



UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO

FACULTAD DE INGENIERÍA

**ESTIMACIÓN DE PARÁMETROS SÍSMICOS
POR MEDIO DE REDES NEURONALES
ARTIFICIALES**

TESIS

Que para obtener el título de:

INGENIERO EN COMPUTACIÓN

P R E S E N T A :

JORGE GEOVANNY GARCÍA DE AQUINO

DIRECTOR DE TESIS

DR. LEONARDO ALCÁNTARA NOLASCO

Ciudad Universitaria, Cd. Mx., 2017



Solo tenemos un futuro, y estará hecho de nuestros sueños, si tenemos la valentía de enfrentarnos a las convenciones.

Soichiro Honda

Dedicatoria

A mi madre.

Por haberme apoyado en todo momento, por sus consejos, sus valores, por la motivación constante que me ha permitido ser una persona de bien, pero más que nada, por su amor.

A la señora Petra Nolasco.

Por ser una estrella de luz en mí camino. Gracias a su apoyo, consejos, cariño y amistad, he llegado a realizar una de mis más grandes metas.

Agradecimientos

A dios por brindarme la oportunidad y la dicha de la vida, al brindarme la luz necesaria para encaminar las metas que me he propuesto con confianza, fortaleza, salud, y sobre todo perseverancia.

A mi madre, por ser el pilar más importante y ser lo más bello que Dios me ha dado en esta vida. Con tu apoyo has logrado que llegue a esta meta, porque con amor me has mostrado la belleza de la vida, con tu ejemplo me has enseñado a vivir y reír con el mundo, donde hemos compartido momentos felices. Me has hecho crecer como persona, ayudándome a salir adelante en momentos difíciles para hacer de mi lo que hoy soy. A tu lado, la vida es un regalo divino, porque eres y serás un ejemplo en mi vida. Gracias Mamá te amo.

A mi padre quien a lo largo de toda mi vida me ha apoyado y motivado mi formación académica, su tenacidad y lucha interminable ha hecho de él un gran ejemplo en mi vida. Gracias por dedicar todos tus años hacia mi educación y entender que tu amor no tiene límite. Esta tesis es el resultado de lo que me has enseñado en la vida, ya que siempre has sido una persona honesta y entregada a tu trabajo. Te amo Papá.

A mis hermanos Yuridia, Edwin Daniel e Ismael, gracias por compartir alegrías y caídas de los cuales salimos triunfadores, por su confianza y por permitirme estar en sus vidas. Pero esto solo hace más fuerte el lazo que nos mantiene unidos. No deben olvidar que sería capaz de hacer cualquier cosa por ustedes, los amo.

A toda mi familia, en especial a mis tíos Ignacio, Barbara, Aparicio y Eucario, el más sincero reconocimiento al esfuerzo, orientación y apoyo que me brindaron para alcanzar una de mis metas más importantes en mi vida. Con admiración y respeto.

A mis PFS (Ale, Beth y Karen) por ser mis mejores amigas del alma, por crecer juntos y tener tantos recuerdos y anécdotas inolvidables. Dicen que los buenos amigos son los hermanos que podemos escoger, son como ángeles que Dios nos envía para que sean nuestros compañeros en toda circunstancia buena o mala que se puede presentar en la vida y con ustedes lo he comprobado.

Son muchas las personas especiales a las que me gustaría agradecer su amistad, apoyo, ánimo y compañía en las diferentes etapas de mi vida. Algunas están aquí conmigo y otras en mis recuerdos y en el corazón. Sin importar en donde estén o si alguna vez llegaran a leer estas dedicatorias quiero darles las gracias por formar parte de mi vida, por todo lo que me han brindado y por todas sus bendiciones (Daniel, Enrique, Diego, Andrés, German, Maribel, Beatriz, Jorge, Pani, Onasis, Alan, Roberto, Rafael, Kike, Renata, Víctor, Israel, Paulina, Yessica, Nelli, Elisa).

A la Señora Petra Nolasco, por confiar en mí y en mis capacidades.

Al Dr. Leonardo Alcántara Nolasco, por su apoyo, paciencia, asesorías y amistad en la realización de este trabajo de tesis y por darme la oportunidad de ser becario en las instalaciones del Instituto de Ingeniería. Mi más sincero agradecimiento.

A la Universidad Nacional Autónoma de México, por brindarme la oportunidad de estudiar una carrera y por la formación profesional que generosamente me ha brindado.

Al Instituto de Ingeniería de la UNAM, en especial a la Coordinación de Instrumentación sísmica y el grupo de Procesamiento y Análisis Sísmico (Dr. Leonardo Ramírez, Marco Macías, Luis Aguilar, Israel Molina, Mauricio Ayala, Ricardo Vázquez, Héctor Sandoval, Juan Velasco, Gerardo Castro, Alejandro Mora, Citlali Pérez, Ana Ruiz, Rosario Diance, Cristian Tejada, Servando Cortés y Eric Tejada).

A mis amigos becarios en especial a Joaquín, Berenice, Santiago, Fabiola, Diana y Fernando por la revisión crítica de este trabajo, la elaboración de mapas y de imágenes. Gracias por todos los momentos que hemos compartido, por su apoyo y por todo lo que he aprendido de cada uno de ustedes, al igual por compartir sus conocimientos conmigo. Los quiero mucho, somos un gran equipo.

ÍNDICE

1. INTRODUCCIÓN	1
2. REDES NEURONALES	6
2.1 Conceptos Generales	7
2.2 Algoritmo de entrenamiento	15
2.3 Aplicaciones en la Ingeniería Sísmica	17
3. RED ACELEROGRÁFICA EN LA CIUDAD DE OAXACA	19
3.1 Estaciones Acelerográficas	19
3.2 Registros Sísmicos	23
4. MODELO NEURONAL PARA ESTIMAR PARÁMETROS SÍSMICOS	26
4.1 Parámetros Sísmicos	27
4.2 Modelo Neuronal	32
4.3 Base de Datos Sísmicos	33
4.4 Herramienta de cómputo	34
4.5 Procedimiento de entrenamiento del Modelo Neuronal	38
4.6 Resultados	40
5. CONCLUSIONES	46
REFERENCIAS	48
ANEXO	

CAPÍTULO 1

1. INTRODUCCIÓN

En la actualidad uno de los proyectos más ambiciosos de la computación es la Inteligencia Artificial (IA), por tal motivo es difícil definir exactamente qué es y los alcances que tiene. El significado de la palabra inteligencia, está asociado con la capacidad para conocer o entender la forma en que un individuo puede resolver un problema; y artificial por otra parte, es un adjetivo que señala aquello hecho por mano, arte o ingenio del hombre (ref. 1).

Algunos científicos se han caracterizado, por la búsqueda constante para brindar facilidades y orientar sus estudios en las capacidades humanas, como una fuente de nuevas ideas para el diseño de las nuevas máquinas, en donde puedan implementarse fácilmente algoritmos para solucionar multitud de problemas que antes resultaban difíciles de resolver.




Figura 1.1 Áreas de la IA

Alan Turing, considerado el padre de la IA, plantea su artículo *Computing Machinery and Intelligence*, una prueba específica para determinar si una máquina es inteligente o no. La IA tiene su origen en la emulación burda del comportamiento de los sistemas biológicos. Se trata de un enfoque capaz de manejar las imprecisiones e incertidumbres que se presentan al resolver algún problema (reconocimiento de patrones, toma de decisiones, etc.), ofreciendo soluciones robustas y de fácil implementación (ref. 2). La IA ha tenido diversas aportaciones en diferentes áreas como (figura 1.1): 1) la lógica difusa, 2) el razonamiento aproximado, 3) los sistemas expertos, 4) los algoritmos genéticos, 5) la programación genética, 6) los sistemas clasificadores, 7) aprendizaje de árboles de decisiones, y 8) las Redes Neuronales Artificiales (RNA), entre otras.

- 1) Lógica difusa. Proporciona un mecanismo de inferencia que permite simular los procedimientos de razonamiento humano en sistemas basados en el conocimiento. Esta teoría provee un marco matemático para modelar la incertidumbre de los procesos cognitivos humanos de forma que pueda ser tratable por una computadora.

Básicamente, cualquier problema puede resolverse considerando un conjunto de variables de entrada (espacio de entrada), para obtener un valor adecuado de variables de salida (espacio de salida). Asimismo permite establecer este mapeo de una forma adecuada, atendiendo a criterios de significado y no de precisión.

- 2) Razonamiento Aproximado. En casi todas las aplicaciones de la IA es necesario procesar información incierta o imprecisa y evaluarla mediante modelos no deterministas. Dentro del campo de razonamiento incierto, se encuentra el razonamiento aproximado el cual utiliza métodos numéricos para diferenciarlo de los simbólicos de la incertidumbre. Los principales métodos de razonamiento aproximado son: el bayesiano subjetivo, los factores de certeza, la teoría de la evidencia de *Dempster y Shafer* y la teoría de la posibilidad (ref. 3).
- 3) Sistemas Expertos. Son sistemas informáticos capaces de emular el comportamiento de un experto humano en una área limitada del conocimiento. Las reglas son las características principales de los sistemas expertos. Esto significa que contienen un juego predefinido de conocimientos que se utiliza para todas las decisiones. El sistema usa reglas y las inferencias que se le indican para producir sus resultados. Dependiendo del tipo de entrada y las reglas utilizadas, los sistemas expertos pueden emplearse como herramientas cuantitativas o cualitativas. Un sistema experto genérico, consiste de dos módulos principales: la base de conocimientos y el motor de inferencia. La base, contiene el conocimiento disponible sobre un tema específico para el que se diseña el sistema. Este conocimiento se codifica con cierta notación que incluye reglas, predicados, redes semánticas y objetos. El motor de inferencia combina los hechos y las preguntas particulares utilizando el pilar de conocimiento, y seleccionando los datos y pasos apropiados para presentar los resultados.
- 4) Algoritmos Genéticos. Consisten en métodos generalizados de búsqueda, diseño y optimización que simulan un proceso y su evolución. Su objetivo principal es evolucionar a partir de una población determinada, intentando producir nuevas generaciones de soluciones que sean mejores que las anteriores. Son algoritmos matemáticos aplicables a problemas de optimización, con fundamento en la teoría de la evolución de *Darwin*, operan en un ciclo simple de selección y reproducción, implicando una recombinación y mutación del “material genético” de las soluciones. Una población de posibles soluciones se genera al azar y éstas se evalúan con respecto a un objetivo; las más aptas se combinan entre sí para producir otras nuevas. El ciclo se repite hasta llegar a un resultado aceptable u óptimo.

Al igual que en los procesos de selección natural, debe existir equilibrio entre la explotación de soluciones buenas (cruzamiento) y la búsqueda de nuevas posibilidades (mutación) para mantener una razonable diversidad en la población que evoluciona generación tras generación hasta alcanzar un punto de equilibrio que es o está muy cerca del óptimo absoluto del problema.

- 5) **Sistemas Clasificadores.** Son una fusión entre los algoritmos genéticos, el aprendizaje por refuerzo y el supervisado. Se conocen como *Learning Classifier Systems*. Básicamente buscan, mediante algoritmos genéticos y de aprendizaje, un conjunto de reglas que modelen la solución a un problema. Las reglas se componen de una condición y una acción. La población de reglas representa para cualquier condición dada, cual será la mejor acción. Esto se consigue asociando al espacio de entrada una predicción de la mejor recompensa futura obtenida para cada acción posible. Entonces, dado un estado que representa el entorno, se buscan las reglas cuya condición coincide, y de ellas se toma la acción que ofrece mejor resultado.
- 6) **Árboles de Decisión.** Sirven para clasificar instancias caracterizadas como conjuntos de atributos. Cada nodo terminal del árbol representa un atributo y tendrá tantas ramas como valores distintivos puede tomar dicho atributo. Para clasificar una instancia, se comienza por la raíz y se va siguiendo el camino que indica los valores de los atributos hasta llegar al nodo terminal de la clase a la que pertenece. El algoritmo más representativo de este tipo es denominado ID3.
- 7) **Las RNA** son modelos computacionales que pretenden emular el funcionamiento de porciones del cerebro humano en forma paralela, distribuida y adaptiva, mediante muchos procesadores conectados entre sí. Las RNA son un conjunto de técnicas matemáticas para modelar las conexiones entre una familia de datos. Por medio de un proceso de entrenamiento, las redes neuronales aprenden de los datos que se les suministran, el conocimiento adquirido se almacena como pesos sinápticos adjudicados a los distintos enlaces entre las neuronas de la red.

Esta área se caracteriza por su eficiencia en el reconocimiento y aprendizaje de patrones en un conjunto de datos no lineales, incompletos, con ruido y hasta compuestos por ejemplos contradictorios. La habilidad de esta herramienta para manipular datos imprecisos, incrementa la actividad de las redes en el procesamiento de información sin reglas claras o que no puedan ser formuladas fácilmente. Sin reglas convencionales, una red neuronal obtiene experiencia analizando automática y sistemáticamente una base de datos, para determinar pautas de comportamiento. Con base en estas normas inferidas, las RNA, realizan predicciones sobre nuevo casos, siempre que estos pertenezcan a la misma familia de las incluidas en la base de datos.

