural de vibración de un edificio prefabricado de media altura (Kuzniar *et al.*, 2000) y como método predictivo del comportamiento estructural de una losa de concreto (Hegazy *et al.*, 1998).

Ingeniería geotécnica

La geotecnia es conocida como un área imprecisa dentro de la ingeniería debido a que trabaja con materiales producidos durante complejos procesos geológicos ocurridos en la naturaleza. El entendimiento del comportamiento del suelo frente a diferentes

fenómenos es aún limitado, lo cual reduce la posibilidad de predecir el comportamiento de obras geotécnicas. Es por ello que el juicio de los expertos juega un papel crucial dentro de los criterios de diseño y se establece como complemento necesario de las relaciones empíricas que se emplean usualmente para fijar estos criterios. Las RNs han sido usadas exitosamente en diferentes problemas geotécnicos: predicción de capacidad de pilotes, modelado del comportamiento del suelo, caracterización de sitio, estructuras de retención de tierra, asentamiento, estabilidad de taludes, diseño de túneles, licuación, permeabilidad de suelos, conductividad hidráulica, compactación de suelos, mejoramiento de suelos, presas y clasificación de suelos y rocas. Se presenta a continuación, una revisión de algunas de estas aplicaciones.

Capacidad de pilotes: Goh (1994a, 1995b) presentó un modelo neuronal para predecir la capacidad de pilotes de fricción en arcillas. Considera como entrada la longitud y diámetro del pilote, esfuerzo efectivo medio y resistencia cortante no drenada y como salida la resistencia por fricción en la superficie del pilote. Goh (1995a, 1996b), desarrolló otro modelo neuronal para estimar la capacidad de carga última de pilotes en suelos sin cohesión.

Abu-Kiefa (1998) introdujo tres modelos neuronales para predecir la capacidad de pilotes hincados en suelos sin cohesión. El primero de ellos, estima la capacidad total de los pilotes, el segundo la capacidad de pilotes por punta y el tercero la capacidad de pilotes por fricción. Estos modelos fueron comparados con algunos métodos convencionales (Meyerhof, 1976 y Coyle y Costello, 1981) y determinó que las predicciones realizadas con el modelo neuronal producen menor dispersión. Entre otros de los trabajos realizados en este campo, pueden mencionarse los de Chan *et al.*, 1995; Lee y Lee, 1996; Teh *et al.*, 1997 y Nawari, 1999.

Cimentaciones: En el diseño de cimentaciones (selección del tipo apropiado de cimentación), Shukla (1988) y Adams *et al.*, (1989) generaron un sistema experto que permite seleccionar un tipo de cimentación para un edificio. Este sistema proporciona una lista de alternativas de cimentación basado en las condiciones del suelo, localización del nivel freático, profundidad del estrato duro y las condiciones de carga impuesta de la estructura. Hadipriono *et al.*, (1995) desarrollaron un sistema experto, para la determinación de las causas de falla de la cimentación: asentamiento del suelo, expansión de suelos, erosión del suelo, falla por capacidad de carga, inestabilidad de taludes y corrosión de la cimentación. Los sistemas expertos (KBS: Knowledge-based

systems), son los sistemas predecesores de las redes neuronales, que combinan la medición del fenómeno y el criterio de expertos.

Asentamientos: El diseño de cimentaciones está, por lo general, controlado por los criterios de capacidad de carga y asentamiento. Goh (1994a) desarrolló un modelo neuronal para la predicción de asentamientos de una cimentación con pilotes cargada verticalmente sobre un estrato homogéneo. Sivakugan *et al.* (1998) exploraron la posibilidad de usar un modelo neuronal para predecir el asentamiento de una cimentación superficial sobre suelo granular, los resultados obtenidos fueron comparados con métodos propuestos por Terzaghi y Peck (1967) y Schemertmann (1970) y establecieron que estos métodos sobreestiman los asentamientos 2 y 3 veces, respectivamente. Shahin *et al.* (2000) construyeron un modelo neuronal para predecir asentamientos de cimentaciones superficiales en suelos sin cohesión.

Comportamiento y propiedades del suelo: Goh (1995a, 1995c) usó un sistema neuronal para modelar la correlación entre la densidad relativa y la resistencia a la penetración de una prueba de cono (CPT), para arenas normalmente consolidadas y sobreconsolidadas. El sistema usa como entrada la densidad relativa y el esfuerzo medio efectivo del suelo y como salida la resistencia de cono. Ellis *et al.* (1995) desarrollaron un sistema neuronal para modelar el comportamiento del suelo, a partir de la distribución granulométrica e historia de esfuerzos. Sidartha y Gaboussi (1998) emplearon un modelo neuronal dentro de un análisis de elemento finito para determinar el comportamiento constitutivo de los geomateriales. Penumadu y Jean-Lou (1997) usaron una red neuronal para representar el comportamiento de arenas y arcillas.

Ghaboussi y Sidarta (1998) usaron una red neuronal para modelar el comportamiento drenado y no drenado de arenas limpias en una prueba de compresión triaxial. Penumadu y Zhao (1999) también usaron RNs para modelar la relación esfuerzo – deformación y el cambio de volumen de arenas y gravas bajo condiciones de una prueba de compresión triaxial drenada. Zhu *et al.* (1998a, 1998b) usaron RNs para modelar el comportamiento de suelos residuales de grano fino, arenas de duna y suelos volcánicos de Hawaii. Cal (1995) usó RNs para generar una clasificación cuantitativa de suelos a partir de tres factores (Índice de plasticidad, límite líquido y contenido de arcilla).

Najjar *et al.* (1996a) demostraron que pueden construirse modelos neuronales que permitan medir de forma aproximada la expansión de suelos y que estos modelos son significativamente mejores que los métodos estadísticos. Romero y Pamukcu (1996) demostraron que las RNs son efectivas para caracterizar y estimar el módulo de corte de materiales granulares. Agrawal *et al.* (1994); Gribb y Gribb (1994) y Najjar y Basheer (1996b) usaron RNs para estimar la permeabilidad de arcillas. Basheer y Najjar *et al.* (1995) y Najjar *et al.* (1996b) validaron una RN para la compactación de suelos. Romo *et al.* (2003) desarrollaron un modelo basado en RN que permite, con valores de la resistencia a la penetración por punta de sondeos de cono, inferir un valor de velocidad de onda de corte y posteriormente a través de un modelo neuronal, estimar el valor del módulo de corte y la relación de amortiguamiento, en función de la deformación al corte, para caracterizar dinámicamente un depósito de suelo. García *et al.* (2002) construyeron una topología neuronal recurrente que permite determinar el comportamiento esfuerzo-deformación y presión de poro-deformación de un material granular a partir de valores de densidad relativa, esfuerzo de confinamiento y diámetro de partícula. Aplicaciones pueden también encontrarse en Romo, 1999; García y Romo, 2003; Romo *et al.*, 1998.

Efectos de licuación inducida por sismos: Jeng *et al.* (2003) propusieron un modelo neuronal que evalúa el potencial de licuación. La capacidad de este modelo fue puesta a prueba en algunos sitios de la ciudad de Wufeng (Taiwán). Se estableció la buena concordancia entre los valores alcanzados con el modelo y las mediciones reales en cada sitio.

Goh (1994b) usó RNs para modelar la compleja relación entre los parámetros sísmicos y del suelo e investigar el potencial de licuación. Usó como entrada parámetros del suelo y características del sismo (Magnitud y aceleración horizontal), y como salida un valor binario (valor de 1 para sitios con alto o moderado potencial de licuación y un valor de 0 para un potencial de licuación marginal o nulo). Los resultados fueron comparados con el método de Seed *et al.* (1985) y encontró un 95% de predicciones correctas usando este modelo neuronal, mientras que el método de Seed alcanzó un 84%. Goh (1996a); Najjar y Ali, 1998; Ural y Saka, 1998 usaron RNs para evaluar el potencial de licuación a partir de los datos de resistencia de la prueba de penetración de cono (CPT). Najjar y Ali (1998) usaron RNs para caracterizar la resistencia a la licuación del suelo utilizando datos de campo de varios sismos representativos de sitios

alrededor del mundo. Otros trabajos en esta área son presentados por Wang y Rahman (1999), y Baziar y Ghorbani (2005).

Caracterización de sitio: Establece el análisis e interpretación de los datos geotécnicos del sitio investigado. Zhou y Wu (1994) usaron un modelo neuronal para caracterizar la distribución espacial de la profundidad del manto de roca que permitió construir un mapa de contorno con las estimaciones de tales profundidades. Basheer *et al.* (1996) plantearon una RN para mapear y predecir la variación de la permeabilidad del suelo. Wharry y Ashley (1986), presentan un sistema experto (SOILCOM), para planear la exploración de sitio, determinando el nivel de investigación geotécnica requerida, basado en la estructura civil propuesta y el nivel de información conocida del sitio.

Magnan (1992) generó un sistema experto (CESSOL) que proporciona reglas cualitativas sobre el tipo de investigación y el tipo de pruebas requeridas; igualmente, da consejos cuantitativos sobre el número de perforaciones, piezómetros y cantidad de ensayos requeridos. Moula (1993) y Moula y Toll (1993), presentan un modelo neuronal que ayuda en la selección de los ensayos de campo apropiados. El sistema aconseja cuál ensayo proporciona un parámetro requerido y cómo se aplica para las condiciones específicas de suelo. Para la interpretación de las condiciones del suelo Norkin (1985) y Rehak *et al.* (1985) generaron un sistema experto (SITECHAR) que usa razonamiento geométrico para inferir los patrones de sedimentación de los materiales por debajo de la superficie, así como sus propiedades físicas. Otras aplicaciones son presentadas por Rizzo *et al.* 1996; Najjar y Basheer, 1996a y Rizzo y Dougherty, 1994. Caracterizaciones de sitio han sido también realizadas para los suelos del valle de México por Romo *et al.* (2001), García *et al.* (2005a) y García y Romo (2004a, 2004c).

Estructuras de retención de tierra: Sistemas de inteligencia artificial se han desarrollado para el diseño de estructuras de retención, predicción de movimientos y análisis de fallas. Goh *et al.* (1995b) desarrollaron un modelo neuronal para dar estimaciones iniciales máximas de deflexión en las paredes de una excavación de arcilla. Martínez y Romo (2002), aplicaron RNs para la evaluación de desplazamientos laterales de excavaciones apuntaladas en suelos blandos. Hutchinson *et al.* (1987) presentan un sistema experto (RETWALL) para la selección y diseño preliminar de estructuras de retención de tierra. Chahhine y Janson (1987) desarrollaron un sistema experto (WADI) para el diagnóstico preliminar de las fallas en muros de retención.

Estabilidad de taludes: Ni *et al.* (1996) propusieron una metodología que combina lógica difusa y RNs para evaluar la estabilidad de taludes. Los resultados son concordantes con resultados obtenidos de modelos analíticos. Dos sistemas expertos se desarrollaron para evaluar la estabilidad de taludes, el SISYOHE y el XPENT. El XPENT (Faure *et al.*, 1988; Faure *et al.*, 1991; Mascarelli *et al.*, 1992; Faure *et al.*, 1995) hace un diagnóstico del tipo de deslizamiento, basado en la geología, vegetación, geomorfología e hidrogeología y aconseja sobre métodos de estabilización basados en el tamaño del deslizamiento, el material y accesibilidad del sitio. Por otro lado, SISYPHE (Asté, 1992) es un sistema experto usado en el diagnóstico de deslizamientos y evaluación de amenaza; tiene la capacidad de desarrollar representaciones tridimensionales de la superficie del suelo, la superficie piezométrica y la superficie de falla.

Túneles: Shi *et al.* (1998) presentan una RN para predecir asentamientos en túneles; la capacidad de esta red fue probada con datos del Túnel de Brasilia (Brasil). Lee y Sterling (1992) desarrollaron una RN para la identificación de probables modos de falla para túneles. Sterling y Lee (1992) y Moon *et al.* (1995) usaron individualmente modelos neuronales integrados a un sistema experto para el diseño preliminar de túneles. Gökay (1993) desarrolló un sistema experto que asiste al ingeniero de rocas en decisiones relacionadas con la excavación de minas. El sistema considera el tipo de excavación, estado de esfuerzos in-situ, hidrogeología y método de minero. Cálculos de asentamientos en túneles a través de RNs fueron realizados por Rangel y Romo (2000), y posteriormente los acoplaron con sistemas difusos para establecer un procedimiento controlado de excavación de túneles en roca (Rangel *et al.*, 2003 y Rangel, 2002).

Presas: Sieh *et al.* (1988) describen un sistema inteligente que asiste en el diagnóstico de filtración de presas de tierra, que define el tipo de problema, la seriedad del problema y recomienda la acción en curso. García y Romo (2004b), generaron un sistema neurodifuso que permite resolver el problema inverso (identificación de parámetros) para evaluar las propiedades dinámicas de la presa El Infiernillo.

Los resultados obtenidos en los estudios mencionados muestran el enorme potencial de las RN como herramienta para modelar los complejos y aún no bien entendidos problemas geotécnicos, mejorando o igualando la respuesta de los métodos convencionales. En la mayoría de modelos matemáticos que intentan solucionar estos

problemas, la falta de entendimiento físico es usualmente suplida por simplificaciones del problema o incorporando supuestos al modelo. En contraste, las RN se basan en el entrenamiento con pares de datos de entrada y salida, para determinar la estructura y parámetros del modelo; por ello no hay la necesidad introducir hipótesis simplificadoras.

2.2 Algoritmos Evolutivos, AE

Los Algoritmos Evolutivos conforman una familia de técnicas de búsqueda estocástica e iterativa inspirada en los conceptos de la teoría de evolución natural propuesta por Charles Darwin en 1858. Él se percató que una especie que no sufriera cambios se volvería incompatible con su ambiente, ya que éste tiende a cambiar con el tiempo; es decir, las especies evolucionan de acuerdo a la transformación del medio para adaptarse a él. Así mismo, las similitudes observadas en la naturaleza entre padres e hijos le sugirieron a Darwin que ciertas características de las especies eran hereditarias y que, de generación en generación ocurrían cambios cuya principal motivación era hacer a los nuevos individuos más aptos para sobrevivir (Coello, 2001).

Estas ideas causaron polémica en el mundo científico de la época, puesto que bajo esta perspectiva el universo pasaba de ser una creación de Dios estática y perfecta desde su inicio, a un conjunto de individuos en constante competencia y evolución para perpetuar su especie en el tiempo. En este orden de ideas, la existencia pasó entonces a ser dinámica, es decir, las especies se crean, evolucionan y desaparecen (si no se adaptan). Para cada especie animal la naturaleza propone un crudo filtro: sólo los mejores, los más aptos, los que mejor se adapten al medio, consiguen sobrevivir, para llegar a la madurez y perpetuar sus aptitudes a través de la reproducción.

La informática descubre aquí elementos para un claro proceso de optimación. Los individuos mejor adaptados –mejores soluciones temporales-, se cruzan –mezclan-, generando nuevos individuos –nuevas soluciones- que contendrán parte del código genético –información- de sus dos antecesores y por lo tanto, aunque el nuevo individuo no tenga que estar forzosamente mejor adaptado, el promedio de la adaptación de toda la población mejora, ya que tienden a perpetuarse y extenderse las mejores características y a extinguirse las poco benéficas o perjudiciales.

Bajo esta perspectiva, si se considera a la inteligencia como una capacidad de un *ente* para adaptarse a los cambios del ambiente, se puede considerar a los AE como parte del Cómputo Aproximado (CA). La aplicación del CA ha probado tener dos ventajas principales: a) permite resolver problemas no-lineales, para los cuales no se tienen modelos matemáticos disponibles y b) introduce el conocimiento humano hacia la percepción, el reconocimiento, el entendimiento, el aprendizaje y otras tareas de la computación.

Los AE agrupan 3 áreas: Algoritmos Genéticos (AGs), Estrategias de Evolución (EE) y Programación Evolutiva (PE), las cuales se ejecutan a partir de iteraciones del ciclo básico de evolución (Fig. 2.7). Las variaciones de los AE incorporan el mismo ciclo básico con diferentes presentaciones del modelo o combinación específica de los métodos de *cruce*, *mutación* y *selección* (conceptos detallados en una sección posterior). El punto interesante es el balance entre dos operaciones opuestas: por un lado la *selección* que intenta reducir la diversidad de la población (conjunto de posibles soluciones) y por otro lado el *cruce* y la *mutación* que tratan de incrementar la diversidad de la población y dirigir la velocidad de convergencia y la calidad de la solución.

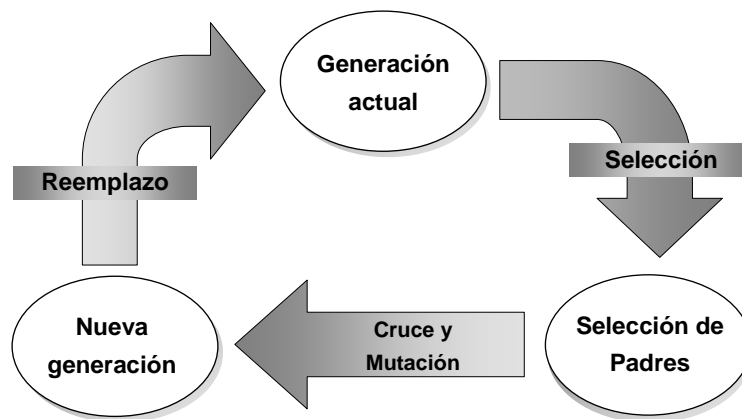


Figura 2.7 Ciclo básico de evolución.

El origen de los AE se establece con los trabajos en cómputo entre los años de 1950 y 1960, con la idea de que los procesos evolutivos podrían aplicarse a problemas ingenieriles de optimización. Por su parte, los AGs fueron desarrollados inicialmente por Bremermann (1958) y popularizados por Holland (1962) quien aplicó AGs para estudiar formalmente la adaptación en la naturaleza para relacionarla con mecanismos

en la ciencia de la computación. Holland estableció que un estudio de la adaptación de las especies debe reconocer que: i) la adaptación ocurre en un ambiente, ii) la adaptación es un proceso poblacional, iii) el comportamiento de un individuo puede representarse mediante programas, iv) pueden generarse nuevos comportamientos a partir de variaciones aleatorias de los programas, y v) las salidas de los programas normalmente están relacionadas si sus estructuras están relacionadas. De esta forma, Holland diseñó el proceso de adaptación en términos de un formalismo en el que los programas de una población interactúan y mejoran con base en un cierto ambiente que determina lo apropiado de su comportamiento. Combinar variaciones aleatorias con un proceso de selección (en función de qué tan apropiado es el comportamiento de un programa dado), conduce a un sistema adaptativo general.

2.2.1 Algoritmos genéticos

Los AGs son técnicas de optimación y búsqueda aleatoria inspiradas en la selección y genética natural y se utilizan para hallar el valor o conjunto de valores (parámetros) que ofrecen una solución óptima a un problema particular. Esencialmente, se consideran como un proceso de *educación* (conocimiento previo de los candidatos de solución) y *aproximación* (resulta de la combinación de candidatos que genere una mejoría de solución).

Consisten básicamente de una secuencia de pasos llamados *generaciones*, donde en cada generación el mejor arreglo (especie, cromosoma o individuo) es creado usando bits y piezas de las especies mejor ajustadas de la generación anterior. No son una técnica de búsqueda aleatoria, estos explotan y exploran eficientemente la información histórica para ejecutar la búsqueda sobre nuevos candidatos de solución con la esperanza que mejoren el desempeño final del problema propuesto.

Base biológica

Cromosomas: Todos los seres vivos están formados por células que tienen el mismo número de *cromosomas*. Los cromosomas son cadenas de *ADN* que definen a un ser vivo y se dividen en *genes* (bloques de ADN) y cada gen codifica una proteína particular; es decir, cada gen codifica una característica de un ser vivo (p.e. el color de ojos). Al conjunto de todos los cromosomas se denomina *genoma*. Cada ser vivo posee un conjunto de cromosomas particular, diferente en mayor o menor medida del resto

de seres vivos, incluso de su especie, que se denomina *genotipo*. A la manifestación externa (color de ojos, inteligencia, etc.) del genotipo en un ser vivo se llama *fenotipo*. *Reproducción*: En la reproducción de los seres vivos ocurre, en primera instancia, un proceso de *cruce* en el cual, los genes de los padres se combinan para generar un nuevo cromosoma (descendiente, *offspring* o hijo). Este nuevo cromosoma puede sufrir cambios a partir del proceso de *mutación*, que ocurre normalmente por errores al ser copiados de los padres. Otro concepto interesante es la función de ajuste (*fitness*) de un ser vivo: El *fitness* es una medida de lo bueno que es un individuo según su grado de adaptación al entorno. Si se adapta bien, se puede asegurar su supervivencia y por tanto tendrá un *fitness* mayor.

Funcionamiento general

Existen 4 etapas fundamentales dentro del proceso de búsqueda genética: *creación*, *selección*, *cruce* y *mutación*. En la etapa de *creación* se genera aleatoriamente un conjunto (población) de arreglos de posibles soluciones (especies o cromosomas), el cual corresponde a los parámetros del modelo que se quiere optimizar y representan las condiciones del sistema en estudio; así, cada especie es una potencial solución. Posteriormente, cada una de las especies es evaluada con una función de ajuste (*fitness*) o función objetivo que determina la calidad de una solución, a partir de las características del problema; es decir, el *fitness* es una medida que permite evaluar el nivel que tiene cada especie para solucionar el problema.

En la etapa de *selección* se eliminan los malos candidatos con base en su *fitness* y en la etapa de *cruce* (proceso de reproducción sexual en el cual dos *padres* intercambian genes para crear dos nuevos *hijos*); partes de especies (genes) de la generación anterior (padres) son cambiadas con la idea de generar especies mejor adaptadas (mayor *fitness*). Cuando se alcanza similitud en todas las especies, el *cruce* pierde su capacidad de generar nuevas especies y en ese momento la *mutación* (proceso de reproducción asexual, en el cual el hijo es creado a partir de un padre cambiando aleatoriamente el valor de uno de sus genes), interviene para producir una alteración (con pequeña probabilidad) de bits (genes) en cada nueva especie para prevenir la pérdida de diversidad de la población.

La meta del *cruce* y la *mutación* es generar *diversidad* dentro de la población y con ella explorar varias combinaciones de especies o soluciones para el problema. Esto permite

explorar el parámetro *espacio* a través de una combinación de las mejores soluciones. Revisiones exhaustivas de estas técnicas pueden hallarse en los libros de Goldberg (1988), Michalewicz (1996) y Mitchell (1996).

Los principales pasos del AG son los siguientes:

- ∅ Codificación: Característica esencial de un AG, donde se codifican las variables que describen el problema, transformándolas hacia arreglos binarios de longitud específica llamados *cromosomas* (especies o individuos).
- ∅ Reproducción: Producción de la próxima generación de la población, a partir del proceso de selección, basado en un criterio específico del problema conocido como función de ajuste (*fitness*) o función objetivo.
- ∅ Cruce y mutación: En el cruce, dos miembros de la población son seleccionados aleatoriamente y cambian parte de información cromosómica con una probabilidad específica. En la mutación, ciertos dígitos del cromosoma son alterados con una determinada probabilidad.
- ∅ Decodificación: La solución de cada generación es decodificada y se determina el valor de la función objetivo (*fitness*) correspondiente a la especie evaluada. A partir de esta evaluación, este paso se repite desde la fase de reproducción hasta que un criterio de convergencia es alcanzado.

De acuerdo con lo anterior, los AGs requieren de 5 componentes (Goldberg, 1989):

1. Una manera de codificar las soluciones del problema en cromosomas (especies o individuos).
2. Una función de evaluación (*fitness*) que mida la adaptación del cromosoma.
3. Una manera de inicializar la población de cromosomas.
4. Operadores que se aplican a los padres cuando ellos reproducen o alteran su composición genética. Los operadores genéticos básicos son el cruce y la mutación.
5. Ajustes iterativos para los parámetros del algoritmo.

Con estas cinco componentes, un AG opera según los siguientes pasos (Fig. 2.7):

1. Inicializar la población usando un procedimiento de generación aleatoria o proponiendo valores de los parámetros que contenga el problema y evaluar el *fitness* de cada miembro de la población inicial.
2. Reproducir hasta que se alcance el criterio de convergencia. Esta reproducción consiste en iterar los siguientes pasos:
 - a) Seleccionar uno o más padres para reproducir. La selección es estocástica, pero los individuos con más altas evaluaciones son favorecidos en la selección.
 - b) Seleccionar un operador genético y aplicarlo a los padres.
 - c) Evaluar al hijo y almacenarlo para la nueva generación. Después de almacenar suficientes individuos, estos son insertados hacia la nueva población, reemplazando los miembros peor ajustados. Cuando los componentes del AG son escogidos apropiadamente, el proceso de reproducción mejorará continuamente la población, convergiendo finalmente a soluciones más cerradas en un óptimo global. Los criterios de convergencia se cumplen cuando se logra un ajuste lo suficientemente bueno o cuando cierto número de generaciones ha pasado y no se alcanza un ajuste satisfactorio. Los AGs pueden buscar eficientemente en grandes y complejos (por ejemplo; procesar muchos óptimos locales) espacios para encontrar soluciones globales óptimas.

Operadores genéticos

Los tres operadores básicos de los AGs son la *selección*, *cruce* y *mutación*, a continuación se describen cada uno de ellos.


Selección: Simula el proceso de selección natural donde el más *fuerte* tiene mayor capacidad de supervivencia. Los padres se seleccionan de acuerdo a su ajuste (*fitness*) y los mejores individuos (con mayor *fitness*) son los que tienen mayores posibilidades de ser elegidos. Intuitivamente, el proceso construye una ruleta en la que cada una de las porciones representa a una especie. La porción que le toca a cada individuo es proporcional a su *fitness*. Así los individuos *buenos* se llevarán las mayores porciones y al revés ocurrirá con los *peores*.

Entre las técnicas de selección más comunes se encuentran:


- 1) Selección directa: toma elementos de acuerdo a un criterio objetivo, como son «los x mejores», «los x peores». Los del tipo «el cuarto individuo a partir del último escogido» son empleados con mucha frecuencia cuando se quieren seleccionar dos individuos distintos, y se selecciona el primero por un método aleatorio o estocástico.
- 2) Selección aleatoria: puede ser realizada por selección equiprobable o selección estocástica.
 - o *Selección equiprobable*: todos tienen la misma probabilidad de ser escogidos.
 - o *Selección estocástica*: El hecho de que un individuo sea escogido es heurístico. Los distintos procedimientos estocásticos son:
 - *sorteo*: cada individuo de la población tiene asignado un rango proporcional -o inversamente proporcional- a su adaptación. Se escoge un número aleatorio dentro del rango global, y aquel que tenga dicho número dentro de su rango es seleccionado. La probabilidad de ser escogido es directamente/inversamente proporcional al grado de adaptación del individuo.
 - *ruleta*: cada individuo es definido como un trozo de una rueda, donde el tamaño de cada trozo es proporcional al ajuste del individuo. La rueda se hace girar y el individuo seleccionado por el marcador de la ruleta será uno de los padres.
 - *torneo*: varios individuos son seleccionados aleatoriamente y el más *ajustado* llega a ser uno de los padres.

Cruce: Crea nuevos candidatos de solución. Para ello, una posición del código de los padres es seleccionada aleatoriamente y se cruzan en este punto para dar origen a dos nuevas soluciones. Este operador es responsable de las propiedades del algoritmo genético y determina la evolución de la población. Entre las técnicas de cruce básicas se pueden mencionar:


- *Cruce básico*: se selecciona al azar un punto de la cadena. La parte anterior del punto es copiada del genoma del padre y la posterior del de la madre:



Cruce multipunto: Es igual que el cruce básico, sólo que estableciendo más de un punto de cruce:




- *Cruce uniforme:* para cada gen de la cadena del descendiente existe una probabilidad de que el gen pertenezca al padre, y otra de que pertenezca a la madre:



- *Cruces para permutación:* Existe una familia de cruces específicos para los problemas de permutación:
 - Cruce de mapeamiento parcial: toma una subsecuencia del genoma del padre y procura preservar el orden absoluto de los fenotipos -es decir, orden y posición en el genoma- del resto del genoma lo más parecido posible de la madre.
 - Cruce de orden: toma una subsecuencia del genoma del padre y procura preservar el orden relativo de los fenotipos del resto del genoma lo más parecido posible de la madre.
 - Cruce de ciclo: Tomamos el primer gen del genoma del padre, poniéndolo en la primera posición del hijo, y el primer gen del genoma de la madre, poniéndolo dentro del genoma del hijo en la posición que ocupe en el genoma del padre. El fenotipo que está en la posición que ocupa el gen del genoma del padre igual al primer gen del genoma de la madre se va a colocar en la posición que ocupe en el genoma del padre, y así hasta rellenar el genoma del hijo.

Mutación: variación de la información contenida en el código genético -habitualmente, un cambio de un gen a otro producido por algún factor exterior al algoritmo genético-. En Biología se definen dos tipos de mutaciones: las *generativas*, que se heredan y las *somáticas*, que no se heredan. En los algoritmos genéticos sólo son de utilidad las mutaciones generativas. Cada bit del código de los padres puede mutar, a partir de una probabilidad de mutación. En código binario, la mutación involucra el cambio de un bit de valor 1 a valor 0 o viceversa. El papel que juega la mutación es el de introducir un factor de diversificación ya que en ocasiones, la convergencia del procedimiento a buenas soluciones puede ser prematura y quedarse atrapado en óptimos locales. Entre los operadores de mutación se encuentran:

- Inversión de genes: Se seleccionan genes aleatoriamente y se invierte su valor. Se utiliza en representaciones de bits, cambiando *ceros* por *unos* o viceversa:



- Cambio de orden: Se seleccionan dos genes aleatoriamente y se intercambian sus posiciones. Se utiliza en representaciones basadas en permutaciones.

Dentro de las razones que motivan la incorporación de mutaciones son:

- *Desbloqueo del algoritmo*. Cuando el algoritmo se bloquea en un mínimo local, una mutación puede sacarlo al incorporar nuevos fenotipos de otras zonas del espacio.
- *Acabar con poblaciones degeneradas*. Cuando existe un cuasi-mínimo o apareció un individuo demasiado bueno que acabó con la diversidad genética, se ha llegado a una población degenerada. Por lo cual, es preciso que la mutación introduzca nuevos genomas.
- *Incrementar el número de saltos evolutivos*. Los saltos evolutivos -aparición de un fenotipo especialmente valioso, o dicho de otra forma, salida de un mínimo local- son muy poco probables en un genético *puro*. La mutación permite explorar nuevos subespacios de soluciones, por lo que, si el subespacio es bueno en términos de

adaptación, se producirá después de la mutación un salto evolutivo que se expandirá exponencialmente por la población.

- *Enriquecer la diversidad genética.* La mutación es un mecanismo de prevención de las poblaciones degeneradas.

Parámetros básicos de los AGs

Permiten la convergencia controlada del problema. Estos parámetros son:

Porcentaje de cruce (Pc): Indica la frecuencia con que se cruzarán los individuos. Con un Pc de 0%, los hijos serán como los padres y sólo serán alterados por la mutación. Si el Pc es de 100% todos los individuos nuevos serán creados mediante cruce de los padres de la generación previa. Cuanto más se crucen los individuos se supone que los hijos serán mejores.

Porcentaje de mutación (Pm): Establece la probabilidad con la cual los individuos serán mutados. Con un Pm de 0% los individuos generados después de aplicarse el cruce no sufrirán ningún cambio, por el contrario si es de 100% todos los individuos de la población sufrirán cambios o mutaciones. La mutación trata de impedir que la búsqueda del genético caiga en extremos locales por eso es conveniente que ocurra de vez en cuando. No es bueno que la mutación ocurra continuamente, ya que la búsqueda del genético pasa de ser "inteligente" a una simple búsqueda aleatoria.

Tamaño de la población: Establece cuántos individuos habrá en cada una de las generaciones. Si el tamaño de la población es muy bajo, el AG tiene pocas posibilidades de evolucionar por el cruce y los individuos nuevos se parecerán mucho a sus padres. A su vez un tamaño excesivo tampoco es adecuado porque hay un punto en el que los resultados no mejoran. Lo ideal es establecer un límite adecuado del tamaño de la población en función del problema y la codificación.

Número de generaciones: Con el paso de las generaciones la población del genético evolucionará obteniendo cada vez mejores individuos. Conviene, al igual que con el tamaño de la población, fijar un número de generaciones adecuado para conseguir el resultado deseado.

Tamaño del individuo: Depende del número de elementos que constituyan la solución.

2.3 Técnicas Clásicas de Optimación y AGs

Existen técnicas clásicas para resolver problemas de optimación con ciertas características específicas (p.e. funciones lineales con una o más variables) y es

necesario conocer de su existencia, ya que si el problema puede resolverse a partir de alguna de ellas no tiene sentido emplear otro tipo de técnicas (p.e. técnicas heurísticas; del griego *heuriskein* = encontrar o descubrir). Uno de los problemas de las técnicas clásicas de optimización es que suelen requerir de información que no siempre está disponible. Por ejemplo, métodos como el del gradiente conjugado requieren de la primera derivada de la función objetivo; otros, como el de Newton, requieren además de la segunda derivada. Por tanto, si la función objetivo no es diferenciable (y en algunos casos, ni siquiera está disponible en forma explícita), estos métodos no pueden aplicarse.

Un problema de optimización típico, consta de variables que controlan el proceso y una ecuación o algoritmo que combina las variables o parámetros que modelan dicho proceso. Tiene como objetivo determinar los valores de las variables, tal que sea optimizado el proceso.

Las técnicas tradicionales de optimización tienden a colapsar cuando la función objetivo o función de ajuste no es una fórmula matemática continua y suave, debido a que necesitan de las características propias del problema para determinar el punto de adaptación de los parámetros, lo cual de algún modo requiere linealidad, continuidad y diferenciabilidad en ese punto. Por otro lado, Las técnicas de búsqueda estocástica (técnicas heurísticas) usan reglas de muestreo y decisión estocástica para determinar la adaptación del siguiente punto; por ejemplo, los AGs son métodos eficientes de optimización estocástica, usados para la solución de problemas donde la función objetivo no cumple con las propiedades matemáticas necesarias, como la continuidad y diferenciabilidad (Davis, 1991; Goldberg, 1989; Holland, 1962 y Michalewicz, 1996).

Un interesante tipo de problemas con pobres propiedades matemáticas son los problemas de optimización donde las funciones son dependientes del tiempo, no lineales y discontinuas, ya que es casi imposible usar métodos gradientes debido a que las funciones no son diferenciables. Este tipo de problemas son típicos en el área de identificación de sistemas y teoría de control.

Los AGs son esencialmente probabilistas, a diferencia de los métodos tradicionales de optimización que son netamente deterministas. La naturaleza probabilista de los AE (algoritmos evolutivos) les permiten explorar áreas en el espacio de búsqueda que

parecen imprácticos a primera vista y el carácter determinista de las técnicas de optimización tradicionales es la principal razón de que queden atrapadas en óptimos locales. Los AGs siempre tienen mayor oportunidad de escapar de óptimos locales a través del mencionado proceso de mutación.

2.3.1 Técnicas heurísticas

Existen problemas de optimización en los cuales no puede determinarse una solución eficiente y donde el mejor algoritmo tradicional requeriría tiempo exponencial para obtenerla. En estos casos las técnicas de optimización y búsqueda clásicas son insuficientes, y es cuando se recurre a la *heurística*.

La heurística fue un área predominante en los orígenes de la Inteligencia Artificial (IA), actualmente, el término suele usarse como un adjetivo, refiriéndose a cualquier técnica que mejore el desempeño de la solución de un problema (Russell *et al.*, 1995). Una definición más precisa y adecuada es proporcionada por Reeves (1993):

“La heurística es una técnica que busca soluciones buenas (es decir, casi óptimas) a un costo computacional razonable, aunque sin garantizar factibilidad u optimalidad de las mismas. En algunos casos, ni siquiera puede determinar qué tan cerca del óptimo se encuentra una solución factible en particular”

Como ejemplos de técnicas heurísticas se encuentran: a) búsqueda tabú, b) *Simulated annealing* y c) Escalando la Colina. La búsqueda *tabú* (Glover y Laguna, 1998) es realmente una meta-heurística, porque es un procedimiento que debe acoplarse a otra técnica, ya que no funciona por sí sola. Emplea una memoria para dirigir la búsqueda, de tal forma que algunas soluciones examinadas recientemente son memorizadas y se vuelven tabú (prohibidas) al tomar decisiones acerca del siguiente punto de búsqueda. La búsqueda tabú es determinista, aunque pueden agregársele elementos probabilistas.