Las RNA se han utilizado para resolver problemas en diferentes áreas del conocimiento como la Medicina, las Telecomunicaciones, la Economía, etc. Las aplicaciones en Medicina encuentran su reflejo en problemas de diagnóstico médico, por ejemplo la predicción de enfermedades degenerativas cardiacas; pacientes que han sufrido un infarto recientemente presentan un cierto factor de riesgo de sufrir otro, las RNA se han utilizado para modelar el comportamiento de las arterias coronarias (ref. 4). En el área de las Telecomunicaciones una aplicación es la ecualización de canales de comunicación, lo cual consiste en recuperar la señal que, al pasar a través de un canal de comunicaciones, sufre una distorsión (ref. 5). En el área de la Economía, las redes neuronales son directamente aplicables frente a otros métodos por sus características intrínsecamente no lineales, una aplicación es la detección de posibles fraudes en tarjetas de crédito. Las RNA pueden ser usadas como elementos discriminativos para conceder o no una determinada cantidad en un cajero automático (ref. 6).

Particularmente, el estudio del fenómeno sísmico es vital para la seguridad de la población, sin embargo, dada la complejidad del problema su análisis se ha abordado por diversas áreas de la Ingeniería, como son la Civil, Geológica, Geofísica, Computacional, etc., todas ellas por supuesto ligadas a una base científica. Además involucra diversas variables en su evaluación, por lo mismo, las técnicas convencionales no ofrecen los mejores resultados y limitan el avance en el conocimiento sísmico, dando como consecuencia que las técnicas actuales no se puedan aprovechar al máximo en la mitigación de estos fenómenos. Una alternativa reciente para el fenómeno la ofrecen las RNA.

Generalmente los sismos ocurren en zonas de debilidad de la corteza a las que se les llama fallas geológicas. Los efectos de este fenómeno, entre otras cosas dependen de la naturaleza de la roca a lo largo de la falla, si ésta es poco resistente y dúctil, la energía es liberada lentamente, de lo contrario si la roca es muy resistente y rígida, la energía es liberada rápidamente provocando movimientos fuertes de terreno.

Entre la información más relevante para caracterizar un temblor están los denominados parámetros sísmicos: Magnitud, Epicentro, Profundidad focal, Distancia epicentral, Aceleración máxima, Duración de la fase intensa del movimiento, etc. Si bien la Magnitud y la Distancia epicentral son factores que condicionan el valor máximo de intensidad en un determinado lugar, también se ha observado que la repetición de diversas intensidades durante un determinado periodo es capaz de producir un mayor daño en las estructuras.

Por tal motivo el objetivo de esta tesis es presentar una alternativa de solución para estimar la Duración de la Fase Intensa del Movimiento Sísmico mediante el uso de las Redes Neuronales Artificiales, utilizando la Base de Registros sísmicos en la ciudad de Oaxaca.

En este capítulo 1 se ha hecho una breve introducción al contenido general del trabajo. Lo referente a los conceptos de las Redes Neuronales Artificiales se presenta en el capítulo 2. Los aspectos de la Red Acelerográfica de la ciudad de Oaxaca así como los registros de aceleración utilizados están incluidos en el capítulo 3. El Modelo Neuronal desarrollado para estimar la duración de la Fase Intensa se describe en el capítulo 4. Finalmente, en el capítulo 5 se incluyen las conclusiones de este trabajo.

CAPÍTULO 2

2. REDES NEURONALES

Los seres humanos siempre han buscado la manera de solucionar problemas de una forma rápida, sencilla y confiable, además de encontrar nuevos caminos que faciliten nuestra existencia, nos ha permitido el descubrimiento y desarrollo de máquinas calculadoras que ayuden a resolver de forma automática y rápida determinadas operaciones.

La capacidad de raciocinio ha permitido al ser humano desarrollar tecnologías propias orientadas a descubrir su origen. ¿Cómo funciona el cerebro? ¿Se pueden desarrollar máquinas inteligentes? ¿Se pueden construir modelos artificiales que lo emulen? Todas estas preguntas han conducido a un desarrollo exponencial de un campo multidisciplinario del conocimiento conocido como IA. Este se divide en dos clases una “macroscópica o clásica y otra microscópica o conexionista”.

En el primero se intenta modelar el funcionamiento del cerebro basándose en reglas tipo “si ocurre esto entonces...”. El nombre de macroscópica se debe a que no se toma en cuenta en ningún momento la estructura interna del cerebro, solo se modela su comportamiento con base en un funcionamiento global.

Para el caso de la segunda clase, se construyen modelos que consideran la estructura interna del cerebro; de tal forma que se integran neuronas artificiales que se combinan entre sí para formar estructuras multicapas, simulando la estructura en niveles del cerebro. Esta aproximación de la IA conocida como redes neuronales ha tenido, en los últimos años un gran desarrollo en la investigación básica y aplicada. Estos sistemas, también llamados de procesamiento distribuido en paralelo, sistemas conexionistas y neurocomputadoras, constituyen la base de las nuevas computadoras.

Entre las razones de este desarrollo, destaca el que las redes neuronales artificiales presentan en ciertos campos claras ventajas sobre las computadoras digitales comunes, llamadas del tipo *Von Neumann*, pues no sólo son capaces de aprender de la experiencia sin grandes complicaciones de *software* o *hardware*, sino que pueden resolver de forma sencilla y económica algunos de los problemas que constituyen los mayores retos para las computadoras tradicionales, tales como el reconocimiento de patrones complejos, procesamiento de imágenes, generación e interpretación de lenguaje natural, problemas de clasificación y diagnóstico difusos.

Las RNA se basan en la emulación del funcionamiento del cerebro humano, de como procesan la información las redes neuronales, para resolver problemas complejos reales, son una técnica de modelado flexible que se fundamenta en la eficiencia de los procesos nerviosos biológicos. Estos sistemas son capaces de descubrir relaciones lineales y no lineales entre datos numéricos con fines de predicción de comportamientos complejos.

Las RNA pretenden emular el funcionamiento del cerebro humano en tres aspectos:

- **Procesamiento paralelo.** Una computadora puede realizar cálculos mucho más rápido que un ser humano, pero no es capaz de desarrollar los procesos que este realiza de forma relativamente sencilla, como el de reconocer un rostro, comprender una imagen, etc. Esto se debe a que el cerebro humano, para poder realizarlo utiliza simultáneamente millones de neuronas.
- **Memoria distribuida.** En una computadora la información ocupa posiciones de memoria bien definidas, mientras que en los sistemas neuronales se encuentra distribuida por las sinapsis de la red; en caso de resultar dañada una sinapsis, no se pierde más que una muy pequeña parte de la información. Los sistemas neuronales biológicos son redundantes, de modo que muchas neuronas y sinapsis puede realizar un papel similar, por lo tanto, el sistema resulta tolerante a fallos.
- **Adaptabilidad al entorno.** Las redes neuronales artificiales aprenden de la experiencia, pudiendo generalizar conceptos a partir de casos particulares además de adaptarse fácilmente al entorno modificando sus sinapsis.

2.1 Conceptos Generales

Modelo biológico

Las neuronas desde un punto de vista funcional constituyen unidades básicas de procesamiento de información y se estima que el cerebro humano cuenta con cien mil millones de ellas, que ejecutan millones de instrucciones indispensables para realizar una vida normal. Como todo sistema de este tipo poseen un canal de entrada de información, un órgano de cómputo y un canal de salida (ref. 7).

El sistema nervioso está compuesto por millones de células llamadas neuronas, las cuales tienen características que les permiten comunicarse entre si, lo que las diferencia del resto de las células biológicas. Su estructura (figura 2.1) está integrada por dendritas, soma y axón. Las dendritas son ramificaciones extremadamente delgadas del soma que actúan como canales que transmiten la información que proviene de otras neuronas. Esta información es procesada por

el cuerpo celular llamado soma (mismo que contiene un núcleo celular) y la envía a otras neuronas a través del axón. La unión entre dos neuronas se denomina sinapsis, además se habla de la neurona presináptica (la que envía las señales), y la postsináptica (la que las recibe), ambas son unidireccionales, es decir la información fluye siempre en un único sentido, la intensidad de sinapsis no es fija, sino que puede modificarse con base en la información proveniente del medio.




Figura 2.1 Estructura de una neurona biológica

Neurona artificial

Las RNA están conformadas por unidades básicas llamadas nodos o neuronas que fungen como elementos de procesamiento. Una neurona está compuesta por una capa de entradas, conexiones (o pesos), una función de entrada, una función de transferencia y una capa de salida (ref. 8). Los elementos que constituyen la neurona artificial de etiqueta i son los siguientes (figura 2.2).




Figura 2.2 Modelo estándar de una neurona artificial

- Conjunto de entradas. Son los elementos $x_j(t)$, donde (t) representa el estado actual de la RNA.

- Pesos sinápticos. Los valores w_{ij} , que representan la intensidad de interacción entre cada neurona presináptica i y la neurona postsináptica j .
- Regla de propagación. Es definida como $n_i(t) = \sigma(w_{ij}, x_j(t))$ y permite obtener, a partir de las entradas y los pesos, el valor del potencial postsináptico n_i de la neurona.

$$n_i(t) = \sigma(w_{ij}, x_j(t)) \quad (1)$$

- Función de activación. Representada por $y_i(t) = f_i(n_i(t))$, es la salida de la neurona y su estado de activación. Se encarga de atribuir las características no lineales al procesamiento en los nodos. La función actúa sobre el valor arrojado por la función de entrada limitando su crecimiento numérico.
- Función de salida. Esta proporciona la salida actual $y_k(t)$ de la neurona k en función de su estado de activación actual $a_i(t)$. Muy frecuentemente la función de salida es simplemente la identidad $F(x) = x$ de modo que el estado de activación de la neurona se considera como la propia salida, es decir:

$$y_i(t) = F_i(a_i(t)) = a_i(t) \quad (2)$$

De manera general, la operación de la neurona i puede expresarse de la siguiente forma

$$y_i(t) = F_i(f_i(a_i(t-1), \sigma_i(w_{ij}, x_j(t)))) \quad (3)$$

Al conjunto de pesos de la neurona se añade un parámetro adicional θ_i que se denominara umbral (mínima señal registrada por un sistema), y se resta del potencial postsináptico por lo que el argumento de la función de activación se expresa:







$$\sum_j w_{ij} x_j - \theta_i \quad (4)$$

Ahora bien, si los índices i y j comienza en 0, y definiendo $w_{i0} = \theta_i$ y $x_0 = -1$ constante), se puede obtener el comportamiento de la neurona a través de:

$$y_i(t) = f_i \left(\sum_{j=0}^n w_{ij} x_j \right) \quad (5)$$

Después de definir la neurona estándar, basta con establecer la forma de la función de transferencia para determinarla por completo. Una función de transferencia se escoge para satisfacer alguna característica del problema que la neurona está intentando resolver. Hay una gran variedad de funciones de transferencia, en la tabla 2.1 se muestra, para cada una de estas funciones, sus características principales y su representación gráfica.

Tabla 2.1 Funciones de transferencia

Nombre	Función	Intervalo	Gráfica
Identidad	$y(x) = x$	$\{-\infty, +\infty\}$	
Escalón	$y(x) = \begin{cases} 0, & x < 0 \\ 1, & x \geq 0 \end{cases}$	$\{0, +1\}$	
Lineal por tramos	$y(x) = \begin{cases} 0, & x < 0 \\ x, & 0 \leq x \leq 1 \\ 1, & x \geq 1 \end{cases}$	$\{0, +1\}$	
Sigmoide	$y(x) = \frac{1}{1 + e^{-x}}$	$\{0, +1\}$	
Gaussiana	$y(x) = e^{-x^2}$	$\{0, +1\}$	
Senoidal	$y(x) = \begin{cases} 0, & x < (-5)(\pi) \\ \frac{\sin\left(\frac{x}{10}\right)}{2} + 0.5, & 0 \leq x \leq 1 \\ 1, & x \geq (5)(\pi) \end{cases}$	$\{0, +1\}$	

Arquitectura de las Redes Neuronales Artificiales

Una Red Neuronal Artificial está constituida por neuronas interconectadas entre si, cada una de ellas recibe señales de entrada proveniente de otras y tienen una gran variedad de formas en las que se pueden organizar y conectar, a cada una de estas formas se le llama arquitectura. La cual se define a través de: a) número de capas, b) el tipo de conexiones y c) el grado de conexión (ref. 9).

- a) Número de capas. Las neuronas se organizan en unidades estructurales denominadas capas, su información es procesada en paralelo y en distintos niveles, de tal forma que la información fluye de las capas superiores a las capas inferiores. En términos del número de capas las RNA se pueden clasificar en dos:
- Red neuronal monocapa. Es la red más sencilla ya que se tiene una capa que proyecta las entradas a una capa de salida donde se realizan los cálculos, sus conexiones puede ser laterales o cruzadas (figura 2.3).




Figura 2.3 Red neuronal monocapa

- Red neuronal multicapa. Es una red donde hay un conjunto de capas intermedias, llamadas capas ocultas, entre la capa de entrada y la de salida (figura 2.4).




Figura 2.4 Red neuronal multicapa

b) Tipo de conexiones. Las conexiones entre dos neuronas artificiales se realizan de manera unidireccional, es decir la información solo fluye en un sentido, debido a esta propiedad se pueden clasificar según el tipo de conexión.

- Conexiones de propagación hacia adelante o *feedforward*. La propagación de las señales se transmite solo en una dirección y solamente de la entrada hacia la salida. Este tipo de conexión cuenta con capas cuyos nodos no están interconectados, sin embargo, sí lo están con los de la capa siguiente.
- Conexiones de retroalimentación o *feedback*. La conexión se caracteriza por la existencia de lazos de retroalimentación, es decir, las capas están unidas desde la salida hasta la entrada en el orden inverso en el que viajan las señales de la información. Estos lazos pueden ser entre neuronas de diferentes capas, de la misma capa o entre una misma neurona (figura 2.5).




Figura 2.5 Función de conexión de retroalimentación

c) Grado de conexión. No existe una regla la cual establezca que una neurona debe de estar conectada con todas las neuronas de la capa siguiente. Esto lleva a que se puedan clasificar las redes en totalmente conectadas y en parcialmente conectadas.

- Redes neuronales totalmente conectadas. Todas las neuronas de una capa se encuentran conectadas con las de la capa siguiente (redes no recurrentes) o con las de la anterior (redes recurrentes).
- Redes parcialmente conectadas. No hay conexión total entre neuronas de diferentes capas.

Tipos de aprendizaje

El aprendizaje es el proceso por el cual una RNA modifica sus pesos en respuesta a una información de entrada, con el objetivo de permitir a la red realizar correctamente el tipo de procesamiento deseado. Para que la red resulte operante es necesario entrenarla, antes de iniciar el entrenamiento se debe definir la condición de ajuste a una tarea específica, es decir cuando la red ha “aprendido”. Entre los criterios más comunes se encuentran: 1) se ha alcanzado una cota de error que se considere suficientemente pequeña, 2) se ha llegado a un número máximo de iteraciones y 3) se ha llegado a un punto de saturación en el que, aun cuando el proceso continúe por más que se entrene, ya no es posible reducir el error.

La fase de entrenamiento consiste en hacer que la red sea capaz de extraer, a partir de ejemplos, normas generales que le permitan en el futuro responder adecuadamente a patrones nunca antes vistos. Existen dos tipos de aprendizaje: a) supervisado y b) no supervisado.

- a) Aprendizaje supervisado. Se presenta a la red un conjunto de patrones, junto con la salida esperada e iterativamente esta ajusta sus pesos hasta que la salida tiende a ser la deseada, para ello se utiliza información detallada del error que se comete en cada paso. De este modo, la red es capaz de estimar relaciones entrada/salida sin necesidad de proponer una cierta forma funcional de partida. Hay tres tipos de aprendizaje supervisado:
 - Aprendizaje por corrección de error. Se lleva a cabo ajustando los pesos de las conexiones de la red en función de la diferencia entre los valores deseados y los obtenidos en la salida
 - Aprendizaje por refuerzo. Se basa en la idea de no disponer de un ejemplo completo del comportamiento deseado, es decir, de no indicar durante el entrenamiento de forma exacta la salida que se desea que proporcione la red ante una determinada entrada.
 - Aprendizaje estocástico. Consiste básicamente en realizar cambios aleatorios en los valores de los pesos de las conexiones de la red y evaluar su efecto a partir del objetivo deseado y de distribuciones de probabilidad.

- b) Aprendizaje no supervisado. En este tipo de aprendizaje la red no requiere influencia externa para ajustar los pesos de las conexiones entre sus neuronas y no recibe ninguna información por parte del entorno que le indique si la salida generada en respuesta a una determinada entrada es o no correcta. Asimismo se les proporcionan únicamente los estímulos y ellas ajustan sus interconexiones basándose en sus propias salidas.

Tipos de RNA

- Perceptrón. A partir del modelo de la neurona artificial, *Rosenblatt* desarrolló el modelo del Perceptrón, está compuesto por dos capas de neuronas, una de entrada y otra de salida, su información fluye unidireccionalmente, de la capa de entrada hacia la capa de salida. Su proceso consiste en la suma de señales de entrada, multiplicadas por valores de pesos escogidos inicialmente aleatorios y enviados como respuesta (ref. 10).
- Adeline. La red adeline (*Adaptive Linear Element*) es un modelo desarrollado por *Bernard Widrow* y *Marcian E. Hoff*, utiliza una neurona similar a la del perceptrón pero de respuesta lineal y cuyas entradas pueden ser continuas. Implementa como método de aprendizaje la regla de *Widrow-Hoff*, también conocida como regla *MLS (Least Mean Squares)*, que realiza una actualización continua de los pesos sinápticos de acuerdo a la contribución de cada neurona sobre el error total de la red. Este método produce un conjunto de pesos sinápticos óptimos y en caso que los vectores de entrada sean linealmente independientes produce una asociación perfecta entre entradas-salidas.
- Perceptrón multicapa. El Perceptrón multicapa es una extensión del Perceptrón, está integrado de una capa de entrada, cuya función es transmitir la información hacia la red, después existen varias capas ocultas, cuya misión es procesar y transmitir la información hacia la capa de salida que puede estar integrada de uno o varios nodos (ref. 11). El flujo de la información se realiza en la dirección que va de la capa de entrada hasta la capa de salida y está restringida la comunicación lateral con nodos de una misma capa, la conexión entre nodos se realiza únicamente con los elementos de la capa siguiente (figura 2.6). Las características anteriores le permiten contar con una estructura no lineal con tolerancia a fallas, para poder establecer la relación existente entre el conjunto de datos de entrada y el correspondiente a los datos de salida.




Figura 2.6 Estructura mínima del perceptrón multicapa

El número de neuronas que forman las capas de entrada y de salida está determinado por el problema en cuestión, mientras que el número de capas ocultas y de neuronas en cada una de ellas no está fijado ni por el problema ni por ninguna regla teórica, es el diseñador quien define dicha arquitectura(ref. 12).

2.2 Algoritmo de entrenamiento

Retropropagación

El algoritmo de retropropagación es el método de entrenamiento más utilizado en redes multicapas de propagación hacia adelante. Se basa en el aprendizaje supervisado en el que se distinguen dos fases: propagación hacia adelante y propagación hacia atrás. En la primera, un patrón de entrada se presenta a la red como estímulo en los nodos de la capa de entrada. Su efecto se propaga a través de toda la red, capa por capa hasta que una señal de salida es producida. El valor de salida actual es comparado con el valor de salida deseado, obteniéndose un determinado error para cada neurona de salida. Dicho error es propagado hacia atrás desde la capa de salida a través de cada neurona en las capas ocultas que contribuyen directamente a la salida. Cada neurona en las capas intermedias, solo recibe una parte total del error, esto de acuerdo a la contribución relativa que haya aportado cada neurona a la salida original. Este proceso se repite en cada capa, hasta que cada neurona en la red ha recibido un valor determinado del error que describe su contribución relativa al total. Con base en lo anterior, se actualizan los pesos de la conexión en la red para hacer que esta converja hacia un estado que permita clasificar correctamente todos los patrones de entrada (ref. 13).

Algoritmo de retropropagación

El algoritmo de retropropagación (*BP* por sus siglas en inglés) busca el error mínimo de la función en el espacio de los pesos, usando el método del gradiente descendiente. La combinación de los pesos que minimizan la función de error es considerada para ser una solución al problema de aprendizaje (ref. 14). De acuerdo con lo anterior, el orden para aplicar el algoritmo *BP* sería el siguiente:

1. El valor de entrada es propagado hacia adelante a través de la red neuronal hasta obtener el valor de salida, después se calcula para la neurona d el error e_b asociado, de tal forma que:

$$e_b = d_b - y_b \quad (6)$$

Donde y_b es la salida calculada y d_b es la salida deseada de la neurona b .

El error e_b es usado para calcular un valor δ_b , el cual permite ajustar los pesos:

$$\delta_b = e_b g(y_b) \quad (7)$$

Donde $g(y_b)$, es la función de activación.

2. Una vez obtenido el valor de δ_b se calcula el valor δ_c de las capas anteriores con la siguiente ecuación.

$$\delta_c = ng(y_c) \sum_{b=0}^n \delta_b W_{bc} \quad (8)$$

Donde b es el número de neuronas en esta capa y n es la tasa de aprendizaje propuesto heurísticamente, el cual determina que tanto debe ser ajustado el peso. Por lo tanto, los valores de ΔW con el que los pesos deben ser ajustados, se calcula

$$\Delta W_{bc} = \delta_c y_b \quad (9)$$

El valor ΔW_{bc} permite modificar el peso W_{bc} de forma tal que el valor ajustado estará dado por:

$$W_{1c} = W_{1b} + \Delta W_{jc} \quad (10)$$

3. Realizado lo anterior, el algoritmo de *BP* se mueve hacia la siguiente entrada y ajusta los pesos de acuerdo a la salida. El proceso se repite hasta que se alcanza una condición límite previamente determinada para detenerlo.

2.3 Aplicaciones en la Ingeniería Sísmica

El uso de la IA por medio de las RNA ha abarcado diversos campos del conocimiento y la Ingeniería Sísmica no ha estado ajena a tal hecho. Actualmente, en la solución de los problemas de índole sísmica se utilizan una serie de hipótesis simples que permitan encontrar la solución a un determinado fenómeno. Sin embargo, este recurso en muchas ocasiones provoca que se esté lejos de la solución debido a la falta de un entendimiento real del problema. Como se ha establecido las RNA artificiales son una herramienta de cómputo aproximado que no requiere de dichas hipótesis para llegar a una solución de aplicación práctica.

En el caso de la Ingeniería Sísmica las RNA se han utilizado para calcular diversos parámetros sísmicos como lo son la Magnitud de un temblor y la intensidad de los movimientos sísmicos; también se han utilizado para estimar la respuesta del suelo considerando su constitución así como la respuesta dinámica de estructuras (edificios, puentes, presas, etc.) ante acción sísmica. A continuación se indican 3 casos de aplicación:

1. Evaluación del movimiento del terreno. Después del sismo del 19 de septiembre de 1985 ($M=8.1$) diversas investigaciones sobre la respuesta del terreno se han realizado a partir de una importante Base de Datos Sísmicos recolectados desde 1961 en el valle de México. La integración de este vasto conjunto de información abrió la oportunidad de utilizar procedimientos basados en el conocimiento para modelar la respuesta sísmica de los depósitos de suelo. Entre las técnicas innovadoras se encontró la asociada a las RNA, para ello se propuso un modelo que utilizando registros de aceleración permitiera la obtención del Espectro de Respuesta para fines de diseño sísmico de estructuras (ref. 15).
2. Sismicidad Inducida. En general cuando se habla de la generación de sismos, al término se le asocia con aquellos producidos ya sea por la actividad de las placas tectónicas o por el vulcanismo; sin embargo existen otros denominados sismos inducidos, especialmente en áreas en donde se almacena una gran cantidad de aguas, como lo son los vasos de las grandes presas para la generación de energía eléctrica o riego. Al almacenarse agua, esta se filtra tanto en los depósitos de suelo como en las montañas aledañas, provocando un incremento importante de la carga a la que han estado sometidos y por lo tanto produciéndose una eventual falla en su estructura y por ende el colapso de material, a los movimientos generados por este fenómeno se le conoce como sismicidad inducida.

En estos casos las RNA artificiales se han utilizado para estimar la Magnitud máxima de los eventos, sobre todo para estimar si pueden poner en riesgo la estructura de contención de agua conocida como presa (ref. 16).

3. Evaluación de la Aceleración Máxima. La Aceleración máxima o pico ha sido utilizada para establecer: 1) el efecto de un sismo en una determinada localidad, 2) dicho parámetro también ha sido utilizado para la elaboración de mapas de zonificación sísmica que permitan generar espectros de diseño sísmico y 3) más recientemente para la generación automática de mapas de intensidad inmediatamente después de la ocurrencia de un temblor. Los dos primeros casos serán útiles de la elaboración de las normas sísmicas y su puesta en práctica después del periodo de investigación; sin embargo el último tiene una utilidad inmediata pues provee a las autoridades y a los sistemas de protección civil una herramienta para atender la emergencia sísmica. Las RNA se han utilizado en estos aspectos, en el caso de la estimación de Amax se han desarrollado modelos que utilizan como valores de entrenamiento los parámetros sísmicos de: Magnitud, Distancia epicentral, Profundidad Focal e información sobre la fuente sísmica así como las características del tipo de depósito del suelo (ref. 17).

CAPÍTULO 3

3. RED ACELEROGRÁFICA EN LA CIUDAD DE OAXACA

La ciudad de Oaxaca por su posición geográfica, se ha visto afectada por diversos eventos sísmicos importantes a lo largo de su historia, se puede considerar el año de 1970 como el principal antecedente para instalar una red acelerográfica en dicha ciudad debido a la puesta en operación de la primera estación con registros de aceleración en la Facultad de Medicina de la Universidad Autónoma Benito Juárez (OXMF). Posteriormente, en 1998 da inicio el proyecto de la Red acelerográfica de la ciudad de Oaxaca (RACO) con la instalación de 8 estaciones adicionales (ref. 18). Lo anterior, ha permitido realizar estudios sobre la propagación de las ondas sísmicas, su atenuación y el efecto de amplificación que sufren en los diferentes tipos de suelo en la ciudad.