Simulated annealing (Kirkpatrick *et al.*, 1983) es una técnica estocástica derivada de la mecánica de los materiales basada en el enfriamiento de los cristales. El algoritmo requiere de una temperatura inicial, una final y una función de variación de la temperatura que determina el buen desempeño del algoritmo. Finalmente, La técnica *escalando la colina* se aplica a un punto a la vez (técnica local); es decir, a partir de un punto, se generan varios estados posibles y se selecciona el mejor de ellos. Este

algoritmo determinista no tiene retroceso ni lleva ningún tipo de registro histórico (aunque éstos y otros aditamentos son susceptibles de ser incorporados) y puede quedar atrapado fácilmente en óptimos locales; es determinista.

Como técnica heurística, una de las más poderosas características de los AGs es su *simplicidad* ya que no hay gradientes que derivar ni requerimientos de diferenciabilidad o continuidad que satisfacer, siendo en esencia una aplicación repetitiva de operaciones simples. Además, un AG no conoce nada acerca del problema ni necesita saber nada sobre él, sólo es necesario reconocer una buena solución cuando se observe.

En contraste con las técnicas numéricas, que iterativamente refinan un vector simple de solución como búsqueda de los óptimos en un espacio multidimensional; los AGs operan sobre una población de candidatos de solución en paralelo. En efecto, el *paralelismo* en la búsqueda estocástica de los AGs es una de las principales virtudes de esta técnica.

Esto implica que los AGs tienen mayor probabilidad de localizar un óptimo global que las técnicas tradicionales, porque tienen menos probabilidades que queden atrapadas en un óptimo local. Además, su funcionamiento es menos sensible a las condiciones iniciales, y por lo tanto el tiempo de convergencia es más reducido; es decir, los valores óptimos encontrados se ajustan confiablemente al criterio de convergencia debido al poder exploratorio de los AGs.

Este *paralelismo* también tiene sus consecuencias, ya que a pesar de que hace más robusta a la técnica al permitir encontrar un óptimo global, la hace más lenta que las técnicas tradicionales; es decir, con una buena aproximación inicial del óptimo global, una técnica numérica es más rápida y más aproximada que una búsqueda genética. En esencia, el AG invierte tiempo en la evaluación de la función de ajuste de soluciones sub-óptimas y además por la naturaleza estocástica de los AGs, la solución será sólo una estimación del óptimo global, mientras que las técnicas tradicionales encuentran esta solución exactamente. Es decisión del usuario determinar si la solución encontrada por los AGs es suficientemente aceptable; la cuestión es, ¿qué significa ¿suficientemente aceptable?, esto es algo subjetivo y dependiente de la aplicación.

2.3.2 Características de los AGs

Los AGs tienen ventajas sobre otras técnicas de optimización que los hacen preferibles para determinado tipo de aplicaciones (p.e. identificación de sistemas). Algunas de las características de los algoritmos genéticos se comentan enseguida:

- ☞ *Son algoritmos estocásticos.* Dos ejecuciones distintas pueden dar dos soluciones distintas. Esto es útil porque pueden existir distintos valores que corresponden a soluciones válidas.
- ☞ *Son algoritmos de búsqueda múltiple.* Buscan en una población de puntos proporcionando varias soluciones. Aunque habitualmente el ajuste de los individuos de la población final es similar, los individuos suelen ser distintos entre sí. Por ello, puede elegirse la solución más conveniente de acuerdo a la naturaleza del problema; para este caso, analizar los parámetros dinámicos generados por el AG para decidir sobre los más interesantes o ajustados al sentido físico del sistema propuesto.
- ☞ Hacen una amplia barrida al subespacio de posibles soluciones válidas. Se considera que de todos los algoritmos de optimización estocásticos, los algoritmos genéticos son los que tienen mayor capacidad de exploración.
- ☞ Otras técnicas de optimización son fuertemente dependientes de la población inicial para alcanzar la convergencia; en los AGs -salvo poblaciones iniciales realmente degeneradas, en los que el operador de mutación tendrá serios inconvenientes de trabajo- la convergencia del algoritmo es poco sensible a la población inicial si ésta se escoge de forma aleatoria y es lo suficientemente grande.
- ☞ Por su grado de penetración casi nulo, la curva de convergencia asociada al algoritmo presenta una convergencia excepcionalmente rápida al principio, que casi enseguida se bloquea. El AG es excelente descartando subespacios realmente malos y cada cierto tiempo, la población vuelve a dar un salto evolutivo produciéndose un incremento excepcional en la velocidad de convergencia. La razón es que algunas veces aparece una mutación altamente beneficiosa, o un individuo que propaga algún conjunto de cromosomas excepcional al resto de la población. La deficiente penetración es la desventaja más importante en los AGs y la razón fundamental de la aparición de los *algoritmos híbridos*.

- ∞ La optimización es función de la representación de los datos. Este es el concepto clave dentro de los algoritmos genéticos, ya que una buena codificación puede hacer la programación y la resolución muy sencillas e influir en la velocidad de convergencia del algoritmo, mientras que una codificación errada obliga a estudiar que el nuevo genoma cumpla las restricciones del problema, y en muchos problemas tendremos que *abortar* los genomas que no cumplan con dichas restricciones, por ser éstas demasiado complejas.
- ∞ Es una búsqueda paramétricamente robusta, lo que quiere decir que se deben escoger realmente mal los parámetros del algoritmo para que no converja. Con tasas razonables, va a converger -mejor o peor- en una solución razonablemente buena si la representación es la adecuada. Esto es muy importante por la naturaleza de la búsqueda. No pueden efectuarse comparativos, buscando *números mágicos* para que el algoritmo converja, ya que el objetivo es llegar a la solución del problema, de por sí muy complejo. Por ello, es necesario un algoritmo en el cual pueda existir incertidumbre en los parámetros iniciales o de partida, y estos son los algoritmos genéticos.
- ∞ Por último, los AGs son intrínsecamente paralelos, esto significa que, independientemente de que lo hayamos implementado de forma paralela o no, evalúan muchos puntos simultáneamente dentro del espacio de búsqueda mejorando la probabilidad de encontrar un óptimo global. Esto permite que sea fácil modificar el código para que se ejecute simultáneamente en varios procesadores.

2.3.3. Diferencias de las técnicas evolutivas con respecto a las tradicionales

Hay varias diferencias por destacar entre los algoritmos evolutivos y las técnicas tradicionales de búsqueda y optimización [Goldberg, 1989; Buckles y Petry, 1992; Fogel, 1995):

- a) Los AG usan información de la función objetivo sin contemplar información alguna del gradiente.
- b) Pueden realizar tareas de optimización multiobjetivo.
- c) Busca en una población de puntos en vez de proponer el mejoramiento de un simple punto. El AG no es un simple algoritmo de búsqueda aleatoria, explora eficientemente información contenida en cada individuo para

investigar sobre nuevos puntos de búsqueda con intención de mejorar el rendimiento. Esto lo hace menos sensible de quedar atrapado en mínimos o máximos locales.

- d) Los AGs no necesitan conocimiento específico sobre el problema que intentan resolver.
- e) Usan operadores probabilistas, mientras las técnicas tradicionales utilizan operadores deterministas.
- f) Aunque las técnicas evolutivas son estocásticas, el usar operadores probabilistas no significa que operen de una manera análoga a una simple búsqueda aleatoria.
- g) Trabajan con variables codificadas y no con la variable misma.
- h) Presentan simplicidad conceptual y amplia aplicabilidad.
- i) Son superiores a las técnicas convencionales en muchos problemas prácticos, ya que permiten su solución en tiempo real.
- j) Permiten hibridizarse naturalmente con técnicas de modelado y optimación.
- k) No requieren que la función objetivo sea continua y diferenciable

CAPITULO 3:

Sistema de Identificación, SI

Se define como SI al modelo matemático que permite entender el funcionamiento de un sistema físico, a partir de la medición de sus entradas (excitación) y salidas (respuestas) asociadas a condiciones particulares; y a su vez determinar el comportamiento de sistemas dinámicos y desarrollar o mejorar su comprensión, representación y modelación matemática.

En geotecnia el SI es una alternativa a la determinación directa de las propiedades mecánicas del suelo, cuando ésta es demasiado complicada o no se dispone del equipo de laboratorio necesario. Por ejemplo, para determinar el módulo de rigidez dinámico, pruebas geofísicas tienen limitaciones en la magnitud de las deformaciones, en tanto que los ensayos de laboratorio, aunque cubren un amplio intervalo de deformaciones, están afectados por la alteración de los especímenes causada por la extracción y preparación de la muestra y por la dificultad para reproducir el estado de esfuerzos *in situ*, la historia de cargas y las condiciones de frontera (Taboada *et al.*, 1999).

Estas limitantes han obligado a preferir la determinación de las propiedades dinámicas a partir de la observación del comportamiento del suelo *in situ* sujeto a excitaciones naturales. Esta manera de proceder tiene la ventaja de cubrir respuestas en un amplio rango de deformación y bajo una gran variedad de excitaciones, mejorando el conocimiento sobre las leyes que gobiernan el comportamiento dinámico del suelo.

En ingeniería geosísmica este procedimiento usa estaciones acelerográficas, en arreglos verticales, que registran la respuesta de los depósitos de suelo ante excitaciones; es decir, los registros provenientes de cada estación acelerográfica permiten modelar la distribución de las aceleraciones que alcanza el depósito de suelo (sistema) a profundidades específicas, cuando es excitado por sismos con determinadas características. Esto proporciona una imagen del comportamiento del sistema y permite derivar de ello las propiedades de interés. En otros términos, el suelo *in situ* transforma una señal de entrada en una señal de salida que contiene información sobre las propiedades mecánicas del material.

El objetivo de un SI geosísmico es identificar las propiedades que determinan el comportamiento dinámico de un depósito de suelo, a partir de la información contenida en las entradas (excitaciones) y las salidas (respuestas del sistema). De acuerdo con esto, la construcción de un SI puede partir de dos enfoques: i) determinar los parámetros que definen el comportamiento del sistema una vez que se fija la estructura matemática y ii) obtener el modelo estructural o modelo asociado al comportamiento del sistema y determinar los parámetros de este modelo a partir de observaciones realizadas sobre dicho sistema.

3.1 SI en ingeniería

Se entiende como problemas en ingeniería al conjunto de situaciones que se generan cuando la necesidad o curiosidad humana hacen indispensable el estudio del comportamiento de los materiales y fenómenos naturales. Por ejemplo, el diseño sísmico de un edificio que se ve afectado por el entorno (depósito de suelo, medio ambiente, etc.); o un espécimen de concreto sometido a carga, al cual se le determina su deformación para establecer sus propiedades.

En general, los problemas en ingeniería resueltos a partir de información disponible, se dividen en dos grupos básicos, como se indica en la Fig. 3.1 (Santamarina y Fratta, 1998):




Figura 3.1 Problemas en ingeniería (modificado de Santamarina y Fratta, 1998).

❖ **Problemas Directos:**

Diseño de sistemas: El sistema es diseñado para satisfacer un criterio de funcionamiento predefinido basándose en una carga estimada; esta es la metodología convencionalmente usada para resolver problemas en ingeniería.

Convolución: Se estima la respuesta de un sistema de características conocidas a partir de una entrada conocida.

❖ **Problemas Inversos:** Agrupan aquellos problemas donde la salida es conocida pero la entrada o las características del sistema son desconocidas. Pueden encontrarse:

Sistemas de identificación: Son conocidas la entrada y la salida del sistema y la tarea es determinar sus características.

Deconvolución: Determinación de la señal de entrada conociendo tanto la salida como las características del sistema.

La mayoría de problemas inversos son complejos e involucran, por lo general, conocimiento previo del sistema y de las señales de entrada; por tal motivo, existe la posibilidad de encontrar más de una solución al problema.

Ahora bien, los SIS encontrados en la literatura simulan el comportamiento del suelo a través de modelos matemáticos con hipótesis sobre la estratigrafía, el tipo de onda sísmica, etc. que restringen el desempeño de dicho modelo, ya que el suelo como sistema físico, es un sistema complejo, no lineal y multi-dimensional cuyo comportamiento definitivamente cambia con el tiempo. Por ejemplo, en geotecnia los SIS diseñados buscan determinar las propiedades que controlan el comportamiento dinámico del suelo (módulo de rigidez G y relación de amortiguamiento λ), a través de procedimientos matemáticos (estructuras) bien conocidos (Método de Doble Integración y el Método Diferencial, por ejemplo).

Método de doble integración

En este método se obtienen los parámetros dinámicos (G y λ) a partir de la historia de deformaciones y esfuerzos cortantes definidos de registros acelerográficos (análisis en el dominio del tiempo). Para la determinación de la historia de esfuerzos y deformaciones usualmente se considera el modelo unidimensional de ondas de corte (Anexo B), expresado por:

$$\frac{\partial \tau}{\partial z} = \rho \frac{\partial^2 u}{\partial t^2} \quad \text{[Ec. 3.1]}$$

Determinación del esfuerzo cortante:

La integración de la ecuación 3.1 permite determinar la historia de esfuerzos cortantes a una profundidad z , según la ecuación 3.2. Para ello, se recurre a una interpolación lineal de las aceleraciones registradas entre acelerógrafos, planteando los límites de la integral definida de acuerdo al nivel donde se requiere obtener la magnitud de los esfuerzos (Fig. 3.2).

$$\tau(z,t) = \int_0^z \rho \frac{\partial^2 u(z,t)}{\partial t^2} dz \quad \text{[Ec. 3.2]}$$

Donde,

$\tau(z,t)$: Esfuerzo cortante

$\frac{\partial^2 u(z,t)}{\partial t^2}$: Aceleración horizontal absoluta

$u(z,t)$: Desplazamiento horizontal absoluto

z : Profundidad

ρ : Densidad de la masa de suelo

t : Tiempo




Figura 3.2 Esquema de interpolación entre estaciones acelerográficas

Determinación de la deformación al cortante

La deformación por cortante (γ) a la profundidad donde están ubicados los acelerógrafos (z) se determina con (Pearson, 1986):

$$\gamma_i(t) = \frac{1}{\Delta z_i + \Delta z_{i-1}} \left[(u_{i+1} - u_i) \frac{\Delta z_{i-1}}{\Delta z_i} + (u_{i+1} - u_{i-1}) \frac{\Delta z_i}{\Delta z_{i-1}} \right], \dots i = 1, 2, 3 \dots \quad \text{[Ec. 3.3]}$$

En los puntos medios entre acelerógrafos dicha deformación se obtiene a partir de (Zeghal y Elgamal, 1993):

$$\gamma_{\frac{i-1}{2}}(t) = \frac{u_i - u_{i-1}}{\Delta z_{i-1}}, \dots i = 1, 2, 3 \dots \quad \text{[Ec. 3.4]}$$

Finalmente, para estimar la deformación por cortante a cualquier profundidad (z) localizada entre tres estaciones acelerográficas, se utiliza (Zeghal y Elgamal, 1993):

$$\gamma_z(t) = \frac{1}{\Delta z_i + \Delta z_{i-1}} \left[(u_i - u_{i-1}) \frac{\Delta z_{i+1}}{\Delta z_i} + (u_{i+1} - u_i) \frac{\Delta z_i}{\Delta z_{i+1}} + 2z \left(\frac{(u_{i+1} - u_i)}{\Delta z_{i+1}} - \frac{(u_i - u_{i-1})}{\Delta z_i} \right) \right] \quad [\text{Ec. 3.5}]$$

El procedimiento derivado de esta secuencia matemática (ecuaciones 3.1 a 3.5), se describe con los siguientes pasos:

1. Definir un arreglo acelerográfico de pozo vertical.
2. Filtrar y sincronizar los registros de aceleraciones medidos.
3. Determinar las expresiones para evaluar la respuesta del depósito de suelo en estudio. Para dicha selección debe realizarse un reconocimiento del comportamiento físico del sistema (Zeghal *et al.*, 1989; Zeghal, 1990).
4. Calcular la historia de esfuerzos y deformaciones angulares (τ, γ) a partir de las ecuaciones anteriores.
5. Conocidas estas historias, establecer el comportamiento histerético y con ello determinar los parámetros dinámicos a partir del modelo lineal equivalente (ver Anexo A.2.3).
6. Se realiza una verificación de estos parámetros con los obtenidos en campo o laboratorio.

El valor de los parámetros dinámicos calculados con este método depende de las siguientes consideraciones:

- i) Procesamiento de la señal: La historia de aceleraciones debido al ruido propio del acelerógrafo, contiene valores a frecuencias altas que no son necesarios dentro de los procedimientos de cálculo. Adicionalmente, se contamina por la introducción de constantes durante el proceso de integración. En consecuencia, la obtención de las historia de esfuerzos y deformaciones dependen del correcto diseño de filtros para eliminar las frecuencias no deseadas, cuidando que no se alteren las características originales de las deformaciones y esfuerzos cortantes.
- ii) Configuración de los instrumentos dentro del pozo. El método de doble integración supone una distribución lineal de las aceleraciones con la profundidad, por lo cual las estaciones del arreglo vertical deben ubicarse cercanas entre sí para que dicha condición cobre validez.
- iii) Obtención de los ciclos de histéresis. La obtención de las historias de esfuerzos y deformaciones permiten la construcción de ciclos de histéresis con los cuales

conocer la evolución de los parámetros dinámicos en un determinado evento sísmico. Los parámetros dinámicos determinados de este modo dependen de la interpretación subjetiva de los ciclos generados.

Elgamal *et al.* (1995), desarrollaron una técnica para evaluar directamente las historias de esfuerzo cortante y deformación usando los registros de aceleraciones del arreglo de pozo vertical de Lotung, Taiwan. Esta técnica considera un procedimiento de interpolación entre estaciones acelerográficas para evaluar las historias de esfuerzo cortante y deformación para un evento sísmico particular, y de este modo determinar las propiedades dinámicas del suelo. Encontraron que el módulo de rigidez se ajusta a los ensayos de laboratorio, pero el amortiguamiento equivalente sobreestima el valor de los ensayos de laboratorio documentados. Martínez (1998) usó esta metodología para identificar los parámetros dinámicos de algunos sitios de la zona de lago de la ciudad de México. Los resultados concuerdan en términos generales con los obtenidos de ensayos de laboratorio en investigaciones anteriores (p.e. Romo *et al.*, 1988).

Método diferencial

Este método propone la solución de la ecuación 3.1 (expresión que relaciona esfuerzos con desplazamientos) a través de modelos como el visco-elástico Kelvin-Voigt (ver Anexo A.2.2). Dicha solución (Ec. 3.6) es una expresión diferencial en términos del desplazamiento que se resuelve cuando se definan las condiciones de frontera y continuidad en las interfaces de los estratos.

$$\rho \frac{\partial^2 u}{\partial t^2} = G \frac{\partial^2 u}{\partial z^2} + \eta \frac{\partial^3 u}{\partial z^2 \partial t} \quad \text{[Ec. 3.6]}$$

En el Anexo C, se plantean las expresiones para calcular los desplazamientos generados por una onda de corte en un medio visco-elástico (Ec. 3.7), los cuales dependen de la frecuencia angular de la excitación (ω), el número de onda complejo (k^*), la amplitud de la onda incidente (A) y reflejada (B) y la profundidad (z).

$$u(z, t) = Ae^{i(\omega t + k^* z)} + Be^{i(\omega t - k^* z)} \quad \text{[Ec. 3.7]}$$

Al aplicar la ecuación 3.7, a un medio estratificado que se supone en campo libre, se obtienen las ecuaciones que cuantifican las amplitudes de las ondas incidentes y reflejadas en cada uno de los estratos que constituyen el medio (ver Anexo D):

$$\begin{aligned}
 A_{m+1} &= \frac{1}{2} A_m (1 + \alpha^*) e^{ik_m^* h_m} + \frac{1}{2} B_m (1 - \alpha^*) e^{-ik_m^* h_m} && \text{Onda incidente} \\
 B_{m+1} &= \frac{1}{2} A_m (1 - \alpha^*) e^{ik_m^* h_m} + \frac{1}{2} B_m (1 + \alpha^*) e^{-ik_m^* h_m} && \text{Onda reflejada}
 \end{aligned}
 \tag{Ec. 3.8}$$

Donde,

α^* : Valor de impedancia compleja

h_m : Espesor del estrato, en m.

Las amplitudes de onda de un par de estratos i y j (Fig. 3.3) permiten calcular la función de transferencia ($FT_{j \rightarrow i}$) (Anexo D) entre ellos a través de la ecuación 3.9. Se describe cómo una función en el dominio de la frecuencia que depende de las características inherentes al sistema (módulo de rigidez (G); relación de amortiguamiento (λ), peso volumétrico (ρ); y el espesor del estrato (h)).

$$FT_{j \rightarrow i} = \frac{|u_i|}{|u_j|} = \frac{A_m + B_m}{A_{m+1} + B_{m+1}}
 \tag{Ec. 3.9}$$

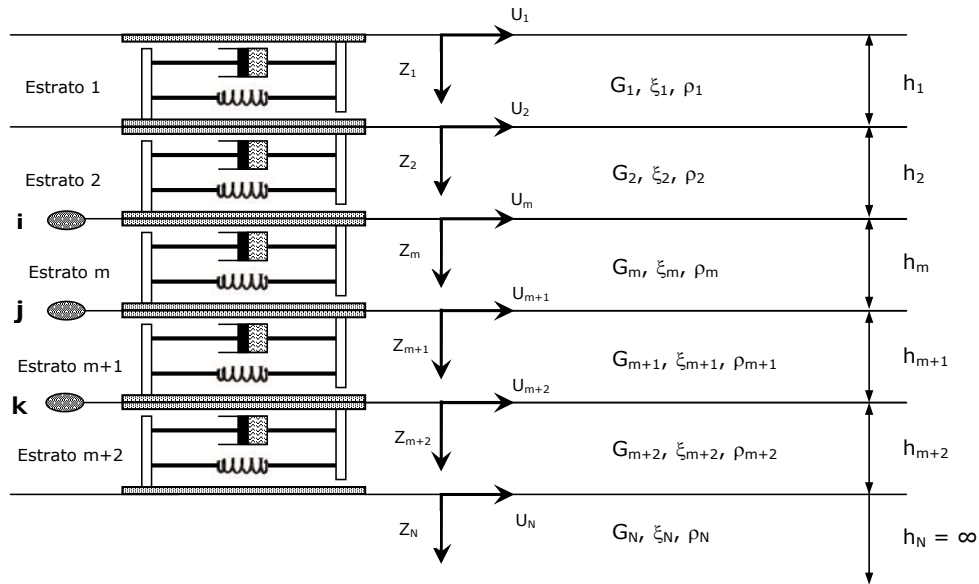


Figura 3.3 Representación estratigráfica para el análisis de la función de transferencia en un medio estratificado.

Las ecuaciones 3.6 a 3.9 conforman el funcionamiento del método diferencial, para identificar los parámetros dinámicos del sistema en estudio. Al cuestionamiento ¿cómo

puede calcularse la respuesta del sistema ante una excitación determinada?, la función de transferencia surge como elemento clave.

$$Y_{(\omega)} = H_{(\omega)} * X_{(\omega)} \quad \text{[Ec. 3.10]}$$

En la ecuación 3.10 se establece que la respuesta de un sistema lineal $Y_{(\omega)}$ (respuesta calculada del sistema), resulta del producto entre la función de transferencia $H_{(\omega)}$ y la excitación del sistema $X_{(\omega)}$ (Fig. 3.4); ambas en el dominio de la frecuencia. La excitación del sistema (comúnmente se usa la señal que se encuentra a mayor profundidad en el arreglo de pozo), originalmente en el dominio del tiempo, se traslada al dominio de la frecuencia con la transformada rápida de Fourier (FFT). Vale la pena puntualizar que el procedimiento descrito es una de las formas que existen para desarrollar la identificación de parámetros a partir del método diferencial y tiene sólo objetivos ilustrativos.




Figura 3.4 Representación para la obtención de la respuesta de un sistema lineal en el dominio de la frecuencia

Se ha presentado hasta este punto, una manera de determinar la respuesta del sistema a partir de un criterio de prueba y error que dirige la convergencia del modelo propuesto sin considerar las mediciones del sistema. Queda aún por resolver la mitad del problema, ya que falta por determinar las propiedades dinámicas asociadas al comportamiento medido de dicho sistema.

Así cuando se dispone de: i) información de la excitación (entrada) y la respuesta medida del sistema (salida), y ii) un modelo que permita obtener la respuesta analítica del sistema (respuesta calculada), se determina la respuesta analítica a partir de un conjunto inicial de parámetros dinámicos, la cual se compara con la respuesta medida

del sistema. Este proceso se realiza de manera iterativa hasta obtener un conjunto de parámetros donde la diferencia entre ambas respuestas sea mínima (Fig. 3.5).

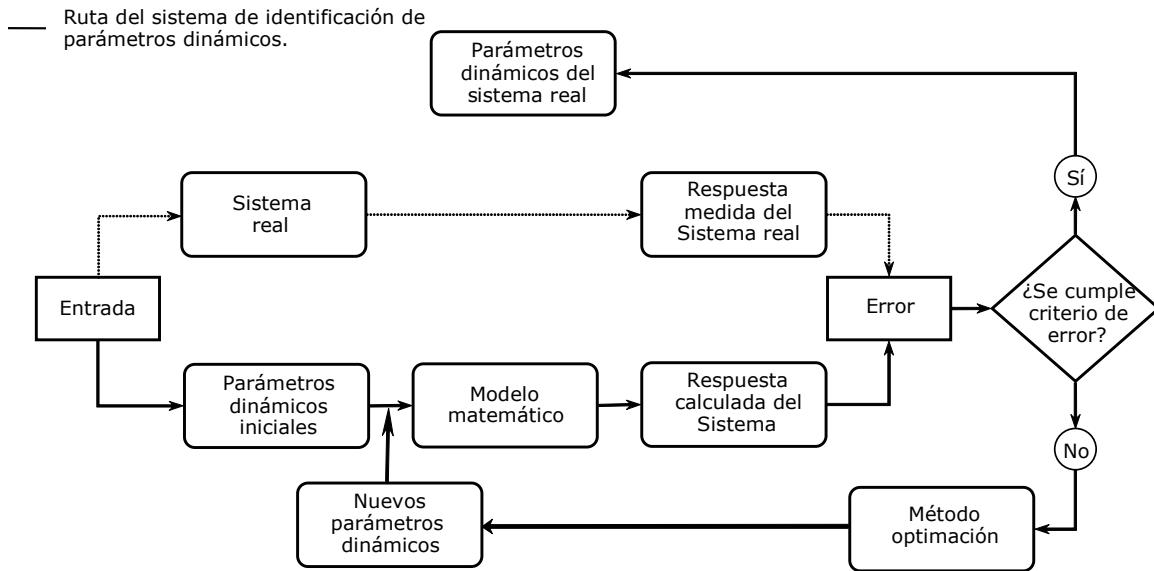


Figura 3.5 Esquema del procedimiento usado para la determinación de parámetros dinámicos.

La complejidad de este procedimiento se incrementa conforme el número de estratos del sistema crece; por lo cual es útil establecer un método de optimación que permita minimizar el error de manera eficiente.

A continuación se presenta el procedimiento general que describe la identificación de parámetros dinámicos del suelo a partir del método diferencial:

1. Definir un arreglo acelerográfico de pozo vertical.
2. Filtrar y sincronizar los registros de aceleraciones medidos.
3. Determinar las expresiones para evaluar la respuesta del depósito de suelo en estudio. Para dicha selección debe realizarse un reconocimiento del comportamiento físico del sistema (Zeghal *et al.*, 1989; Zeghal, 1990).
4. Obtener la respuesta analítica del depósito a las profundidades requeridas determinando la ubicación de las estaciones acelerográficas y la estratigrafía del sitio de estudio, para un par de parámetros dinámicos dados por cada estrato considerado.
5. Comparar la respuesta calculada con la respuesta medida y estimar un valor de error entre dichas respuestas.

6. Proponer un método iterativo de optimación que minimice el error (donde se proponen otro conjunto de parámetros) conforme a un umbral aceptable. Los parámetros con los que se alcance el error mínimo se considerarán como los parámetros representativos del depósito.
7. Validación de los parámetros a partir de los obtenidos por medio de ensayos de campo y laboratorio.

El resultado de esta aplicación depende de:

- i) El preprocesamiento de las señales para la eliminación de las frecuencias que no estén ligadas al comportamiento del suelo.
- ii) El modelo visco-elástico, a partir del cual la respuesta se considera cuasi-lineal.
- iii) El modelo seleccionado para simular el comportamiento del depósito de suelo.
- iv) El proceso de optimación, donde debe asegurarse que los parámetros seleccionados no correspondan a un mínimo local de la función de error.
- v) El modelo estratigráfico considerado. Los modelos estratigráficos usados en ingeniería, consideran a los estratos horizontales y de extensión infinita.

Con este enfoque se han desarrollado SIs en el dominio del tiempo, en el dominio de la frecuencia y a partir de análisis modales. Por ejemplo, Arai *et al.* (1990) realizaron uno de los primeros trabajos en el tema, calculando la respuesta dinámica de un depósito de suelo por medio de elementos finitos y el método de mínimos cuadrados, para ajustar los coeficientes de Fourier entre la respuesta medida y calculada. Los parámetros identificados fueron el módulo de Young y el coeficiente de amortiguamiento asumiendo un comportamiento elástico lineal y un amortiguamiento viscoso. Romo y Villarraga (1989) construyeron un método semejante para el caso de la presa El Infiernillo.

Honjo *et al.* (1998) usaron un arreglo de pozo vertical localizado en el centro de Tokio (Japón) para estimar los parámetros del modelo unidimensional, por medio de un análisis inverso que emplea el método Bayesiano. Encontraron que los valores del módulo de rigidez son lo suficientemente confiables para su uso en la práctica, pero los valores de relación de amortiguamiento son mayores que los obtenidos en ensayos triaxiales. Por otro lado, Honda *et al.* (1995) analizaron registros de arreglos de pozo vertical de 4 sitios para estimar los parámetros dinámicos del suelo. Realizaron un análisis en el dominio de la frecuencia para obtener la respuesta y emplearon el

método de mínimos cuadrados para estimar el módulo de rigidez y la relación de amortiguamiento. El módulo de rigidez estimado fue razonable, mientras que la relación de amortiguamiento fue inestable y sensible al nivel de aceleraciones.

Kokusho *et al.* (1996) usaron la teoría de propagación de ondas y el método lineal equivalente combinado con el método de mínimos cuadrados para realizar un análisis en el dominio de la frecuencia. Concluyeron que el módulo de rigidez obtenido es lo suficientemente aproximado para propósitos prácticos. Zentar *et al.* (2001) proponen un método basado en un análisis inverso para identificar los parámetros constitutivos del modelo Cam-Clay modificado a partir de ensayos de presiometro, usando una herramienta de optimación y una de elementos finitos. Zentar y colaboradores demostraron que los parámetros optimizados son muy cercanos a aquellos definidos de ensayos de laboratorio. Ikemoto *et al.* (2000), proponen un análisis inverso combinando técnicas de optimación (algoritmos genéticos) con la teoría de propagación de ondas, para encontrar el conjunto de parámetros dinámicos del suelo, usando un arreglo acelerográfico de pozo.

En conclusión, la revisión de estos métodos (doble integración y diferencial), reconoce i) que el módulo de rigidez se puede estimar de manera confiable, pero la relación de amortiguamiento difiere de los valores encontrados en ensayos de campo y laboratorio e ii) el uso de un modelo matemático (modelo paramétrico) que representa el comportamiento del suelo en estudio, junto con un proceso de minimización que ajusta la respuesta medida a la respuesta calculada (en el dominio del tiempo o de la frecuencia) a través de la variación de los parámetros dinámicos asociados (módulo de rigidez y relación de amortiguamiento, principalmente).

Por lo general, se acepta como simplificación conveniente al modelo matemático, un modelo unidimensional conformado por estratos horizontales de extensión infinita, donde se propagan verticalmente ondas SH, según lo expuso inicialmente Kanai *et al.* (1966). El principal problema del sistema de identificación bajo este enfoque es lo que podría denominarse como identificabilidad: ¿pueden los parámetros de un sistema dinámico en principio, ser únicamente determinados de las observaciones?. Esto es un problema teórico, por lo general, bien comprendido para sistemas lineales de dimensión finita, pero no satisfactoriamente establecido en el caso de sistemas dinámicos no-lineales (Van Schuppen, 2004).

3.2 SI geotécnico

En esta aplicación el SI busca definir tanto el modelo matemático que describe adecuadamente el comportamiento del sistema, como establecer los parámetros asociados a dicho modelo. Bajo este enfoque el SI involucra dos actividades básicas (Fig. 3.6): a) la *identificación estructural*, orientada a determinar la forma (funcional) general del modelo (por ejemplo una ecuación diferencial ordinaria en el análisis de un péndulo simple) y b) la *estimación paramétrica*, en la que se establecen los valores de parámetros específicos (coeficientes desconocidos) que permiten al modelo ajustarse a los datos observados (Casdagli, 1992). El funcionamiento del SI (Fig. 3.6) con el estudio del comportamiento del sistema natural (depósito de suelo), involucra la representación de éste, a través de un modelo matemático que asocia o simula este comportamiento a partir de mediciones realizadas en dicho sistema (depósito de suelo).

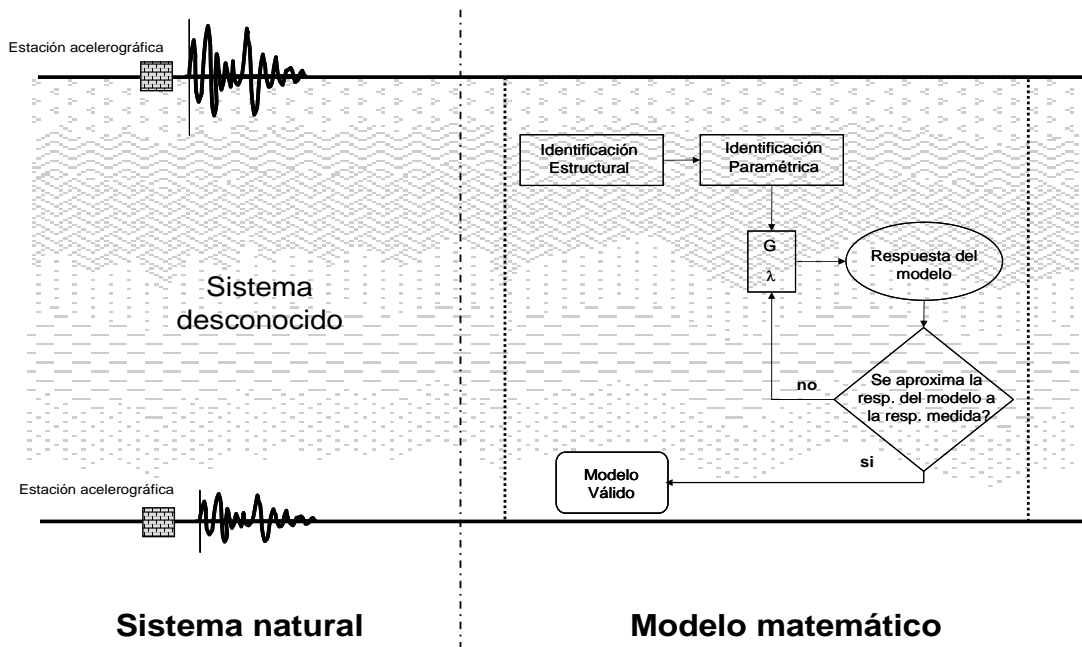


Figura 3.6 Sistema de identificación bajo el enfoque geotécnico.

Para establecer el modelo matemático se realiza un reconocimiento del depósito de suelo que incluye: i) la determinación de su geometría y sus propiedades índice y mecánicas, ii) la determinación de la entrada (registro de aceleraciones en un punto de control) y salidas (registro de aceleraciones en diferentes puntos del depósito) (Fig. 3.7) e iii) el reconocimiento de las características que inciden sobre la respuesta del sistema en estudio (p.e., directividad y tipo de onda sísmica) (Fig. 3.8).