3.1 Estaciones Acelerográficas

Una estación acelerográfica es una infraestructura de observación y medición del movimiento sísmico (ref. 19). De manera general se puede decir que está integrada por una base de concreto, una caja metálica y finalmente una torre metálica sobre la cual se instalan los paneles solares (figura 3.1).

- La base de concreto está firmemente ligada al terreno para evitar desplazamientos relativos entre esta y el propio terreno; en el caso de roca se utilizan anclas metálicas y para la condición de suelo se cuela un muro perimetral de concreto armado.
- La caja metálica se encuentra embebida en la base de concreto y en su interior alberga el acelerógrafo (instrumento de registro), el regulador de corriente y las baterías.
- En la torre metálica se instalan los paneles solares utilizados para el suministro de la alimentación eléctrica. En la misma también se instala el sistema satelital de control de tiempo (GPS).




Figura 3.1 Estación Acelerográfica, a) roca, b) suelo (ref. 20)

El acelerógrafo es un instrumento autónomo, de alta resolución, cuyo objetivo es registrar los niveles de aceleración producidos por la actividad sísmica. Este dispositivo está integrado principalmente por los sensores y el registrador; los primeros se componen de acelerómetros (transductores que convierten el movimiento sísmico en una señal eléctrica). El registrador tiene tres componentes, el primero realiza la conversión analógica-digital de la señal, el segundo se encarga del control de datos y el último de su almacenamiento. Su operación consiste en muestrear continuamente las señales analógicas de aceleración y las convierte a señales digitales, inmediatamente el aparato comienza a registrar la información en una unidad de memoria (figura 3.2).




Figura 3.2 Componentes de un acelerógrafo K2 (ref. 21)

Para estudiar la respuesta sísmica de los diferentes tipos de suelos, como se indicó, en 1970 se instaló la estación OXFM y en 1998 se pone en operación la estación en el parque la ciudad de las Canteras (OXLC), construida sobre un afloramiento de roca. En 1999 se instalaron 5 estaciones más en diferentes tipos de suelo, considerando la zonificación preliminar establecida para el valle de Oaxaca (ref. 22). Las estaciones se ubican en la División de Ciencias de la Tierra del Instituto Tecnológico de Oaxaca (OXTO), la Facultad de Arquitectura de la Universidad Autónoma Benito Juárez (OXCU), y tres más en la zona histórica de la ciudad, en las escuelas primarias Múgica (OXPM), Benito Juárez (OXBJ) y en la Alameda de León (OXAL) frente a la Catedral de Oaxaca. Finalmente, se integraron a la red las estaciones ubicadas en las oficinas de la unidad de Protección Civil de Oaxaca (OXPC) y en las instalaciones del aeropuerto (OXAE) al sur de la ciudad (ref. 23). La tabla 3.1 resume las estaciones que integra la RACO y en la figura 3.3 se indica su ubicación.

La construcción de las estaciones se hizo considerando los siguientes criterios: alcanzar una cobertura general de la zona urbana de alto riesgo sísmico en la ciudad de acuerdo a la microzonificación sísmica existente, instrumentar sitios con diferentes condiciones de subsuelo y contar con una referencia en roca. En todas ellas se requirió libre acceso, seguridad y protección.

Tabla 3.1 Estaciones de la RACO

Estación	Clave	Coordenadas		Equipo
		Lat. N	Long. W	
Facultad de Medicina	OXFM	17°084'	96°710'	ETNA/4441
Alameda de León	OXAL	17°061'	96°726'	ETNA/1531
Primaria Benito Juárez	OXBj	17°067'	96°744'	ETNA/1020
Ciudad Universitaria	OXCu	17°049'	96°713'	ETNA/1022
Primaria Múgica	OxPM	17°061'	96°717'	ETNA/1021
Instituto Tecnológico	OxTO	17°078'	96°744'	ETNA/1918
Las Canteras	OxLC	17°060'	96°700'	ETNA/1328
Aeropuerto	OxAE	17°001'	96°721'	ETNA/4454
Protección Civil	OxPC	17°051'	96°723'	ETNA/4576




Figura 3.3 Ubicación de las estaciones acelerográficas de la RACO

3.2 Registros Sísmicos

Los sismos que han ocurrido en México durante los últimos años son prueba de la necesidad de contar con registros instrumentales de los temblores con el fin de precisar sus parámetros sísmicos tanto en el suelo como en las estructuras. Los instrumentos que se emplean principalmente para poder realizar estas tareas son los sismógrafos y los acelerógrafos que registran el movimiento del terreno al paso de las ondas sísmicas.

El estado de Oaxaca ha sido seriamente afectado por los eventos sísmicos generados en la zona de subducción definida entre las Placas de Cocos y de Norteamérica. Entre los sismos producidos se pueden señalar los eventos de: 1931 ($M=7.8$), 1980 ($M=7.1$), 15 de junio ($M=7$) y 30 de septiembre ($M=7.6$) ambos en 1999. Debido a la falta de información de la respuesta sísmica del subsuelo del estado y la forma en que los efectos de sitio modifican los movimientos sísmicos, en Oaxaca se han instalado redes de instrumentación sísmica con equipos sismológicos y acelerográficos, por parte de instituciones dedicadas al estudio de la actividad sísmica.

Durante el periodo 1972 a 2004 se integró una base de 172 registros de aceleración obtenidos en la ciudad de Oaxaca y que fueron producidos por 67 sismos cuyas magnitudes se encuentran entre 4.1 a 7.8. Es importante señalar que de la Base de Datos aquí integrada fueron eliminados una gran cantidad de registros debido a su baja relación señal-ruido, por lo que la base se redujo a 151 registros de aceleración. En la figura 3.4 se incluye la localización epicentral de los eventos sísmicos citados, se aprecia que la gran mayoría de los temblores, proceden de la región costera del estado, un menor número se localizan hacia la parte central y algunos más en las fronteras con los estados Chiapas, Veracruz, Puebla y Guerrero.

En la tabla 3.2 se incluye la información referida. La clave del sismo registrado tiene el formato AAAAMMDDE, en donde AAAA se refiere al año, MM al mes, DD al día y E al número de evento. Además se incluye la magnitud del sismo y la clave de las estaciones que registraron el evento.




Figura 3.4 Localización de los epicentros de la Base de Datos de la ciudad de Oaxaca (ref. 24)

Tabla 3.2 Registros de aceleración de la Base de Datos de la ciudad de Oaxaca

#	Sismo	M	Estación de Registro	#	Sismo	M	Estación de Registro
1	197308281	6.8	OXFM	35	200111101	6	OXPM, OXTO
2	197811291	7.8	OXFM	36	200111281	6	OXTO
3	198010241	7	OXFM	37	200201161	6.3	OXLC, OXPM, OXTO
4	198206072	7	OXFM	38	200201301	5.1	OXFM, OXLC, OXPM, OXTO
5	198301241	5.3	OXFM	39	200202261	5	OXTO
6	199407041	5.9	OXFM	40	200205111	4.5	OXPM, OXTO
7	199408271	5	OXFM	41	200206071	4.7	OXFM, OXTO
8	199408281	5.2	OXFM	42	200206072	5.6	OXFM, OXAL, OXLC, OXPM, OXTO
9	199509141	7.2	OXFM	43	200206111	4.9	OXTO
10	199604011	5	OXFM	44	200206181	4.5	OXFM
11	199802031	6.2	OXFM	45	200208051	5.3	OXFM, OXLC, OXPM, OXTO
12	199805021	4.4	OXFM	46	200208271	4.9	OXFM, OXAL, OXLC, OXPM, OXTO
13	199906151	7	OXFM, OXLC	47	200211081	5.2	OXTO
14	199906152	4.5	OXFM, OXLC	48	200212021	4.7	OXTO
15	199909301	7.5	OXFM, OXLC	49	200212291	4.6	OXFM, OXPM, OXTO
16	199910071	4.4	OXAL, OXTO	50	200301221	7.6	OXLC
17	199910251	4.6	OXTO	51	200302011	5.3	OXTO
18	199911061	4.5	OXFM, OXAL, OXLC, OXPM, OXTO	52	200306131	4.1	OXTO
19	199911101	4.3	OXAL, XPM, OXTO	53	200307081	4.6	OXTO
20	199911291	4.4	OXTO	54	200309251	4.6	OXTO
21	199912171	4.4	OXPM, OXTO	55	200312011	4.3	OXAL, OXPM, OXTO
22	200001191	4.5	OXLC, OXPM, OXTO	56	200401131	5.1	OXFM, OXAL, OXLC, OXPM
23	200003011	4.7	OXFM, OXLC, OXPM, OXTO	57	200401132	5.5	OXFM, OXAL, OXLC, OXPM, OXTO
24	200003121	6.4	OXLC, OXTO	58	200401141	4.6	OXTO
25	200005101	4.7	OXFM, OXPM, OXTO	59	200401171	4.7	OXFM, OXAL,
25	200005101	4.7	OXFM, OXPM, OXTO	59	200401171	4.7	OXFM, OXAL, OXLC, OXPM, OXTO
26	200007211	5.9	OXTO	60	200402101	4.4	OXFM, OXAL, OXTO
27	200008171	4.4	OXTO	61	200402181	4.3	OXFM, OXAL, OXLC, OXPM, OXTO
28	200009291	4.7	OXLC, OXPM, OXTO	62	200404201	5.4	OXFM, OXAL, OXPM, OXTO
29	200010171	5.4	OXTO	63	200405061	4.3	OXTO
30	200101261	5	OXTO	64	200406141	5.8	OXFM, OXAL, OXPM, OXTO
31	200102191	4.8	OXTO	65	200408011	4.6	OXFM, OXAL, OXTO
32	200102201	4.7	OXTO	66	200408071	5.3	OXFM, OXAL, OXLC, OXPM, OXTO
33	200109081	4.8	OXAL, OXLC, OXPM, OXTO	67	200408181	5.7	OXFM, OXAL, OXLC, OXPM, OXTO
34	00110031	4.4	°				

CAPÍTULO 4

4. MODELO NEURONAL PARA ESTIMAR PARÁMETROS SÍSMICOS

Los sismos o temblores, son vibraciones de la corteza terrestre, generados por distintas fuentes como son: los deslizamientos de laderas, el vulcanismo o el desplazamiento de las placas tectónicas; sin embargo, también la actividad humana puede generar este tipo de movimientos, siendo las pruebas nucleares un ejemplo típico. Para la Ingeniería Sísmica los temblores de mayor relevancia son los de origen tectónico debido a la gran magnitud que puede alcanzar y a las grandes áreas que pueden afectar.

Las presiones que se generan en la corteza, por los flujos de magma desde el interior de la tierra llegan a vencer la fricción que mantiene en contacto los bordes de las placas, rompiendo la roca y produciendo caídas de esfuerzos y liberación de enormes cantidades de energía almacenada; una parte de esta se libera en forma de ondas vibratorias que se propagan a grandes distancias (ref. 25).




Figura 4.1 Acelerogramas correspondientes a las tres direcciones, Estación OXLC, sismo del 9 de febrero de 2010 (M=5.8)

Una de las maneras en que se pueden estudiar las características del movimiento del terreno es a través de registros de aceleraciones los cuales almacenan gran cantidad de información, que sirve para realizar una descripción precisa del movimiento del terreno. Los registros muestran la aceleración del terreno en función del tiempo, en dos direcciones horizontales y una vertical (figura 4.1).

4.1 Parámetros Sísmicos

Para la caracterización de un sismo y del efecto que produce en un lugar determinado se utilizan diversos parámetros sísmicos entre los que se pueden indicar:

- 1) Hipocentro o Foco. Es un punto en el interior de la tierra en donde inicia la ruptura de la falla, liberando la energía necesaria para producir un sismo en un determinado tiempo y espacio, esta energía se propaga en formas de ondas (ref. 26).
- 2) Epicentro. Es la proyección vertical hacia la superficie terrestre del hipocentro (figura 4.2).




Figura 4.2 Puntos de proyección de un sismo

- 3) Profundidad focal. Es la distancia vertical entre el Hipocentro y la superficie (Epicentro) y es un parámetro importante para determinar el potencial de daño de un sismo. La mayoría de los temblores perjudiciales son someros, es decir, tienen una profundidad focal menor a 70 km, por arriba de este valor los eventos sísmicos se clasifican como de profundidad intermedia o profunda.