Figura 3.7 Reconocimiento de sistema natural

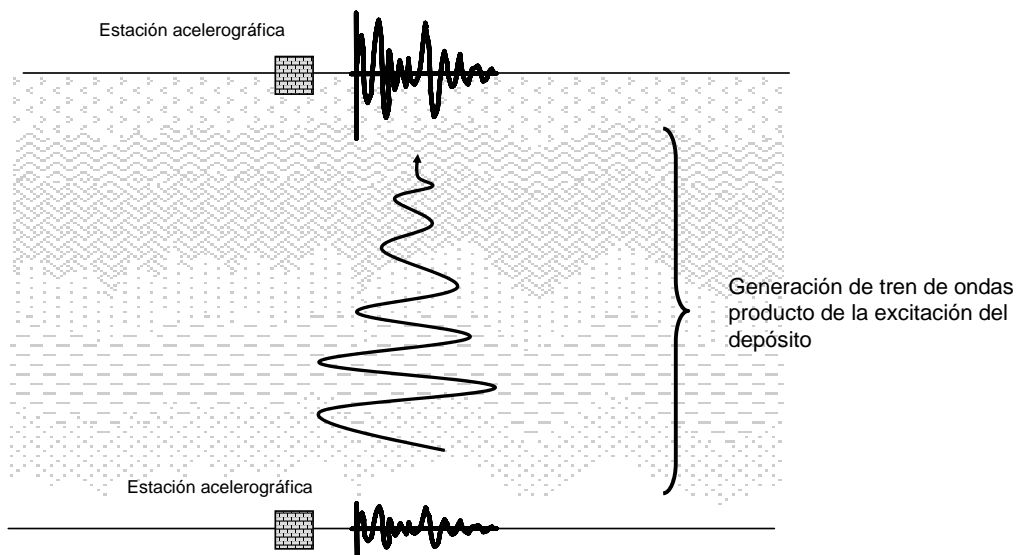


Figura 3.8 Comportamiento del sistema natural

En el caso de un depósito de suelo, se discrimina dentro de un conjunto de funcionales matemáticos, aquellos que por las capacidades de cómputo y teóricas del diseñador resulten factibles; y se definen los parámetros asociados a estos funcionales que ayuden a describir los factores que dirigen el comportamiento del sistema. En un primer paso se procede con la *identificación estructural* (IE), donde con las propiedades evaluadas en los materiales naturales, una señal excitadora, y apoyados en algún modelo, se representa el comportamiento del sistema (Fig. 3.9).




Figura 3.9 Identificación estructural del sistema

Posteriormente toma lugar la *identificación paramétrica* (IP), en donde se determinan los parámetros dinámicos (G, λ) a partir de mediciones realizadas sobre el sistema (Fig. 3.10).




Figura 3.10 Identificación paramétrica del sistema

Con la *identificación paramétrica* e *identificación estructural*, se evalúa la respuesta del

modelo. Esta respuesta contiene todas las características del sistema (Fig. 3.11).

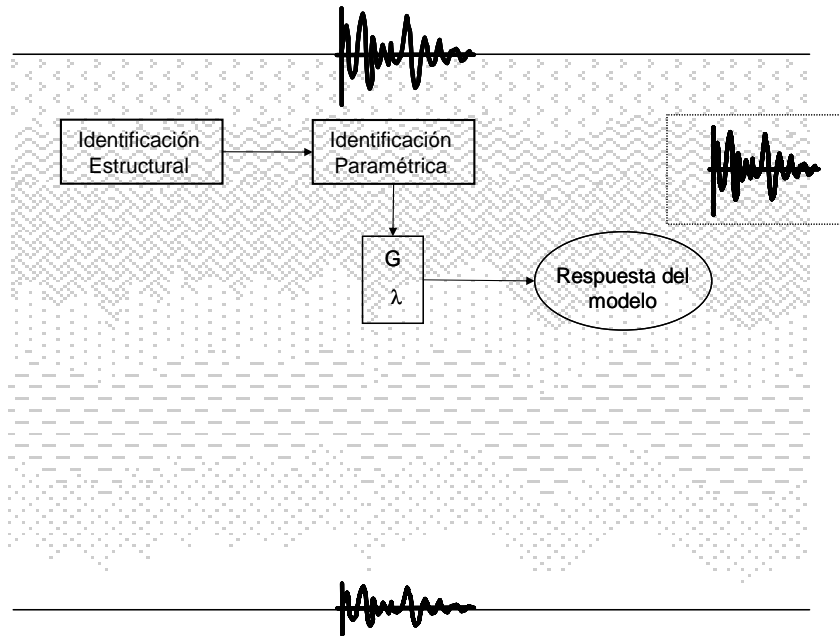


Figura 3.11 Respuesta del modelo

El propósito básico del SI, es lograr una respuesta del modelo (respuesta calculada) tal que se aproxime a la respuesta medida del sistema. Para alcanzarlo se establece un criterio de convergencia (Fig. 3.12) que involucra la proximidad entre respuestas (respuesta medida *versus* respuesta calculada).




Figura 3.12 Criterio de convergencia

Este criterio de convergencia da origen a un procedimiento de optimización, donde se compara la respuesta calculada en la etapa anterior y la respuesta medida del sistema. En el caso en que la respuesta calculada y la respuesta medida sean diferentes (no cumplen criterio de convergencia), comienza un proceso iterativo de modificación de los parámetros dinámicos (Fig. 3.13), hasta que se cumpla el criterio de convergencia; donde se considera: i) a los parámetros obtenidos como aquellos que permitan reproducir la respuesta medida del depósito de suelo e ii) al modelo matemático como aquel que representa el comportamiento del sistema natural en estudio (el proceso completo se detalla en un capítulo posterior (Fig. 3.14)).

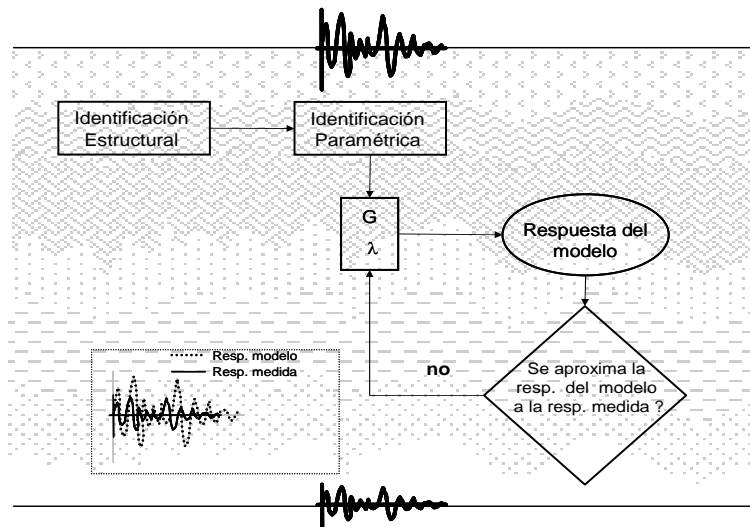


Figura 3.13 Proceso de iteración

El éxito de este SI depende en gran medida del tipo de herramientas teóricas y de la cantidad y calidad de los análisis "entradas→salidas" que se lleven a cabo. En fenómenos no lineales -como la mayoría de los fenómenos geosísmicos- la *estimación paramétrica* es una tarea difícil, pero sin duda la *identificación estructural* es aún más complicada. La adecuada selección del modelo paramétrico debe tener como criterio de aceptación, aquel que contenga términos que estén directamente relacionados con las propiedades físicas conocidas del sistema.

Por otro lado, la ciencia en general y la ingeniería en particular postulan problemas cuyas soluciones demandan diferentes clases de modelos y técnicas de modelado. Cualquier metodología diseñada para razonar acerca de estos modelos debe ser: a)

suficientemente flexible para permitir el manejo de varios grados de incertidumbre y complejidad y b) suficientemente poderosa para tratar con situaciones en las cuales la señal de entrada puede ser o no controlable (García *et al.*, 2004b).

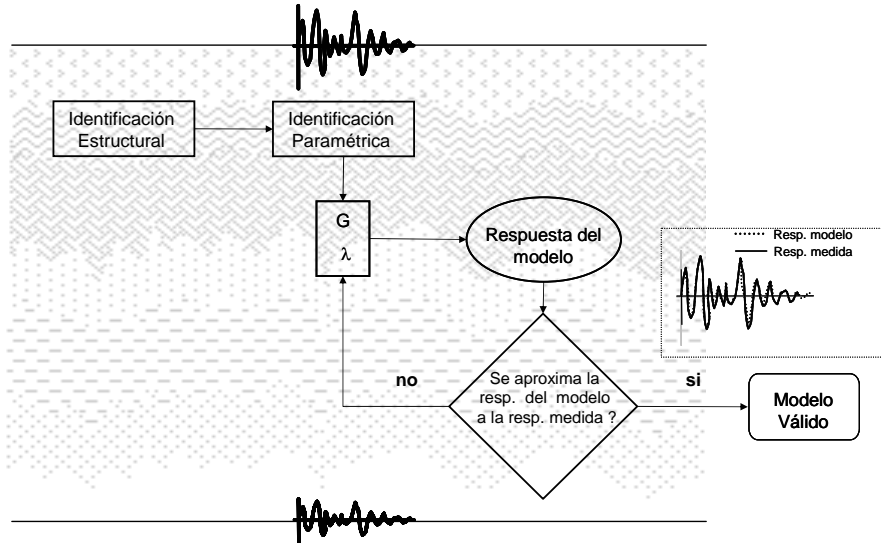


Figura 3.14 Modelo para la obtención de la respuesta del sistema en estudio

Un depósito de suelo como sistema físico dinámico, debe entenderse como un sistema de tres dimensiones, cuya evolución geológica lo convierte en un sistema heterogéneo, y que como ente dinámico presenta variaciones espacio-temporales; que lo transforma en un sistema con alto grado de complejidad.

El análisis unidimensional, por ejemplo, usualmente considera al depósito de suelo compuesto por estratos horizontales de extensión infinita, cuya respuesta se debe a la propagación vertical de ondas SH a través de él; a partir de parámetros que describen: i) las condiciones de los materiales (módulo de rigidez G , amortiguamiento λ , densidad ρ , y espesor de los estratos h) e ii) las características de la carga sísmica (registro de aceleraciones en un punto denominado de control -en la mayoría de los casos se toma el registrado en suelo firme-).

Para considerar el efecto del comportamiento no lineal de los suelos, los programas convencionales recurren al método "lineal equivalente", que considera valores de propiedades dinámicas (G y λ) que varían de acuerdo con los niveles de deformación angular (γ) alcanzados en cada historia de carga. La determinación de la pareja de valores G - λ que satisfacen el criterio de convergencia siguiendo un proceso recursivo

(no se trata de un proceso de optimación), se considera el correspondiente al nivel de deformaciones inducidas por el sismo específico. Modelos convencionales como el SHAKE (Schanabel *et al.*, 1972), siguen esta metodología para el análisis unidimensional de un depósito de suelo, y son ampliamente usados en la práctica ingenieril.

El método propuesto en esta investigación, permite por medio de registros de entrada y salida del depósito de suelo y las características para el modelado de sistemas dinámicos del CA (no linealidad, capacidad de generalización y alta dimensionalidad), desarrollar un SI que: i) permite evaluar la respuesta de un depósito de suelo ante movimientos sísmicos severos e ii) establece valores de G y λ útiles en la comprensión del fenómeno de amplificación de una manera simple. Para lograr esto, se hace uso de una red neuronal y un programa de análisis 1D convencional (modelo teórico al que se asocian parámetros dinámicos del suelo, usualmente estimados de ensayos de laboratorio). En este proceso se adopta una estrategia de control que combina las ideas de los modelos tradicionales y los formalismos matemáticos dinámicos no lineales, para la descripción del comportamiento físico observado.

CAPITULO 4:

Resultados del Sistema de Identificación Neuro-genético, SI-NG

4.1 Base de datos

A partir de lo discutido en el capítulo 3, se desprende que los registros sísmicos, intrínsecamente, contienen información sobre el comportamiento del sistema monitoreado; es decir, los registros sísmicos obtenidos en diferentes profundidades de depósitos instrumentados proporcionan información valiosa sobre el comportamiento del sistema; la cual, al ser interpretada correctamente proporciona conocimiento respecto al fenómeno físico. Indudablemente, este hecho debe ir acompañado de una comprensión adecuada del comportamiento dinámico de los materiales que componen el depósito de suelo en particular. Además, el conocimiento de la geología y propiedades de los materiales que conforman el sitio es de gran utilidad para complementar los datos necesarios para caracterizar el depósito en estudio.




Figura 4.1 Zonificación geotécnica y localización del sitio CDAO (Modificado de Sarmiento et al., 2002).

El Reglamento de Construcciones del Distrito Federal (RCDF'2004) establece en su Artículo 170 la existencia de tres zonas geotécnicas: *Zona I* denominada Zona de Lomas, *Zona II* o Zona de Transición y *Zona III*, con características mecánicas únicas en el mundo, denominada Zona de Lago a la que pertenece el sitio estudiado en esta investigación (Fig. 4.1); a continuación se enuncian características generales de las zonas mencionadas.

- *Zona de Lomas*: Suelos firmes depositados fuera del ambiente lacustre producto de grandes eventos volcánicos, donde es posible encontrar depósitos arenosos en estado suelto. Es frecuente la presencia de oquedades y túneles excavados en suelos para explotar minas de arena.
- *Zona de Transición*: Esta zona comprende la región entre la Zona de Lago y la Zona de Lomas, alcanzando en promedio los 20 m de profundidad. Está conformada por estratos arenosos y limos arenosos intercalados con capas de arcilla lacustre.
- *Zona de Lago*: Integrada por potentes estratos de arcilla blanda altamente compresible, separados por capas arenosas con contenido diverso de limo y

arcilla. Dichos estratos subyacen a una fuerte costra superficial conformada por suelos aluviales, materiales desecados y rellenos artificiales.

En particular, la Zona de Lago se caracteriza por una variación errática de las propiedades de los materiales que conforman sus depósitos (disminución de la compresibilidad y aumento de la resistencia al esfuerzo cortante conforme aumenta la profundidad), debida principalmente a dos fenómenos:

- a. Una *consolidación natural* de los suelos bajo su propio peso, excepto las costras duras que se preconsolidaron por deshidratación o secado solar, y
- b. Una *consolidación inducida*, resultado de un complejo proceso influenciado por los siguientes factores (Marsal y Mazari, 1957):
 - Bombeo de acuíferos para el abastecimiento de agua potable.
 - Peso de las estructuras.
 - Abatimiento de nivel freático por bombeo superficial para la construcción de cimentaciones y mantenimiento de sótanos.
 - Apertura de tajos y túneles para el drenaje de aguas pluviales y negras.
 - Efecto de la sobre carga de antiguos rellenos superficiales.

Para el desarrollo de un SI eficiente, es necesario el conocimiento de las propiedades (mecánicas y físicas) y una adecuada instrumentación del depósito. Este par de requerimientos los reúne el sitio Central De Abasto Oficinas (CDAO), ubicado en la ciudad de México, 4 Km al norte del Cerro la Estrella. La manera en que se encuentran dispuestas las estaciones acelerográficas en este sitio permiten analizar el comportamiento de las ondas sísmicas durante su viaje hacia la superficie a través de los diferentes materiales que conforman el subsuelo; de hecho cada instrumento monitorea el movimiento sísmico tridimensional del punto donde se encuentra el acelerógrafo; es oportuno mencionar que el registro en superficie, además de contener información sobre el arribo de ondas sísmicas primarias, contiene ondas superficiales (*e.g., Lomnitz, 2004*) y potencialmente ondas de esfuerzo generadas por el efecto de interacción suelo estructura debido a la presencia del edificio de las oficinas de la Central de Abasto.

4.1.1 Perfil estratigráfico del sitio CDAO

La secuencia estratigráfica en CDAO, típica de la zona de lago (Fig. 4.2), está compuesta por (e.g., Jaime *et al.*, 1987):

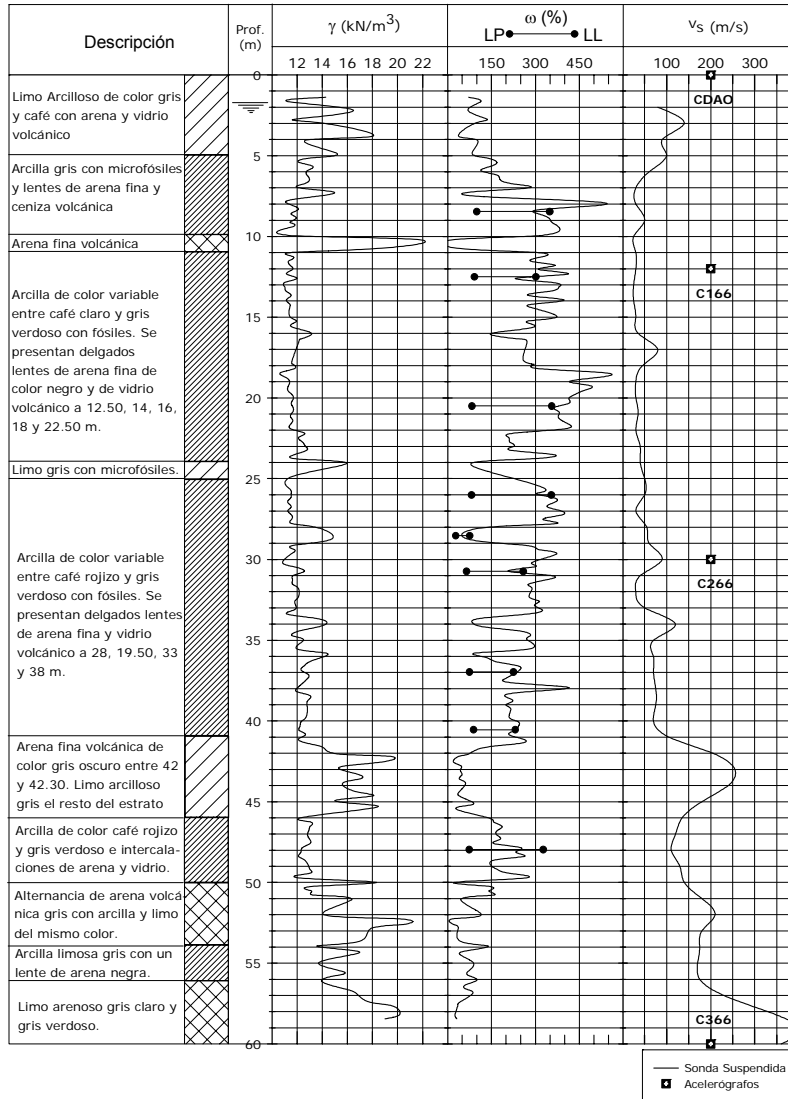


Figura 4.2 Estratigrafía y estaciones acelerográficas en CAO (Modificado de Jaime *et al.*, 1987)

- *Costra Superficial*: Constituida por intercalaciones de material de origen aluvial, compuesto principalmente por limos arenosos (SM), limos y arcillas orgánicas (CH, OH y OL), que presentan endurecimiento por secado solar.
- *Serie arcillosa superior*: Es un potente paquete de arcillas (CH) cuyo origen lacustre las ha hecho extraordinariamente compresibles. Se presentan

intercaladas con delgados lentes de arenas o vidrio volcánico a diferentes profundidades.

- *Capa Dura*: Compuesta por limos, con algo de arcilla y ocasionalmente gravas, compacta y rígida con espesor promedio de 3m. Su gran continuidad lo hace un excelente marcador o guía estratigráfico en prácticamente toda la zona central del valle, pero tiende a desaparecer hacia las zonas profundas del lago.
- *Formación arcillosa inferior*: Conformada por arcillas volcánicas con características semejantes a las de la formación superior, aunque más resistentes y menos compresibles. Este estrato se encuentra fuertemente influenciado por los efectos del bombeo regional de los estratos más profundos y se destaca la presencia de una secuencia de estratos duros, especialmente de vidrio volcánico.
- *Depósitos profundos*: Depósitos arena y grava de origen aluvial, cementadas con arcillas duras y carbonatos de calcio. La parte superior de estos estratos se encuentra más endurecida.

Conviene señalar que las propiedades mecánicas y dinámicas de las arcillas de la ciudad de México cambian con el tiempo debido a la extracción de agua de los acuíferos superficiales, estas modificaciones pueden cambiar apreciablemente las características vibratorias del subsuelo y por ende su capacidad para amplificar los movimientos sísmicos que inciden en ella (Ovando *et al.*, 1993).

A partir de la figura 4.3 y para propósitos del trabajo, se plantea una estratigrafía simplificada del sistema compuesta básicamente por 7 estratos hasta la profundidad de 60 m; con dos potentes estratos arcillosos (formación arcillosa inferior y superior), que otorgan al depósito prominentes características de amplificación; los estratos restantes se componen de materiales limosos y arenosos.

4.1.2 Descripción del arreglo acelerográfico vertical en CDAO

El arreglo de pozo vertical en CDAO está conformado por 4 estaciones acelerográficas dispuestas de la siguiente forma (Fig. 4.3): una estación superficial administrada por el Instituto de Ingeniería de la UNAM (CDAO) y otras tres estaciones a 12 m (C166), 30 m (C266) y 60 m (C366) de profundidad, administradas por el Centro de Instrumentación y Registro Sísmico (CIRES). Se hace notar que la estación ubicada en superficie funciona de manera independiente a las estaciones de pozo, por lo que los registros en esta estación suelen estar desfasados (en el tiempo) de los registros

obtenidos en la otras estaciones. Este hecho cobra importancia debido a que las metodologías tradicionales del análisis de señales parten de la hipótesis que éstas tienen un tiempo común de inicio; así que para subsanar el desfase potencial, se recurre para su estimación de la *correlación cruzada* (Bendat y Piersol, 1971) entre señales. Conocido ésta, la señal desfasada se desplaza (en el tiempo) la cantidad calculada para homologar los tiempos de disparo. En este estudio esta metodología no es necesaria, ya que las RNs como aproximadores universales para el análisis de sistemas complejos permite establecer patrones de comportamiento bajo ambientes y condiciones reales de monitoreo, evitando el uso de hipótesis adicionales.

Estación




Figura 4.3 Estratigrafía considerada para los análisis llevados a cabo en este trabajo

4.1.3 Registros acelerográficos en CDAO

Los registros de aceleraciones de las estaciones ubicadas en CDAO (tabla 4.1) se obtuvieron de la Base Mexicana de Sismos Fuertes; que reúne información sobre los registros de aceleraciones de las diferentes estaciones acelerográficas dispuestas sobre la ciudad de México (SMIS, 2000).

Tabla 4.1 Características de estaciones acelerográficas en sitio CAO

Estación	Institución	Clave de estación	Profundidad	Lat. N	Long. W
CDAO	I de I – UNAM	CDAO	Superficie	19.373	99.096
CDAO POZO 12	CIRES	C166	12 m	19.373	99.098
CDAO POZO 30	CIRES	C266	30 m	19.373	99.098
CDAO POZO 60	CIRES	C366	60 m	19.373	99.093

Tabla 4.2 Eventos sísmicos considerados

Evento	Fecha dd/mm/aa	Profundidad del epicentro (km)	Coordenada del epicentro		Magnitud M _c
			Lat. N	Long. W	
1	24/10/93	19	16.540	98.980	6.5
2	29/07/93	43	17.380	100.650	5.0
3	05/08/93	32	17.080	98.530	5.1
4	04/07/94	31	14.830	97.290	5.9
5	12/10/95	-	18.600	104.100	6.1
6	27/03/96	7	16.21	98.21	4.6
7	21/01/97	18	16.440	98.150	5.0
8	23/03/97	31	17.390	100.880	4.7
9	08/05/97	12	17.320	100.440	4.8
10	10/09/93	20	16.570	98.940	4.8
11	23/02/94	5	17.820	97.300	5.0
12	19/09/85	15	18.081	102.942	8.1
13	14/09/95	22	16.310	98.880	7.3
14	31/05/90	16	17.106	100.893	5.5
15	11/01/97	16	17.910	103.040	6.9
16	23/05/94	23	18.030	100.570	5.6
17	10/12/94	20	18.020	101.560	6.3
18	22/05/97	59	18.410	101.810	6.0

Los eventos sísmicos empleados en esta investigación se presentan en la tabla 4.2. Su elección se realizó considerando un amplio rango de magnitudes máximas M_c para proporcionar al modelo neuronal características de respuesta bajo diferentes intensidades de carga sísmica, y a su vez considerando el hecho que el mismo evento se haya registrado tanto en la estación Ciudad Universitaria (CU, ver Fig. 4.1) como en el sitio CDAO. Esta condición se establece a partir de los resultados de estudios anteriores (Romo y Jaime, 1986; Romo y Seed, 1986) que muestran que los

movimientos sísmicos registrados en CU, se pueden utilizar como los temblores de control (excitación) en el cálculo de la respuesta de estratigrafías en la Zona de Lago de la ciudad de México.

La base de datos se construyó agrupando los sismos de acuerdo al nivel de aceleraciones registrado: *Menores* (aceleración máxima (AM) < 1 cm/s²), *Moderados* (1 cm/s² < AM < 15 cm/s²), *Severos* (15 cm/s² < AM < 30 cm/s²) y *Muy Severos* (AM > 30 cm/s²). Los sismos Muy Severos, por su parte, son sintéticos compatibles con los espectros de diseño del Reglamento de Construcciones del Distrito Federal (RCDF'2004) para la Zona de Lago -sismos sintéticos cuyos espectros de aceleraciones se encuentra entre los límites de la envolvente previamente definida por Mateos (Mateos, 2004)-.

4.2 Análisis de resultados

Se considera pertinente iniciar con la descripción de la secuencia metodológica del SI-NG y la explicación pormenorizada de cada uno de los módulos que lo constituyen, facilitando la comprensión del funcionamiento del identificador para el sitio CDAO.

4.2.1 Descripción general del SI-NG

En los siguientes párrafos se detalla la estructura del SI propuesto el cual se logra a partir de herramientas matemáticas no lineales para el reconocimiento de estructuras matemáticas –funciones- (red neuronal) y optimización (algoritmos genéticos), y conjugando conceptos de control, dinámica de suelos e ingeniería sísmica. Este sistema de identificación permite establecer el modelo matemático y los parámetros (módulo de rigidez y relación de amortiguamiento), con los que se reproducen y predicen las respuestas en términos de espectros de respuesta de aceleración del depósito estudiado.

A continuación se describen, progresivamente, los pasos que conforman el SI-NG propuesto en esta investigación, con lo cual se indica el “funcionamiento directo” o reconocimiento funcional paramétrico.

1. **Sistema y Primera aproximación empírica:** Se presenta un depósito de suelo (sistema) del cual se conocen sus parámetros dinámicos, físicos y geométricos a partir de pruebas de campo y laboratorio (Fig. 4.4). El sistema se encuentra

instrumentado a diferentes profundidades por medio de la ubicación de estaciones acelerográficas que permiten monitorear su comportamiento dinámico. Posteriormente, con la información de estas pruebas (campo y laboratorio), sobre los materiales que componen el depósito, se propone un conjunto de pares de parámetros dinámicos ($G_{propuesto}$ y $\lambda_{propuesto}$). Estos valores son usados comúnmente para calcular los efectos de sitio y con fines de diseño sísmico de obras en la ingeniería práctica utilizando modelos lineales y lineales equivalentes.




Figura 4.4 Reconocimiento del sistema y primera aproximación de los parámetros dinámicos.

2. **Identificación Estructural (IE):** Con información de las características de los materiales del depósito del suelo (propiedades índice, mecánicas y dinámicas) y un registro de aceleraciones (tomado como excitación), y aceptando como punto de partida la hipótesis del comportamiento unidimensional para los depósitos del valle de la ciudad de México (Romo y Jaime, 1986; Romo y Seed, 1986); se realizaron numerosos análisis con un programa convencional de análisis unidimensional (SHAKE, Schnabel *et al.*, 1972), con el cual se conformó una base de datos para el entrenamiento de una *Red Neuronal de Identificación Estructural (RN-IE)*, diseñada con patrones teórico-numéricos, con el propósito de reproducir el comportamiento

de este modelo matemático (red mecanista, Fig. 4.5). Convencionalmente, los sistemas naturales de alta complejidad han sido estudiados a través de modelos lineales con hipótesis de trabajo restrictivas que proporcionan una respuesta aproximada del comportamiento del sistema en estudio. Estos modelos requieren del conocimiento de los parámetros de rigidez y capacidad de disipación de energía para el cálculo de las respuestas sísmicas de depósitos de suelo.

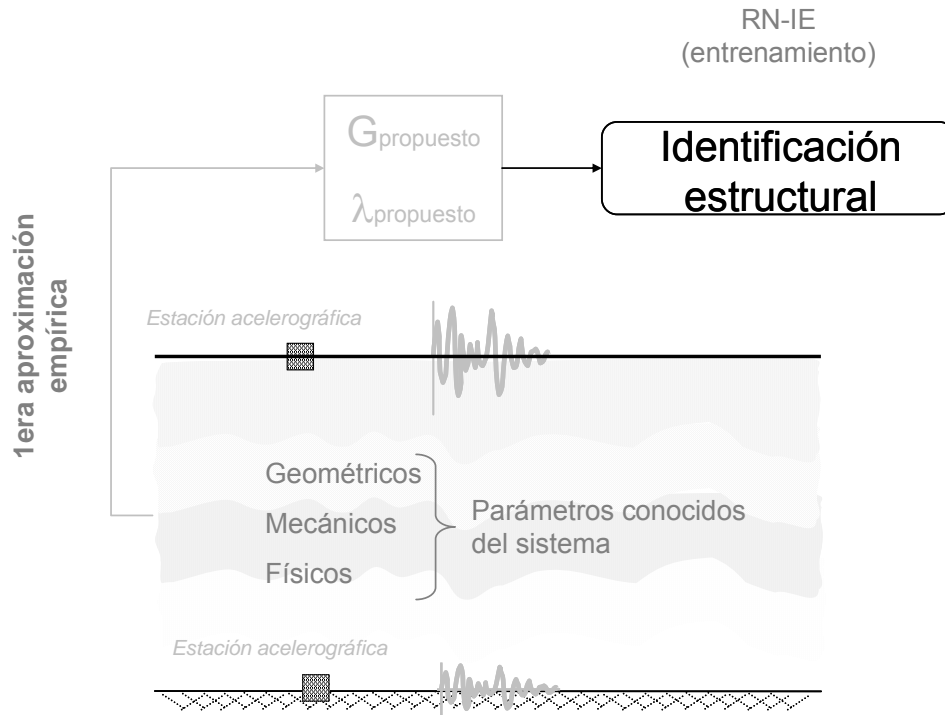


Figura 4.5 Red Neuronal de Identificación Estructural, RN-IE. Se construye (entrenamiento) a partir de los parámetros conocidos del sistema y una aproximación de los parámetros dinámicos, apoyados en un modelo unidimensional.

3. **Primera evaluación:** Cuando la identificación estructural se ha logrado, es decir, se haya alcanzado una alta concordancia entre la respuesta obtenida con la RN-IE y el modelo unidimensional (etapa de entrenamiento de la RN-IE); se lleva a cabo, con un conjunto de datos de prueba, una evaluación de la respuesta. Un primer acercamiento permite distinguir que la respuesta obtenida es capaz de mimetizar la generada con un modelo unidimensional, reconociendo que las características no lineales del proceso neuronal le otorgan una mayor flexibilidad y generalización. En la figura 4.6 se especifica la incorporación del módulo neuronal dentro del sistema

SI, donde a partir de los datos de prueba se produce una respuesta del modelo (etapa de prueba de RN-IE) que luego es comparada con la respuesta medida o registrada en campo (punto de control) a la misma profundidad, para establecer la aproximación del modelo RN-IE a través un criterio de convergencia. En este punto pueden tomarse dos caminos: 1) donde se cumple el criterio, y se acepta el modelo como válido para la identificación del sistema y 2) donde no se cumple tal criterio y se plantea la optimización de esta respuesta, no a partir de la modificación del funcional neuronal (RN-IE) ya que este funcional es "fijo", sino a partir de la modificación de los parámetros dinámicos. Esta última opción se adopta en este trabajo de investigación. Por lo general, en esta primera evaluación la convergencia no se alcanza debido a que los parámetros dinámicos considerados son independientes de la frecuencia, aspecto debatible dado que las arcillas son función de la velocidad de aplicación de la deformación.

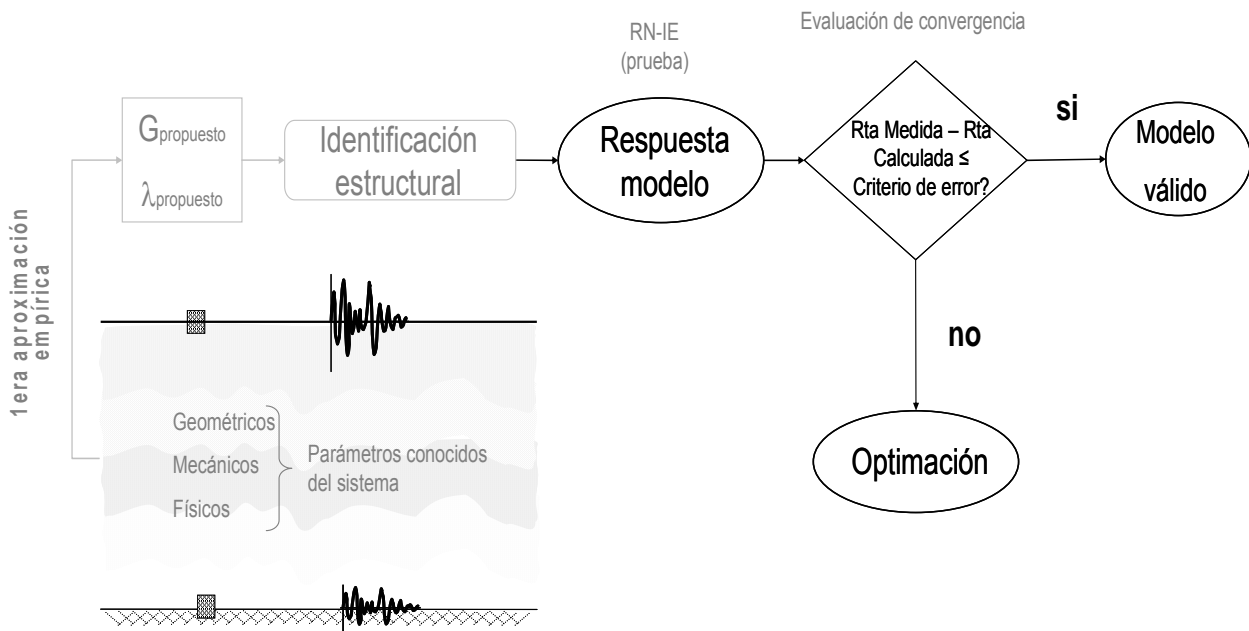


Figura 4.6 Primera evaluación: Se realiza con la evaluación de los datos de prueba de la RN-IE. Se evalúa un criterio de convergencia a partir de la comparación entre la respuesta del modelo y la respuesta de campo. En el caso en que el criterio se cumpla se asume el modelo como válido; en caso contrario, se propone una búsqueda de nuevos parámetros dinámicos.

4. **Identificación Paramétrica (IP):** Los registros de las aceleraciones en el depósito de suelo (sistema), permiten la determinación de los parámetros (G_{RN} y λ_{RN}) que

califican el comportamiento dinámico del depósito de suelo, a partir de una *Red Neuronal de Identificación Paramétrica* (RN-IP) que se construye con los registros de aceleraciones de entrada y salida del sistema en estudio, con los parámetros geométricos que definen la estratigrafía y los parámetros físicos de los materiales que conforman el depósito (Fig. 4.7); es decir, que a través de la RN-IP es posible determinar el conjunto de parámetros dinámicos que mejor ajustan la señal de entrada en puntos específicos del depósito; lo interesante es que esto sólo se logra considerando la variación de los parámetros dinámicos con la frecuencia.




Figura 4.7 Identificación paramétrica.

Los parámetros dinámicos, módulo de rigidez y relación de amortiguamiento, G y λ , se estiman a partir de la historia esfuerzo-deformación descrita por el comportamiento del suelo cuando está sometido a fuerzas cortantes. De este concepto parten modelos que permiten evaluar la respuesta de sistemas naturales. Estudios de campo y laboratorio han aclarado muchos aspectos sobre la influencia de diferentes factores sobre las características de la relación esfuerzo-deformación y por ende en las propiedades dinámicas (Seed e Idriss, 1969; Hardin y Drnevich, 1972; Romo y Jaime, 1986; Vucetic y Dobry, 1991); entre los que destacan el nivel de deformación angular, el esfuerzo efectivo vertical y la relación de vacíos o índice de plasticidad. Cualquier relación esfuerzo-deformación que pretenda describir el comportamiento de un suelo debería ser lo suficientemente compleja para tomar en cuenta la gran cantidad de factores que la caracterizan (Hardin y Drnevich, 1972).