- 4) Distancia Epicentral. Se define como la distancia entre el epicentro y el sitio de medición (estación sismológica), se determina empleando la fórmula para calcular la distancia entre dos puntos, la cual se expresa a continuación (figura 4.3).

$$D = \sqrt{(X_e - X_s)^2 + (Y_e - Y_s)^2} (K) \quad (11)$$

en donde:

D = Distancia epicentral

(X_e, Y_e) = Coordenadas del epicentro

(X_s, Y_s) = Coordenadas del sitio de registro

$K = 111.12$ (Constante para convertir los valores de las coordenadas en grados a km)



Figura 4.3 Distancia epicentral y Profundidad focal

- 5) Magnitud. Este concepto fue introducido por *Charles Richter* en 1935 y lo asoció a la energía de deformación liberada en el foco sísmico (ref. 27). El valor de la magnitud base fue determinado como aquel que es producido por una onda de amplitud de una micra a una distancia de 100 km del epicentro, por lo que se estableció la expresión:

$$M_R = \log(A / A_0) \quad (12)$$

A = Amplitud del Sismograma a la misma distancia que la amplitud

La energía liberada esta dada por:

$$\text{Log}_{10} E = 11.4 + 1.5M \quad (13)$$

E = Energía en ergios

M = Magnitud

Existen varios tipos de magnitudes: 1) Local (M_L), definida originalmente para el sur de California con el uso de un sismómetro de torsión *Wood-Anderson*, 2) Ondas de cuerpo (M_b) cuya estimación es a partir de la amplitud de la ondas de cuerpo, 3) Ondas superficiales (M_s). Sin embargo una de las más empleadas es la de 4) Momento Sísmico (M_w) la cual está basado en el deslizamiento y el área de fractura de la zona.

$$M_w = \frac{2}{3} \log M_0 - 10.73 \quad (14)$$

en donde:

$M_0 = \mu Ds$ (Momento Sísmico)

μ = Módulo de rigidez de la roca

D = Desplazamiento promedio en el área de falla

S = Área del desplazamiento

- 6) Amplitud del movimiento. Una forma de describir la respuesta del suelo ante la acción sísmica, es con un historial de los movimientos. La amplitud de estos queda definida por las trazas del registro sísmico, expresadas en términos de aceleración, velocidad o desplazamiento (figura 4.4). Los valores Amax, Vmax, Dmax representan los máximos del correspondiente parámetro y son vitales para estimar la intensidad que un movimiento sísmico generó en un determinado lugar.




Figura 4.4 Amax, Estación OXLC, sismo del 9 de febrero 2010, (M=5.8)

- 7) Duración de la fase intensa. La duración de la fase intensa del movimiento del suelo durante un sismo D_{FI} pretende ser una variable que ayude a entender mejor las características dinámicas del suelo. De acuerdo con la literatura, diversas investigaciones han sido desarrolladas con el fin de explicar, en forma empírica o analítica, el concepto de la D_{FI} , algunos investigadores la han definido como el lapso de tiempo en el que ocurren las mayores amplitudes de aceleración durante un sismo (figura 4.5), a partir de un determinado manejo de los registros sísmicos obtenidos para una zona específica, aunque los resultados pueden ser difícilmente generalizados a todas las regiones sísmicas del mundo (ref. 28).




Figura 4.5 Duración de la fase intensa, Estación OXLC, sismo del 9 de febrero 2010, (M=5.8)

EL profesor Arturo Arias, en 1970, propone una expresión que refleja la energía sísmica en un determinado sitio y que está contenida en el registro obtenido ya sea por un acelerograma o un sismograma (ref. 29). Para estimar la Intensidad Sísmica en un determinado sitio propone la expresión:

$$I_A = \frac{\pi}{2g} \int_0^{t_0} a^2(t) dt \quad (15)$$

I_A = Intensidad de Arias

$a(t)$ = Son los valores de aceleración del suelo

g = Gravedad de la Tierra

t_0 = Duración total del movimiento

La expresión representa en su totalidad la intensidad en un sitio de registro y producida por el arribo al mismo de las ondas sísmicas. Este valor de intensidad puede ser estimado mediante un registro de aceleración o de velocidad.

Considerando la ecuación 15 se estableció una metodología gráfica para el cálculo de la duración de la fase intensa del movimiento sísmico registrado, la cual se basa en la acumulación de la energía durante un cierto intervalo. El procedimiento radica en realizar la suma acumulada de los valores $a^2(t)$, para el acelerograma en cuestión. Generalmente se considera que la D_{FI} , se encuentra entre los límites de 5 a 95% de la energía acumulada.

En la figura 4.6 se muestra la forma de calcular la D_{FI} , según la propuesta de Arias, se determinan los tiempos t_0 y t_f para los cuales ocurren respectivamente el 5 y el 95% de la acumulación de la energía. Finalmente el valor de D_{FI} queda definida por:

$$D_{FI} = 95\% - 5\% \quad (16)$$




Figura 4.6 Duración de Arias

4.2 Modelo Neuronal

La duración de la fase intensa del movimiento sísmico es precisamente aquel intervalo en el cual se genera la mayor energía del movimiento sísmico, la cual está asociada al mayor daño producido en suelos y estructuras. Por lo que dada la importancia de este parámetro sísmico, se decidió implementar un Modelo Neuronal para estimar su valor aún ante eventos hipotéticos, pero con una alta probabilidad de ocurrencia real.

El modelo que se propone se basa en una arquitectura del Perceptrón Multicapa en donde la información se transmite únicamente hacia el frente y no se permiten conexiones laterales. De esta manera el modelo está representado por una capa de entrada, un máximo de dos capas ocultas y una capa de salida. Con relación a la capa de entrada se determinó que los parámetros que tienen una mayor influencia en el valor de la duración de la fase intensa son: Magnitud (M), Distancia epicentral (De) y Profundidad focal (Pf). Con la finalidad de considerar la posición geográfica de los epicentros con relación a los sitios de registro se incluyó el parámetro Azimut (Az), el cual para el enfoque de esta tesis se definió como el ángulo que se forma entre el norte geográfico y el segmento dirigido que va del epicentro a la estación como se describe en la figura 4.7.




Figura 4.7 Definición del parámetro Azimut (Az)

Como los datos para el modelo incluyen diferentes condiciones del subsuelo en donde se obtuvieron los registros sísmicos, se definió un parámetro de clase que atienda, de manera genérica el tipo de suelo (Cs). Por lo que se definieron para Cs los valores: 1= Roca, 2= Intermedio y 3= Blando.

Finalmente, la capa de salida está determinada por un solo nodo que contiene el valor de la duración de la fase intensa (D_{FI}). De lo anterior la arquitectura del modelo está representada en forma general como se describe en la figura 4.8.




Figura 4.8 Arquitectura del Modelo Neuronal propuesto

4.3 Base de Datos Sísmicos

Considerando que el estado de Oaxaca tiene una tasa de sismicidad alta y al importante banco de datos existentes, se decidió utilizar los acelerogramas generados en cinco estaciones (OXLC, OXFM, OXAL, OXPM y OXTO) para la implementación del Modelo Neuronal.

Es importante señalar que por cada registro sísmico se cuenta con acelerogramas en las direcciones Norte-sur (N-S), Este-Oeste (E-W) y Vertical (V), por lo que se desarrolló un Modelo Neuronal para cada dirección. El banco de datos como fue indicado está integrado por 151 acelerogramas de 3 componentes.

El proceso de entrenamiento del modelo (el cual será detallado posteriormente) requiere la conformación de un conjunto de entrenamiento y otro de prueba, por lo que la Base de Datos antes citada fue subdividida, de tal manera que el primer subconjunto quedó integrado por 137 acelerogramas y el segundo subconjunto (de prueba) quedó definido por 34 acelerogramas como se presenta en la tabla del anexo (figura 4.9).




Figura 4.9 Conjunto de datos para el Modelo Neuronal

El criterio para la integración del subconjunto de entrenamiento se basó en tener, en la medida de lo posible, una representatividad de un amplio intervalo de magnitudes. Evidentemente existe limitación para contar con eventos de magnitudes mayores ($M > 7$) debido a que sus periodos de ocurrencia son mucho más grandes que para eventos de menor magnitud ($M < 6$). Con relación al conjunto de prueba este fue integrado únicamente por eventos de magnitudes $M < 6$.

4.4 Herramienta de cómputo

Se utilizó el *software* denominado *ThinksPro* desarrollado por la consultora *Logical Desing* (ref. 30). Este tiene una interfaz de usuario intuitiva, interactiva y altamente sensible, como se indica en la figura 4.10, se puede modificar cualquier parámetro o dato, mientras se esté ejecutando e inmediatamente ver los resultados. Contiene hojas de cálculo para la importación y exportación conveniente de datos procedentes de otras aplicaciones (*e.g. Excel*); además contiene gráficas y tablas dinámicas de datos que ilustran continuamente el proceso de la información.




Figura 4.10 Software ThinkPro

La forma en que se establecen los parámetros generales de la arquitectura de la RNA se presenta en la figura 4.11. En ella se hace la captura correspondiente, en este caso se utilizó el Perceptrón Multicapa y el tipo de error se optó por el error cuadrático medio. Además se estableció la capa de entrada con 5 nodos, con un procesamiento de Max-Min. Se define también el tamaño del conjunto de muestras. Regularmente, el proceso se inicia mediante una semilla aleatoria que permite inicializar un generador de números aleatorios, cuyos valores se utilizan para los pesos iniciales de cada nodo.

The screenshot shows the "Neural Network Setup" dialog box. The configuration options are as follows:

- Architecture:** Multilayer Normal Feed Forward
- Error Type:** Mean Square Error
- Hidden Layers:** 2
- Random Seed:** 777
- Batch Size:** 1 (selected), 137, Training Set
- Global Parameters:**
 - Input Noise Factor (InputNoise): 0
 - Training Error Tolerance (ErrorTol): 0
- Layer Definition:**
 - Inputs: 5
 - Input Preprocessing: Max Min Processing (MaxMin)
 - Sample Arrangement: Normal (selected), Time Series
 - Time Series: 2 consecutive samples

Buttons for OK, Cancel, and Defaults... are located on the right side of the dialog.

Figura 4.11 Configuración de la arquitectura y la capa de entrada

Para el número de capas ocultas se eligió tener una o dos capas ocultas variando el número de nodos de estas, utilizando el algoritmo de retropropagación como regla de aprendizaje. La función de entrada que se utilizó en las capas ocultas fue el producto punto, es una suma ponderada del producto de valores con un sesgo. Dado un vector de entrada de valores n , definidos en los reales ($\mathbb{R}$), $x_1, x_2, \dots, x_n$ y un conjunto de valores ponderados $n+1$, se tienen dos conjuntos de vectores x y w .

$$w = (w_0, w_1, w_2, \dots, w_n) \quad (18)$$

El vector de entrada está definido por:

$$x = (1, x_1, x_2, \dots, x_n) \quad (19)$$

El primer elemento del vector x es una constante de entrada llamada constante de sesgo y el primer elemento del vector w es llamado peso del sesgo. La suma ponderada se obtiene mediante la sumatoria de los productos de entrada con su peso correspondiente.

$$f(x, w) = w_0 + x_1 w_1 + x_2 w_2 + \dots + x_n w_n \quad (20)$$

La función de transferencia utilizada para las capas ocultas fue la *Sigmoide*, todo lo anterior se muestra en la figura 4.12.




Figura 4.12 Configuración de las capas ocultas

Con respecto a la configuración de la salida de la red, la regla de aprendizaje fue el algoritmo de retropropagación, la función de entrada un producto punto y una función de transferencia lineal, como se observa en la figura 4.13.




Figura 4.13 Configuración de una capa de salida

Para el conjunto de entrenamiento y prueba se importaron los archivos *.txt* que contienen los datos utilizados para la formación y evaluación de la RNA. En el conjunto de entrenamiento, se observa el proceso de la red y de una forma iterativa ajusta los pesos en la búsqueda de un error mínimo. El proceso de prueba se utilizó para evaluar el rendimiento de la red durante y después del entrenamiento. Estos conjuntos muestran las salidas reales recientemente procesadas, como se ilustra en la figura 4.14.