Debe entenderse que son necesarios los valores G y λ en los modelos cuantitativos (de respuesta sísmica) porque son los parámetros naturales del suelo que más influyen en el desarrollo de modelos que explican y generan conocimiento sobre lo que se observa (García, 2005b).

5. **Segunda evaluación de la respuesta:** En esta segunda evaluación, los valores de los parámetros dinámicos arrojados por la RN-IP, ingresan ahora como los valores de parámetros dinámicos para la evaluación del modelo estructural (RN-IE) para los eventos de prueba. De igual manera que para la primera evaluación, se calcula la aproximación que alcanza la respuesta del modelo con la respuesta medida en campo a partir del criterio de convergencia (ver Fig. 4.8). La respuesta de esta segunda evaluación, generalmente no reproduce la respuesta óptima del depósito; esto es comprensible si se toma en cuenta que los valores para esta segunda evaluación son cercanos a los inicialmente propuestos. Sin embargo, la obtención de las respuestas en esta segunda evaluación permite reconocer tendencias de magnitud.

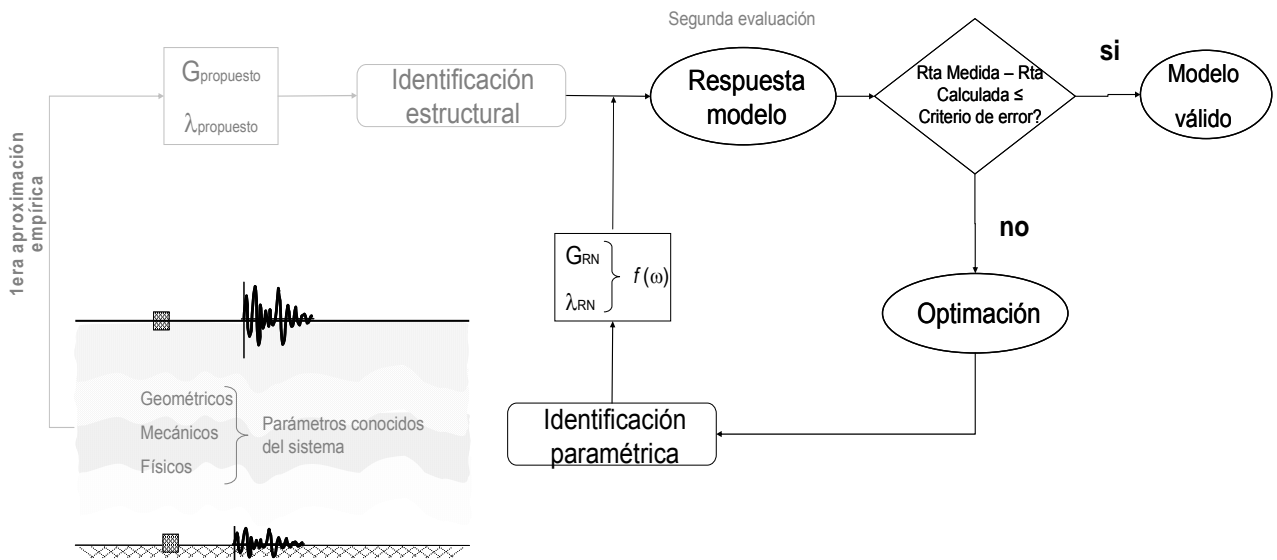


Figura 4.8 Segunda evaluación. Se realiza cuando no se alcanza el criterio de convergencia en la primera evaluación, comprometiendo a establecer un nuevo conjunto de parámetros dinámicos con los cuales pueda evaluarse nuevamente la respuesta.

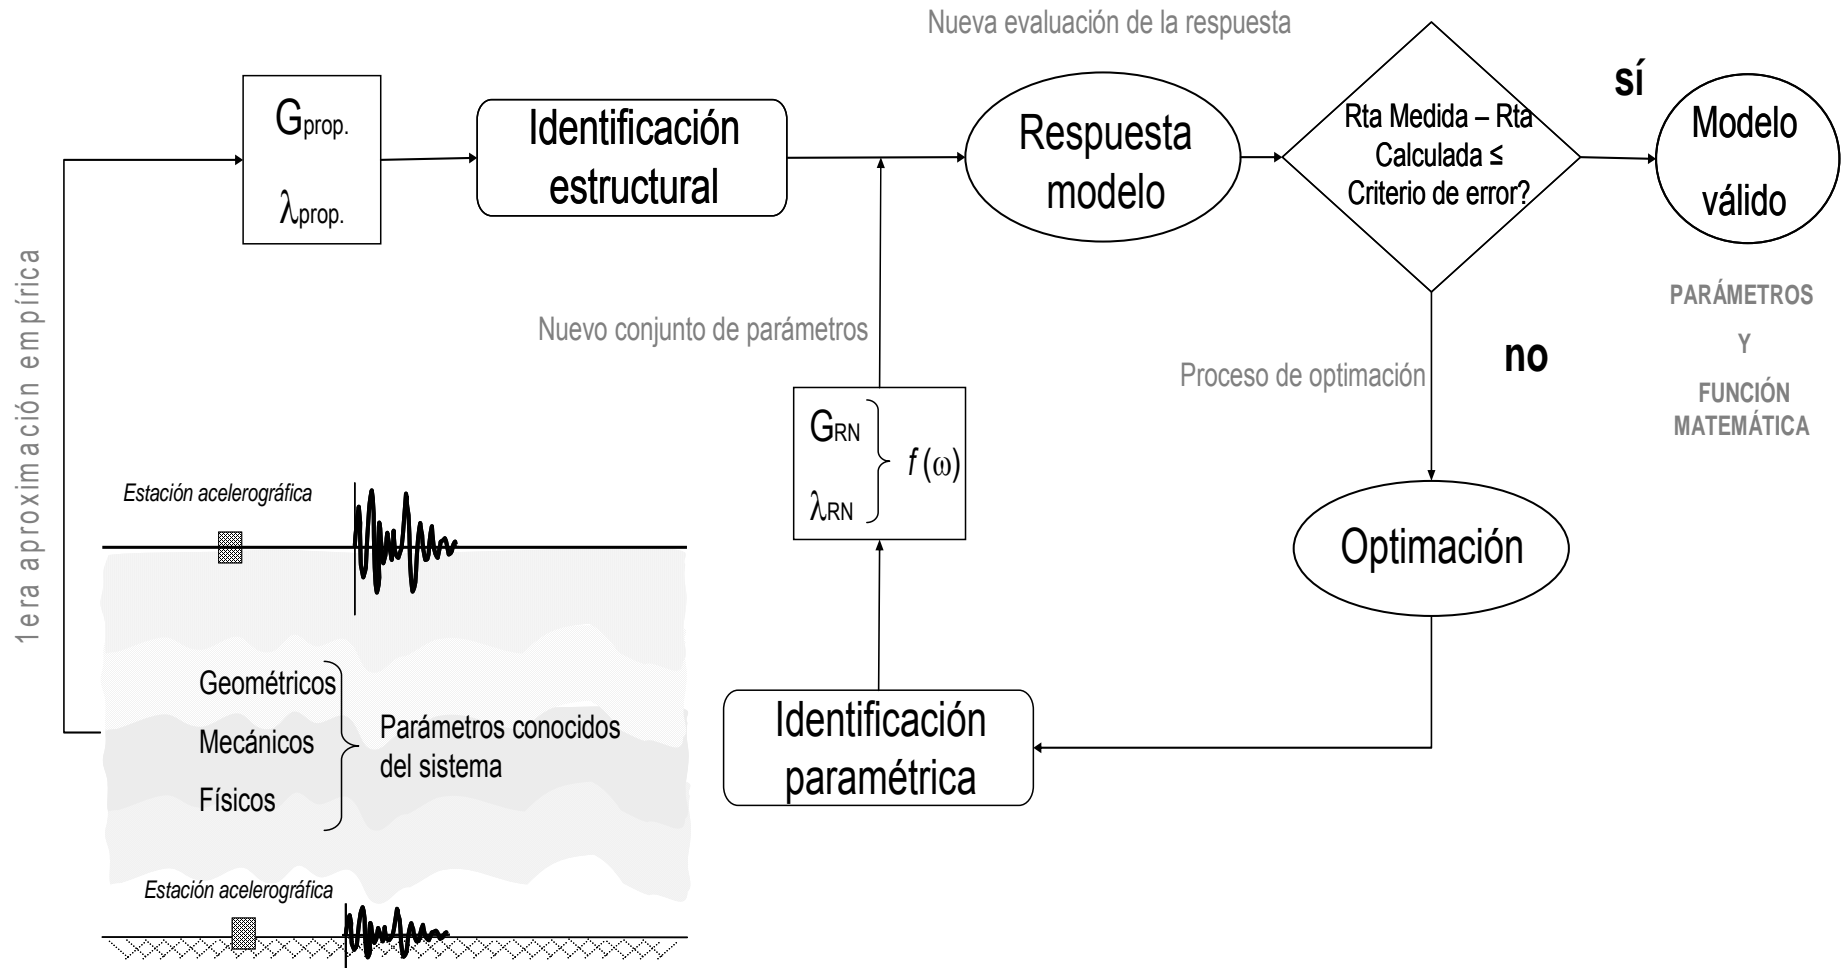


Figura 4.9 SI en funcionamiento directo. Se muestra cómo la etapa de optimización contiene la búsqueda de parámetros hasta que el criterio de convergencia se logra.

6. **Proceso de optimación:** La RN-IE representa el comportamiento del modelo unidimensional lineal; pero por definición, las redes neuronales fueron concebidas para el estudio de sistemas altamente no lineales, así que para alcanzar las respuestas medidas a partir de este modelo se explora dicha virtud, buscando mediante un proceso de optimación los valores G y λ que hacen que la RN-IE reproduzca la respuesta medida del depósito; es decir, se realiza un proceso iterativo hasta que se logra el criterio de convergencia requerido (Fig. 4.9). Cuando esto se logra, se cierra el SI y al conjunto de parámetros dinámicos (los cuales resultan dependientes de la frecuencia) se les considera como los parámetros "reales" del sistema y al modelo neuronal resultante como modelo matemático válido para la determinación de las respuestas para este sistema particular. A diferencia de SIs como los mencionados anteriormente (doble integración y diferencial), donde a partir de un modelo matemático aceptado para el comportamiento del sistema en estudio se hace una búsqueda de los valores de los parámetros requeridos para que la respuesta del modelo se aproxime a la respuesta del modelo, en este trabajo se realiza un proceso de identificación más completo, ya que se obtiene la estructura no lineal de comportamiento del sistema y los valores de los parámetros que ajustan las respuestas del modelo a los datos observados, lo cual se ajusta a la definición propuesta por los pioneros (expertos en control) de los SI (*e.g.*, Easley y Bradley, 1999).

4.2.2 Funcionamiento del SI-NG

La puesta en marcha del SI neuronal permitirá aclarar cada uno de los pasos anteriormente descritos, para ello se propone el desarrollo de ejemplos numéricos en dos etapas: una primera, donde se considera un sistema de identificación (SI) para un depósito de suelo compuesto por sólo un estrato y una segunda etapa, en la cual a partir de los resultados de la etapa anterior, se establece la metodología para lograr un SI para un depósito compuesto por 7 estratos y 4 estaciones acelerográficas según se presenta en la figura 4.3. Con respecto a la figura 4.9, se observa que el éxito del SI está sujeto al funcionamiento de los módulos Identificación Estructural (IE) y la Identificación Paramétrica (IP), donde este funcionamiento depende en gran medida del tipo de herramientas teóricas empleadas así como de la cantidad y calidad de los análisis entrada-salida que se lleven a cabo. Debe tenerse en cuenta que en fenómenos no lineales –como la mayoría de los problemas geosísmicos- la identificación paramétrica es difícil, pero sin duda la identificación estructural es aún

más compleja, por lo que se requieren herramientas y conceptos de otros campos de la ciencia (Teoría de control, cómputo aproximado, optimización de sistemas no lineales).

4.2.3 Descripción de las Variables Involucradas en el SI-NG

El comportamiento de la arcilla del valle de México ha sido extensamente estudiado debido a sus excepcionales características. Los parámetros asociados a su comportamiento dinámico han evidenciado un comportamiento elástico-lineal hasta deformaciones por cortante del orden de $10^{-1}\%$ (Romo *et al.*, 1988), de tal forma que al considerar sismos con intensidades bajas resulta válido fijar un comportamiento lineal del suelo donde los valores de los parámetros dinámicos (módulo de rigidez y relación de amortiguamiento) se mantienen constantes para deformaciones por cortante inferiores al umbral señalado. Usando esta aproximación de linealidad y considerando las características estratigráficas de los depósitos los suelos de la ciudad de México, su respuesta dinámica se ha estimado a partir de la teoría unidimensional de propagación de ondas sísmicas (ver método diferencial, capítulo anterior) considerando las siguientes hipótesis:

- 1) Estratigrafía: El depósito está compuesto de estratos horizontales de extensión infinita, cuyas fronteras no generen movimientos adicionales al primario.
- 2) Comportamiento: La respuesta del depósito se debe primordialmente a la propagación de ondas SH, las cuales reflejan y refractan ondas del mismo tipo.
- 3) Materiales: Los materiales que constituyen cada uno de los estratos se consideran isótropos y homogéneos en toda su extensión, es decir, cualquier punto dentro de un estrato tendrá las mismas características que otro punto dentro del mismo estrato.
- 4) Depósito: El depósito se considera en campo libre, es decir, no se contemplan efectos por las construcciones en superficie, por lo cual el esfuerzo cortante (τ) en superficie es igual a cero.
- 5) Estrato: Cada estrato del sistema está completamente definido por su valor de módulo de rigidez (G), relación de amortiguamiento (λ), densidad y espesor.
- 6) Propiedades dinámicas del suelo: La dependencia de G y λ con la deformación se toma en cuenta utilizando un procedimiento lineal equivalente basado en el nivel medio de deformación efectiva calculada para cada capa (Schnabel, *et al.*, 1972); que a su vez independiza los parámetros dinámicos de la frecuencia.

Estas hipótesis pueden ser restrictivas, si se piensa por ejemplo, en el caso de la estratigrafía, donde a causa de los complejos procesos geológicos de formación de los materiales que conforman los depósitos en estudio, no necesariamente son continuos ni homogéneos. En lo que se refiere a la hipótesis de campo libre en zonas urbanas de alta densidad, resulta cuestionable. Por otro lado, resultados de ensayos de laboratorio (columna resonante) han demostrado la dependencia de las propiedades dinámicas con la frecuencia (*e.g.*, Stokoe, 1999); así mismo, aunque se ha argumentado sobre el comportamiento lineal de las arcillas del valle de la ciudad de México por algunos casos monitoreados, esto no permite extrapolarlo a eventos o sitios diferentes. Es resumen, las hipótesis de las que parte el modelo unidimensional no se cumplen estrictamente en la realidad, pero para fines prácticos éstas premisas ofrecen la posibilidad de usar herramientas más sencillas y obtener evaluaciones en términos generales satisfactorias.

4.2.4 Algunas consideraciones sobre G y λ .

Ahora bien, cuando se hizo evidente el efecto de los sismos sobre nuestro entorno, surgió la necesidad de estudiar el comportamiento de los suelos ante movimientos cíclicos. Para ello, debieron establecerse parámetros o variables que enmarcaran el comportamiento del suelo bajo esta perspectiva, se adaptaron modelos tomados de la mecánica clásica para materiales con características homogéneas que dinámicamente recurren a dos parámetros básicos: i) la rigidez del material y ii) el amortiguamiento que da idea de su capacidad para disipar energía. Estos modelos se han adaptado a la mecánica de suelos para proporcionar sustento teórico a los modelos de sistemas tan complejos como los compuestos por materiales térreos.

Un aspecto de las características de estos dos parámetros, y que se ha soslayado, es que G y λ se consideran independientes de la frecuencia. Los resultados de los estudios reportados aquí permiten deducir que el suelo responde de forma particular ante excitaciones sísmicas con contenidos de frecuencia diferentes, aún cuando estas sean similarmente severas. En rigor, la respuesta medida en los depósitos de suelo ante excitaciones debe indiscutiblemente contener información de la variación de G y λ con la frecuencia, y cómo influye ésta en la respuesta del depósito de suelo.

A los SI basados en modelos que consideran a G y λ independientes de la frecuencia, evidentemente, les es realmente difícil reproducir la respuesta medida en campo; el SI

neuronal propuesto en este estudio permite ajustar los valores de los parámetros dinámicos tal que sean obtenidos los niveles medidos en el depósito; lo cual se logra adaptando las características de las redes neuronales a los modelos aceptados en la práctica para la estimación del comportamiento de estos suelos.

4.2.5 Rangos dinámicos, atributos y representación numérica de las variables involucradas en el modelo neuronal

Las propiedades físicas y mecánicas de los materiales del depósito considerado, involucradas directamente en el modelo neuronal son: contenido natural de agua (ω , %), índice de plasticidad (IP, %), peso volumétrico (γ , kN/m³) y velocidad de onda de corte (V_s , m/s). Los valores de estas propiedades se obtuvieron del informe interno del Instituto de Ingeniería (Jaime *et al.*, 1987). A continuación se describe cada una de estas variables.

Índice de plasticidad (IP): Indica la magnitud del intervalo de contenidos de agua en el cual el suelo posee consistencia plástica. Se interpreta como la diferencia numérica entre el límite líquido y el límite plástico y su valor está dado en porcentaje. Los valores típicos de las arcillas del valle de la ciudad de México, varían entre 250% y 350%; sin embargo, existen una gran cantidad de arcillas y arcillas limosas en el valle con índices de plasticidad menores. Esta propiedad es muy importante en cualquier análisis dinámico del suelo pues se ha demostrado la dependencia de los parámetros dinámicos con la plasticidad del suelo. La plasticidad no es una propiedad permanente sino circunstancial y dependiente de los ciclos de humedecimiento y secado (intenso) del suelo. Como límite superior (de las curvas módulo de rigidez *versus* deformación angular) se consideran las arcillas plásticas de la ciudad de México con $IP > 250\%$ y el límite inferior lo constituyen las arenas limpias con $IP = 0\%$; los rangos de IP considerados dentro del trabajo van desde 300% en las capas superiores, pasando por 150% para los potentes estratos de arcilla y terminando con 70% para el estrato arcilloso más profundo. Los suelos plásticos juegan un papel fundamental en las características de amplificación de la zona de lago del distrito federal (Romo y Seed, 1986); en igualdad de condiciones, al disminuir la plasticidad de la arcilla, decrece la intensidad de los movimientos sísmicos del terreno.

Contenido de agua (ω): Se define como la relación entre el peso del agua y el peso seco del suelo; se expresa usualmente como porcentaje (%), en el valle de la ciudad de México son normales contenidos mayores a 300%. El rango de valores en el sitio va

desde 322% para el estrato francamente arcilloso hasta valores de 72% para el estrato más profundo. Este parámetro al igual que el IP, tiene una influencia directa en los efectos de amplificación del depósito.

Peso volumétrico (γ): Parámetro que relaciona el peso total con el volumen total del suelo. Este parámetro da una idea de la composición del depósito, es decir, valores altos de peso volumétrico son típicos de materiales arenosos y limosos fuertemente empaquetados ($\geq 13 \text{ kN/m}^3$), valores entre 11 kN/m^3 y 13 kN/m^3 son típicos de materiales arcillosos; este parámetro se utiliza como clasificador del suelo en el sistema neuronal.

Velocidad de onda de corte (V_s): Se refiere a la velocidad con la que una onda de corte atraviesa un espesor de suelo con determinadas características y depende de la rigidez y densidad del material (Ec. 4.1). Así, al aumentar el peso volumétrico del suelo, se incrementa la velocidad V_s . Este parámetro resulta fundamental en todo diseño sísmico, ya que además de ser un parámetro que da idea de las propiedades físicas del material, permite la estimación preliminar del módulo de rigidez máximo (o a deformaciones muy pequeñas).

$$V_s = \sqrt{\frac{G^* g}{\gamma}} \quad \text{[Ec. 4.1]}$$

Donde,

G =Módulo de rigidez

g = Aceleración de la gravedad

γ = Peso volumétrico

En el sitio CDAO se tienen intervalos de velocidades de 40 a 90 m/s para los materiales arcillosos y valores entre 100 y 250 para las capas más duras. En el sitio de interés, la velocidad aumenta con la profundidad.

4.3 Ejemplo de Aplicación

4.3.1 Depósito: 1 Estrato

Se propone como punto de partida el análisis de un sistema compuesto por un estrato, ubicado entre las estaciones acelerográficas a 12 m y 30 m (Fig. 4.3). La condición de este estrato es ideal ya que la disposición de las estaciones permite la calibración del modelo neuronal (los registros acelerográficos en los límites superior e inferior del

estrato aseguran la influencia de las características de esos 18 m de material en la respuesta a 12m), a través de la evaluación de las variables que permiten al modelo neuronal reproducir dicha respuesta, y que en definitiva será vital para la construcción del modelo final que considera la columna de 60 m del depósito del sitio CDAO (Fig. 4.3). Con el propósito de clarificar la metodología propuesta, se desarrollará este ejercicio siguiendo a cabalidad los pasos que constituyen el modelo neuronal presentado en la figura 4.9.

Sistema y primera aproximación empírica

El depósito en estudio corresponde al estrato comprendido entre los 12 m y 30 m de profundidad en el sitio CDAO (Fig. 4.10); el cual se encuentra instrumentado en sus límites superior e inferior. Son conocidos, a partir de ensayos de campo y laboratorio, el índice de plasticidad, humedad natural, peso volumétrico, velocidad de onda de corte, módulo de rigidez y relación de amortiguamiento; vale la pena reiterar que este conjunto de valores son los empleados comúnmente en análisis sísmicos y están rodeados de incertidumbre debido a, por ejemplo, perturbaciones del espécimen de suelo durante el muestreo y/o errores durante la realización del ensaye.




Figura 4.10 Identificación estructural (IE): 1 estrato

La construcción del modelo neuronal para este sistema requiere determinar los eventos sísmicos registrados en dichas estaciones, particularmente aquellos que fuesen, para un mismo evento, registrados por ambas estaciones. No es restrictivo para dicha selección, el considerar sismos provenientes de una zona sismogénica particular. Los eventos contemplados para el análisis se muestran en la tabla 4.3.

Tabla 4.3 Eventos para el entrenamiento y prueba del modelo neuronal. Caso: 1 estrato.

Evento	Fecha (dd/mm/aa)	Mc	Prof (Km)	Coordenada del epicentro		Tipo
				Lat. N	Long. W	
1	24/10/93	6.50	<5	16.540	98.980	Prueba
2	23/02/94	5.00	5	17.820	97.300	Entrenamiento
3	23/05/94	5.60	23	18.030	100.570	Entrenamiento
4	10/12/94	6.3	20	18.020	101.560	Entrenamiento
5	09/10/95	6.5	5	18.740	104.67	Entrenamiento
6	11/01/97	Ms=6.9	16	17.910	103.040	Entrenamiento
7	15/06/99	5.4	69	18.180	97.510	Prueba
8	21/06/99	5.8	54	17.990	101.720	Entrenamiento

Identificación estructural

En esta etapa se construye la Red Neuronal de Identificación Estructural (RN-IE); y como en toda red neuronal supervisada, su construcción requiere de una etapa de entrenamiento y una etapa de prueba. Para reunir los datos necesarios para la etapa de entrenamiento, se tomaron los registros de la tabla 4.3 y se llevaron a cabo análisis unidimensionales (SHAKE, Schnabel *et al.*, 1972), considerando como entrada la historia de aceleraciones registrada a 30 m de profundidad y las propiedades (físicas y dinámicas) de suelo, y como salida la historia de aceleraciones a 12 m de profundidad. Las condiciones iniciales de dicho estrato (G_{max} , λ_{min} , IP y ρ) se obtuvieron del informe de Jaime *et al.* (1987) y las curvas de degradación del módulo de rigidez y del amortiguamiento utilizadas durante el análisis unidimensional con el programa SHAKE, son congruentes con las recomendadas para ese tipo de material descritas en el trabajo de Romo (1995). Esto permitió, según se mencionó, el entrenamiento de un funcional neuronal con el cual se construyó una red mecanicista que reproduce el modelo unidimensional considerado en el sistema de cómputo SHAKE, considerando los efectos no lineales del suelo.

Una vez alcanzada, durante la etapa de entrenamiento, una concordancia aceptable entre las respuestas calculadas con la RN (RN-IE) y el SHAKE (Correlación > 0.98), se puede tomar a este modelo como un equivalente de los métodos usados comúnmente en la ingeniería práctica. Por medio de las RNs, a este modelo unidimensional se le imprimen notables ventajas: a) interpretación simple, b) no presenta problemas de estabilidad numérica, c) no requiere tratamientos ni condiciones especiales en las señales empleadas y d) permite gran flexibilidad en la inclusión de parámetros que describen el ambiente sísmico que afecta el depósito. El resultado de esta red mecanicista se presenta en la figura 4.11, donde se indica cómo el modelo neuronal

alcanza la respuesta calculada por el SHAKE a 12 m de profundidad para dos eventos de entrenamiento cualquiera.

La topología neuronal RN-IE es: una capa oculta de 50 nodos y un nodo de salida que expresa la respuesta en un punto del depósito en términos del espectro de aceleraciones; como regla de aprendizaje se usa el algoritmo *Quickpropagation* (QP), como función de entrada se emplea *Dot product* (DP) y la *Sigmoide* como función de transferencia. Las variables empleadas dentro de este módulo neuronal se agrupan en: i) un espectro de respuesta en un punto conocido –excitación–, ii) una variable de posición y otra geométrica (Profundidad Z y espesor del estrato h), iii) una calificación promedio del valor del índice de plasticidad (IP) y peso volumétrico (γ) del material del mismo estrato de espesor h y iv) propiedades dinámicas G y λ promedio para la misma capa; como salida, el modelo arroja el espectro de respuesta en la frontera superior del estrato (12 m). Un esquema con las entradas y salidas del modelo neuronal se muestra en la figura 4.12.




Figura 4.11 Identificación estructural (IE): 1 estrato

El uso de espectros de respuesta como variables de entrada y salida se justifica debido a que es de uso común en la ingeniería práctica, puesto que permite de una forma fácil y rápida interpretar el contenido frecuencial del sismo, reflejándose de manera

inmediata el periodo donde ocurren las máximas aceleraciones lo que resulta útil para fines de diseño sísmico.




Figura 4.12 Identificación estructural neuronal: 1 estrato

Primera evaluación

Luego de realizado el entrenamiento de la red neuronal, se lleva a cabo una evaluación de la respuesta para un conjunto de datos de prueba (ver tabla 4.3). De este modo, la respuesta del modelo neuronal corresponde a la respuesta del modelo unidimensional a una profundidad específica, la cual se compara con la respuesta registrada en campo (punto de control) a la misma profundidad. De esta evaluación se estableció que la respuesta a partir del modelo unidimensional, considerando los parámetros dinámicos constantes con la frecuencia, no alcanza los niveles de aceleración espectral calculados del histograma a 12 m de profundidad.

Identificación paramétrica

Con el propósito de establecer una herramienta a través de la cual pueda realizarse la búsqueda de parámetros dinámicos que varíen con las frecuencias contenidas en la señal sísmica y que a su vez permita establecer respuestas más cercanas a la realidad, se construye la Red Neuronal de Identificación Paramétrica (RN-IP). Así cuando la excitación y la respuesta del sistema son variables conocidas, la tarea ahora se invierte (en el módulo RN-IE, se empleó la excitación y propiedades físicas del sistema) y se busca entonces determinar los parámetros (coeficientes funcionales) del sistema que relacionan las señales de entrada y salida. La construcción de la RN-IP se realizó a partir de 4 tipos de entradas: i) un espectro de respuesta conocido –excitación-, ii) un espectro de respuesta registrado en la frontera superior del estrato –respuesta- iii) una variable de posición Z y otra geométrica h y iv) una calificación promedio de los valores de IP y γ para el material comprendido en el espesor h ; como salidas se declaran los parámetros dinámicos G y λ . La misma información que sirvió para

generar la base de datos del funcional neuronal de la identificación estructural que se utilizó aquí para conseguir una red de 2 capas ocultas de 35 nodos cada una, siete variables de entrada y dos de salida que proporcionan las propiedades dinámicas del suelo a partir de registros acelerográficos (Fig. 4.13).

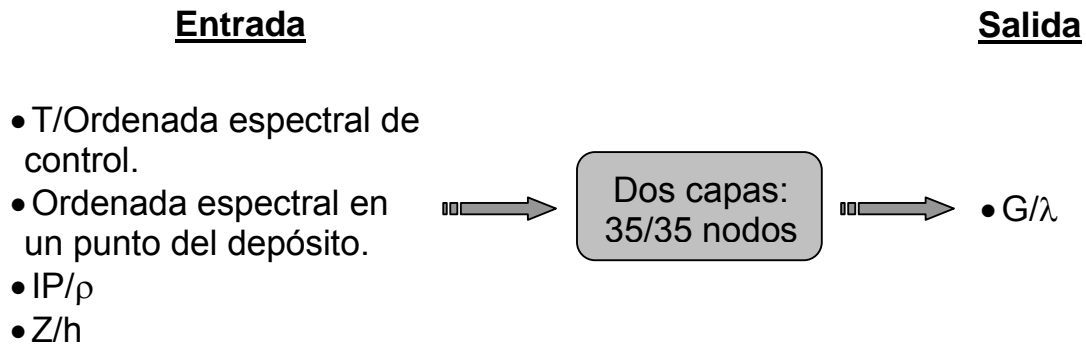


Figura 4.13 Identificación paramétrica neuronal

Segunda evaluación

Para calificar el comportamiento del Sistema de Identificación (SI), deben ponerse las redes de identificación estructural (RN-IE) y de identificación paramétrica (RN-IP) en funcionamiento directo, es decir, debe evaluarse la RN-IE con el par de valores G y λ , obtenidos con la RN-IP para cada patrón de un conjunto de prueba real. Con ello se entiende que el objetivo principal de establecer estos módulos neuronales bajo funcionamiento directo es el de plantear una metodología que permita la búsqueda del conjunto de valores G y λ con los cuales la RN-IE aproxime la respuesta medida del depósito considerado.

Se estableció con esta evaluación que la respuesta obtenida con la RN-IE considerando los parámetros dinámicos obtenidos con la RN-IP, no logra aún determinar correctamente la respuesta real registrada a 12 m de profundidad, a pesar de que los valores de los parámetros dinámicos usados en esta segunda evaluación corresponden a los valores que ajustan la mediciones reales del sistema, pero en definitiva, no corresponden a los valores que le son necesarios al modelo unidimensional para reproducir dicha respuesta.

Proceso de optimación

La RN-IE constituye un modelo no lineal que representa en este caso, el comportamiento de un modelo paramétrico unidimensional, así que para alcanzar la respuesta medida se explora la virtud de no linealidad de las redes neuronales, buscando, mediante un proceso de optimación, los valores G y λ que hacen que la RN-IE alcance la respuesta medida en el depósito de suelo. Cuando esto se haya logrado, se cierra el SI y al conjunto de parámetros dinámicos, los cuales resultan dependientes de la frecuencia, se les considera como los parámetros del sistema y al modelo neuronal resultante como el modelo matemático válido para la determinación de las respuestas para este sistema particular.

Los resultados de la red en funcionamiento directo para el caso de un estrato, se presentan en la figura 4.14. Esta figura muestra los resultados para los eventos de prueba (ver tabla 4.3), particularmente los espectro de respuesta de aceleraciones medido en campo (MEDIDO), el obtenido a través del sistema de identificación (NN-SHAKE) y el calculado a partir del modelo unidimensional propuesto en el programa SHAKE. Es claro, en ambos eventos, la notoria diferencia entre la respuesta calculada con el SHAKE y la respuesta medida en campo, y por otro lado, cómo el NN-SHAKE se aproxima bastante bien a la respuesta medida luego del proceso de optimación, alcanzando los niveles de aceleración en los períodos importantes del sistema. Este hecho resulta destacable puesto que, el modelo neuronal propuesto muestra que el efecto de la frecuencia sobre los parámetros dinámicos G y λ es potencialmente significativo (Fig. 4.15), lo cual es indispensable que se considere debidamente en los análisis de la respuesta de los depósitos de suelo. Para el sistema estudiado (1 estrato), la optimación para reducir el error entre la respuesta medida y calculada fue hecha en forma manual; para sistemas más complejos conviene establecer un procedimiento de optimación que agilice el procedimiento de búsqueda y minimización del error.

Al cruzar información de la figuras 4.14 y 4.15, se observan variaciones de los parámetros dinámicos entre 2.5 s y 3.5 s, períodos que coinciden con el periodo fundamental del sistema; este hecho haría imposible a un método unidimensional convencional, que no considere la variación del módulo de rigidez y del amortiguamiento con la frecuencia, alcanzar los niveles de respuesta reales del sitio.




Figura 4.14 Metodología de funcionamiento directo

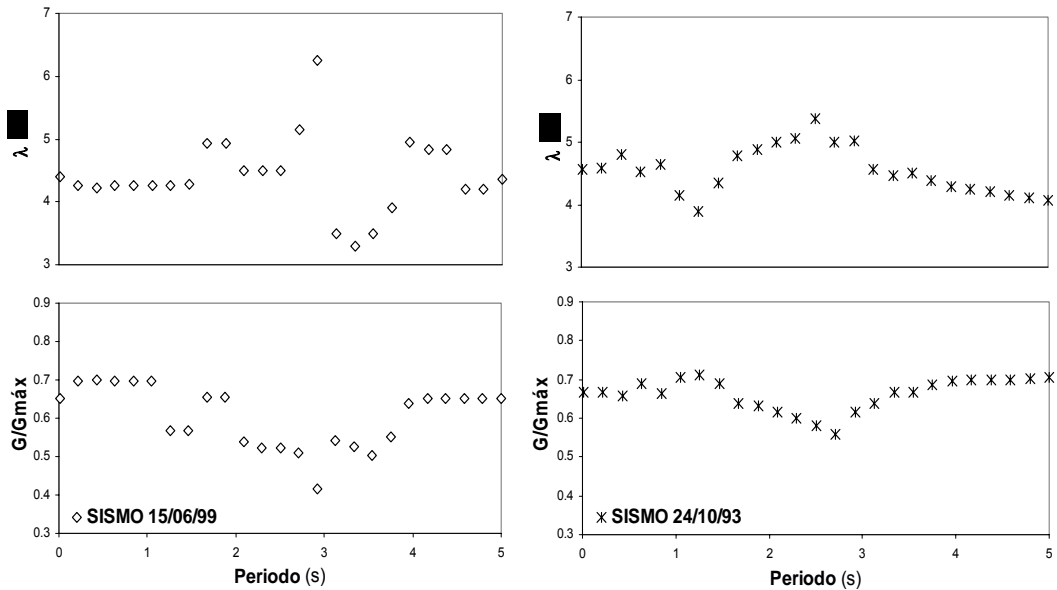


Figura 4.15 Comportamiento de los parámetros dinámicos con respecto a la frecuencia.

El resultado obtenido con este módulo neuronal, evidencia la importancia de la frecuencia en el análisis de respuesta sísmica, ya que para que se alcance la respuesta medida en campo son necesarios diferentes pares de valores G y λ , dependientes del nivel de frecuencia, particularmente en la zona correspondiente al periodo fundamental. Esta dependencia la avalan trabajos de Carvajal *et al.* (2002) y Sugito *et al.* (1994), por lo que tenerla en cuenta se apega sustancialmente a la naturaleza y física del fenómeno.

4.3.2 Depósito: CASO CDAO

Aprovechando las observaciones realizadas para el ejemplo anterior, se plantea el desarrollo del SI para el caso de la estratigrafía del sitio CDAO. Este caso será desarrollado considerando los pasos propuestos en la figura 4.9.

Sistema y primera aproximación empírica

La estratigrafía del depósito de CDAO se presenta en la figura 4.3. Este depósito se encuentra instrumentado con 4 estaciones acelerográficas a 0 m, 12 m, 30 m y 60 m de profundidad y se le reconocen 7 estratos bien definidos, cuyas geometrías, propiedades índice y características dinámicas se definieron a partir de ensayos de campo y laboratorio. Cuenta con 2 potentes estratos de arcilla, a los que se les atribuyen las características de notable amplificación registrada en la superficie del sitio y comunes a sitios ubicados en zona de lago. Es bien sabido que el gran contraste de impedancias entre los estratos profundos y superficiales, sumado a las particulares propiedades de esta arcilla, generó este efecto de amplificación singular (Romo y Seed, 1986).

Identificación Estructural

Para la construcción de la RN-IE, de igual manera que para el caso de un estrato, se llevaron a cabo numerosos análisis unidimensionales con SHAKE (Schnabel *et al.*, 1972), en los cuales se considera como excitación del depósito los eventos registrados en la estación CU y las propiedades de los materiales reportadas en el informe interno del Instituto de Ingeniería (Jaime *et al.*, 1987), así mismo fueron consideradas las curvas de degradación recomendadas para estos materiales en el trabajo de Romo (1995). A partir de estos análisis se obtienen las respuestas en las frontera superior de cada uno de los estratos, y con este conjunto de datos se realiza el entrenamiento de este módulo neuronal con el cual se aprovechan las características de no linealidad de

las redes neuronales para llevar a cabo la representación conceptual del modelo unidimensional. Los eventos considerados para el análisis unidimensional se presentan en la tabla 4.4.

Tabla 4.4 Eventos para las etapas de entrenamiento y prueba del modelo neuronal

Evento	Fecha dd/mm/aa	Profundida d del epicentro (km)	Coordenada del epicentro		Magnitud Mc	Tipo
			Lat. N	Long. W		
1	24/10/93	19	16.540	98.980	6.5	Prueba
2	29/07/93	43	17.380	100.650	5.0	Entrenamiento
3	05/08/93	32	17.080	98.530	5.1	Entrenamiento
4	04/07/94	31	14.830	97.290	5.9	Entrenamiento
5	12/10/95	- -	18.600	104.100	6.1	Entrenamiento
6	27/03/96	7	16.210	98.210	4.6	Entrenamiento
7	21/01/97	18	16.440	98.150	5.0	Entrenamiento
8	23/03/97	31	17.390	100.880	4.7	Entrenamiento
9	08/05/97	12	17.320	100.440	4.8	Entrenamiento
10	10/09/93	20	16.570	98.940	4.8	Entrenamiento
11	23/02/94	5	17.820	97.300	5.0	Entrenamiento
12	19/09/85	15	18.081	102.942	8.1	Prueba
13	14/09/95	22	16.310	98.880	7.3	Prueba
14	31/05/90	16	17.106	100.893	5.5	Entrenamiento
15	11/01/97	16	17.910	103.040	6.9	Prueba
16	23/05/94	23	18.030	100.570	5.6	Prueba
17	10/12/94	20	18.020	101.560	6.3	Entrenamiento
18	22/05/97	59	18.410	101.810	6.0	Prueba

Para la selección de los eventos usados en este análisis se tomó en cuenta el hecho de que hubieran sido registrados tanto en la estación Ciudad Universitaria (CU), como en cualquiera de las estaciones ubicadas en CDAO y se desestimó, de igual forma que para el caso de un estrato, el hecho que los sismos pertenecieran a una zona sismogénica particular (Fig. 4.16). Como se mencionó anteriormente, considerar para la selección que el evento sea registrado tanto en CU con en CDAO obedece a que por un lado se ha demostrado que las respuestas calculadas en sitios de la Zona de Lago, tomando como excitación los eventos registrados en CU, concuerdan aceptablemente con las mediciones de campo, y por otro lado con el que los resultados obtenidos en esta investigación sean comparables con los obtenidos con otros métodos analíticos.

La RN-IE presenta las siguientes características: Arquitectura multicapa *normal feed forward*, con 2 capas ocultas de 50 nodos cada una; *Quickpropagation* (QP) como regla de aprendizaje, *Dot Product* como función de entrada y Sigmoide como función de transferencia. Las entradas de este módulo neuronal se presentan en la figura 4.17,

donde se distinguen 4 grupos de datos: i) señal de excitación (espectro de respuesta de aceleraciones en un punto de control), ii) características geométricas del depósito (profundidad Z y espesor de los estratos h), iii) propiedades físicas (índice de plasticidad IP , contenido de agua ω , peso volumétrico γ y velocidad de onda de corte V_s) y iv) parámetros dinámicos declarados para esta clase de materiales naturales (módulo de rigidez G y relación de amortiguamiento λ).

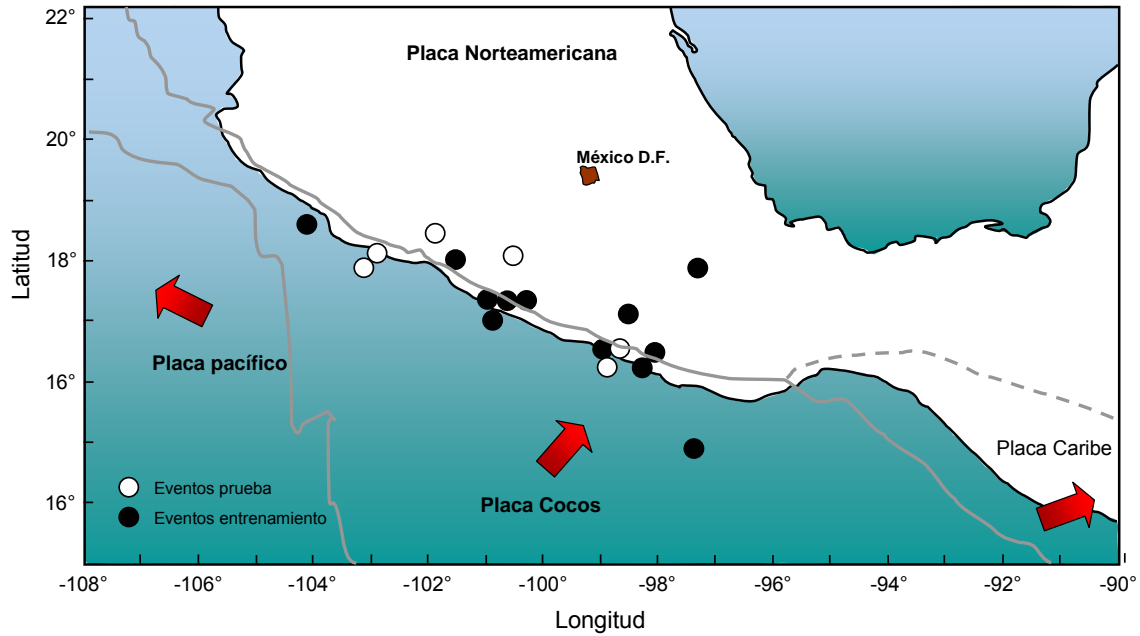


Figura 4.16 Origen de los eventos de entrenamiento y prueba dentro de la republica mexicana

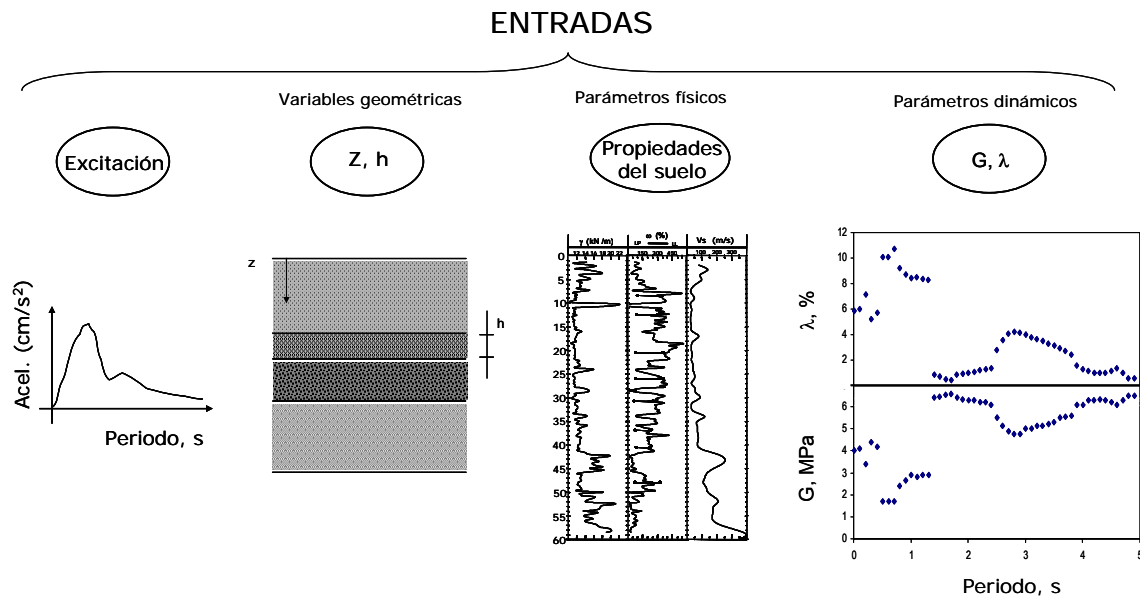


Figura 4.17 Parámetros de entrada para el módulo neuronal de identificación estructural

Cuando se han alcanzado, durante la etapa de entrenamiento, buenas aproximaciones entre los resultados del modelo unidimensional (SHAKE) y los alcanzados por el modelo neuronal (NN-SHAKE), se toma este último como una red mecanicista construida a partir de conceptos teóricos del modelo unidimensional. Los resultados de esta etapa se presentan en la figura 4.18, donde se observa cómo el módulo neuronal logra identificar las características del modelo unidimensional aproximándose correctamente a las respuestas obtenidas a partir de dicho modelo para diferentes profundidades. Un aspecto fundamental en esta red mecanicista es que está abierta para ser asociada con los resultados del módulo de identificación paramétrica, considerando la verdadera naturaleza dinámica de G y λ .

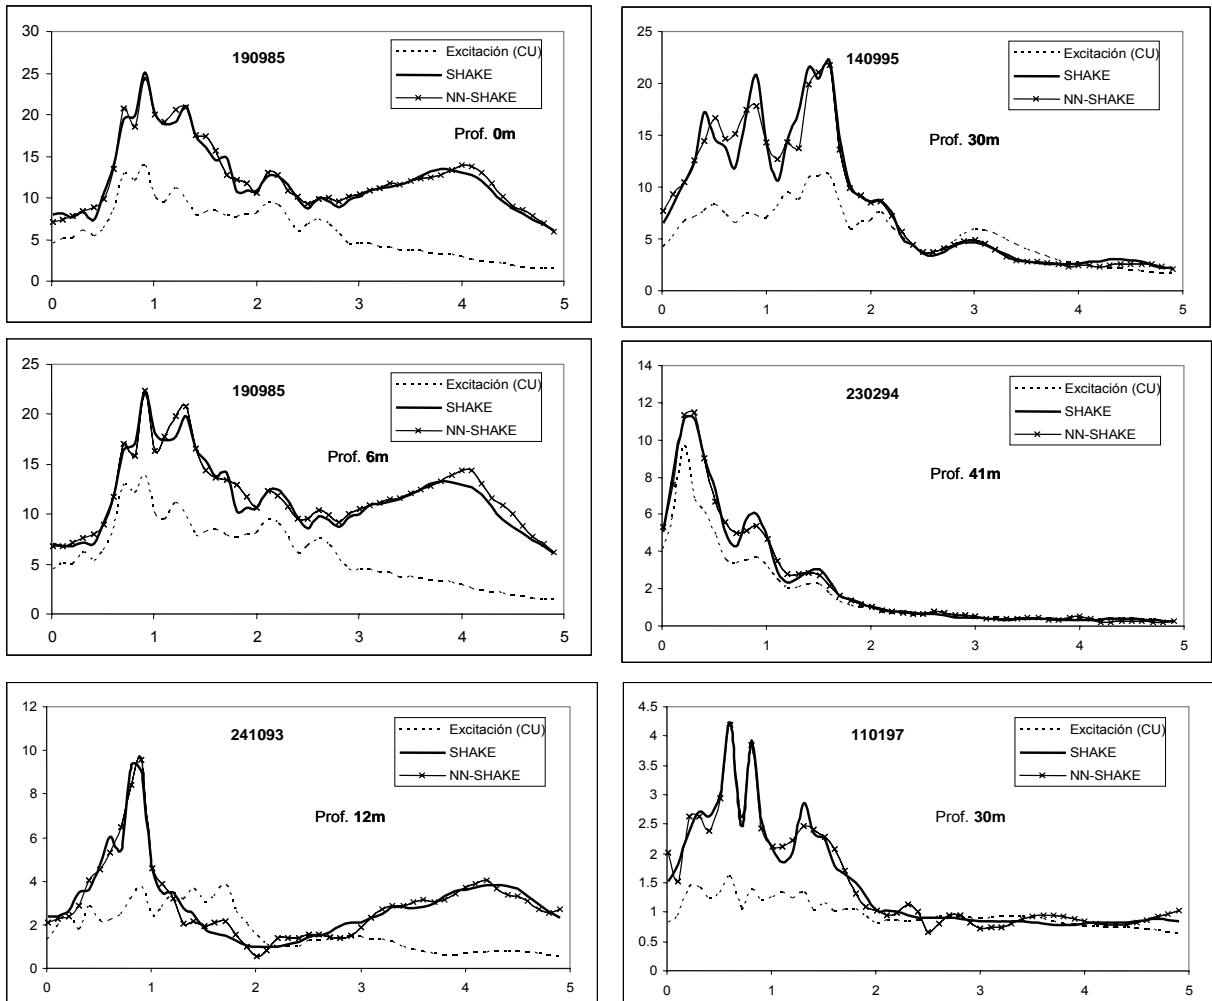


Figura 4.18 Comparación análisis unidimensional y respuesta del funcional neuronal producto de la red mecanicista.

Primera evaluación

Cuando se ha realizado el entrenamiento de la red neuronal, se lleva a cabo una evaluación de la respuesta para el conjunto de datos de prueba (ver tabla 4.4). Como se estableció para el ejemplo de un estrato, la respuesta de este modelo neuronal obtenido corresponde a la respuesta del modelo unidimensional a una profundidad específica, la cual se compara con la respuesta registrada en campo (punto de control) a la misma profundidad. De esta evaluación se estableció que la respuesta a partir del modelo unidimensional, considerando los parámetros dinámicos independientes de la frecuencia, no alcanza los niveles reales de aceleración espectral de los registros a las diferentes profundidades, así que siguiendo el esquema de la figura 4.9, se entra al proceso de optimación en el cual se procede con la búsqueda de nuevos valores de parámetros dinámicos con la construcción de un modelo neuronal que permite dicha búsqueda.

Identificación paramétrica

La Red Neuronal de Identificación Paramétrica (RN-IP) presenta características similares al modelo neuronal anterior: Arquitectura multicapa *normal feed forward*, con 2 capas ocultas de 50 nodos; *Quickpropagation* (QP) como regla de aprendizaje, *Dot Product* como función de entrada y *Sigmoide* como función de transferencia. La RN-IP tiene como objetivo establecer el valor de los parámetros dinámicos que ajusten las condiciones de entrada (excitación) y características de los materiales del depósito a la respuesta medida en el sitio; dichos parámetros se ajustan a condiciones reales y no a modelos preestablecidos.

La entrada de la RN-IP consta del siguiente grupo de entradas (Fig. 4.19): i) excitación del sistema (espectro de respuesta de aceleraciones registrado en un punto de control); ii) respuesta medida (espectro de respuesta de aceleraciones medido en uno o más de los estratos considerados); iii) variables geométricas (profundidad Z y espesor h) y iv) parámetros físicos (índice de plasticidad IP , contenido natural de agua ω , peso volumétrico γ y velocidad de onda de corte V_s) y como salida los valores de los parámetros dinámicos G y λ . Debe señalarse que para el entrenamiento de esta red se estableció como excitación el espectro de respuesta de aceleraciones en CU y como respuesta medida el espectro de respuesta calculado con el programa SHAKE en la frontera superior de los estratos considerados dentro del sistema. Plantear este

módulo neuronal tiene como propósito diseñar un modelo que otorgue flexibilidad al realizar la búsqueda de los parámetros a partir de variables conocidas.


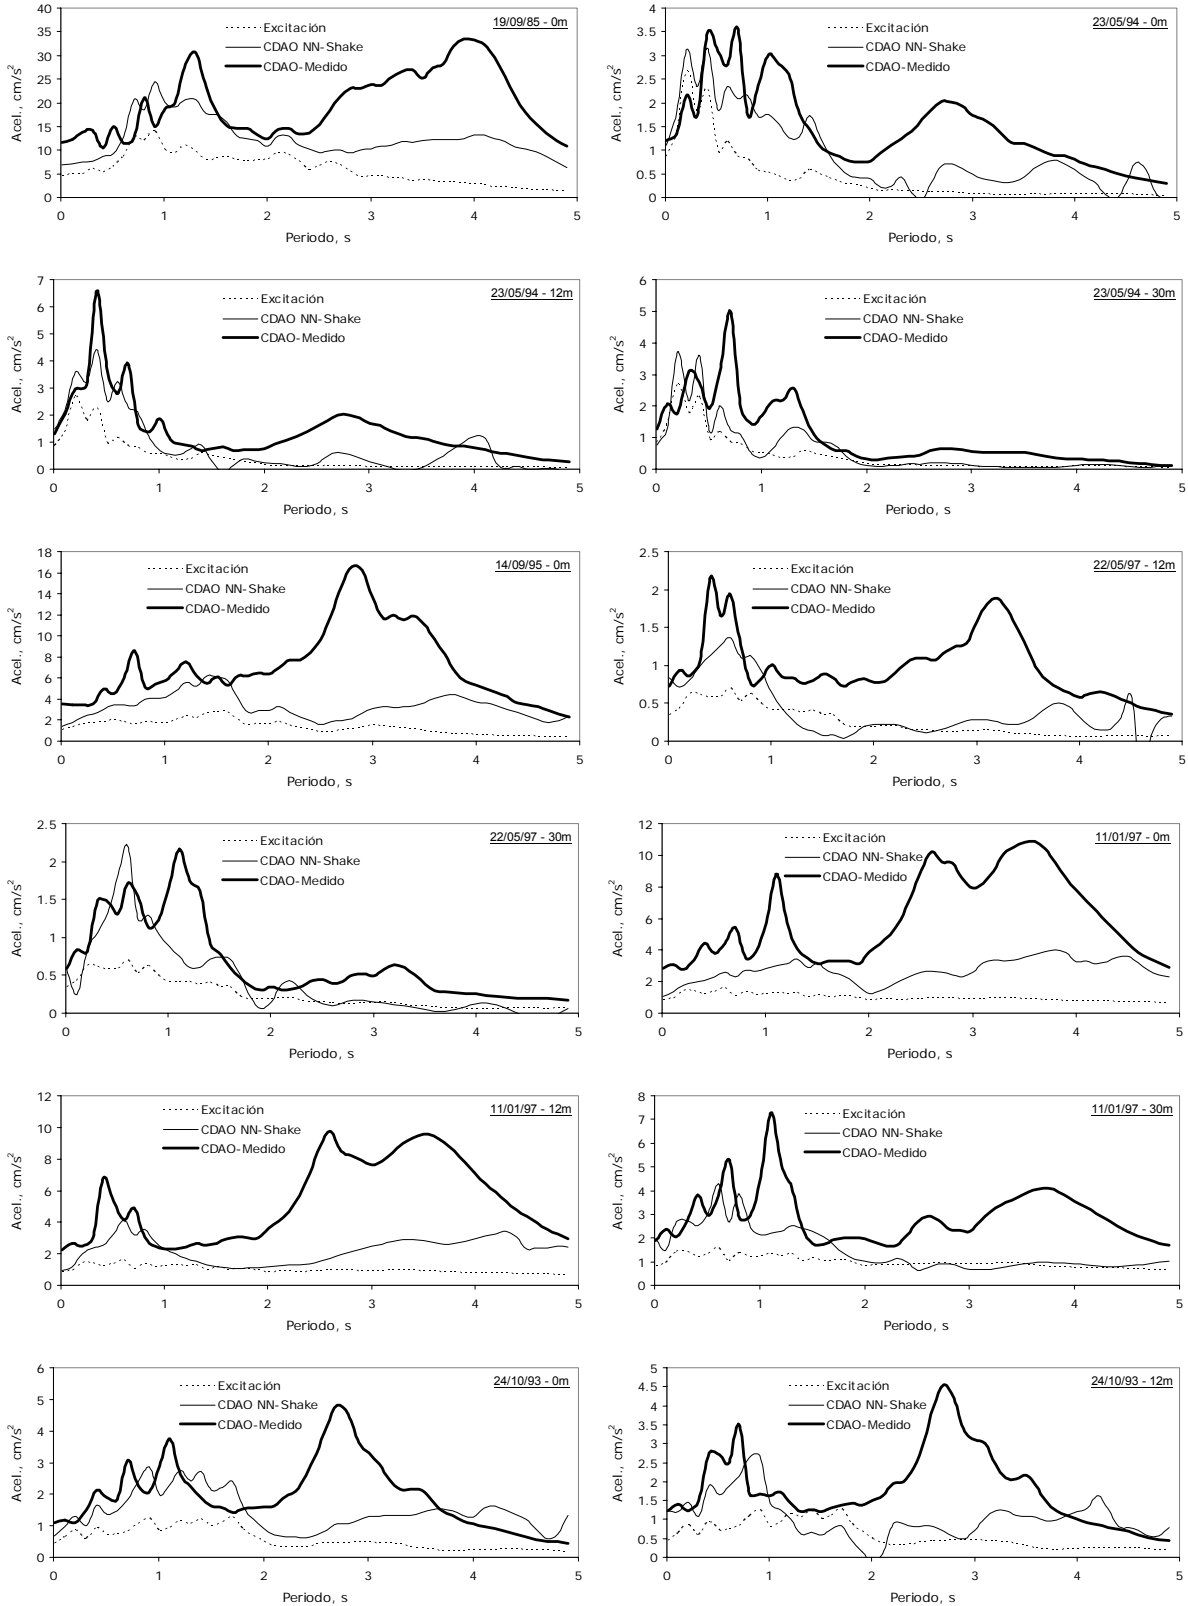


Figura 4.19 Parámetros de entrada para el módulo neuronal de identificación paramétrica

Los valores de los parámetros dinámicos obtenidos a partir de este modelo neuronal evidencian dos características fundamentales: i) los valores de los parámetros dinámicos varían con las frecuencias y ii) los valores de dichos parámetros dependen sustancialmente del contenido de energía en los diversos intervalos de frecuencia. Los valores de G disminuirán al aumentar la energía y λ aumentará consecuentemente.

Segunda evaluación

Cuando han sido construidas las redes neuronales RN-IE y RN-IP, se establece la operación de ambas en funcionamiento directo. Así, los parámetros dinámicos obtenidos para los eventos de prueba alimentan la RN-IE y se obtienen las respuestas presentadas en la figura 4.20. Aquí se observa que evaluando la respuesta con los parámetros dinámicos obtenidos con el RN-IP, no se logran alcanzar los niveles de aceleración espectral de las respuestas medidas, particularmente en la zona del periodo fundamental. Es decir, a pesar que los parámetros obtenidos con la RN-IP representan las condiciones del depósito (excitaciones y propiedades), estos parámetros deben ajustarse al concepto teórico (modelo unidimensional) bajo el cual fue construida esta red neuronal.






Figura 4.20 Respuesta del modelo neuronal de identificación estructural: primera evaluación.

Para sistemas complejos como el depósito propuesto (7 estratos), la modificación de los parámetros dinámicos para que se ajuste a la respuesta real en diferentes puntos del depósito es un proceso, que de hacerse punto a punto resulta dispendioso y poco eficiente; por ello el empleo de técnicas de búsqueda y optimización resultan un recurso valioso y una alternativa obligada.

Proceso de optimación

Establecer el conjunto de parámetros dinámicos necesarios para que se alcance el nivel de respuesta registrado en campo no es una tarea fácil, ya que deben existir dos condiciones fundamentales para que un modelo pueda hacerlo: la primera relacionada con la capacidad del modelo de interpretar las variaciones no lineales que tienen ambos parámetros con la deformación angular; y la otra con la adaptabilidad del modelo para que permita estudiar la variación de estos parámetros con las frecuencias contenidas dentro de la señal excitadora. Bajo esta perspectiva el SI propuesto es capaz de realizar lo anterior, adaptando los módulos neuronales (RN-IE y RN-IP) con un procedimiento de búsqueda y minimización a través de Algoritmos Genéticos (AG), lo que permite encontrar para cada valor de frecuencia el valor de la respuesta que se ajuste a las mediciones de respuesta del sitio.

Para aclarar este procedimiento en la figura 4.21 se presenta un sistema compuesto por 6 estratos, y del cual se conocen una excitación y su respectiva salida (respuesta medida), a esto se le toma como "condición natural". Por otro lado, si el comportamiento de dicho sistema puede reproducirse a partir de un modelo, en el cual teniendo la excitación pueda calcularse la respuesta del sistema (respuesta calculada) se tomará a esta como una "condición analítica".




Figura 4.21 Condiciones del sistema en estudio

De tal modo, se tendrá para el mismo sistema una respuesta medida (real) y una respuesta calculada (analítica) (Fig. 4.22), en todos los casos se busca que el modelo que intente predecir el comportamiento del suelo se ajuste lo más posible a la respuesta “real”, para que pueda ser tomado como el modelo óptimo para la estimación y estudio de las respuestas del sitio en estudio. Para los materiales del valle de la ciudad de México ha sido aceptado, por las características estratigráficas de los depósitos antes mencionadas, el modelo unidimensional para determinar la respuestas en diferentes puntos del valle, pero dicha respuesta está sujeta a fuertes hipótesis restrictivas, que no en todos los casos hace posible que dichas respuestas sean tan cercanas a las mediciones.




Figura 4.22 Respuesta del modelo neuronal de identificación estructural: 1 evaluación.

Ahora bien, el proceso de optimación tiene el objetivo de aproximar las respuestas medidas y calculadas modificando el valor de los parámetros de los cuales depende el modelo analítico, en este caso se habla de modificar los parámetros dinámicos del suelo en el cual está basada la estructura de la RN-IE. Así, para alcanzar la respuesta medida, deben encontrarse el conjunto de parámetros dinámicos para cada nivel de frecuencia, a los cuales se haya sometido el suelo para alcanzar los niveles de respuesta de un evento específico. El procedimiento mejorado del SI, incluyendo el proceso de optimación se muestra en la figura 4.9, pero una explicación particular del propósito de la optimación se presentará a continuación.

T	G	λ	Respuesta calculada	Respuesta Medida	Función de error (%)
0.01	13	2.1	1.8	3.9	20.1




Figura 4.23 Respuesta del modelo neuronal de identificación estructural: 1 evaluación.

Inicialmente, en la figura 4.23 se muestra para el periodo $T=0.01$ el conjunto de valores de G y λ obtenidos con la RN-IP y la respuesta calculada con la RN-IE para ese nivel de frecuencia. El valor de la respuesta calculada se compara con la respuesta medida a partir de una función de error (Ec. 4.2), que está obviamente en función de ambas respuestas. Conseguido lo anterior se inicia el procedimiento de optimación con el algoritmo genético, el cual propone un par de nuevos valores de G y λ , con los que se “recalcula” la respuesta con la RN-IE y se compara con la respuesta medida, de tal forma que disminuya el error entre las respuestas (Fig. 4.24). Este procedimiento se lleva a cabo hasta alcanzar un cierto criterio de error (+/- 5%) para todo los periodos del espectro de respuesta. En el caso CDAO, se puede realizar la optimación sobre

aqueellos estratos donde se ubiquen estaciones acelerográficas (0m, 12m, 30m y 60m) usando información monitoreada o bien, en los estratos donde no exista estación se realiza por medio de señales (espectros) predichos en dichos puntos.




Figura 4.24 Respuesta del modelo neuronal de identificación estructural: 1 evaluación.

$$\varepsilon(\omega) = \left[\frac{RC_{(\omega)} - RM_{(\omega)}}{RM_{(\omega)}} \right] \quad [\text{Ec. 4.2}]$$

Donde,

$\varepsilon(\omega)$: Función de error evaluada en cada nivel de frecuencia, expresada en %

$RC_{(\omega)}$: Respuesta calculada en cada nivel de frecuencia considerada

$RM_{(\omega)}$: Respuesta medida en cada nivel de frecuencia considerada

4.4 Resultados finales

Cuando el SI se encuentra listo, se procede con el cálculo para diferentes eventos de prueba según se presentan en las siguientes figuras:


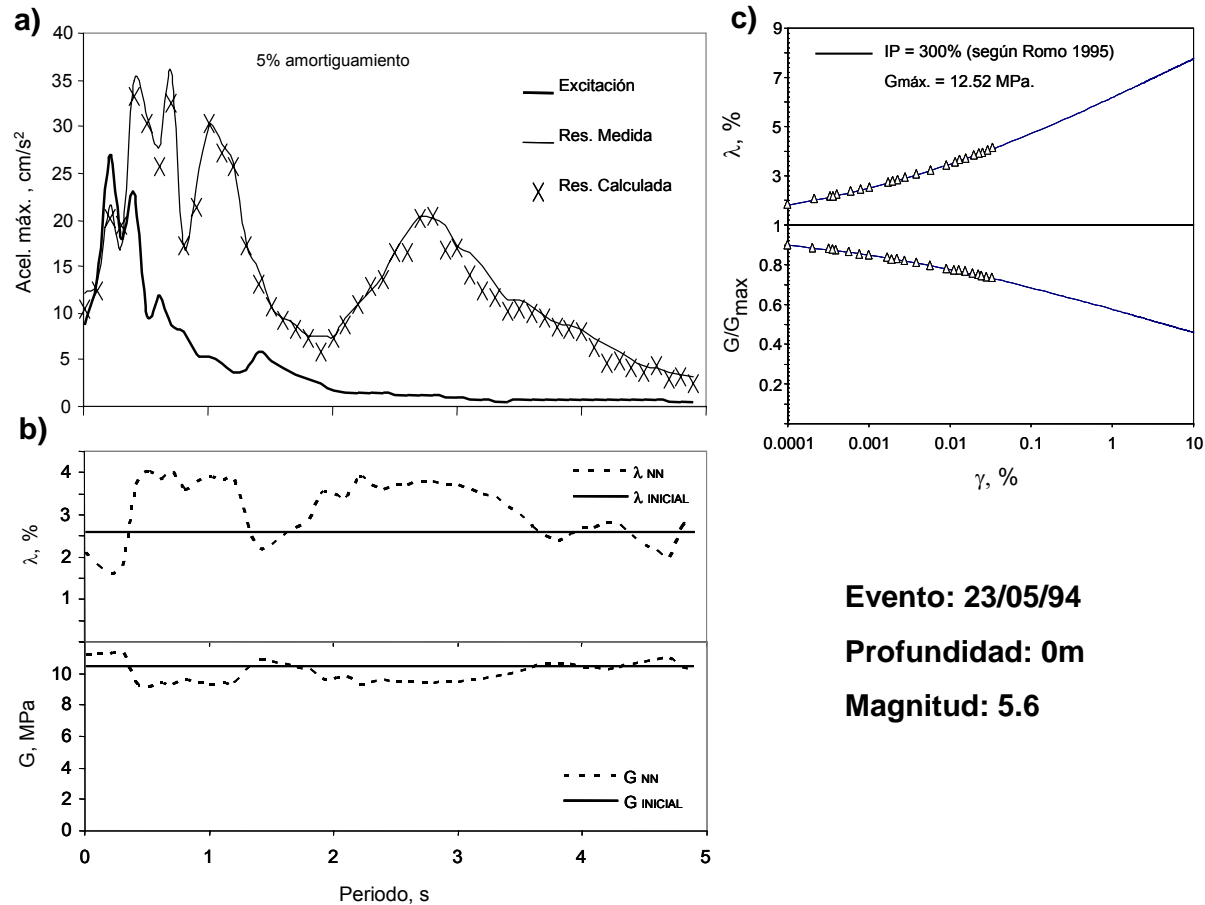


Figura 4.25 Resultados para el evento del 19 de septiembre de 1985: a) respuesta medida y respuesta calculada con el SI neuronal: las estimaciones SI-NG alcanzan los niveles de aceleración de la respuesta medida para este evento, excepto para los periodos comprendidos entre 3.7s y 4.5s, dentro del cual no se encontraron valores G , λ razonables para este tipo de materiales; b) variación de los parámetros G y λ con el contenido de frecuencia: se observa una variación importante entre los parámetros dinámicos iniciales (constantes para un modelo 1D) y los necesarios para alcanzar la respuesta medida a través del sistema de identificación neuronal. La movilización más importante


de estos parámetros, para este evento, inicia a partir de los 2.4 s que coincide con la zona del periodo fundamental del sistema, por debajo de dicho periodo los parámetros permanecen cercanos a los iniciales, excepto en 1.4 s donde se localiza el segundo periodo de vibración; c) movilización de los parámetros dinámicos con la deformación angular: se observa que los valores G/λ identificados sobrepasan el rango lineal. Particularmente en este evento, G y λ se movilizan con altas deformaciones para alcanzar la respuesta medida en sitio, considerando por supuesto, valores razonables de estos parámetros para estos materiales.



Evento: 23/05/94
Profundidad: 0m
Magnitud: 5.6

Figura 4.26 Respuesta para el evento del 23 de mayo de 1994: a) respuesta del depósito y respuesta calculada con el SI-NG: este evento, catalogado como de magnitud "baja", generó en superficie aceleraciones espectrales máximas en $T \approx 0.5 \text{ s}$. Las estimaciones del SI-NG alcanzan satisfactoriamente la respuesta a todos los niveles de frecuencia; b) variación de los parámetros G y λ con el contenido de frecuencia del sistema: se observa que estos

parámetros se alejan sustancialmente de los parámetros iniciales, específicamente donde se ubican los periodos fundamentales de vibración del sistema (0.5 s y 3 s); c) movilización de los parámetros dinámicos con la deformación angular: durante la incidencia de este evento, G y λ sobrepasan el rango lineal asociados a estos parámetros para deformaciones hasta de $10^{-1}\%$.



Evento: 23/05/94
Profundidad: 12m
Magnitud: 5.6

Figura 4.27 Respuesta para el evento del 23 de mayo de 1994 a 12m de profundidad: a) respuesta medida y respuesta calculada con el SI-NG: Se logra identificar la respuesta del sistema en todo su contenido de frecuencias, alcanzándose los niveles de aceleración en el periodo fundamental del sistema (0.5 s); b) variación de los parámetros G y λ con el contenido de frecuencia: considerando dependencia de los parámetros dinámicos con la frecuencia, se logran estimaciones muy cercanas a la respuesta medida, observándose que para ello dichos valores se separan

considerablemente de los valores iniciales, principalmente en las zonas de periodos fundamentales (0.5 s y 3 s); c) movilización de los parámetros dinámicos con la deformación angular: la variación de estos parámetros alcanza niveles de deformación mayores a $10^{-2}\%$, por encima del rango lineal, que permiten generar valores de respuesta muy congruentes con los medidos para este evento, y asociados al comportamiento típico identificado para la arcilla del Valle de México.