Training Set									
	I1	I2	I3	I4	I5	D1	O1		
1	2	4.7	142	16	198.3	8.3	26.7907		
2	2	4.5	139	22	205.4	8.4	25.2921		
3	2	4.4	24	91	334.4	9.5	9.38863		
4	2	5	91	39	124.3	10.2	12.8068		
5	2	4.7	130	28	205.8	10.4	22.5435		
6	2	4.5	55	84	0.7	11.5	20.583		
7	1	4.3	21	71	223.5	12	17.2684		
8	2	4.5	153	34	319.4	12.5	12.1145		
9	3	4.4	18	66	229.8	13.4	15.3125		
10	2	5	215	115	97.8	13.8	14.257		
11	2	4.7	180	8	161.3	14	18.3895		
12	2	4.3	90	87	185.5	14.4	16.0198		
13	1	4.4	17	66	225	14.7	15.9972		
14	1	4.4	18	66	227.5	15.2	15.2846		
15	1	4.3	128	50	156.6	15.6	23.1164		
16	2	5.4	66	22	95.9	16	16.9204		
17	2	4.7	141	16	197.2	16.5	17.7672		
18	2	5.9	257	31	194.3	16.7	17.0255		
19	2	4.3	24	71	221.3	17.3	18.0698		
20	3	4.3	23	71	228.8	17.5	15.9434		
21	1	4.3	89	87	187.1	17.5	25.1888		
22	3	4.7	138	63	140.1	17.9	18.3672		
23	2	4.1	76	45	226	18.3	17.1081		
24	1	4.3	21	71	228.7	18.4	12.7578		
25	2	4.8	199	100	105.2	18.6	19.3732		
26	2	4.4	17	66	213.9	18.8	19.1401		
27	1	4.8	195	100	105	19	18.299		
28	2	7	197	70	301	19.2	18.7939		

Test Set									
	I1	I2	I3	I4	I5	D1	O1		
1	2	4.4	19	66	220.4	14	29.5681		
2	1	4.4	17	66	225	14.1	24.7489		
3	1	4.3	22	71	225.4	15	24.2724		
4	1	4.9	141	45	206	19.9	35.2228		
5	2	5.5	135	16	194.9	20.2	32.2975		
6	3	4.5	72	28	178.2	21.5	28.2986		
7	2	4.4	159	42	59.1	21.8	30.3181		
8	2	5.7	188	66	115.6	22.7	39.6042		
9	1	5.7	187	66	114.9	24.8	34.7925		
10	2	4.4	125	43	205.8	25.3	33.4927		
11	2	4.4	123	43	204.6	25.5	32.8495		
12	2	4.7	143	7	179.8	26.7	27.0629		
13	2	4.9	141	45	204.7	27.4	27.7853		
14	1	4.3	130	50	156.6	27.7	32.7889		
15	2	4.9	143	45	205.7	27.9	27.8975		
16	1	5.5	133	16	194.7	28.9	28.9738		
17	1	5.1	131	3	209.5	30.2	35.7439		
18	2	4.5	73	28	174.8	30.3	28.1182		
19	1	4.8	196	100	104.9	30.4	32.8846		
20	1	5.1	132	3	209	32	35.7207		
21	2	4.7	123	11	188.5	32.1	27.027		
22	2	7	212	24	245.3	32.6	38.69		
23	1	4.5	130	30	222	32.9	33.5296		
24	1	5.5	133	16	195.1	33.5	29.1041		
25	1	4.7	132	109	59.7	33.9	39.714		
26	1	5.3	91	10	130	33.9	34.5147		
27	1	5.3	91	10	130.7	37.8	34.4992		
28	2	5.8	165	10	225.3	38	38.4505		

Figura 4.14 Conjuntos de entrenamiento y prueba

En la figura 4.15 se tiene una ventana donde se visualizan las estadísticas y gráficas de la red neuronal, se representan tanto el error total para el conjunto de entrenamiento como para el de prueba asociados a las iteraciones correspondientes.




Figura 4.15 Variación del error durante el entrenamiento

4.5 Procedimiento de entrenamiento del Modelo Neuronal

No hay una metodología precisa para establecer el número óptimo de nodos en las capas ocultas del modelo neuronal, por lo que la experiencia tiene un papel fundamental para proponer una arquitectura que sea optima a nuestro modelo. El criterio que se utilizó para empezar el entrenamiento y decidir el número de capas ocultas se basó en los resultados de distintos autores (ref. 15, 16 y 17), algunos de ellos mencionados en el tema de Aplicaciones de las RNA en la Ingeniería Sísmica. La sugerencia es simple, se construye una red robusta y se van eliminando neuronas de las capas ocultas mientras se mantenga la convergencia del algoritmo de entrenamiento, es decir el error disminuye; también se puede proceder a la inversa, se diseña una red pequeña y se van agregando neuronas hasta que se alcanza la convergencia a un nivel de error preestablecido.

En la figura 4.16 se presenta un diagrama de flujo que describe el proceso de entrenamiento a partir de los datos de entrada, integrados por: Cs_{ki} , M_{ki} , De_{ki} , Pf_{ki} y asociados a su correspondiente peso w_{ki} . Estos patrones alimentan a la RNA para empezar el proceso de aprendizaje; posteriormente, se obtiene una salida $D_{RNA_{ki}}$, la cual se compara con el patrón objetivo $D_{FI_{ki}}$, utilizando un criterio de error $\varepsilon_k = D_{RNA_{ki}} - D_{FI_{ki}}$. El resultado del error ε_k se compara con un error tolerable ε_t y si este es menor, se concluye el proceso y se considera que la red está entrenada. Si por el contrario el error ε_k es mayor que el error ε_t se procede a

realizar un ajuste en los pesos w_{ki} mediante el algoritmo de retropropagación. Para ello el error se distribuye hacia atrás, desde la capa de salida hasta la capa de entrada. Cada nodo es ajustado en su peso w_{ki} correspondiente considerando su contribución relativa al error de salida en la capa correspondiente. Este proceso se realiza de forma iterativa hasta que se cumpla la condición en donde el error ε_k es menor que el error ε_t para dar por concluido el entrenamiento.




Figura 4.16 Diagrama de flujo del entrenamiento del modelo propuesto

En forma paralela, al proceso de entrenamiento del Modelo Neuronal, se realizaron evaluaciones del mismo mediante la utilización del conjunto de prueba, es importante recordar que dicho conjunto está integrado por una serie de patrones que no son utilizados durante el entrenamiento.

Un argumento que se presenta durante el entrenamiento de una RNA, es que a pesar de tener una red entrenada y de la experiencia del que la diseña, no hay una garantía total de encontrar el error mínimo global para indicar que es la mejor red que pueda entrenarse para resolver el problema. De tal forma que si el error encontrado se mantiene constante o no varía mucho y los resultados que se obtienen del conjunto de prueba son muy cercanos a los reales se puede considerar que la red está bien entrenada.

4.6 Resultados

En la tabla 4.1 se presentan las mejores arquitecturas propuestas, considerando que son las que tienen los mejores factores de correlación (R^2) tanto para el entrenamiento como para la etapa de prueba. Se estableció que el número máximo de nodos en las capas ocultas estuviera en el intervalo de 10 a 100, de esta forma se inició un proceso de incrementos a partir de la configuración de 10X10, los incrementos correspondientes a las capas fueron de 5 en 5 hasta alcanzar el valor de 100. De acuerdo a las variaciones observadas del error y de los factores de correlación, en algunos casos, se incrementó una capa y se decremento la otra. En la primer columna de la tabla E representa el número de parámetros de la capa de entrada, C_1 y C_2 indican los correspondientes nodos de las capas ocultas 1 y 2 y finalmente, S representa el único nodo de la capa de salida. La segunda columna indica el número de la iteración o ciclo en donde se interrumpió el proceso, debido a que el error se mantuvo constante o porque se incrementó. Las columnas 3 y 4 presentan el factor de correlación R^2 del entrenamiento y prueba correspondientes; dicho factor representa una medida del grado de variación entre los datos reales y los estimados por la RNA.

Tabla 4.1 Arquitecturas del Modelo propuesto

Componente N-S			
Arreglo RNA E x C_1 x C_2 x S	Número de Iteraciones	Factor de correlación del conjunto (R^2)E	Factor de correlación del conjunto (R^2)E
5x100x100x1	6000	0.9135	0.2389
5x100x20x1	3001	0.8034	0.5282
5x100x1	4300	0.7972	0.215
5x90x1	2000	0.7882	0.4416
5x60x30x1	10700	0.8870	0.3331
5x60x30x1	7102	0.9028	0.3226
5x50x50x1	10002	0.9153	0.2488
5x50x40x1	21000	0.9297	0.3161
5x50x40x1	14181	0.8783	0.2095
5x30x15x1	2002	0.7881	0.3226
Componente E-W			
5x65x35x1	20002	0.9355	0.469
5x65x45x1	11901	0.9338	0.5748
5x65x35x1	2208	0.8950	0.4430
5x60x50x1	12302	0.9163	0.4962
5x60x45x1	10203	0.9290	0.6182
5x55x45x1	1200	0.8141	0.6176
5x50x50x1	1300	0.8581	0.5930

Tabla 4.1 (Continuación)

5x50x45x1	20120	0.9423	0.6180
5x50x45x1	12000	0.9423	0.5783
5x50x40x1	1400	0.8761	0.7238
Componente V			
5x70x40x1	11004	0.9337	0.07600
5x70x40x1	8203	0.9341	0.1654
5x70x40x1	2003	0.8996	0.1610
5x60x50x1	13300	0.9325	0.0254
5x50x40x1	9803	0.9328	0.0362
5x50x40x1	1304	0.8730	0.6068
5x40x40x1	1600	0.9120	0.1214
5x40x10x1	2000	0.8795	0.3033
5x40x10x1	1400	0.8754	0.2550
5x30x20x1	6999	0.9278	0.0954

Se observa que los valores indicados de las mejores configuraciones para un determinado componente no necesariamente lo son para otro. Por ejemplo, los valores de R^2 para N-S, E-W y V son: 0.90, 0.93 y 0.91 correspondientemente; sin embargo sus arquitecturas son muy diferentes esto es 5x60x30x1, 5x65x45x1 y 5x40x40x1.

Como se mencionó el entrenamiento aplicado es del tipo supervisado, para lo cual se utilizan patrones de prueba y durante el proceso se realiza un control de la variación de los errores tanto en prueba como en entrenamiento. En el caso del componente N-S el mejor valor de correlación en entrenamiento se tiene para la configuración 5x60x30x1 y mediante la cual se alcanzó un valor de $R^2=0.9$, sin embargo para los datos de prueba se obtuvo un valor de 0.3 lo que significa que nuestro modelo fue sobreentrenado y perdió capacidad de generalización. Los mejores valores de correlación fueron de: 0.87 y 0.72 (entrenamiento y prueba) y corresponden al componente E-W con arreglo de 5x50x40x1, si bien las correlaciones no son altas se consideraron adecuadas para el problema en cuestión. En general se puede señalar que los componentes N-S y V no tienen una adecuada correlación y por lo tanto las arquitecturas propuesta no resuelven el problema de la estimación de la Duración de la Fase Intensa en forma aceptable; situación diferente a lo ya señalado para el componente E-W.

En el caso del componente V se observa que para la configuración 5x40x10x1 se ensayó un número diferente de iteraciones (1400 y 2000) obteniéndose un factor de correlación similar tanto en entrenamiento como en prueba lo que es un indicio de que no necesariamente el incremento en el número de iteraciones puede mejorar el rendimiento de la red en cuanto a la reducción del error. No obstante lo anterior, pudiera darse el caso que, utilizando la misma arquitectura, se obtuviera una buena correlación con un número mucho mayor de iteraciones, lo que significaría que probablemente se estaría escapando de un error mínimo local y llegando al mínimo global.

La tabla A del anexo presenta la matriz que contiene el conjunto de datos utilizados para el entrenamiento del modelo neuronal y la tabla B del mismo anexo, incluye el conjunto de prueba de la red neuronal. En la figura 4.18 se hace una comparación de las estimaciones para las mejores arquitecturas del modelo tanto en entrenamiento como en prueba, para el N-S (5x100x20x1), E-W (5x50x40x1) y V (5x50x40x1). En el eje de las abscisas se presentan los valores de la Duración de la Fase Intensa estimados de acuerdo a la definición del Profesor Arias y en el eje las ordenadas las estimaciones del modelo para cada componente, en ambos casos las duraciones son expresadas en segundos. Se observa claramente que independientemente de los valores de R^2 ya discutidos existe una buena correlación en la etapa de entrenamiento salvo algunos casos que se alejan del eje a 45° (cualquier punto sobre este indicaría una correlación del 100%). En la etapa de prueba la correlación es menor debido a que existe un mayor número de casos que se alejan del eje a 45° . De los resultados se concluye que el modelo sobreestima los valores de la Fase Intensa en los componentes N-S y V y en el caso de E-W existe en una mejor tendencia hacia la recta a 45° .




Figura 4.18 Resultados del Modelo Neuronal

De acuerdo a los resultados presentados el Modelo Neuronal Artificial para estimar la duración de la fase Intensa del movimiento sísmico quedo definido como se indica en las figuras 4.19 a 4.21.

- Para la componente N-S: 5x100x20x1 (5 entradas, 100 nodos para la capa oculta 1, 20 nodos para la capa oculta 2 y 1 salida).
- Para la componente E-W: 5x50x40x1 (5 entradas, 50 nodos para la capa oculta 1, 40 nodos para la capa oculta 2 y 1 salida).
- Para la componente V: 5x50x40x1 (5 entradas, 50 nodos para la capa oculta 1, 40 nodos para la capa oculta 2 y 1 salida).




Figura 4.19 Arquitectura del Modelo Neuronal componente N-S




Figura 4.20 Arquitectura del Modelo Neuronal componente E-W




Figura 4.21 Arquitectura del Modelo Neuronal componente V

CAPÍTULO 5

5. CONCLUSIONES

En la actualidad la Inteligencia Artificial es una disciplina fundamental en la ciencia y la tecnología, misma que tras el paso del tiempo ha creado una serie de conocimientos básicos que le permiten emular diversas capacidades del ser humano para exhibir comportamientos inteligentes. Cuyo fin es utilizarla en el trabajo diario, en la toma de decisiones para mejorar la efectividad de muchos procesos cotidianos.