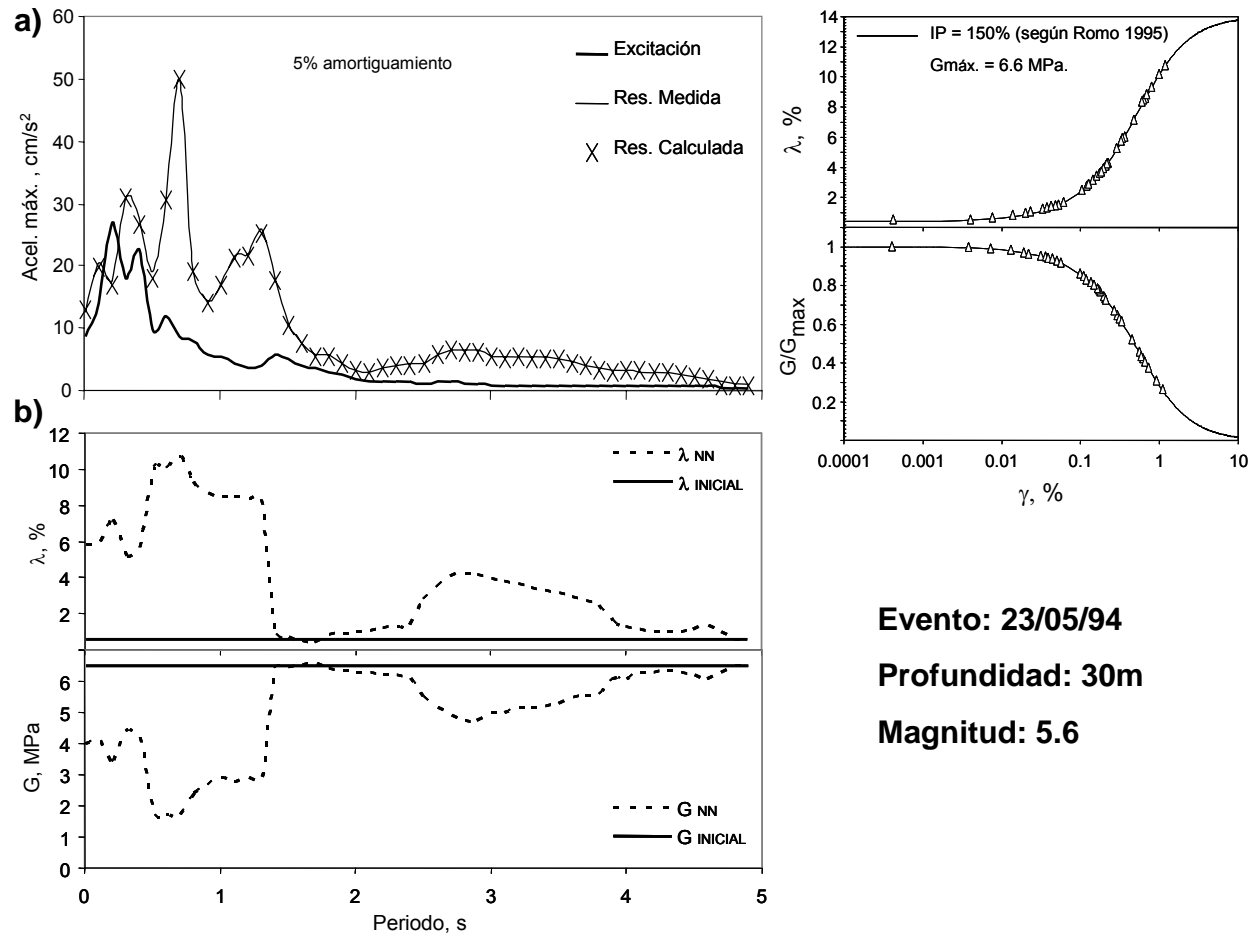


Figura 4.28 Respuesta para el evento del 23 de mayo de 1994 a 30m de profundidad: a) respuesta medida y respuesta calculada con el SI-NG: de igual forma que para la figura anterior (mismo evento, diferente profundidad), se observa la clara identificación de la respuesta medida para todo el contenido de frecuencia; b) variación de los parámetros G y λ con el contenido de frecuencia: se observa la marcada diferencia entre los parámetros dinámicos

iniciales y los obtenidos a partir del SI neuronal, en especial sobre la zona donde se ubica el periodo fundamental ($\approx 0.5s$) alcanzándose diferencias hasta de un 90%; c) movilización de los parámetros dinámicos con la deformación angular: a esta profundidad los parámetros se mueven claramente por encima del rango lineal hasta valores de deformación del 1%.




Figura 4.29 Respuesta para el evento del 14 de septiembre de 1995: a) respuesta medida y respuesta calculada con el SI-NG: este evento junto al del 19/09/85 son los eventos con mayores magnitudes registradas; para ambos casos el periodo fundamental se encuentra en los alrededores de los 3 s. El SI neuronal alcanza los niveles de aceleración medidos en el depósito para todo el contenido de frecuencias; b) variación de los parámetros G y λ con

el contenido de frecuencias: los parámetros dinámicos varían drásticamente, de manera particular, en la zona donde se encuentra el periodo fundamental del sistema (3 s); c) movilización de los parámetros dinámicos con la deformación angular: los parámetros se movilizan en todo el rango de deformación, por encima del rango lineal.

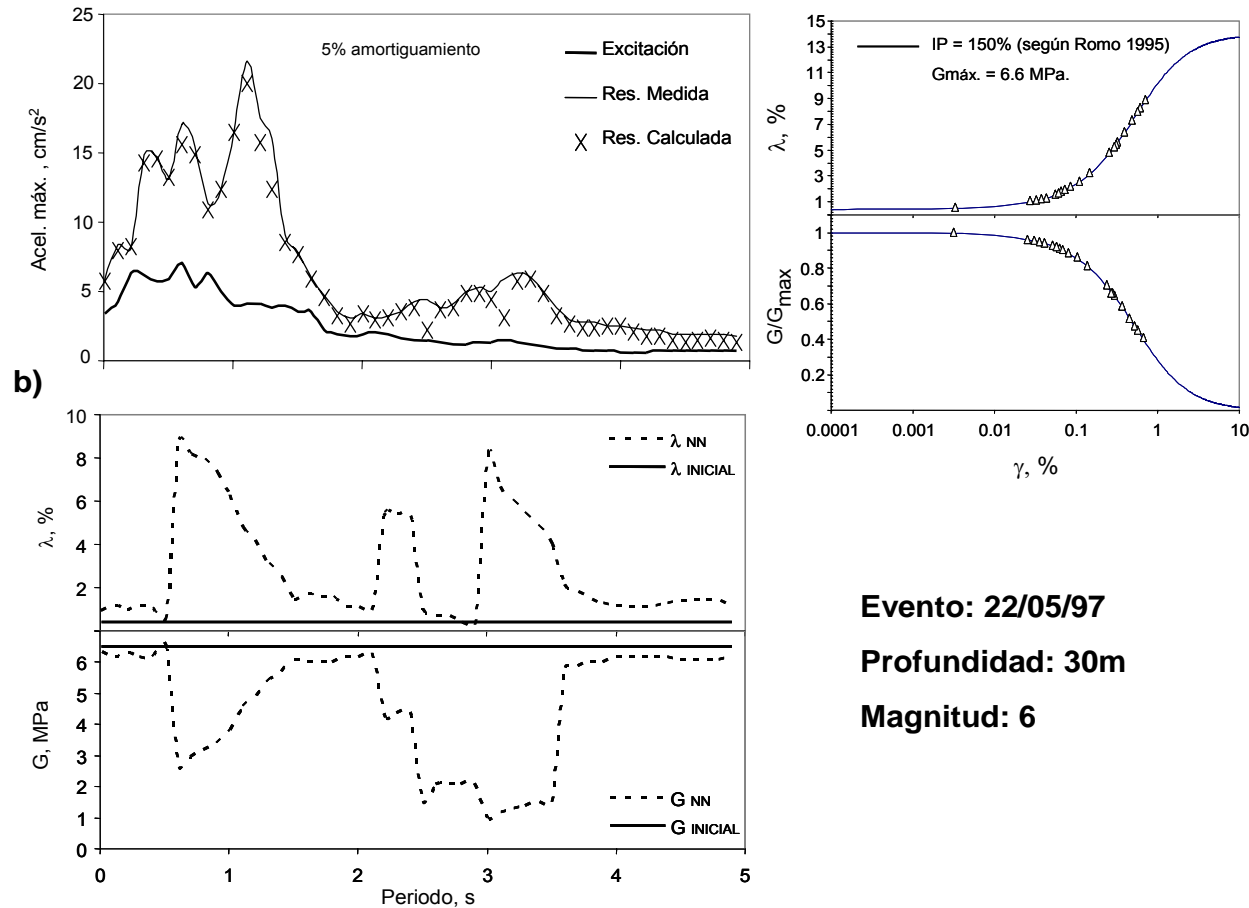


Figura 4.30 Respuesta para el evento del 22 de mayo de 1997 a 30 m de profundidad: a) respuesta medida y respuesta calculada con el SI-NG: este evento presenta la máxima amplitud espectral cercana a los 0.8 s, el SI logra estimar los niveles de la respuesta medida en todo el contenido de frecuencia; b) variación de los parámetros G y λ con el contenido de frecuencia: la manera en que se movilizan los parámetros dinámicos para lograr la respuesta

medida del sitio varía significativamente de los parámetros iniciales, presentándose mayores diferencias en la zona del periodo fundamental y periodos superiores a 2 s; c) movilización de los parámetros dinámicos con la deformación angular: los parámetros se movilizan en un amplio margen de deformación, principalmente sobre el rango no lineal del comportamiento.

De los resultados presentados en las figuras 4.25 a 4.30 se deduce que:

1. Los parámetros G y λ varía de acuerdo con la energía contenida en las diferentes frecuencias existentes en la excitación. Sólo considerando tal dependencia es posible reproducir los movimientos de terreno registrados en diversas profundidades en el sitio CDAO.
2. Se observa que los valores de los parámetros dinámicos no son valores únicos y se movilizan dependiendo de los efectos de la intensidad (nivel de deformación generado en la masa de suelo), la cual depende de la variación temporal del contenido de energía.
3. El depósito responde, de acuerdo con las características de cada sismo, variando el periodo en el que se desarrollan las respuestas máximas en términos espectrales de acuerdo a las condiciones naturales del sistema.
4. Las variaciones de G y λ con la frecuencia se vuelven más importantes hacia las zonas de máximas amplitudes; en todos los casos el SI-NG identifica la respuesta para todo el rango de periodos en el que el evento se considera significativo. Sin embargo, por las características particulares del evento de 1985, hay una zona (periodo entre 3.7 s y 4.5 s) donde no se definieron valores "razonables" de parámetros dinámicos para materiales arcillosos con los cuales se puede alcanzar la respuesta medida.
5. La movilización de los parámetros dinámicos con la deformación angular a partir de su dependencia con el índice de plasticidad, se realiza sobre esta curva considerando el comportamiento que impone la carga sísmica; describe las curvas de comportamiento obtenidas de ensayos de laboratorio y movilizándose con la deformación para cada frecuencia del sismo estudiado.

4.4.1 Consideraciones prácticas para la estimación de la respuesta sísmica

El problema fundamental en regiones bajo amenaza sísmica es la estimación (predicción) de la respuesta dinámica de depósitos de suelo estratificados. Con el sistema neuro-genético cerrado (modo de operación), y estableciéndose por un lado el modelo que reproduce el comportamiento dinámico del depósito y por otro lado los parámetros asociados a dicho comportamiento, el Sistema de Identificación Neuro-Genético (SI-NG) puede realizar la estimación de la respuesta del depósito ante

eventos particulares, usando vectores de G y λ (dependientes de la frecuencia) como los obtenidos para movimientos que conforman la base de información del SI-NG.

El proceso de estimación neuro-genética de la respuesta sísmica propuesta en este trabajo requiere de:

- 1) La determinación y categorización del evento sísmico de entrada.
- 2) Un vector de propiedades dinámicas dependientes de la frecuencia, de acuerdo con las propuestas por el SI-NG según los eventos sísmicos reconocidos en la generación del modelo. A partir de la información de eventos registrados en la estación CU y en la estación en superficie en el sitio CDAO, el conjunto de parámetros G y λ para cada grupo de severidad (Menores, Moderados, Severos y Muy Severos) se presenta como una propuesta "general" para que el diseñador seleccione un tipo de variación de acuerdo con la severidad o bien de manera flexible, presente la variación que a su juicio considere conveniente, particularmente en la zona que corresponde al periodo fundamental y al segundo periodo del sistema.

Ejemplo 1: Estimación neurogenética de la respuesta sísmica: Aplicación para movimiento de entrada (espectro de respuesta)

A partir de un evento sísmico registrado en el sitio CU y CDAO (09/10/95), donde no se conocen los parámetros dinámicos movilizados en el depósito de suelo blando, se realiza la estimación de la respuesta eligiendo los vectores de parámetros dinámicos a partir de los obtenidos de eventos con las mismas condiciones de severidad y frecuencia. Esto representa el funcionamiento del software SI-NG en modo de trabajo.

Con el mismo grado de severidad del evento 09/10/95 (clasificado como Moderado) existen dos eventos sísmicos a los cuales les fueron obtenidas sus propiedades dinámicas (23/05/94 y 09/10/95), entendiéndose que son valores de G y λ para cada nivel de frecuencia. Estos eventos fueron seleccionados como los candidatos para utilizar los vectores de G y λ por poseer las siguientes características:




Figura 4.31 Características de los eventos 23/05/94 y 14/09/95, entrada (CU) y salida medida en el deposito (CDAO).

Evento 23/05/94 (Fig. 4.31A):

Entrada CU: Alcanza la máxima aceleración espectral (30 cm/s^2) entre un periodo de 0.2 s y 0.5 s para luego descender bruscamente. No se presentan otros periodos con amplitudes importantes.

Salida CDAO: Según lo marcan las propiedades dinámicas obtenidas para este evento existen dos zonas donde se alcanzan amplitudes espectrales importantes: 0.4 s -1.2 s y 2.5 s -3 s. Puede notarse la profunda influencia de las características del suelo, generando amplificación en la respuesta, principalmente en el periodo correspondiente a los 3 s.

Por lo que:

Propiedades Dinámicas: Presentan dos zonas que cubren los periodos con amplitudes espectrales importantes en la respuesta del sistema de suelo para este evento: i) entre 0.4 s y 1.2 s y ii) entre 2 s y 3.5 s, donde los valores de G y λ son constantes entre dicho rango y alcanzan en promedio los mismos valores ($G \approx 10 \text{ MPa}$ y $\lambda \approx 14\%$).

Evento 14/09/95 (Fig. 4.31B):

Entrada CU: Su periodo fundamental se encuentra en 1.5 s pero existen amplitudes espectrales importantes en 0.5 s, 2 s y 3 s.

Salida CDAO: La máxima aceleración espectral se encuentra en los alrededores de 3 s, que coincide con la importante movilización de los parámetros dinámicos mencionados anteriormente. Destacan así mismo, aceleraciones espectrales próximas a 1 s. En este evento se hace aún más notorio el efecto de amplificación (efecto de sitio), alcanzando aceleraciones espectrales 10 veces mayores a las que se marcan para la señal de entrada, en especial para el periodo de 3 s.

Por lo que:

Propiedades Dinámicas: La movilización más importante de los parámetros dinámicos se encuentra entre los 2 s y 3.5 s, que son drásticamente diferentes de los valores de los parámetros en otros periodos y permanecen constantes para dicho rango ($G \approx 7 \text{ MPa}$ y $\lambda \approx 7\%$).

Comparando los parámetros dinámicos movilizados en ambos eventos pueden notarse 3 zonas (Fig. 4.32): *Zona I*: 0 s - 2 s ($G \approx 10MPa$ y $\lambda \approx 3\%$); *Zona II*: 2 s - 3.5 s (notoria diferencia entre la movilización de los parámetros entre un evento y otro) y *Zona III*: 3.5 s - 5 s ($G \approx 10MPa$ y $\lambda \approx 3\%$).




Figura 4.32 Comparación de los parámetros obtenidos por el sistema neuro-genético para los eventos 23/05/94 y 14/09/95.

Cuando se observa el evento 09/10/95 (evento ante el cual se pretende predecir la respuesta del sistema), puede identificarse que su forma espectral es similar a la del evento 14/09/95 (ver Fig. 4.31B y 4.31C); bajo este criterio puede esperarse que las condiciones de respuesta sean similares, por lo que una primera predicción podría considerar como los parámetros dinámicos los encontrados para este evento (14/09/95).

Por otro lado, las magnitudes de estos eventos sísmicos (23/05/94= 5.6; 09/10/95= 6.5 y 14/09/94 = 7.3), permiten asociar la idea que la estimación realizada con los valores G y λ movilizados por el evento 14/09/95 (cota máxima) generará una respuesta que posiblemente sobrestime la respuesta del depósito para el evento 09/10/95, principalmente en lo que se refiere al periodo fundamental (Fig. 4.33). Por el contrario, si se usan los valores G y λ obtenidos para el evento 23/05/94 de magnitud inferior, marcarían la cota mínima de amplitudes asociadas a esas características de frecuencia.




Figura 4.33 Predicción de la respuesta según la condiciones de entrada del evento 09/10/95 a partir de los parámetros dinámicos obtenidos para el evento 14/09/95 y 23/05/94 y comparación con la respuesta medida en el depósito para dicho evento.

Al analizar la figura 4.33, donde se muestran las respuestas con los vectores $G-\lambda$ del evento cota máxima y cota mínima; además de la respuesta medida (objetivo de este análisis), se observa que el sistema tiene un muy buen comportamiento sobre los valores de amplitud y de periodos que identifica en la respuesta, además de la excelente congruencia entre lo evaluado y lo medido, que en definitiva comprueba la calidad de la predicción que puede desarrollarse con esta metodología neuro-genética. Para fines de diseño puede proponerse una envolvente que cubra los comportamientos máximos de las respuestas cota máxima y cota mínima y establecer características apegadas a la realidad del comportamiento particular del depósito.

A partir de todas estas observaciones, es notorio que este depósito tiene una marcada respuesta alrededor de los 3 s, así que las estimaciones en este sitio deben hacerse con parámetros dinámicos que reconozcan esta diferencia respecto a los otros periodos. Un efecto que no debe ser despreciado aparece en periodos próximos a 1 s (Fig. 4.32); ya que existe una movilización de parámetros dinámicos importante en este nivel de frecuencia y cuyo nivel de aceleración pueden ser enmascarado por la herramienta con la que se analiza la señal sísmica, pero que el sistema neuro-genético logra identificar (Solís-Estrella *et al.*, 2005). Una predicción que considere los aspectos generales de la respuesta del depósito, contribuye de manera más racional en la toma de decisiones para efectos de prevención, mitigación y evaluación de amenaza sísmica.

CAPITULO 5:

Conclusiones

1. Los complejos procesos geológicos formadores del suelo le otorgan a éste prominentes características de aleatoriedad que hacen que en su estudio indiscutiblemente se considere: i) que como material natural no debería ser analizado usando propiedades que permanezcan constantes en grandes masa de suelo y ii) que dichas propiedades, resultado de la acción sísmica, sean dependientes de las variables tiempo, frecuencia e intensidad. Bajo esta perspectiva, su estudio es complejo y por ello los modelos convencionales que analizan su comportamiento son muy limitados debido a que están cubiertos de hipótesis restrictivas que pretenden en términos prácticos, disminuir la complejidad a la vez que sesgan la interpretación y la calidad de los resultados.
2. El modelado de sistemas naturales puede realizarse aprovechando las ventajas que ofrecen, por una parte las técnicas de Cómputo Aproximado (CA) para generar conocimiento sobre el comportamiento de los sistemas, desarrollando la reconstrucción del fenómeno a través del criterio de los expertos y las leyes físicas involucradas y, por otro lado, los conceptos derivados de la Teoría de Control para expresar estos fenómenos como sistemas/parámetros identificables a partir de observaciones y monitoreo.

3. Se reconoce a partir de los resultados presentados que, los parámetros con los cuales se describe el comportamiento dinámico de un depósito de suelo son dependientes de la frecuencia. Cuando una masa de suelo es excitada, ésta moviliza su capacidad de soportar el corte y disipar energía, para cada nivel de frecuencia, desarrollando respuestas particulares; así que cualquier técnica de modelado que no considere las características “naturales” de la masa de suelo no será capaz de reproducir las características de los movimiento sísmicos registrados en campo. Es importante señalar que cada evento sísmico posee características únicas desde su generación, propagación a través de la corteza hasta su registro en el sitio de interés, con lo cual los valores de los parámetros dinámicos obtenidos en esta investigación contienen información sobre diferentes mecanismos de falla y patrón de transmisión de ondas, lo que permite concluir que el modelo de predicción es capaz de generalizar sobre respuestas producto de diversas fuentes sísmicas.

4. Un análisis de respuesta de sitio requiere de los siguientes procedimientos (Fig. 5.1): 1) caracterización dinámica de sitio en la que se establece información concerniente al comportamiento dinámico del sitio (perfiles de velocidad de onda de corte, curvas de degradación de parámetros dinámicos, espectro de diseño); 2) selección del movimiento de entrada (roca), en la que se determinan las características sísmicas (contenido espectral) del evento con el que va a ser excitado el sistema, generalmente se toma como punto de control la estación CU; 3) con los pasos anteriores y seleccionando un modelo de comportamiento dinámico se realiza un análisis de la respuesta en el sitio y finalmente, 4) se propone el espectro de diseño y se realizan evaluaciones de riesgo sísmico. La metodología propuesta en esta investigación es lo suficientemente flexible para realizar este proceso, otorgando al diseñador la posibilidad de verter su experiencia y capacidad teórica, que finalmente redundan en una mejor proyección del diseño y a su vez en la seguridad de las obras civiles y protección de vidas humanas.



Figura 5.1 Etapas para la determinación de la respuesta de sitio

5. Los modelos tradicionalmente usados para la estimación de la respuesta en el Distrito Federal se basan en: "funciones de transferencia" (SHAKE, Schnabel, 1972) y "relaciones espectrales" (Programa "Z", Ordaz *et al.*, 1996). Ambas aproximaciones lineales y cuasi-lineales de las relaciones entrada→salida, discrepan de las condiciones "reales" de respuesta del sitio en estudio. El sistema SI-NG propuesto en esta investigación, con la consideración de no linealidad dentro del modelo matemático y los parámetros movilizados estima la respuesta ante eventos sísmicos con buena aproximación. Un ejemplo de aplicación de estas metodologías se presenta en la figura 5.2 para un evento no considerado en la construcción del modelo SI-NG.




Figura 5.2 Evaluación de las respuesta de sitio con diferentes metodologías para CDAO

ANEXO A

Fundamentos teóricos

A.1 Ondas sísmicas

Sismos, vulcanismo y formación de montañas son algunos de los fenómenos geológicos que ocurren debido al movimiento de las placas tectónicas. En el interior de la corteza terrestre, estrictamente en el manto, se originan corrientes de convección que son el motor del movimiento relativo entre placas tectónicas a lo largo de los grandes y complejos sistemas de falla, debido al desequilibrio termodinámico que existe entre su frontera inferior y superior (figura 1).




Figura 1 Proceso de Convección (Modificada, Kramer 1996).

En las zonas de falla se acumula gradualmente energía, que se almacena hasta que se rebasa la resistencia de la roca, momento donde se produce su liberación intempestiva que se irradia por medio de ondas que se propagan en todas direcciones. Estas ondas son conocidas como ondas sísmicas y son las causantes de la mayor parte de los movimientos (sismos) que se perciben en la superficie terrestre. Cuando estos movimientos alcanzan niveles tan altos, que causan daños catastróficos en superficie (infraestructura, vidas humanas, etc.), toman el nombre de terremotos y sus devastadores efectos han sido extensamente reconocidos (Tabla A.1).

Las ondas sísmicas sufren, durante su propagación, cambios en sus características originales, causados por la heterogeneidad en los materiales por los que atraviesan (discontinuidades geológicas, anisotropía de los materiales, entre otros), produciéndose los fenómenos de refracción, reflexión, difracción, dispersión, atenuación y amplificación. De acuerdo con esto, el arribo de las ondas en superficie se produce de forma errática y sus características difieren de la onda original como resultado de la constitución de los materiales, geomorfología de la zona de incidencia y trayectoria de propagación.




Figura 2 Tipos de ondas de cuerpo

Existen básicamente dos tipos de ondas: ondas de cuerpo y ondas superficiales; las ondas de cuerpo por su parte, constituyen las ondas más importantes dentro del análisis del presente estudio ya que se establece como hipótesis que dichas ondas rigen el comportamiento de los materiales que conforman el depósito de suelo. Están divididas en ondas P y ondas S; Las ondas P (Primarias o longitudinales) reciben su nombre por ser las primeras en ser registradas por los acelerógrafos y su principal característica es que

ocasionan vibraciones dilataciónales en la dirección de su propagación. Las ondas S (secundarias, transversales o equivolúmetricas) son las segundas en arribar y ocasionan vibraciones perpendiculares a la dirección de propagación (figura 2).

El movimiento de las ondas S es de dos componentes; una componente horizontal (SH) y una componente vertical (SV), contribuyendo a la generación de esfuerzos cortantes durante su propagación, lo que podría provocar según la magnitud del sismo, deformaciones permanentes en el material (figura 3), y cambios en las propiedades dinámicas del mismo.



Figura 3 Deformación permanente de una vía férrea ocurrida en México durante el sismo de 1985

A.1.2 Sismicidad en México

México se encuentra en una zona de alta sismicidad, debido principalmente a que las placas de Cocos y de Riviera, que se encuentra al sur y suroeste de México, cubriendo los estados de Chiapas, Oaxaca, Guerrero, Michoacán, Colima y Jalisco subducen a la placa Norteamérica con velocidades según se muestran en la figura 4.



Figura 4 Distribución y desplazamiento de las placas tectónicas en la costa occidental de México (Alcocer et al., 2003)

A.2 Teoría del modelo viscoelástico

Este modelo resulta de la necesidad de proponer un modelo con el cual se pueda establecer o predecir el comportamiento en un rango de deformación por encima del comportamiento lineal del suelo (figura 5).

Deformación al cortante	10^{-6}	10^{-5}	10^{-4}	10^{-3}	10^{-2}	10^{-1}
	Deformación pequeña	Deformación Media		Deformación Grande	Deformación a la falla	
Elástico	[Barra de deformación]					
Elasto-plástico		[Barra de deformación]				
Falla					[Barra de deformación]	
Efecto de carga repetida				[Barra de deformación]		
Efecto de velocidad de carga				[Barra de deformación]		
Modelo	Modelo Elástico Lineal		Modelo visco-elástico		Modelo dibujando el tipo de historia de carga	
Método para el análisis de la respuesta	Método Lineal		Método lineal equivalente		Método de integración paso a paso	


Figura 5 Rango de deformaciones donde son usados cada uno de los modelos que representan el comportamiento del suelo (Ishihara, 1996)

A.2.2 Modelo constitutivo Kelvin-Voigt

Este modelo en particular permite estudiar las deformaciones permanentes que sufre el suelo a través del tiempo (por ejemplo las debidas a la consolidación) considerando una

componente viscosa lineal. El modelo Kelvin-Voigt ha sido extensamente usado en geotecnia pues reproduce adecuadamente el comportamiento del suelo bajo cargas dinámicas, al contemplar la disipación de energía elástica del suelo cuando este se encuentra sometido a una excitación.

Este modelo (figura 6) esta conformado por un elemento que representa las condiciones elásticas (resorte) y un elemento que representa la capacidad de disipación de energía del sistema a través de una relación de proporcionalidad directa entre el esfuerzo aplicado y la velocidad de deformación por medio de un pistón que se mueve dentro de un cilindro lleno de liquido perfecto, es decir incompresible y de viscosidad lineal (amortiguador); el esfuerzo aplicado se distribuye en ambos elementos, buscando que las deformaciones sean las mismas en cualquier tiempo para ambos elementos.



a) Simil del comportamiento de un estrato de espesor Z, por medio del modelo Kelvin-Voigt

b) Análisis de la deformación angular en un elemento diferencial

Figura 6 Modelo Kelvin-Voigt

De acuerdo a la figura 6, la relación esfuerzo cortante-deformación angular a partir de la consideración de un modelo Kelvin-Voigt se puede expresar de la siguiente forma:

$$\tau_{(t)} = G\gamma_{(t)} + \eta \frac{\partial \gamma}{\partial t} \tag{A-1}$$

Donde:

τ : Esfuerzo cortante [Pa]

G : Modulo de rigidez, [MPa]

η : Coeficiente de viscosidad, [Pa*s]

$\gamma = \frac{\partial u}{\partial t}$: Deformación angular, [Adimensional ó %]

A.2.3 Modelo lineal equivalente

Este modelo básicamente modifica el modelo Kelvin-Voigt para analizar el comportamiento no lineal del suelo cuando se alcanzan niveles de deformación de 10^{-3} o 10^{-4} (Ishihara, 1996); por medio de los siguientes principios:

- Amortiguamiento viscoso inversamente proporcional a la frecuencia (para que la pérdida de energía por ciclo sea independiente de la frecuencia del sistema).
- La pendiente de la línea que conecta los extremos del ciclo histerético, es el modulo de rigidez secante (aceptado como el valor que representa el modulo de rigidez del material).

A partir de una excitación armónica del modelo Kelvin-Voigt se producen una deformación armónica, expresada en la ecuación 2.

$$\gamma_{(t)} = \gamma_o \text{Sen}(\omega t) \quad \text{[A-2]}$$

Donde, γ_o es la amplitud de la deformación angular y ω es la frecuencia circular (rad/s); ahora bien, si se remplace la ecuación 2 en la ecuación 1, se obtiene la ecuación 3, cuya grafica muestra un ciclo completo de forma elíptica (figura 7a)

$$\tau_{(t)} = G\gamma_o \text{Sen}(\omega t) + \omega\eta\gamma_o \text{Cos}(\omega t) \quad \text{[A-3]}$$

Este ciclo presenta dos características; la primera se refiere a la pendiente de la elipse, la cual es interpretada como el modulo de rigidez por ciclo que varia con el nivel de deformación en una prueba dinámica.

La segunda característica se refiere al ancho de la elipse, de donde se puede interpretar la capacidad que tiene el material para disipar energía. Es importante la determinación de estas dos características pues de ahí derivan los parámetros que suministran información acerca del comportamiento dinámico del suelo.

En el modelo lineal equivalente se usa un módulo de rigidez secante (G_{sec}) según se muestra en la figura 7a. Este módulo secante se puede obtener a partir de la siguiente expresión:

$$G_{\text{sec}} = \frac{\tau_s}{\gamma_s} \quad \text{[A-4]}$$

El otro de los parámetros dinámicos manifiesta la capacidad de disipación de energía que tiene el sistema, el cual se resume en un concepto llamado relación de amortiguamiento (β), válida cuando la frecuencia de excitación es la frecuencia natural del material

$$\beta = \frac{1}{4\pi} \frac{\Delta W}{W} \quad \text{[A-5]}$$

Donde,

ΔW = Energía elástica disipada en un ciclo

W = Energía almacenada en un ciclo

La energía disipada en un ciclo es representada por el área de la elipse, según la siguiente expresión (figura 11b):

$$\Delta W = \text{Area elipse} = \pi ab \quad \text{[A-6]}$$

Donde,

a : Longitud del radio menor

b : Longitud del radio mayor

ΔW : Energía disipada en un ciclo

De la figura 11b se observa que la longitud de b es igual a γ_o ; el punto a corresponde a un valor de deformación igual a cero ($\gamma = 0$) de tal forma que la ecuación 2 queda expresada según se muestra a continuación:

$$0 = \gamma_o \text{Sen}(\omega t)$$

Dicha igualdad se cumple cuando $\omega t = \pi$ y usando esto en la ecuación 3 se tiene que:

$$\tau = G\gamma_o \text{Sen}(\pi) + \omega\eta\gamma_o \text{Cos}(\pi)$$

$$\left| \tau_{(\gamma=0)} \right| = \omega \eta \gamma_o$$

De tal suerte que la energía elástica disipada durante un ciclo esta dada por la siguiente relación:

$$\Delta W = \pi \omega \eta \gamma_o^2 \quad \text{[A-7]}$$

La máxima energía almacenada (W), corresponde al trabajo realizado por la componente elástica en el primer cuarto de ciclo (figura 11b), representada por el área del triangulo formado, quedando la siguiente expresión:

$$W = \frac{1}{2} G \gamma_o^2 \quad \text{[A-8]}$$

Al remplazar las ecuaciones 7 y 8 en la ecuación 5, se obtiene una definición de la relación de amortiguamiento (ecuación 9) en función de la frecuencia y de las constantes viscoelásticas fundamentales del modelo kelvin Voigt, que permite independizar el esfuerzo cortante de la frecuencia que es uno de los principios que cumple este modelo.}

$$\beta = \frac{\omega \eta}{2G} \longrightarrow \eta = \frac{2G\beta}{\omega} \quad \text{[A-9]}$$

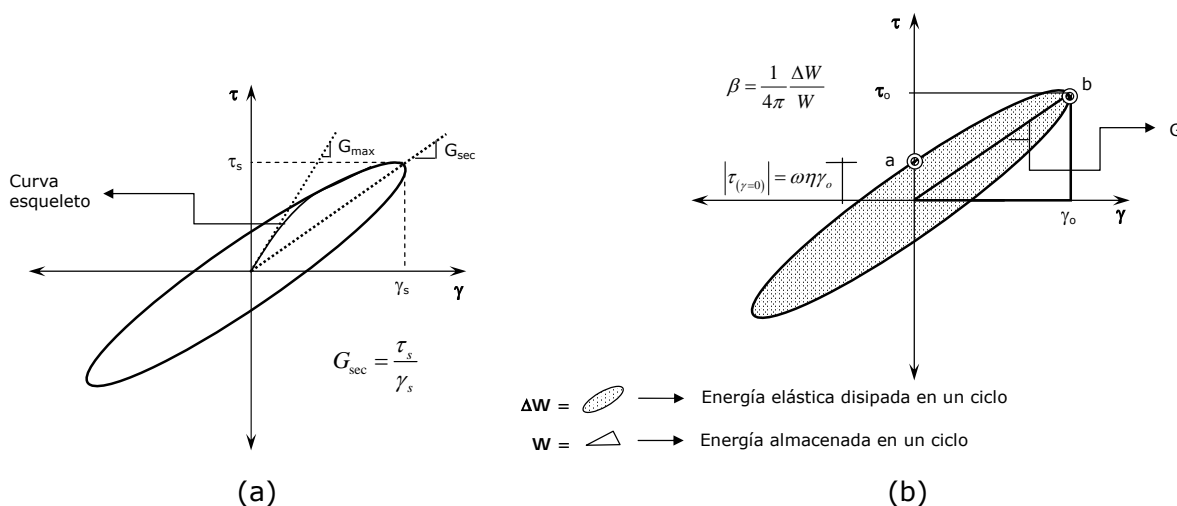


Figura 7 Comportamiento cíclico del suelo bajo carga dinámica

A.2.4 Comportamiento de la arcilla del valle de México

El comportamiento de la arcilla del valle de México ha sido extensamente estudiado debido a sus excepcionales características, por ejemplo, el comportamiento dinámico y los parámetros asociados a él, han evidenciado un comportamiento elástico-lineal (Romo, 1988) hasta deformaciones por cortante del orden de 10^{-2} (figura 8). De tal forma que si se consideran sismos con intensidades bajas es válido establecer un comportamiento lineal del suelo donde los valores del módulo de rigidez y amortiguamiento se mantengan constantes dentro de un rango de deformación por corte.




Figura 8 Comparación del módulo de rigidez de una arcilla típica del valle de México y otras arcillas (Modificado Romo et al., 1988)

Luego de sobrepasar el comportamiento lineal, el suelo empieza a degradarse con la deformación exhibiendo ahora un comportamiento no lineal. Romo (1995), propone un modelo que permite predecir este comportamiento considerando la influencia del índice de plasticidad.

A.3 Espectro de respuesta

Un espectro de respuesta es una gráfica donde se presenta la respuesta máxima de la aceleración, velocidad o desplazamiento como función del periodo de vibración natural (T_n) o de parámetros relacionados como la frecuencia circular (ω_n) o la frecuencia cíclica (f_n) de un sistema de un grado de libertad amortiguado, cuando es sometido a una excitación. La respuesta de un sistema de un grado de libertad en el dominio de la frecuencia $Y(\omega)$ se obtiene por medio de la ecuación 10:

$$Y(\omega) = H(\omega) * X(\omega) \quad \text{[A-10]}$$

Donde:

$X(\omega)$: Señal de entrada al sistema de un grado de libertad

$H(\omega)$: Función de amplificación compleja de un sistema de un grado de libertad.

$Y(\omega)$: Respuesta del sistema de un grado de libertad

El término $H(\omega)$ llamado función de amplificación compleja, representa las características del sistema de un grado de libertad (frecuencia y amortiguamiento), según se muestra en la ecuación 11.

$$H(\omega) = \frac{1}{1 - \left(\frac{\omega}{\omega_n}\right)^2 + i 2 \lambda \left(\frac{\omega}{\omega_n}\right)} \quad \text{[A-11]}$$

Donde:

ω_n : Frecuencia natural de vibración del sistema

ω : Frecuencia de la excitación

λ : Factor de Amortiguamiento del sistema

- a) Se obtiene entonces la respuesta del sistema de un grado de libertad para cada una de las frecuencias que componen la excitación de acuerdo a diferentes frecuencias de vibración del sistema, obteniendo el valor máximo de la respuesta en cada caso. A partir de estos valores máximos se construye el espectro de respuesta.