Se estableció que la Duración de la Fase Intensa (D_{FI}) es función de: la Magnitud del temblor (M), su profundidad focal (P_f), la distancia epicentral (De), las condiciones del subsuelo en donde se ubica el sitio de registro (C_s) y la posición relativa entre el epicentro y la estación del registro, definida por el Azimut (Az).

Se propuso un modelo basado en la teoría de las Redes Neuronales Artificiales para evaluar la Duración de la Fase Intensa del movimiento sísmico. El banco de datos está integrado por 151 acelerogramas de 3 componentes cada uno, de ellos se utilizaron 137 para la etapa de entrenamiento y 34 acelerogramas en la de prueba. Los registros indicados incluyen únicamente 5 estaciones sísmicas (OXLC, OXFM, OXAL, OXPM y OXTO) de las 9 que opera la red.

Debido a que el movimiento sísmico se registra en tres direcciones (Norte-Sur, Este-Oeste y vertical) se propuso un modelo para cada una, de tal forma las Redes Neuronales quedaron definidas mediante una capa de entrada con los parámetros M , P_f , De , C_s y Az ; 2 capas ocultas y una capa de salida con el parámetro D_{FI} . El número de nodos para las capas ocultas quedó definido como: 100x20 (componente N-S), 50x45 (componente E-W) y 50x20 (componente V).

El modelo para la componente E-W, es capaz de estimar con suficiente aproximación la duración de la fase Intensa para la ciudad de Oaxaca, debido a tener una cercana tendencia de los valores reales con los estimados por la red. Sin embargo, para las componentes N-S y V los modelos no tienen una apropiada correlación y por ende no resuelven el problema.

En la componente V se obtuvo para la configuración 5x40x10x1, un factor de correlación similar tanto en el entrenamiento como en la prueba, utilizando un número diferente de iteraciones (1400y 2000) lo que es un indicio de que no necesariamente el incremento en el número de iteraciones puede mejorar el rendimiento de la red. Sin embargo, para la componente EW con la configuración 5x50x45x1, si el número de iteraciones se incrementa de 1200 a 20120 el factor de correlación es mucho mejor.

Aunque se ha considerado a las RNA como modelos de caja negra, el caso del modelo propuesto no es exactamente así, debido a que es necesario un conocimiento adecuado del fenómeno en cuestión que permita la correcta selección de los parámetros que tienen la mayor influencia en el mismo.

La selección del conjunto de entrenamiento deberá contar con un número suficiente de casos que representen verdaderamente al fenómeno dentro del intervalo en el cual puede presentarse. Es recomendable actualizar la base de datos de registros sísmicos, para mejorar las estimaciones de los modelos propuestos, sin embargo, un vasto número de elementos de dicho conjunto no necesariamente sería representativo y las estimaciones de la RNA estarían limitadas a un intervalo más reducido.

Si bien el diseño de una RNA es un proceso heurístico para establecer la red más adecuada para modelar un problema específico, es muy importante el nivel de experiencia que se tenga en problemas similares para proponer: 1) la arquitectura de la red, 2) la regla de aprendizaje y 3) las funciones de transferencia.

Finalmente, es importante puntualizar el alcance de este tipo de metodologías y su aplicación a la solución de problemas asociados, en este caso, a los campos de la Sismología y la Ingeniería Sismológica. Debido a que la determinación de la Duración de la Fase Intensa del movimiento sísmico es un parámetro vital para analizar la respuesta de las estructuras y su posible daño ante la acción sísmica. Con una herramienta como la propuesta se pueden tener estimaciones aceptables de dicha duración aún ante escenarios sísmicos futuros.

REFERENCIAS

1. Arauz R, (1998), *Sistema experto de clasificación y apoyo al diseño arquitectónico de edificios inteligentes (Tesis de Licenciatura)*, Facultad de Ingeniería, UNAM, México.
2. Huerta J, (2009), *Diagramación de argumentos dialógicos y derrotantes en el sistema inteligente Expertius, (Tesis de Licenciatura)*, Facultad de Derecho, UNAM, México.
3. Bromley J, Jackson N, Clymer O, Giacomello A, Jensen F, (2005), *The use of Hugin to develop Bayesian networks as an aid to integrated water resource planning*, Environmental Modelling y Software, **20:2**, 231-242.
4. Azuaje F, (1999), *"Predicting Coronary Disease Risk Based on Short-Term RR Interval Measurements: A Neural Network Approach"*, Artificial Intelligence, **15:3**, 275-297.
5. Gibson C, Siu S, Cowan C, (1991), *The Application of Nonlinear Structures to the Reconstruction of Binary Signals*, IEEE Transactions on Signal Processing, 39, 1877-1884.
6. Weigend A, (1997), *Decision technologies for financial engineering* Y. Abu-Mostafa, & A. P. N. Refenes (Eds.). New York, NY: World Scientific.
7. Bojórquez J, (2011), *Uso de redes neuronales artificiales para estimar la respuesta sísmica de sistemas estructurales (Tesis de Maestría)*, DEPMI, UNAM, México.
8. Rumelhart D, Mc Clelland J, (1986), *Parallel Distributed processing. Vol: foundations*, MIT Press.
9. Brío B, Sanz A, (2002), *Redes neuronales y sistemas difusos*, México, Alfaomega.
10. Ponce P, (2010), *Inteligencia artificial con aplicaciones a la ingeniería*, México, Alfaomega.
11. Rosenblatt F, (1959), *Mechanization of Thought Processes: Two Theorems of Statical Separability in the Perceptron*, Symposium at National Physical Laboratory, London.
12. Minsky M y Papert S, (1969), *Perceptrons*, MIT Press.
13. Bautista G, (2008), *Implementación numérica de una red neuronal para el modelo constitutivo del comportamiento de materiales, (Tesis de Maestría)*, IPN, México.

14. Fritsch, J, (1996), *Modular Neural Networks for Speech Recognition*, (Master's Thesis), Carnegie Mellon University.
15. Romo M, (1999), *Earthquake geotechnical engineering and artificial neural networks*, 4th Arthur Casagrande Lecture, Proc of the XI Panamerican Conference on Soil Mechanics and Geotechnical Engineering, **4**, Foz do Iguassu, Brasil.
16. García S, Romo M, Taboada-Urtuzuástegui V, Mendoza M, (2002), *Sand behavior modeling using static and dynamic artificial neural networks*, Instituto de Ingeniería, UNAM, SID/631, ISBN 970-32-0291-8.
17. S Garcia, L Alcántara, L Manjarrez, (2017), *Neural-Attenuation Laws for the Mexican Subduction: An Updating Effort*, 16th World Conference on Earthquake Engineering, 455, Santiago, Chile.
18. Alcántara L, Almora D, Macías M, Castro G, Velasco J, Torres M, Vázquez R, Ayala M, Pérez C, Sandoval H, Ruiz A, (2005), *La Red de Registro de sismos fuertes en el Instituto de Ingeniería de la UNAM. Pasado, presente y futuro*, XV Congreso Nacional de Ingeniería Sísmica, CD-ROM, I-08.
19. Lagos I, (2014), *La Instrumentación Sísmica en México (Tesis de Licenciatura)*, Facultad de Ingeniería, UNAM, México.
20. Alcántara L, (2013), *Análisis de los movimientos sísmicos en las ciudades de Oaxaca y Puebla con Redes Neuronales (Tesis de Doctorado)*, DEPMI, UNAM, México.
21. Kinemetrics Inc, Altus K2, *High Dynamic Range Accelerograph, Operations manual*.
22. Lermo J, Chávez-García F, Urbietta J, Mijares H, (1991), *Amplificación relativa en la zona urbana de Oaxaca. Contribución a la microzonificación sísmica*, Memorias del IX Congreso Nacional de Ingeniería Sísmica, Manzanillo, Col., pp 1-34 a 1-44.
23. *Ídem*
24. Alcántara L, (2013), *Op. Cit.*, p. 79.
25. Fundación ICA, (1988), *Experiencias derivadas de los sismos de Septiembre de 1985*, México, Noriega Editores.

26. Tarbuck E, Lutgens F, (2001), *Ciencias de la Tierra: una introducción a la geología física*, Madrid España, Prentice Hall, 6ª edición.
27. Richter C, (1935), *An instrumental earthquake magnitude*, Bull. Seismol. Soc. Am., **25**, 1-32.
28. Guerrero R, (1997), *Duración del Movimiento Durante los Sismos*, (Tesis de Maestría) Facultad de Ingeniería, UNAM, México.
29. Arias A, (1970), *A Measure of Earthquake Intensity*, in *Seismic Desing of Nuclear Power Plants*, R Hansen, Ed, MIT Press, Massachusetts.
30. Logical Designs (1996), *Thinks Pro, Neural Networks for Windows*, User`s guide, USA.

Anexo

Tabla A. Conjunto de entrenamiento Fase Intensa Ciudad de Oaxaca

Tabla B. Conjunto de prueba Fase Intensa Ciudad de Oaxaca

Tabla A. Conjunto de entrenamiento Fase Intensa Ciudad de Oaxaca

Nodos de entrada N-S					Nodos de salida N-S	
<i>Clase de suelo</i>	<i>M</i>	<i>De (Km)</i>	<i>Pf (Km)</i>	<i>Az (°)</i>	<i>D_{FI}(s)</i>	<i>D_{RNA} (s)</i>
2	4.4	24	91	334.4	9.4	9.57652
2	4.7	142	16	198.3	9.6	29.3147
1	4.3	21	71	223.5	10.3	13.7903
2	4.5	55	84	0.7	10.5	17.9598
2	4.7	130	28	205.8	10.5	27.6357
2	5.0	91	39	124.3	10.5	16.7572
2	4.5	153	34	319.4	11.3	11.1043
1	4.4	17	66	225	12.9	12.3265
2	4.4	19	66	220.4	13.1	15.3942
2	5.0	215	115	97.8	14.2	15.1939
3	4.3	23	71	228.8	14.9	14.3853
1	4.8	195	100	105	14.9	20.876
2	4.7	180	8	161.3	14.9	15.1449
2	5.9	257	31	194.3	15	15.6127
3	4.4	18	66	229.8	15.1	14.5918
1	4.3	22	71	225.4	15.5	11.9884
2	4.1	76	45	226	16.1	16.295
2	4.3	24	71	221.3	17.1	17.98
2	4.8	199	100	105.2	18	17.5033
2	4.3	21	71	216.3	18.4	15.8792
1	4.4	118	13	219.3	18.5	19.1074
2	4.5	139	22	205.4	19.3	25.3388
1	5.6	128	8	192.3	19.8	26.015
2	4.3	90	87	185.6	19.9	26.2585
2	4.4	85	135	79.1	20	20.9128
1	4.3	114	63	70.7	20.5	22.0383
1	4.9	140	45	206.5	20.6	22.7895
1	5.7	187	66	114.9	20.7	23.1226
2	5.5	135	16	194.9	21.7	23.3531
2	7.0	197	70	301	21.9	21.7912
1	5.7	188	66	115	22.1	20.9675
1	5.1	131	3	209.5	22.7	22.7059
2	5.5	134	16	193.7	23.1	22.9241
3	4.8	194	100	105	23.3	24.534
2	4.9	143	45	205.7	23.8	18.1857
3	4.5	58	84	358.9	23.9	23.7593
1	4.9	141	45	206	24	22.5707
2	6.8	136	84	12.4	24.1	26.4559
2	4.5	57	84	3.4	24.4	18.9533
1	4.9	141	45	206	24.8	22.78
2	4.6	196	16	202.3	25.6	19.8068
2	4.4	159	42	59.1	25.7	19.7234
2	4.3	116	63	72.7	25.9	19.9861
2	4.4	145	28	203.3	26.1	20.6341
2	4.4	125	43	205.8	26.6	20.6502
2	5.3	382	210	98.8	26.6	26.7566

Tabla A (continuación)