A.4 Propagación unidimensional de ondas de Corte

En este trabajo se establece que la respuesta en campo libre de un depósito de suelo es debida a la acción de ondas de corte SH que viajan en dirección vertical atravesando los estratos de suelo que constituyen dicho depósito. Para el análisis de esta situación se estudia el caso de una barra de longitud infinita tal como se presenta en el Anexo B donde se establece que los desplazamientos dentro de dicha barra pueden obtenerse a partir de la ecuación 12.

$$\rho \frac{\partial^2 u}{\partial t^2} = G \frac{\partial^2 u}{\partial z^2} + \eta \frac{\partial^3 u}{\partial z^2 \partial t} \quad \text{[A-12]}$$

Cuya solución se expresa por la ecuación 13, que representa como es el sentido del viaje de las ondas dentro del depósito (figura 9).

$$u(z, t) = Ae^{i(\omega t + k^* z)} + Be^{i(\omega t - k^* z)} \quad \text{[A-13]}$$




Figura 9 Sentido de viaje de las ondas dentro del depósito según la ecuación 20

A.4.2 Comportamiento de las ondas de cortante en medios estratificados

Es importante analizar el efecto que se produce al considerar las características físicas (rigidez, densidad y amortiguamiento) de cada uno de los materiales que conforman el depósito en estudio, debido a que los depósitos de suelo son sistemas cuyo origen depende de los eventos y condiciones geológicas ocurridas durante el proceso de su formación.

La simplificación del problema por medio de la barra mostrada en la figura 10, junto con la solución de propagación de ondas, ecuaciones de compatibilidad y el modulo de rigidez complejo hace posible establecer expresiones que relacionen el comportamiento de la onda incidente al momento de entrar en un medio con características mecánicas diferentes.

$$A_R = \frac{1 - \alpha_c}{1 + \alpha_c} A_I \quad \tau_R = \frac{\alpha_c - 1}{1 + \alpha_c} \tau_I$$

$$A_T = \frac{2}{1 + \alpha_c} A_I \quad \tau_T = \frac{2\alpha_c}{1 + \alpha_c} \tau_I \quad \text{[A-14]}$$

Donde:

$$\alpha_c = \frac{G_2^* k_2^*}{G_1^* k_1^*} : \text{Función de impedancia.}$$

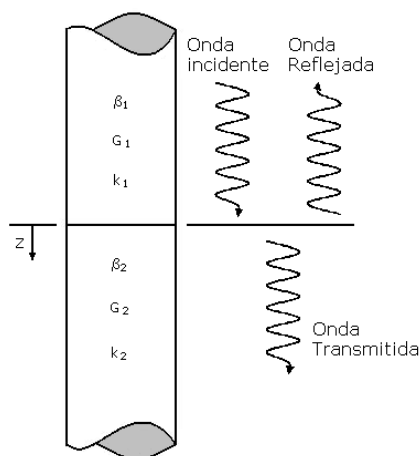


Figura 10 Barra de longitud infinita que representa medio estratificado

El propósito de este numeral es mostrar los efectos físicos producto de dichas ecuaciones, para lo cual se proponen los siguientes casos:

- I. Si $\alpha_c > 1$, $G_2^* k_2^* > G_1^* k_1^*$ que representa una onda que pasa de un medio menos rígido a un medio más rígido (figura 11), si se considera esta situación en las expresiones de la ecuación 14, se obtienen que: $A_R < A_I$ y $A_T < A_I$ y $\tau_R < \tau_I$ y $\tau_T < \tau_I$, lo cual representa una atenuación de la onda incidente al cambia de medio.

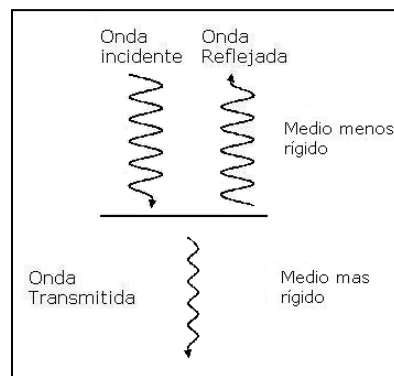


Figura 11 Representación del caso I

- II. Si $\alpha_c < 1$ es decir $G_2^* k_2^* < G_1^* k_1^*$ que representa una onda que pasa de un medio más rígido a un medio menos rígido (figura 12), con lo cual se obtiene una amplificación de la onda incidente cuando cambia de medio, mostrado por el resultado de las expresiones de la ecuación 14 $A_R < A_I$ y $A_T > A_I$ y $\tau_R < \tau_I$ y $\tau_T > \tau_I$.




Figura 12 Representación del caso II

III. Cuando $\alpha_c = 0$ es decir $G_2^* k_2^* = 0$, con el cual se pretende representar el caso de frontera libre, donde en superficie se obtiene el doble de los desplazamientos de la onda incidente (figura 13) y $\tau_R = -\tau_I$ y $\tau_T = 0$. Este caso es útil para interpretar los desplazamientos obtenidos en un acelerógrafo dispuesto en superficie.




Figura 13 Representación del caso III

IV. Cuando $\alpha_c = \infty$ es decir $G_2^* k_2^* = \infty$. Este ultimo caso muestra el comportamiento de las ondas al entrar en roca, donde se observa como la onda incidente no se transmite a pasar a un material con una rigidez muy alta (roca), así que $A_R = -A_I$ y $A_T = 0$ $\tau_R = \tau_I$ y $\tau_T = 2\tau_I$

ANEXO B

Ecuación Unidimensional de

Onda de cortante

Es posible idealizar el comportamiento de un medio unidimensional sometido a una excitación a través de la barra mostrada en la figura B-1. Para esto se supone que dicha barra es de longitud infinita, de sección delgada y uniforme y de área transversal A , donde pueden propagarse ondas transversales, longitudinales o torsionales y que se encuentra sometida a un esfuerzo cortante τ .




Figura B-14 Comportamiento de la barra al ser sometida a un esfuerzo cortante.

El esfuerzo cortante actuante sobre la barra produce una deformación sobre un elemento diferencial de longitud dz , un desplazamiento u , y un esfuerzo τ_0 en la dirección x , de tal manera que el desplazamiento y el esfuerzo causado luego de recorrer la longitud del elemento ($z + dz$), es de $u + \frac{\partial u}{\partial z} dz$ y $\tau_0 + \frac{\partial \tau}{\partial z} dz$ respectivamente.

Cuando se establece el equilibrio del elemento y es aplicada la segunda ley de Newton, igualando las fuerzas al producto de la masa por la aceleración que alcanza el elemento, se obtiene la ecuación B-1.

$$\left(\tau_0 + \frac{\partial \tau}{\partial z} dz \right) A - \tau_0 A = \rho A dz \frac{\partial^2 u}{\partial t^2} \quad \text{[B-1]}$$

Al simplificar la ecuación anterior se llega a la siguiente expresión:

$$\frac{\partial \tau}{\partial z} = \rho \frac{\partial^2 u}{\partial t^2} \quad \text{[B-2]}$$

A la ecuación B-2 se le conoce como *Ecuación diferencial de onda unidimensional*, valida para cualquier comportamiento esfuerzo-deformación y útil para determinar la respuesta del suelo.

ANEXO C

Solución de la ecuación Unidimensional de Onda de cortante

Considerando la ecuación unidimensional de onda de cortante (ecuación B-1), se observa que esta no puede resolverse directamente, ya que se encuentran mezclados esfuerzos con desplazamientos; por ello resulta necesario establecer un modelo constitutivo que uniformice en términos de deformaciones.

$$\frac{\partial \tau}{\partial z} = \rho \frac{\partial^2 u}{\partial t^2} \quad \text{[C-1]}$$

Para solventar este hecho, se acepta como válido un comportamiento viscoelástico representado por un modelo Kelvin-Voigt, con lo que la ecuación unidimensional de ondas de cortante queda expresada en los siguientes términos:

$$\rho \frac{\partial^2 u}{\partial t^2} = G \frac{\partial^2 u}{\partial z^2} + \eta \frac{\partial^3 u}{\partial z^2 \partial t} \quad \text{[C-2]}$$

Cuya solución se expresa en la siguiente forma:

$$u_{(z,t)} = f(z + vt) + g(z - vt) \quad \text{[C-3]}$$

Y en términos armónicos:

$$u(z,t) = U(z) e^{i\omega t} \quad \text{[C-4]}$$

A partir de la ecuación anterior pueden establecerse las siguientes expresiones a partir de su derivación:

$$\frac{\partial^2 u_{(z,t)}}{\partial t^2} = -\omega^2 U_{(z)} e^{i\omega t}, \quad \frac{\partial^2 u_{(z,t)}}{\partial z^2} = \frac{\partial^2 U_{(z)}}{\partial z^2} e^{i\omega t} \quad \text{y} \quad \frac{\partial^3 u_{(z,t)}}{\partial z^2 \partial t} = i\omega \frac{\partial^2 U_{(z)}}{\partial z^2} e^{i\omega t} \quad \text{[C-5]}$$

Remplazando las relaciones expresadas en la ecuación C-5, se obtiene:

$$G \frac{\partial^2 U_{(z)}}{\partial z^2} e^{i\omega t} + \eta \frac{\partial^2 U_{(z)}}{\partial z^2} i\omega e^{i\omega t} = -\rho \omega^2 U_{(z)} e^{i\omega t} \quad \text{[C-6]}$$

Simplificando se obtiene la ecuación C-7.

$$-\rho \omega^2 U_{(z)} = (G + \eta i \omega) \frac{\partial^2 U_{(z)}}{\partial z^2} \quad \text{[C-7]}$$

Introduciendo el término del modulo de rigidez complejo, propio de un sistema viscoelástico:

$$G^* = G + \eta \omega i \quad \text{[C-8]}$$

Ahora bien, a partir de la introducción del modelo lineal equivalente, donde Hardin y Drnevich (1972) propuso establecer la respuesta del suelo independiente, de la frecuencia de excitación, se define la relación del coeficiente de viscosidad, válida para resonancia como:

$$\eta = \frac{2\beta G_{\text{sec}}}{\omega} \quad \text{[C-9]}$$

De tal manera que el módulo de rigidez complejo queda expresado como:

$$G^* = G_{\text{sec}} (2\beta i + 1) \quad \text{[C-10]}$$

Al remplazar la ecuación C-8 en la ecuación C-7 se obtiene:

$$G^* \frac{\partial^2 U_{(z)}}{\partial z^2} = -\rho \omega^2 U_{(z)} \quad [\text{C-11}]$$

Y si se introduce el número de onda complejo, de acuerdo a las expresiones de la ecuación C-12:

$$k = \frac{\omega}{V} \quad \text{donde} \quad V = \sqrt{\frac{G}{\rho}} \quad [\text{C-12}]$$

Resultan las ecuaciones C-13 y C-14 para los modelos elástico y viscoelástico respectivamente.

$$k = \omega \sqrt{\frac{\rho}{G}} = \frac{\omega}{V} \quad \text{Para modelo elástico} \quad [\text{C-13}]$$

$$k^* = \omega \sqrt{\frac{\rho}{G^*}} = \frac{\omega}{V^*} \quad \text{Para modelo viscoelástico} \quad [\text{C-14}]$$

Incorporando finalmente el número de onda complejo en la solución de la ecuación de onda C-3 y C-4, donde:

$$z \pm Vt = z \pm \frac{\omega}{k^*} t = zk^* \pm \omega t \quad [\text{C-15}]$$

Quedan expresadas de la siguiente manera:

$$u_{(z,t)} = f(\omega t + k^* z) + g(\omega t - k^* z) \quad [\text{C-16}]$$

$$u(z,t) = Ae^{i(\omega t + k^* z)} + Be^{i(\omega t - k^* z)} \quad [\text{C-17}]$$

La ecuación C-17 permite obtener los desplazamientos a partir de las amplitudes de onda incidente (sentido positivo de z) y reflejada (sentido negativo de z) que ocurren al interior de un estrato, según se presenta en la figura C-1.




Figura C-15 Representación del viaje de la onda

ANEXO D

Función de transferencia

Pensando en un sistema que se asemeje a las condiciones reales del sitio en estudio, se hace necesario determinar la función de transferencia para un medio estratificado. Por lo cual, a continuación se presenta el desarrollo matemático detallado para la obtención de la función de transferencia estableciendo las hipótesis bajo las cual se acepta su validez.

Dicho análisis inicia estableciendo como propósito, el de obtener la función de transferencia entre el punto i y el punto j a partir de lo presentado en la figura D-1.




Figura D-1 Representación estratigráfica para el análisis de la FT en un medio estratificado

Recordando la ecuación B-17 del anexo B, que permite obtener el desplazamiento al interior de un estrato (ecuación D-1) e introduciendo las coordenadas locales del sistema para cada una de las capas, se obtiene, por ejemplo, que para el estrato m y $m+1$ respectivamente, se cumplen las expresiones de la ecuación D-2.

$$u(z, t) = Ae^{i(\omega t + k^* z)} + Be^{i(\omega t - k^* z)} \quad [\text{D-1}]$$

$$\begin{aligned} u_i = u_m(z_m = 0, t) &= (A_m + B_m) e^{i\omega t} \\ u_j = u_m(z_m = h_m, t) &= (A_m e^{ik_m^* h_m} + B_m e^{-ik_m^* h_m}) e^{i\omega t} \\ u_j = u_{m+1}(z_{m+1} = 0, t) &= (A_{m+1} + B_{m+1}) e^{i\omega t} \\ u_k = u_{m+1}(z_{m+1} = h_{m+1}, t) &= (A_{m+1} e^{ik_{m+1}^* h_{m+1}} + B_{m+1} e^{-ik_{m+1}^* h_{m+1}}) e^{i\omega t} \end{aligned} \quad [\text{D-2}]$$

Si ahora se establece la condición de compatibilidad de desplazamientos que deben existir en las fronteras entre los estratos m y $m+1$, resulta la siguiente expresión:

$$u_m(z_m = h_m, t) = u_{m+1}(z_{m+1} = 0, t) \quad [\text{D-3}]$$

Remplazando las expresiones respectivas de la ecuación D-2, se obtiene:

$$A_{m+1} + B_{m+1} = Ae^{ik^* h_m} + Be^{-ik^* h_m} \quad [\text{D-4}]$$

Ahora bien, recordando que:

$$\tau = G^* \frac{\partial u}{\partial z} \quad [\text{D-5}]$$

Así de la diferenciación con respecto a z de la ecuación D-1 se obtiene:

$$\frac{\partial u}{\partial z} = ik^* e^{i(\omega t \pm k^* z)} (A_m - B_m) \quad [\text{D-6}]$$

Remplazando la ecuación D-6 en D-5 se obtiene que:

$$\tau(z, t) = G^* ik^* e^{i(\omega t \pm k^* z)} (A_m - B_m) \quad [\text{D-7}]$$

A partir de la ecuación D-7 se determinan los esfuerzos en la parte superior e inferior de los estratos m y m+1, como lo muestran las expresiones de la ecuación D-8.

$$\begin{aligned} \tau_m(z_m = 0, t) &= G_m^* ik_m^* e^{i\omega t} (A_m - B_m) \\ \tau_m(z_m = h_m, t) &= G_m^* ik_m^* e^{i\omega t} (A_m e^{ik_m^* h_m} - B_m e^{ik_m^* h_m}) \\ \tau_{m+1}(z_{m+1} = 0, t) &= G_{m+1}^* ik_{m+1}^* e^{i\omega t} (A_{m+1} - B_{m+1}) \\ \tau_{m+1}(z_{m+1} = h_{m+1}, t) &= G_{m+1}^* ik_{m+1}^* e^{i\omega t} (A_{m+1} e^{ik_{m+1}^* h_{m+1}} - B_{m+1} e^{ik_{m+1}^* h_{m+1}}) \end{aligned} \quad [\text{D-8}]$$

Estableciendo de la misma manera que para los desplazamientos, la compatibilidad de esfuerzos cortantes en la frontera, que se define como:

$$\tau_m(z_m = h_m, t) = \tau_{m+1}(z_{m+1} = 0, t) \quad [\text{D-9}]$$

Resultado de remplazar las expresiones de la ecuación D-8 en la ecuación D-9, se obtiene:

$$G_m^* ik_m^* (A_m e^{ik_m^* h_m} - B_m e^{ik_m^* h_m}) = G_{m+1}^* ik_{m+1}^* (A_{m+1} - B_{m+1}) \quad [\text{D-10}]$$

Procediendo al despeje de términos en la ecuación anterior, se obtiene que:

$$(A_{m+1} - B_{m+1}) = \frac{G_m^* ik_m^*}{G_{m+1}^* ik_{m+1}^*} (A_m e^{ik_m^* h_m} - B_m e^{ik_m^* h_m}) \quad [\text{D-11}]$$

Si se denomina α^* a la función de impedancia compleja, definida como:

$$\alpha^* = \frac{G_m^* ik_m^*}{G_{m+1}^* ik_{m+1}^*} \quad [\text{D-12}]$$

La ecuación D-11 se expresa finalmente así:

$$(A_{m+1} - B_{m+1}) = \alpha^* (A_m e^{ik_m^* h_m} - B_m e^{ik_m^* h_m}) \quad [\text{D-13}]$$

Producto de la resta de las ecuaciones D-13 y D-4, se obtienen formulas recurrentes que permiten determinar los valores A_{m+1} y B_{m+1} , que son la amplitudes de la onda incidente y reflejada respectivamente del estrato $m+1$.

$$\begin{aligned} A_{m+1} &= \frac{1}{2} A_m (1 + \alpha^*) e^{ik_m^* h_m} + \frac{1}{2} B_m (1 - \alpha^*) e^{-ik_m^* h_m} \\ B_{m+1} &= \frac{1}{2} A_m (1 - \alpha^*) e^{ik_m^* h_m} + \frac{1}{2} B_m (1 + \alpha^*) e^{-ik_m^* h_m} \end{aligned} \quad [\text{D-14}]$$

Si se establecen las siguientes variables dependientes de la frecuencia para fines de simplificación de la ecuación anterior:

$$\begin{aligned} a(\omega) &= \frac{1}{2} (1 + \alpha^*) e^{ik_m^* h_m} & b(\omega) &= \frac{1}{2} (1 - \alpha^*) e^{-ik_m^* h_m} \\ c(\omega) &= \frac{1}{2} (1 - \alpha^*) e^{ik_m^* h_m} & d(\omega) &= \frac{1}{2} (1 + \alpha^*) e^{-ik_m^* h_m} \end{aligned} \quad [\text{D-15}]$$

De tal manera la ecuación D-14 queda expresada así:

$$\begin{aligned} A_{m+1} &= a(\omega) A_m + b(\omega) B_m \\ B_{m+1} &= c(\omega) A_m + d(\omega) B_m \end{aligned} \quad [\text{D-16}]$$

Implantando la condición de superficie libre, donde los esfuerzos cortantes son cero en superficie, y haciendo uso de la ecuación D-7, se establece que:

$$A_1 = B_1 = 1 \quad [\text{D-17}]$$

Esta expresión Ofrece un condicionante muy útil con el cual concluir que en la superficie de un deposito en campo libre, la amplitud de la onda incidente es igual a la amplitud de la onda reflejada. Si por ejemplo se quiere determinar las amplitudes del estrato 2 (Figura D-1), a partir de la ecuación D-16 se obtiene:

$$\begin{aligned} A_2 &= a(\omega)A_1 + b(\omega)B_1 \\ B_2 &= c(\omega)A_1 + d(\omega)B_1 \end{aligned} \quad \text{[D-18]}$$

Se observa que para obtener los valores para las amplitudes del estrato 2 debe proponerse un valor de amplitudes de onda para el estrato 1, en este caso igual a 1 como se muestra en la ecuación D-17. A partir de la igualdad de la ecuación D-17 la ecuación D-18 queda ahora expresada así:

$$\begin{aligned} A_2 &= [a(\omega) + b(\omega)]A_1 \\ B_2 &= [c(\omega) + d(\omega)]B_1 \end{aligned} \quad \text{[D-19]}$$

Usando de manera recurrente la ecuación D-19, se puede establecer que las amplitudes de las ondas en el estrato m, pueden ser obtenidas a partir de la amplitud de la onda de superficie así:

$$\begin{aligned} A_m &= R(\omega)A_1 \\ B_m &= S(\omega)B_1 \end{aligned} \quad \text{[D-20]}$$

Por lo cual sustituyendo en la ecuación D-16, se establece que:

$$\begin{aligned} A_{m+1} &= a(\omega)R(\omega)A_1 + b(\omega)S(\omega)B_1 \\ B_{m+1} &= c(\omega)R(\omega)A_1 + d(\omega)S(\omega)B_1 \end{aligned} \quad \text{[D-21]}$$

Si se define la función de transferencia como la relación entre los desplazamientos entre los puntos i y j se establece la ecuación 22.

$$FT_{j \rightarrow i} = \frac{|u_i|}{|u_j|} = \frac{A_m + B_m}{A_{m+1} + B_{m+1}} \quad \text{[D-22]}$$

Al remplazar esta ecuación las ecuaciones D-20 y D-21, se obtiene:

$$FT_{j \rightarrow i} = \frac{R(\omega)A_1 + S(\omega)B_1}{a(\omega)R(\omega)A_1 + b(\omega)S(\omega)B_1 + c(\omega)R(\omega)A_1 + d(\omega)S(\omega)B_1} \quad \text{[D-22]}$$

Simplificando;

$$FT_{j \rightarrow i} = \frac{R(\omega) + S(\omega)}{[a(\omega) + c(\omega)]R(\omega) + [b(\omega) + d(\omega)]S(\omega)} \quad \text{[D-23]}$$

Al analizar esta última ecuación se observa como la función de transferencia depende fundamentalmente de las propiedades dinámicas del depósito, es decir es un término que permite predecir el comportamiento dinámico del sistema.

APÉNDICE I

BackPropagation, B.P.

Es un algoritmo de aprendizaje supervisado usado en redes multi-capa, por medio del cual las neuronas son organizadas en capas y se envía su señal hacia "adelante"; donde finalmente se compara la salida producida con la salida deseada, generándose un vector de error, el cual es propagado hacia "atrás", es decir, de la capa de salida hacia la capa de entrada, pasando por las capas ocultas intermedias y ajustando los pesos de las conexiones con el fin de reducir dicho error. En este algoritmo se proponen ejemplos de entradas y salidas (etapa de entrenamiento) que se quiere que la red considere para calcular el error (diferencia entre resultado actual y resultado esperado). La idea central del algoritmo BP es reducir este error hasta que la red "aprenda" de los datos de entrenamiento; entrenamiento que inicia con pesos aleatorios que se van ajustando hasta que el error llegue a ser mínimo.

El algoritmo BP es equivalente al algoritmo de mínimo cuadrado cuando se usa en una red con una capa simple; sin embargo, cuando se aplica una red multi-capa las características son muy diferentes ya que la superficie de error para una red simple tiene solo un mínimo y curvatura constante, en cambio para una red multi-capa posee muchos mínimos locales y la curvatura del error puede variar en diferentes regiones del espacio de los pesos.

Como la red BP trabaja bajo aprendizaje supervisado, y por lo tanto necesita un conjunto de entrenamiento que le describa cada entrada y su valor de salida esperado de la siguiente forma:

$$\{I_1, O_1\}, \{I_2, O_2\}, \{I_3, O_3\}, \dots, \{I_q, O_q\} \quad \text{[I-15]}$$

Donde:

I_q = Entrada q -ésimo de la red

O_q = Salida q -ésima de la red.

El algoritmo BP debe ajustar la entrada y la salida hasta que se minimice el error. El entrenamiento de una Red Neuronal (RN) se realiza mediante un proceso de aprendizaje, para lo cual se debe inicialmente definir la topología de la red: i) número de neurona en la capa de entrada el cual depende del número de componentes del vector de entrada; ii) cantidad de capas ocultas y número de neuronas de cada una de ellas; iii) número de neuronas en la capa de salida el cual depende del número de componentes del vector de salida o patrones objetivo y iv) funciones de transferencia requeridas en cada capa.

La deducción matemática formal que sigue el algoritmo BP, puede entenderse a partir de los pasos que se presentan a continuación (Universidad Tecnológica de Pereira y otros artículos):

PASO 1: La red inicia asignando valores aleatorios a los pesos de la red.

PASO 2: Se eligen los patrones de entrenamiento el cual tiene q componentes

$$I = \begin{bmatrix} I_1 \\ I_1 \\ \vdots \\ I_i \\ \vdots \\ I_q \end{bmatrix} \quad \text{[I-16]}$$

PASO 3: Los pesos se propagan hacia delante a través de todas las conexiones existentes produciendo una entrada neta n en cada una de las neuronas de la siguiente capa. Inicialmente, la entrada neta a la neurona j de la siguiente capa debido a la presencia de un patrón de entrenamiento en la entrada se muestra con la siguiente expresión según se muestra en la figura I-1; donde la entrada neta es justo el valor antes de pasar por la función de transferencia de dicha capa.

$$n_j^o = \sum_{i=1}^q W_{ji}^o I_i \quad \text{[I-17]}$$

Donde:

W_{ji}^o = Peso que une el nodo i de la entrada con la neurona j de la primera capa oculta

I_i = Componente i del vector de entrada I del patrón de entrenamiento de q componentes.

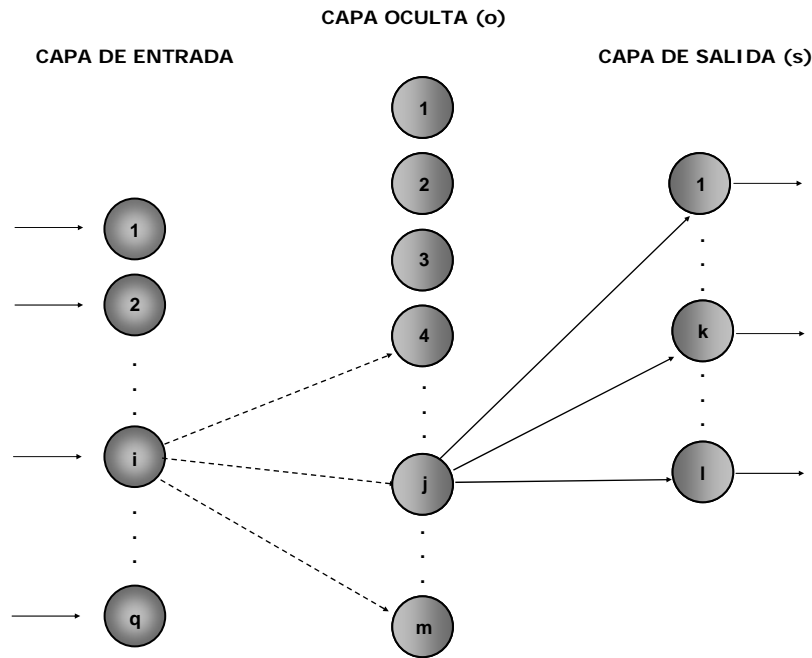


Figura I-16 Esquema de red neuronal con una capa oculta

La neurona j de la capa oculta tiene como salida a_j^o que está dada por la ecuación I-4, según se muestra en la figura I-2.

$$a_j^o = f^o \left(\sum_{i=1}^q W_{ji}^o I_i \right) \quad [I-18]$$

Donde:

f^o = Función de transferencia de la capa oculta.

Las salidas de las neuronas de la capa oculta son las entradas a los pesos de conexión de la capa de salida ($a_j^o \Rightarrow n_k^s$), según lo describe la ecuación I-5.


$$n_k^s = \sum_{j=1}^m W_{kj}^s a_j^o \quad [\text{I-19}]$$

Donde:

W_{kj}^s = Peso que une la neurona j de la capa oculta con la neurona k de la capa de salida

a_j^o = Salida de la neurona j de la capa oculta

n_k^s = Entrada neta de la neurona k de la capa de salida



n = entrada neta a la neurona j

f = Función de transferencia de la capa oculta

a = Salida de la neurona j de la capa oculta

Figura I-17 Esquema de neurona en la capa oculta

Finalmente, la red produce una salida descrita por la siguiente expresión:

$$a_k^s = f^s(n_k^s) \quad [\text{I-20}]$$

Donde:

f^s = Función de transferencia de las neuronas de la capa de salida

PASO 4: Las salidas calculadas a_k^s con la red son comparadas con las salidas deseadas

O_k para calcular el error en cada unidad de salida

$$\delta_k = (O_k - a_k^s) \quad \text{[I-21]}$$

El error debido a cada patrón I propagado esta dado por:

$$ep^2 = \frac{1}{2} \sum_{k=1}^l (\delta_k)^2 \quad \text{[I-22]}$$

Donde:

ep^2 = Error medio cuadrático para cada patrón de entrada I

δ_k = Error en la neurona k de la capa de salida

Este proceso se repite para el número total de patrones de entrenamiento (r). Para un proceso de aprendizaje exitoso el objetivo es actualizar todos los pesos de la red minimizando el error medio cuadrático total según la expresión:

$$e^2 = \sum_{p=1}^r ep^2 \quad \text{[I-23]}$$

Donde:

e^2 = Error total en el proceso de aprendizaje en una iteración luego de presentar a la red los r patrones de entrenamiento.

El error que genera una red neuronal en función de sus pesos genera un espacio de n dimensiones, donde n es el número de pesos de conexión a la red; al evaluar el gradiente de error en un punto de esta superficie se obtendrá la dirección en la cual la función de error tendrá un mayor crecimiento. Como el objetivo del proceso de aprendizaje es minimizar el error debe tomarse la dirección negativa del gradiente para obtener el mayor decremento del error su minimización, es por ello que se dice que el algoritmo BP se basa en el método del gradiente descendente. Así para realizar la actualización de pesos para la neurona de salida k se usa la siguiente expresión:

$$W_{k+1} = W_k - \alpha \nabla ep^2 \quad \text{[I-24]}$$

Donde:

$-\alpha \nabla ep^2$ = Gradiente negativo de ep^2 , que se calcula como la derivada del error de todos los pesos de la red.

CAPA DE SALIDA

En la capa de salida el gradiente negativo del error con respecto a los pesos es:

$$-\frac{\partial ep^2}{\partial W_{kj}^s} = -\frac{\partial}{\partial W_{kj}^s} \left(\frac{1}{2} \sum_{k=1}^l (O_k - a_k^s)^2 \right) = (O_k - a_k^s) \times \frac{\partial a_k^s}{\partial W_{kj}^s} \quad \text{[I-25]}$$

Donde:

$-\frac{\partial ep^2}{\partial W_{kj}^s}$ = Componente del gradiente $-\nabla ep^2$ respecto al peso de la conexión de la neurona de la capa de salida y la neurona j de la capa oculta W_{kj}^s .

$-\frac{\partial a_k^s}{\partial W_{kj}^s}$ = Derivada de la salida de la neurona k de la capa de salida respecto al peso W_{kj}^s

Para calcular $\frac{\partial a_k^s}{\partial W_{kj}^s}$ se debe utilizar la regla de la cadena, pues el error no es una función directa y explícita de los pesos de la red. De la ecuación 6 se observa que la salida de la red a_k^s esta explícitamente en función de n_k^s y de la ecuación I-5 que n_k^s esta explícitamente en función de W_{kj}^s ; considerando esto se obtiene la ecuación I-12.

$$\frac{\partial a_k^s}{\partial W_{kj}^s} = \frac{\partial a_k^s}{\partial n_k^s} \times \frac{\partial n_k^s}{\partial W_{kj}^s} \quad \text{[I-26]}$$

Al remplazar la ecuación I-12 en la ecuación I-11 se obtiene:

$$-\frac{\partial ep^2}{\partial W_{kj}^s} = (O_k - a_k^s) \times \frac{\partial a_k^s}{\partial n_k^s} \times \frac{\partial n_k^s}{\partial W_{kj}^s} \quad \text{[I-27]}$$

Donde:

$\frac{\partial n_k^s}{\partial W_{kj}^s}$ = Derivada de la entrada neta a la neurona k de la capa de salida respecto a los pesos entre las neuronas de la última capa oculta y la capa de salida.

$\frac{\partial a_k^s}{\partial n_k^s}$ = Derivada de la salida de la neurona k de la capa de salida con respecto a su entrada neta.

Remplazando en la ecuación I-13 las derivadas de las ecuaciones I-5 y I-6 se obtiene:

$$-\frac{\partial ep^2}{\partial W_{kj}^s} = (O_k - a_k^s) \times f'^s(n_k^s) \times a_j^o \quad [\text{I-28}]$$

Se observa en la ecuación anterior que las funciones de transferencia usadas deben ser continuas para que su derivada exista en todo en intervalo ya que es requerida para el cálculo del error. De esta misma ecuación se desprenden los términos del error para las neuronas de la capa de salida:

$$\delta_k^s = (O_k - a_k^s) f'^s(n_k^s) \quad [\text{I-29}]$$

CAPA OCULTA

El error de la capa oculta esta dado por:

$$-\frac{\partial ep^2}{\partial W_{ji}^o} = -\frac{\partial}{\partial W_{ji}^o} \left(\frac{1}{2} \sum_{k=1}^l (O_k - a_k^s)^2 \right) = \sum_{k=1}^l (O_k - a_k^s) \times \frac{\partial a_k^s}{\partial W_{ji}^o} \quad [\text{I-30}]$$

Para calcular el último término de la expresión anterior se debe aplicar la regla de la cadena nuevamente puesto que la salida de la red no es una función explícita de los pesos de la conexión entre la capa de entrada y la capa oculta.

$$\frac{\partial a_k^s}{\partial W_{ji}^o} = \frac{\partial a_k^s}{\partial n_k^s} \times \frac{\partial n_k^s}{\partial a_k^o} \times \frac{\partial a_k^o}{\partial n_j^o} \times \frac{\partial n_j^o}{\partial W_{ji}^o} \quad [\text{I-31}]$$

Remplazando la ecuación I-17 en la ecuación I-16 se obtiene:

$$-\frac{\partial ep^2}{\partial W_{ji}^o} = \sum_{k=1}^l (O_k - a_k^s) \times \frac{\partial a_k^s}{\partial n_k^s} \times \frac{\partial n_k^s}{\partial a_k^o} \times \frac{\partial a_k^o}{\partial n_j^o} \times \frac{\partial n_j^o}{\partial W_{ji}^o} \quad [\text{I-32}]$$

Tomando las derivadas de las ecuaciones I-3, I-4, I-5, I-6 y remplazándolas en la ecuación anterior se obtiene el gradiente del error en la capa oculta:

$$-\frac{\partial ep^2}{\partial W_{ji}^o} = \sum_{k=1}^l (O_k - a_k^s) \times f'^s(n_k^s) \times W_{kj}^s \times f'^o(n_j^o) \times I_i \quad [\text{I-33}]$$

Remplazando la ecuación I-15 en la ecuación anterior se tiene que:

$$-\frac{\partial ep^2}{\partial W_{ji}^o} = \sum_{k=1}^l \delta_k^s \times W_{kj}^s \times f'^o(n_j^o) \times I_i \quad \text{[I-34]}$$

Los términos de error para cada neurona de la capa oculta están dados por la ecuación:

$$\delta_j^o = f'^o(n_j^o) \times \sum_{k=1}^l \delta_k^s W_{kj}^s \quad \text{[I-35]}$$

PASO 5: Finalmente, se lleva a cabo un viaje hacia atrás a través de la red, modificando los pesos, a partir del gradiente de error encontrado para la capa de salida y la capa oculta. Los pasos 2 al 4 se llevan a cabo durante todo el proceso de entrenamiento, hasta que el valor del error caiga dentro de algún rango predeterminado. En este punto se dice que la red ha aprendido el problema lo suficientemente bien, considerando que la red nunca aprenderá exactamente la función ideal.

Para la capa de salida la actualización de los pesos se hace a partir de la ecuación I-22.

$$W_{kj}(t+1) = W_{kj}(t) - 2\alpha\delta_k^s \quad \text{[I-36]}$$

Donde:

α = Tasa de aprendizaje.

Luego de actualizar los pesos de la capa de salida se procede a actualizar los pesos de la capa oculta mediante la ecuación I-23.

$$W_{ji}(t+1) = W_{ji}(t) - 2\alpha\delta_j^o I_i \quad \text{[I-37]}$$

Esta deducción fue realizada para una red compuesta de 3 capas, si se quiere realiza el análisis para una red con dos o más capas ocultas, las expresiones pueden derivarse de la ecuación I-21, donde los términos que se encuentran dentro de la sumatoria pertenecen a la capa inmediatamente superior.

En las técnicas de gradiente descendente es conveniente avanzar por la superficie de error con incrementos pequeños de los pesos; esto se debe a que se tiene información local de la superficie y no se sabe lo lejos o cerca que esta el punto mínimo, con incrementos grandes se corre el riesgo de pasar por encima del punto mínimo. El elegir un

incremento adecuado influye en la velocidad de convergencia del algoritmo, esta velocidad se controla a través de la tasa de aprendizaje α .

En el desarrollo matemático que se ha realizado para llegar al algoritmo BP, no asegura en ningún momento que el mínimo que se encuentre sea global; una vez la red quede atrapada en un mínimo local o global cesa el aprendizaje, aunque el error siga siendo alto. En todo caso, si la solución es admisible desde el punto del vista del error, no importa si el mínimo es local o global o si se ha detenido en algún momento previo a alcanzar un verdadero mínimo.

Entre los principales problemas que presenta este algoritmos pueden encontrarse:

- i) La línea de máxima pendiente no siempre es la ruta más directa hacia el mínimo de la función de error.
- ii) Puede converger a un mínimo local.
- iii) Si la pendiente de error es muy escasa el entrenamiento es muy lento
- iv) Si la pendiente es nula el algoritmo se detiene.

Y como características fundamentales se presentan:

- El algoritmo busca el mínimo de la función de error a partir de un conjunto de patrones de entrenamiento
- El algoritmo precisa que la función de activación sea diferenciable (fácilmente)
- Entrenar consiste en modificar los pesos de la red
- Los pesos se modifican hacia la dirección descendente de la función de error
- La red entrenada es capaz de generalizar, clasificando correctamente los patrones ruidosos o incompletos.

REFERENCIAS

- [1] **Abu-Kiefa, M. A. (1998)**. "General regression neural networks for driven piles in cohesionless soils". *J. Geotech. & Geoenv. Engrg.*, ASCE, 124(12), 1177-1185.
- [2] **Adams, T.M., Christiano, P. y Hendrickson, C. (1989)**. "Some expert system applications in geotechnical engineering". *Foundation Engineering: Current principles and practices*, ASCE: New York, pp 885-902.
- [3] **Agrawal, G., Chameau, J. A., and Bourdeau, P. L. (1997)**. "Assessing the liquefaction susceptibility at a site based on information from penetration testing". *Artificial neural networks for civil engineers: fundamentals and applications*, N. Kartam, I. Flood, and J. H. Garrett, eds., New York, 185-214.
- [4] **Alcocer, S., Duran, R., Flores, L. Gutierrez, C. y Reyes, C. (2003)**. "El sismo de Tecomán, Colima del 21 de enero de 2003". *CENAPRED*, pp: 1-18.
- [5] **Arai, K., Iida, K. y Konja, A. (1990)**. "A simple back-analysis in a seismic subsoil context", *Soils and Foundations*. Vol. 30(4): 175-182.
- [6] **Asté J.P. (1992)**. "SISYPHE: Systemè d'Aide au Diagnostic en Matière d'Instabilité de Pentès". *Geotechnique et Informatique, Proc. Int. Conf. on Geotechnics and Computers*, Paris: Presses de l'École Nationale de Ponts et Chaussées, pp 515-524.
- [7] **Basheer, I. A., and Najjar, Y. M. (1995)**. "A neural-network for soil compaction." *Proc., 5th Int. Symp. Numerical Models in Geomechanics*, G. N. Pande and S. Pietruszczak, eds., Rotterdam: Balkema, 435-440.
- [8] **Basheer, I. A., Reddi, L. N., and Najjar, Y. M. (1996)**. "Site characterization by neuronets: An application to the landfill sitting problem." *Ground Water*, 34, 610-617.
- [9] **Baziar, M. y Ghorbani, A. (2005)**. "Evaluation of lateral spreading using artificial neural networks", *Soil Dynamics and Earthquake Engineering*, 25: 1-9.
- [10] **Bendat, J., Piersol, A. (1971)**. "Random Data: analysis and measurement procedures", Wiley and Sons. ISBN 0-471-06470-X.
- [11] **Bremermann, H.J. (1958)**. "The evolution of intelligence. The nervous system as a model of its environment", Technical report, no.1, contract no. 477(17), Dept. Mathematics, Univ. Washington, Seattle.
- [12] **Buckles, B. y Petry, F. editors (1992)**. "Genetic Algorithms". Technology Series. IEEE Computer Society Press.
- [13] **Cal, Y. (1995)**. "Soil classification by neural-network." *Advances in Engineering Software*, 22(2), 95-97.
- [14] **Carvajal, J. C. (2000)**. "Análisis Espectral de Movimientos Sísmicos en la Ciudad de México para Evaluar Propiedades Dinámicas del Suelo". Tesis de Maestría, UNAM, México DF, 152 p.
- [15] **Casdagli, M. (1992)**. "Chaos and deterministic versus stochastic nonlinear modeling", *J. Roy. Stat. Soc. B.*, Vol. 54: 303-328.
- [16] **Chahine J.R. & Janson B.N. (1987)**. "Interfacing Databases with Expert Systems: a Retaining Wall Management Application". *Microcomputers in Civil Eng.*, 2 (1): 19-38.
- [17] **Chan, W. T., Chow, y. K., and Liu, L. F. (1995)**. "Neural network: An alternative to pile driving formulas." *J. Computers and Geotechnics*, 17: 135-156.
- [18] **Coello, C., (2001)**. "Introducción a la computación evolutiva (notas de curso)". CINVESTAV-IPN, sección de computación, Departamento de Ingeniería eléctrica. En: delta.cs.cinvestav.mx/~ccoello/compevol/syllabus2005.pdf
- [19] **Coyle, H. M., and Castello, R. R. (1981)**. "New design correlations for piles in sand". *J. Geotech. Engrg.*, ASCE, 107(7), 965-986.
- [20] **Davis, L. (1991)**. "Handbook of Genetic Algorithms". Van Nostrand Reinhold, New York.
- [21] **Dempster, A. (1967)**. "Upper and Lower Probabilities Induced by Multivalued Mapping" *Annals of Mathematical Statistics*. Vol. 38 (2): 325-339.
- [22] **Easley, M. y Bradley, E. (1999)**. "Generalized physical networks for automated model building". *Int. Joint Conference on Artificial Intelligence (IJCAI-99)*, Stockholm.
- [23] **Elgamal, A. W., Zeghal, M., Tang, H. T. y Stepp, J. C. (1995)**. "Lotung Downhole Array I: Evaluation of Site Dynamic Properties". *Journal of the Geotechnical Engineering Division*, ASCE, Vol. 121 (4): 350-362.

- [24] **Ellis, G. W., Yao, C., Zhao, R., y Penumadu, D. (1995)**. "Stress-strain modelling of sands using artificial neural networks." *J. Geotech. Engrg., ASCE*, 121(5): 429-435.
- [25] **Fahman, S. (1988)**. "An Empirical Study of Learning Speed in Back-Propagation Networks". Department of Carnegie Mellon University, Technical Report CMU-CS-88-162.
- [26] **Faure, R.M., Leroueil, S., Rajot, J.P., Larochele, P., Seve, G. y Tavenas, F. (1988)**. "XPENT, Expert System In Slope Stability (In French)". *Proc. 5th Int. Symp. Landslides*, Lausanne (ed. Bonnard, C.), Brookfield VT: Balkema, pp 625-629.
- [27] **Faure, R.M., Mascarelli, D., Zelfani, M., Charveriat, L., Gandar, J. y Mosuro, O. (1991)**. "XPENT - An Expert System for Slope Stability". *Artificial Intelligence and Civil Engineering* (ed. Topping, B.H.V.), Edinburgh: Civil-Comp Press, pp 143-147.
- [28] **Faure, R.M., Mascarelli, D., Vaunat, J., Leroueil, S. y Tavenas, F. (1995)**. "Present State of Development of XPENT, Expert-System for Slope Stability Problems". *Proc. 6th Int. Symp. Landslides*, Christchurch (ed. Bell, D.H.), Rotterdam: Balkema, pp 1671-1678.
- [29] **Fausett, L. (1994)**. "Fundamentals of Neural Networks: Architectures, Algorithms, and Applications". Prentice Hall, NJ, USA.
- [30] **Fogel, D. (1995)**. "Evolutionary Computation". *Toward a New Philosophy of Machine Intelligence*. The Institute of Electrical and Electronic Engineers, New York.
- [31] **García, S., Romo, M., Mendoza, M. y Taboada-Urtuzuástegui, V. M. (2002)**. "Sand behavior modeling using static and dynamic artificial neural networks". *Series de Investigación y Desarrollo del Instituto de Ingeniería No. SID/631*, 32 p
- [32] **García, S. y Romo M. (2003)**. "Atenuación Sísmica: Una aproximación con Redes Neuronales Artificiales", publicado en las memorias de la XIV Congreso Nacional de Ingeniería Sísmica, Guanajuato-León, México.
- [33] **García, S. y Romo, M. (2004a)**. "Ground motion attenuation relations by means of neurofuzzy systems", in the Proceedings of the 11th International Conference on Soil Dynamics & Earthquake Engineering (11thICSDEE) and The 3rd International Conference on Earthquake Geotechnical Engineering (3rdICEGE), 7th – 9th January 2004, University of California at Berkeley, USA, Vol. 2, pp 61-67.
- [34] **García, S. y Romo, M. (2004b)**. "Dynamic soil properties identification using earthquake records: A NN approximation", in the Proc. of the 13th World Conference on Earthquake Engineering, Vancouver, Canada, paper # 1817, August.
- [35] **García, S. y Romo, M. P., (2004c)**. "Sistema de Información Geográfica y Redes Neuronales", *Memorias de la XXI Reunión Nacional de Mecánica de Suelos*, Guadalajara, noviembre, Vol. 1, pp 171-180.
- [36] **García, S., Romo, M. y Ortega, M. (2005a)**. "Spatial Variation of Soil Properties using Soft Computing", 11th Internacional Conference IACMAG, Turin, Italia, paper # 197.
- [37] **García, S. (2005b)**. Conversación oral.
- [38] **Ghaboussi, J., and Sidarta, D. E. (1998)**. "New nested adaptive neural networks (NANN) for constitutive modeling." *J. Computers and Geotechnics*, 22(1), 29-52.
- [39] **Glover, F. y Laguna, M. (1998)**. "Tabu Search". Kluwer Academic Publishers, Norwell Massachusetts.
- [40] **Goh, A. T. C. (1994a)**. "Nonlinear modelling in geotechnical engineering using neural networks". *Australian Civil Engineering Transactions*, Vol. 36(4): 293-297.
- [41] **Goh, A. T. C. (1994b)**. "Seismic liquefaction potential assessed by neural network". *J. Geotech. & Geoenv. Engrg., ASCE*, Vol. 120(9): 1467-1480.
- [42] **Goh, A. T. C. (1995a)**. "Back-propagation neural networks for modeling complex systems." *Artificial Intelligence in Engineering*, 9: 143-151.
- [43] **Goh, A.T.C. (1995b)**. "Empirical Design in Geotechnics using Neural Networks". *Geotechnique*, Vol. 45 (4): 709-714.
- [44] **Goh, A.T.C. (1995c)**. "Modeling Soil Correlations using Neural Networks". *Journal of Computing in Civil Engineering*, Vol. 9 (4): 275-278.
- [45] **Goh, A.T.C. (1996a)**. "Neural-Network Modeling of CPT Seismic Liquefaction Data". *Journal of Geotechnical Engineering - ASCE*, Vol. 122 (1): 70-73.
- [46] **Goh, A. T. C. (1996b)**. "Pile driving records reanalyzed using neural networks". *J. Geotech. Engrg., ASCE*, 122(6): 492-495.
- [47] **Gökay, M.K. (1993)**. "Developing Computer Methodologies for Rock Engineering Decisions", PhD thesis, Imperial College, University of London.
- [48] **Goldberg, D. E. (1989)**. "Genetic Algorithms in Search, Optimization, and Machine Learning". Addison-Wesley, Nueva York, pp: 1-214.

- [49] **Gribb, M. M., and Gribb, G. W. (1994).** "Use of neural networks for hydraulic conductivity determination in unsaturated soil." Proc., 2nd Int. Conf. Ground Water Ecology, J. A. Stanford and H. M. Valett, eds., Bethesda MD: Amer. Water Resources Assoc., 155-163.
- [50] **Hadipriono F.C., Diaz C.F. y Wolfe W.E. (1991).** "Toward the Development of a Knowledge Base Expert System for Determining the Causes of Foundation Failures". Proc. Conf. on Computational Structures Technology, Edinburgh: Civil-Comp Press.
- [51] **Hardin, B. O. y Drnevich, V.P. (1972).** "Shear Modulus and Damping in Soils: Measurements and Parameters Effects". Proc. ASCE, 98, No. SM 6, Junio 1972, pp. 603-624.
- [52] **Haykin S. (1994).** "Neural Networks". Macmillan.
- [53] **Hecht-Nielsen, R. (1990).** "Neurocomputing", Addison-Wesley Publishing Company.
- [54] **Hegazy, T., Tully, S. y Marzouk, H. (1998).** "A neural network approach for predicting the structural behavior of concrete slabs". Canadian Journal Civil Engineering, Vol. 20: 668-677.
- [55] **Holland, J. (1962).** "Outline for a logical theory of adaptive systems". Journal of the Association for Computing Machinery, 9:297-314.
- [56] **Holland, J. H. (1975).** "Adaptation in Natural and Artificial Systems". MIT Press, Cambridge, pp: 66-121.
- [57] **Honda, H., Kojima, K. y Arai, K. (1995).** "Back analysis of dynamic soil parameters based on actual accelerations during earthquake", Journal of Geotechnical Engineering (JSCE), No 517/III-31, pp. 125-133.
- [58] **Honjo, Y., Iwamoto, S. Sugimoto, M. Onimaru, S. Y Yoshizawa M. (1998).** "Inverse Analysis of Dynamic Soil Properties Based on Seismometer Array Using The Extended Bayesian Method". Soils and Foundations, Japanese Geotechnical Society, Marzo, pp: 131-143.
- [59] **Hutchinson P.J., Rosenman M.A. y Gero J.S. (1987).** "RETWALL: An Expert System for the Selection and Preliminary Design of Earth Retaining Structures". Knowledge-based Systems, Vol. 1 (1): 11-23.
- [60] **Ikemoto, T., Miyajima, M. Y Kitaura, M. (2000).** "Inverse Analysis of Dynamic Soil Parameters Using Acceleration Records". In: Proceedings of the 12th World Conference on Earthquake Engineering, Enero 30-Febrero 4, Auckland, New Zealand, Paper No. 1794.
- [61] **Ishihara, K. (1996).** "Soil Behaviour in Earthquake Geotechnics". Calrendon Press, Oxford, pp: 1-39, ISBN:0198562241
- [62] **Jaime, A. P., Romo, M. P. y Ovando, E. (1987).** "Características del Suelo en el Sitio Central de Abasto Oficinas". Informe Interno del Instituto de Ingeniería, UNAM. 50 p.
- [63] **Jeng, D.-S., Lee, T. L. and Lin, C. (2003),** "Application of artificial neural networks in assessment of Chi-Chi earthquake-induced liquefaction". Asian Journal of Information Technology, Vol. 2 (3): 190-198.
- [64] **Kanai, K. (1966),** "Improved Empirical Formula for the Characteristics of Strong Earthquake Motions," Proc. Japan Earthquake Engineering Symposium, Tokyo, 1-4.
- [65] **Kartalopoulos, S. (1996).** "Understanding Neural Networks and Fuzzy Logic: Basic Concepts and Applications". IEEE Press, NJ, USA.
- [66] **Kirkpatrick, S., Gelatt, C. y Vecchi, M. (1983).** "Optimization by Simulated Annealing". Science, 220:671-680.
- [67] **Kokusho, T. Sato, K. and Matsumoto, M. (1996).** "Nonlinear dynamic soil properties back-calculated from strong motions during Hyogoken-Nambu Earthquake". Proc. 11th World Conference on Earthquake Engineering, Acapulco, CD publication.
- [68] **Kramer, S.L. (1996).** "Geotechnical Earthquake Engineering", Prentice Hall, Inc., Upper Saddle River, New Jersey, 653 pp.
- [69] **Kuzniar, K., Maciag, E., Obiala, R. y Waszczyszyn, Z. (2000).** "Application of neural networks in natural periods identification and simulation of prefabricated building response". Soil Dynamics and Earthquake Engineering, Vol. 20:217-22. Elsevier.
- [70] **Lee, C., y Sterling, R. (1992).** "Identifying probable failure modes for underground openings using a neural network". Int. J. Rock Mechanics and Mining Science & Geomechanics Abstracts, Vol. 29(1): 49-67.
- [71] **Lee, I. M., y Lee, J. H. (1996).** "Prediction of pile bearing capacity using artificial neural networks". Computers and Geotechnics, Vol. 18(3): 189-200.
- [72] **Ljung, L. (1987).** "System Identification: Theory for the User", Prentice-Hall, Englewood Cliffs, NJ.

- [73] **Lomnitz, C. (2004)**. "Las causas probables de la catástrofe sísmica del 19 de septiembre de 1985", Instituto de Geofísica, UNAM, México, en: <http://www.ssn.unam.mx/SSN/Doc/CONACYT/88-82cinna.htm>.
- [74] **Magnan J.P. (1992)**. "CESSOL: Bilan du Développement d'un Système-expert". Geotechnique et Informatique, Proc. Int. Conf. on Geotechnics and Computers, Paris: Presses de l'École Nationale de Ponts et Chaussées, pp 579-585.
- [75] **Maren, A., C. Harston, y Pap, R. (1990)**. "Handbook of Neural Computing Applications". Academic Press, San Diego, California, pp.360.
- [76] **Marsal, R y Mazari, M. (1957)**. "El subsuelo de la Ciudad de México", Facultad de Ingeniería, UNAM, México.
- [77] **Martínez C., H. E. (1998)**. "Identificación de las Propiedades Dinámicas de la Ciudad de México". Tesis de Maestría, UNAM, México DF. 110 p.
- [78] **Martínez S y Romo M P, (2002)**, "RNAs aplicadas en la evaluación de desplazamientos laterales de excavaciones apuntaladas en suelos blandos", Memorias de la XXI Reunión Nacional de Mecánica de Suelos, noviembre, Vol. II, pp 115-122.
- [79] **Mascarelli, D., Faure, R.M. y Kastner, R. (1992)**. "Anatomie d'un projet à base de connaissances XPENT, système de travail en ingénierie des pentes". Geotechnique et Informatique, Proc. Int. Conf. on Geotechnics and Computers, Paris: Presses de l'École Nationale de Ponts et Chaussées, pp 587-598.
- [80] **Mateos, G. (2004)**. "sismos sintéticos generados estocásticamente compatibles con espectros de respuesta y diseño", Tesis de licenciatura, Facultad de Ingeniería, División de ingeniería civil topográfica y geodésica, UNAM.
- [81] **McCulloch, W. y Pitts, W (1943)**. "A logical calculus of the ideas immanent in nervous activity". Bulletin of Mathematical Biophysics. Vol. 7: 115-133.
- [82] **Meyerhof, G. G. (1976)**. "Bearing capacity and settlement of pile foundations." J. Geotech. Engrg., ASCE, Vol. 102(3): 196-228.
- [83] **Michalewicz, Z. (1996)**. "Genetic algorithms + data structures = evolution programs". Berlin; New York: Springer.
- [84] **Minsky, M. y Papert, S. (1969)**. "Perceptrons". MIT Press, Cambridge, MA.
- [85] **Mitchell, M. (1996)**, "An introduction to Genetic Algorithms", The MIT press.
- [86] **Moon, H. K., Na, S. M., y Lee, C. W. (1995)**. "Artificial neural-network integrated with expert-system for preliminary design of tunnels and slopes". Proc., 8th Int. Congress on Rock Mechanics, T. Fujii, ed., Rotterdam: Balkema, Vol.1 y 2, 901-905.
- [87] **Moula M. (1993)**. "A knowledge based system to assist in the selection of appropriate geotechnical field tests", PhD Thesis, University of Durham, 186 p.
- [88] **Moula, M. y Toll, D.G. (1993)**. "Representing Geotechnical Knowledge: Soils and Field Tests". Knowledge Based Systems for Civil and Structural Engineering (ed. Topping B.H.V.), Edinburgh: Civil-Comp Press, pp 171-182.
- [89] **Najjar, Y. M., y Basheer, I. A. (1996a)**. "Neural network approach for site characterization and uncertainty prediction". Geotechnical Special Publication, ASCE, Vol. 58(1): 134-148.
- [90] **Najjar, Y. M., and Basheer, I. A. (1996b)**. "Utilizing computational neural networks for evaluating the permeability of compacted clay liners". Geotechnical and Geological Engineering, Vol. 14: 193-221.
- [91] **Najjar, Y. M., and Ali, H. E. (1998)**. "CPT-based liquefaction potential assessment: A neuronet approach". Geotechnical Special Publication, ASCE, Vol.1: 542-553.
- [92] **Nawari, N. O., Liang, R., y Nusairat, J. (1999)**. "Artificial intelligence techniques for the design and analysis of deep foundations." Electronic J. Geotech. Engrg. <http://geotech.civeng.okstate.edu/ejge/ppr9909/index.html>.
- [93] **Ni, S. H., Lu, P. C., y Juang, C. H. (1996)**. "A fuzzy neural network approach to evaluation of slope failure potential". J. Microcomputers in Civil Engineering, Vol. 11: 59-66.
- [94] **Norkin, D.D. (1985)**. "Expert System for Geotechnical Site Characterization". Master's dissertation, Carnegie-Mellon University, Pittsburgh.
- [95] **Ordaz, M., Perez-Rocha, L., Reinoso, E., Montoya, C. y Arboleda, J. (1996)**, "Programa Z", Instituto de Ingeniería, UNAM.
- [96] **Ovando, E., Romo, M. y Díaz, L. (1993)**. "Ground movements in Mexico City during recent earthquakes", Conference on Case Histories in Geotechnical Engineering, St. Louis Missouri, Vol III, pp 1769-1775, June.

- [97] **Pearson, E. (1986)**. "Numerical methods in engineering and science", Van Nostrand Reinhold Co., New York, NY.
- [98] **Penumadu, D., y Jean-Lou, C. (1997)**. "Geomaterial modeling using artificial neural networks." *Artificial Neural Networks for Civil Engineers: Fundamentals and Applications*, ASCE, 160-184.
- [99] **Penumadu, D., y Zhao, R. (1999)**. "Triaxial compression behavior of sand and gravel using artificial neural networks (ANN)". *J. Computers and Geotechnics*, Vol. 24: 207-230.
- [100] **Rangel, J. y Romo, M. (2000)**. "Análisis de asentamientos por tuneo usando redes neuronales artificiales", XX Reunión Nacional de Mecánica de Suelos, Oaxaca, Vol. 1, pp 247-258, noviembre.
- [101] **Rangel, J. (2002)**. "Diseño del soporte y del procedimiento constructivo de túneles en macizos rocosos utilizando sistemas neurodifusos", Tesis Doctoral (Mecánica de Suelos), División de Estudios de Posgrado, Facultad de Ingeniería, UNAM.
- [102] **Rangel, J., Ayala, G. y Romo, M. (2003)**. "Un sistema de inteligencia artificial aplicado al diseño del procedimiento constructivo de túneles en rocas", 12th Panamerican Conference on Soil Mechanics and Geotechnical Engineering and 39th US Rock Mechanics Symposium, Soil and Rock 2003, June, pp 2059-2066.
- [103] **RCDF (2004)**. "Reglamento de Construcciones para el Distrito Federal", Normas Técnicas Complementarias para Diseño Sísmico en el D.F., 1987. Departamento del Distrito Federal, publicaciones. México.
- [104] **Reeves, C. editor (1993)**. "Modern Heuristic Techniques for Combinatorial Problems. John Wiley & Sons, Great Britain.
- [105] **Rehak, D.R., Christiano, P.P. y Norkin, D.D. (1985)**. "SITECHAR: An Expert System Component of a Geotechnical Site Characterization Workbench". *Applications of Knowledge-based Systems to Engineering Analysis and Design* (ed. Dym C.L.), Am. Soc. Mech. Eng.: New York, pp 117-133.
- [106] **Rizzo, D. M., y Dougherty, D. E. (1994)**. "Application of artificial neural networks for site characterization using hard and soft information". *Proc., 10th Int. Conf. Computational Methods in Water Resources*, A. Peters et al., eds., Dordrecht: Kluwer Academic, Vol. 12: 793-799.
- [107] **Rizzo, D. M., Lillys, T. P., y Dougherty, D. E. (1996)**. "Comparisons of site characterization methods using mixed data". *Geotechnical Special Publication*, ASCE, Vol. 58(1): 157-179.
- [108] **Romero, S. y Pamukcu, S. (1996)**. "Characterization of granular material by low strain dynamic excitation and ANN". *Geotechnical Special Publication*, ASTM-ASCE, Vol. 58(2), 1134-1148.
- [109] **Romo, M. P. y Seed, H. B. (1986)**. "Analytical Modeling of Dynamics Soil Response in the México Earthquake of September 19, 1985". *Proc. Int. Conf. Of the México Earthquake-1985: Factors Involved and Lessons Learned*, pp. 148-162.
- [110] **Romo M P, y Jaime A. (1986)**. "Características dinámicas de las arcillas del valle de México y análisis de respuesta sísmica del suelo", Proyecto 6504, elaborado para el Departamento del Distrito Federal, Instituto de Ingeniería, UNAM, pp 65, marzo.
- [111] **Romo, M. P. y Villarraga, M. R. (1987)**. "Respuesta Aleatoria Tridimensional de Presas de Tierra". *Informe del Instituto de Ingeniería*, No. 584.
- [112] **Romo, M.P., Jaime, A. y Reséndiz, D. (1988)**. "General soil conditions and clay properties in the valley of Mexico", *Earthquake Spectra*, Vol. 4(4):731-752.
- [113] **Romo M P y Villarraga R. (1989)**. "Modelo teórico del comportamiento sísmico de presas. El Infiernillo", *Series del Instituto de Ingeniería*, No 518, julio.
- [114] **Romo, M. P. (1995)**. "Clay Behavior, Ground Response and Soil-Structure Interaction Studies in México City". *Proceedings. Third International Conference on Recent Advances in Geotechnical Earthquake Engineering and Soil Dynamics*, Abril 2-7, St. Louis, Missouri, Vol. II, pp: 1039 – 1051.
- [115] **Romo, M., Rangel, J., Flores, O. y García, S. (1998)**. "Aplicación de redes neuronales artificiales a la geotecnia", *Memorias de la XIX Reunión Nacional de Mecánica de Suelos*, pp 418-427, Puebla, noviembre.
- [116] **Romo, M. P. (1999)**. "Earthquake Geotechnical Engineering and Artificial Neural Networks", *IV Arthur Casagrande Lecture, XI Panamerican Congress on Soil Mechanics and Geoenvironmental Engineering*, Foz do Iguaçu, Brasil, Vol. IV.

- [117] **Romo, M., García, S., Ovando, E. y Rangel, J. (2001)**, "Dynamic characterization of Mexico City clay deposits: a neural network approach", Proceedings of the XVth International Conference on Soil Mechanics and Geotechnical Engineering, Istanbul, Turkey, Satellite Conference on "Lessons learned from recent strong earthquakes", pp 271-274, August
- [118] **Romo.M.P., García, S.R. (2003)**. "Neurofuzzy mapping of CPT values into soil dynamic properties". Soil Dynamics and Earthquake Engineering Vol. 23: 473-482
- [119] **Ripley, B. D. (1996)**. "Pattern recognition and neural networks", Cambridge University Press.
- [120] **Rosenblatt, F (1959)**. "Two Theorems of Statistical Separability in the Perceptron" Mechanization of Thought Processes. pp. 421-456, Symposium at National Physical Laboratory, London, UK 1959.
- [121] **Rosenblatt, F. (1962)**. "A comparison of several perceptron models". In Self-Organizing Systems. Spartan Books, Washington, DC.
- [122] **Russell, S. y Norvig, P. (1995)**. "Artificial Intelligence: A Modern Approach". Prentice Hall, Upper Saddle River, New Jersey.
- [123] **Santamarina, J.C. y Fratta, D. (1998)**. "Introduction to discrete signals and inverse problems in civil engineering". ASCE press. ISBN 0-7844-0311-2.
- [124] **Sarmiento N y Romo M P, (2002)**. "Análisis de la respuesta dinámica de los depósitos de suelo del valle de México con redes neuronales", Memorias de la XXI Reunión Nacional de Mecánica de Suelos, noviembre, Vol. II, pp 107-114.
- [125] **Schmertmann, J. H. (1970)**. "Static cone to compute static settlement over sand". J. Soil Mech. & Found. Div., ASCE, Vol. 96(SM3): 7302-1043.
- [126] **Schnabel, P. B., Lysmer, J. y Seed H. B. (1972)**. "SHAKE: A Computer Program for Earthquake Response Analysis of Horizontally Layered Sites". Report No. EERC 72-12, EERC, University of California, Berkeley, 88 p.
- [127] **Seed, H. B e Idriss, I. (1969)**. "The Influence of Soil Conditions on Ground Motions during Earthquakes". Journal of Soil Mechanics and Foundation Division, ASCE, Vol 94, No. SM1, pp 120-137.
- [128] **Seed, H. B., Tokimatsu, H., Harder, L. F. y Chung, R. M. (1985)**. "Influence of SPT procedure in seismic liquefaction resistance evaluations". J. Geotech. Engrg., ASCE, Vol. 111(12):1425-1445.
- [129] **Shafer, G. (1976)**. "A Mathematical Theory of Evidence". Princeton University Press, Princeton, NJ, USA.
- [130] **Shahin, M. A., Jaksa, M. B. y Maier, H. R. (2000)**. "Predicting the settlement of shallow foundations on cohesionless soils using back-propagation neural networks." Research Report No. R 167, The University of Adelaide, Adelaide.
- [131] **Shahin, M. A., Jaksa, M. B. y Maier, H. R. (2001)**. "Artificial neural network applications in geotechnical engineering." Australian Geomechanics, Vol. 36(1): 49-62.
- [132] **Shepherd A J, (1997)**. "Second-Order methods for neural networks: Fast and reliable training methods for multi-layer perceptrons", Perspectives in Neural Networks, Springer.
- [133] **Shi, J., Ortigao, J. A. R. y Bai, J. (1998)**. "Modular neural networks for predicting settlement during tunneling". J. Geotech. & Geoenv. Engrg., ASCE, Vol. 124(5): 389-395.
- [134] **Shukla S. (1988)**. "EDESYN: A KBES Shell for Preliminary Engineering Design". Master's thesis, Carnegie-Mello University, Pittsburgh.
- [135] **Sidarta, D. E. y Ghaboussi, J. (1998)**. "Constitutive modeling of geomaterials from non-uniform material tests". J. Computers & Geomechanics, Vol. 22(10): 53-71.
- [136] **Sieh D., King D. & Gientke F. (1988)**. "Dam Seepage Analysis Using Artificial Intelligence", Planning Now for Irrigation and Drainage in the 21st Century, New York: ASCE, pp 417-422.
- [137] **Sivakugan, N., Eckersley, J. D., and Li, H. (1998)**. "Settlement predictions using neural networks." Australian Civil Engineering Transactions, Vol. 40: 49-52.
- [138] **SMIS, Sociedad Mexicana de Ingeniería Sísmica A. C. (2000)**. "Base Mexicana de Datos de Sismos Fuertes". CD-ROM, Vol 2.
- [139] **Solís-Estrella, H., Ramírez-Amaro, K., Correa, F., García, S., Figueroa-Nazuno, J., y Angeles-Yreta, A. (2005)**. "Descomposición Empírica en Modos: una interpretación sísmica", publicado en las memorias del XV Congreso Nacional de Ingeniería Sísmica - A 20 AÑOS DEL TERREMOTO DE SEPTIEMBRE DE 1985 ¿Qué hemos hecho?. México D.F., 2005.

- [140] **Sterling, R. L. y Lee, C. A. (1992)**. "A neural network - expert system hybrid approach for tunnel design." Proc., 33rd United-States Symp. Rock Mechanics, J. R. Tillerson and W. R. Wawerisk, eds., Brookfield VT: Balkema, 501-510.
- [141] **Sugito, M., Goda, G. y Masuda, T. (1994)**. "Frequency dependent equi-linearized technique for seismic response analysis of multi-layered ground", Proceedings of JSCE, 493, 49-58 (in Japanese with English abstract).
- [142] **Taboada, V. M., Martínez, H. y Romo M. P. (1999)**. "Evaluation of Dynamic Soil Properties in México City Using Downhole Array Records". Soils and Foundations, Vol. 39, No. 5, pp. 81-92.
- [143] **Teh, C. I., Wong, K. S., Goh, A. T. C. y Jaritngam, S. (1997)**. "Prediction of pile capacity using neural networks". J. Computing in Civil Engineering, ASCE, Vol. 11(2):129-138.
- [144] **Terzaghi, K., y Peck, R. B. (1967)**. "Soil mechanics in engineering practice". John Wiley & Son, Inc., New York.
- [145] **Ural, D., y Saka, H. (1998)**. "Liquefaction assessment by neural networks." *Elec. J. of Geotech. Engrg.* <http://geotech.civen.okstate.edu/ejge/ppr9803/index.html>.
- [146] **UTP (2000)**. "Tutorial redes Neuronales", Universidad Tecnológica de Pereira, colombia. <http://ohm.utp.edu.co/neuronales/main1.htm>.
- [147] **Van Schuppen, J. (2004)**. "System theory for system identification", Journal of Econometrics, Vol. 118: 313-339, Elsevier.
- [148] **Vucetic, M., and Dobry, R. (1991)**. "Effect of soils plasticity on cyclic response", Journal of Geotechnical Engineering, ASCE, 117 (1), pp. 898-907.
- [149] **Wang, J. y Rahman, M. (1999)**. "A neural network model for liquefaction-induced horizontal ground displacement". Soil Dynamics and Earthquake Engineering Vol. 18: 555-568.
- [150] **Wharry M.B. & Ashley D.B. (1986)**. "Resolving Subsurface Risk in Construction Using an Expert System". Tech. Report UTCEPM-86-1, University of Texas, Austin.
- [151] **Zadeh, L.A. (1965)**. "Fuzzy sets: Information and Control". Vol. 8: 338-353.
- [152] **Zadeh, L. (1993)**. "Fuzzy Logic and Softcomputing". Plenary Speaker, Proceedings of IEEE International Workshop on Neuro Fuzzy Control. Muroran, Japan.
- [153] **Zadeh L., (1994)**. "Fuzzy logic, neural network, and soft computing", Commu. *ACM*, Vol.37.
- [154] **Zadeh, L. (1996)**. "The Role of Soft Computing and Fuzzy Logic in the Conception, Design, Development of Intelligent Systems". Plenary Speaker, Proceedings of the International Workshop on soft Computing Industry. Muroran, Japan.
- [155] **Zadeh, L. (1999)**. "From Computing with Numbers to Computing with Words from Manipulation of Measurements to Manipulation of Perceptions". Plenary Speaker, Proceedings of IEEE International Workshop on Soft Computing in Industry. Muroran, Japan.
- [156] **Zeghal, M. y Abdel-Ghaffar, A. M., (1989)**. "Identification of the Behavior of Earth Dams Using Seismic Records", report No. CRECE 9001, Center for Research in Earthquake Engineering and Construction, University of Southern California.
- [157] **Zeghal M. (1990)**. "System identification of the nonlinear seismic response of earth dams". Ph.D. Thesis, Princeton University, NJ.
- [158] **Zeghal, M. y Elgamal A. W. (1993)**. "Lotung Site: Downhole seismic data análisis". Rep., Electric Power research Institute, Palo Alto, California.
- [159] **Zentar, R., Hicher, P. y Moulin, G. (2001)**. "Identification of soil parameters by inverse analysis", Computers and Geotechnics, Vol. 28: 129-144, Elsevier.
- [160] **Zhou, Y., and Wu, X. (1994)**. "Use of neural networks in the analysis and interpretation of site investigation data." Computer and Geotechnics, 16, 105-122.
- [161] **Zhu, J. H., Zaman, M. M., y Anderson, S. A. (1998a)**. "Modeling of soil behavior with a recurrent neural network." Canadian Geotech. J., Vol. 35(5): 858-872.
- [162] **Zhu, J. H., Zaman, M. M., y Anderson, S. A. (1998b)**. "Modelling of shearing behaviour of a residual soil with recurrent neural network." Int. J. Numerical and Analytical Methods in Geomechanics, Vol. 22(8): 671-687.
- [163] **Zurada, J. M. (1992)**. "Introduction to artificial neural systems". West Publishing Company, St. Paul.