Nodos de entrada N-S					Nodos de salida N-S	
<i>Clase de suelo</i>	<i>M</i>	<i>De (Km)</i>	<i>Pf (Km)</i>	<i>Az (°)</i>	<i>D_{FI}(s)</i>	<i>D_{RNA} (s)</i>
2	4.6	181	25	261.5	26.7	24.8138
1	5.1	132	3	209	26.9	26.572
3	5.7	185	66	115.1	27	26.8799
2	5.6	131	8	191.8	27.1	31.2011
3	4.5	72	28	178.2	27.3	27.6652
2	4.5	73	28	174.8	27.6	24.4641
3	4.7	138	63	140.1	27.7	27.4127
3	4.5	156	34	319.5	27.7	27.8626
1	4.8	196	100	104.9	27.7	18.5508
1	4.3	130	50	156.6	28.1	27.1395
2	7.6	130	16	195.5	28.1	27.9747
1	4.4	122	43	205.8	28.8	30.7973
2	5.4	477	141	107.1	28.9	29.2255
2	4.7	130	109	60.6	28.9	29.4522
3	5.6	129	8	192.9	29	29.8299
2	4.7	141	16	197.2	29	24.3794
1	5.5	133	16	194.7	29.1	28.0522
1	5.6	129	8	192.4	29.3	23.9036
3	4.7	140	16	199.3	29.5	29.3235
1	4.5	58	84	1.1	29.6	29.5767
1	4.7	140	16	198.9	29.6	29.759
1	4.4	82	135	78	29.7	30.8914
1	4.5	130	30	222	29.7	27.7313
1	4.6	193	16	202.3	29.9	30.5451
1	5.1	131	3	208.6	30.1	29.223
2	4.9	141	45	204.7	30.3	26.4038
2	4.3	132	50	155.8	30.6	26.062
2	4.7	128	28	204.7	31	26.3924
1	4.5	58	84	0	31.2	30.4091
2	4.7	133	109	61	31.3	31.1456
3	4.9	142	45	206.8	31.5	30.6339
1	5.8	165	10	227.5	31.8	33.6059
2	5.7	190	66	115	31.9	33.6728
1	5.3	132	106	88.2	31.9	37.6803
1	4.7	120	11	188.9	32.6	33.2817
2	4.6	124	27	203.3	33	26.1358
2	4.7	143	7	179.8	33	26.969
2	6.4	159	33	166.1	33.2	33.1913
2	7.0	212	24	245.3	33.2	32.8009
1	4.7	128	28	206.6	33.3	29.9989
1	4.7	132	109	59.1	33.9	36.12
1	5.8	165	10	227.9	34.7	33.4212
2	5.9	261	47	294.5	34.8	35.0136
2	5.3	132	106	89.3	35	35.3107
1	4.7	132	109	59.9	35.1	35.8627
1	5.8	165	10	227.2	35.1	33.6177

Tabla A (continuación)

Nodos de entrada N-S					Nodos de salida N-S	
<i>Clase de suelo</i>	<i>M</i>	<i>De (Km)</i>	<i>Pf (Km)</i>	<i>Az (°)</i>	<i>D_{FI}(s)</i>	<i>D_{RNA} (s)</i>
2	5.3	94	10	131.6	35.2	34.9261
3	4.7	130	109	59.2	35.3	35.3232
2	4.5	130	30	220.2	36	27.2308
2	6.0	219	20	232.6	36.3	35.195
1	6.0	220	20	233.6	36.3	36.9042
2	5.0	178	84	227.9	36.5	35.9432
3	5.1	133	3	209.7	37	37.3735
3	7.6	848	10	278.4	37.1	37.1173
3	5.3	91	10	131.1	37.2	36.836
1	5.1	147	115	31.3	37.3	35.8989
2	6.3	375	36	115.5	37.3	37.737
2	5.8	165	10	226.3	37.6	33.8938
1	5.4	218	142	80.1	37.6	36.5412
2	7.0	148	69	324.1	37.6	35.7703
1	5.3	91	10	130	37.7	36.1256
2	5.6	130	8	190.6	38	36.4172
1	6.3	371	36	115.5	38.5	39.7786
1	5.3	132	106	88.5	38.6	37.4152
2	7.3	246	22	250.3	38.7	36.276
2	4.7	122	11	187.1	39.1	27.6536
2	4.6	172	131	71.3	39.5	36.8708
1	5.3	133	106	88.2	40	39.1865
2	4.6	202	133	80.3	40.2	38.994
2	5.1	145	115	31.7	40.4	37.7926
3	6.4	491	20	125.3	40.6	40.7796
3	7.5	128	16	196.6	40.7	42.1659
3	5.1	146	115	30.6	40.9	42.8282
2	5.3	95	10	130.1	41.5	39.28
2	6.0	391	70	119	42	42.1932
3	5.3	130	106	88.1	42.4	42.6448
2	4.7	175	131	71.4	42.7	41.2134
2	6.4	496	20	125.2	42.8	42.7869
2	5.3	135	106	89	43.2	38.5635
2	5.3	275	33	149.2	43.4	43.2189
1	4.6	173	131	70.6	43.4	43.6336
2	4.4	218	145	79	44.6	44.7683
3	6.3	370	36	115.5	45.2	44.1956
2	5.1	147	115	32.6	45.2	42.5468
1	4.3	89	87	187.8	45.6	45.0257
2	5.4	217	142	81.1	47.5	50.1147
2	5.0	283	116	103.7	47.7	47.4249
1	5.4	218	142	80.5	47.8	42.5014
2	5.4	220	142	81.1	51.5	49.6553
2	4.9	218	150	78.1	51.6	51.7541
3	7.0	151	69	324.1	51.7	51.9212

Tabla A (continuación)

Nodos de entrada E-W					Nodos de salida E-W	
<i>Clase de suelo</i>	<i>M</i>	<i>De (Km)</i>	<i>Pf (Km)</i>	<i>Az (°)</i>	<i>D_{FI}(s)</i>	<i>D_{RNA} (s)</i>
2	4.7	142	16	198.3	8.3	14.0083
2	4.5	139	22	205.4	8.4	8.51291
2	4.4	24	91	334.4	9.5	9.51093
2	5.0	91	39	124.3	10.2	10.1946
2	4.7	130	28	205.8	10.4	17.6778
2	4.5	55	84	0.7	11.5	21.2491
1	4.3	21	71	223.5	12	12.0178
2	4.5	153	34	319.4	12.5	12.5045
3	4.4	18	66	229.8	13.4	13.4025
2	5.0	215	115	97.8	13.8	13.8496
2	4.7	180	8	161.3	14	13.9931
2	4.3	90	87	185.6	14.4	14.3476
1	4.4	17	66	225	14.7	14.686
1	4.4	18	66	227.5	15.2	15.2502
1	4.3	128	50	156.6	15.6	22.8946
2	5.4	66	22	95.9	16	16.1209
2	4.7	141	16	197.2	16.5	11.3978
2	5.9	257	31	194.3	16.7	16.6996
2	4.3	24	71	221.3	17.3	17.3755
3	4.3	23	71	228.8	17.5	17.5238
1	4.3	89	87	187.1	17.5	28.8723
3	4.7	138	63	140.1	17.9	17.8726
2	4.1	76	45	226	18.3	18.1938
1	4.3	21	71	228.7	18.4	18.4213
2	4.8	199	100	105.2	18.6	18.5835
2	4.4	17	66	213.9	18.8	18.8068
1	4.8	195	100	105	19	19.0061
2	7.0	197	70	301	19.2	19.2338
1	4.4	118	13	219.3	19.3	19.579
1	4.9	141	45	206	19.3	24.7409
3	5.7	185	66	115.1	20.7	20.6516
2	4.8	160	10	178.7	20.8	20.5002
3	4.7	140	16	199.3	21.1	21.0917
3	4.8	194	100	105	21.3	21.3147
2	4.4	85	135	79.1	21.4	21.2118
2	4.7	128	28	204.7	21.4	14.7189
2	4.3	21	71	216.3	21.7	21.7048
2	4.3	116	63	72.7	22	22.0496
1	5.5	132	16	195.4	22	21.9911
1	4.3	114	63	70.7	22.4	22.4388
1	4.4	122	43	205.8	22.6	22.6618
3	5.6	129	8	192.9	23.2	23.2179
2	4.7	142	63	139.2	23.4	23.592
2	5.5	134	16	193.7	23.5	23.3795
1	5.6	128	8	192.3	23.6	29.0612
2	6.8	136	84	12.4	23.6	23.5754

Tabla A (continuación)

Nodos de entrada E-W					Nodos de salida E-W	
<i>Clase de suelo</i>	<i>M</i>	<i>De (Km)</i>	<i>Pf (Km)</i>	<i>Az (°)</i>	<i>D_{FI}(s)</i>	<i>D_{RNA} (s)</i>
3	4.5	58	84	358.9	23.9	23.9907
1	5.7	188	66	115	24	26.7781
1	4.9	140	45	206.5	24.1	23.8906
1	4.6	193	16	202.3	24.3	24.2712
2	4.3	132	50	155.8	24.5	24.2772
3	4.9	142	45	206.8	24.8	24.8185
3	5.5	133	16	195.9	25.4	25.3836
1	4.4	145	28	204.2	25.4	25.411
1	4.4	82	135	78	25.6	25.6181
1	4.5	72	28	177.4	25.7	25.6609
2	7.6	130	16	195.5	25.8	25.8424
1	5.6	129	8	191.9	26.3	28.0744
2	5.4	477	141	107.1	26.5	26.5226
2	5.1	132	3	207.5	26.5	26.8392
1	4.7	140	16	198.9	26.7	26.7925
2	5.6	130	8	190.6	27.1	27.092
3	4.5	156	34	319.5	27.2	27.1912
2	4.4	145	28	203.3	27.3	27.3345
1	4.7	120	11	188.9	27.7	27.6621
2	4.5	57	84	3.4	27.8	18.2948
2	5.1	134	3	208.5	27.9	27.473
1	4.3	130	50	156.2	28.5	21.3426
2	5.6	131	8	191.8	28.9	28.9089
2	4.6	196	16	202.3	29	30.8922
2	5.3	382	210	98.8	29.3	29.3094
3	5.1	133	3	209.7	29.5	29.5318
2	4.6	124	27	203.3	29.5	29.444
1	4.5	58	84	0	29.9	30.6896
1	5.7	188	66	114.8	30.1	27.3397
1	4.7	132	109	59.1	30.1	33.8075
1	4.9	141	45	206.4	30.1	24.8534
1	5.1	131	3	208.6	30.1	30.1139
1	4.7	138	63	139.8	30.2	30.0982
2	4.7	133	109	61	31	32.6887
1	4.5	58	84	1.1	31.6	30.7977
1	4.7	128	28	206.6	31.9	31.8151
1	5.6	129	8	192.4	31.9	29.4054
2	6.4	159	33	166.1	32.2	32.2832
2	4.5	130	30	220.2	32.5	32.4408
2	4.6	194	16	201.5	33	31.0194
2	4.7	122	11	187.1	33.1	33.1243
1	5.8	165	10	227.2	33.4	36.3003
3	4.7	130	109	59.2	34.1	34.0908
1	5.6	129	8	191.9	34.2	29.4851
3	5.3	91	10	131.1	34.3	34.263
2	5.7	190	66	115	34.5	34.499

Tabla A (continuación)

Nodos de entrada E-W					Nodos de salida E-W	
<i>Clase de suelo</i>	<i>M</i>	<i>De (Km)</i>	<i>Pf (Km)</i>	<i>Az (°)</i>	<i>D_{FI}(s)</i>	<i>D_{RNA} (s)</i>
2	4.7	130	109	60.6	34.7	32.9208
2	7.3	246	22	250.3	34.8	34.8114
2	5.8	167	10	226.8	35.7	35.6891
1	6.3	371	36	115.5	36.4	36.3129
3	6.4	491	20	125.3	36.7	36.7247
1	5.1	147	115	31.3	37.1	37.8432
3	7.5	128	16	196.6	37.4	37.4062
2	4.6	181	25	261.5	37.6	37.6488
1	4.7	132	109	59.9	37.8	34.2111
2	5.2	176	10	240.5	37.9	37.9007
1	5.8	165	10	227.5	38.2	36.8859
2	6.0	219	20	232.6	38.3	38.3882
2	6.3	375	36	115.5	38.4	38.3801
1	5.8	165	10	227.9	38.6	37.214
1	5.1	147	115	31	39.1	38.6191
2	5.0	178	84	227.9	39.8	39.7555
2	5.1	145	115	31.7	40.2	40.1424
2	4.6	202	133	80.3	40.7	40.7006
2	5.3	95	10	130.1	40.8	40.7578
1	4.3	89	87	187.8	41	29.8053
2	5.3	275	33	149.2	41	40.7999
1	5.3	132	106	88.5	41.1	41.6569
3	5.1	146	115	30.6	41.2	41.2136
1	5.3	133	106	88.2	41.4	41.4505
3	6.3	370	36	115.5	41.7	41.7585
2	5.9	261	47	294.5	41.9	41.923
1	5.3	132	106	88.2	42	41.4232
2	6.0	391	70	119	42	42.0088
2	4.7	175	131	71.4	42.1	42.0752
2	7.0	148	69	324.1	42.3	42.2875
3	5.3	130	106	88.1	42.5	42.4999
1	6.0	220	20	233.6	43.4	43.395
1	4.6	173	131	70.1	43.4	43.4707
2	6.4	496	20	125.2	43.7	43.7107
2	5.0	283	116	103.7	44.2	44.0477
2	4.4	218	145	79	44.6	44.713
1	5.4	218	142	80.1	45.8	48.0811
3	7.6	848	10	278.4	47.6	47.5654
2	5.4	217	142	81.1	47.6	48.7843
2	5.3	135	106	89	48.3	48.2953
1	5.4	218	142	80.5	48.3	47.023
1	5.4	219	142	80.5	48.4	47.4337
2	5.4	220	142	81.1	50.3	49.0941
2	4.9	218	150	78.1	52.6	52.5736
3	7.0	151	69	324.1	53.6	53.5906

Tabla A (continuación)

Nodos de entrada V					Nodos de salida V	
<i>Clase de suelo</i>	<i>M</i>	<i>De (Km)</i>	<i>Pf (Km)</i>	<i>Az (°)</i>	<i>D_{FI}(s)</i>	<i>D_{RNA} (s)</i>
1	4.3	21	71	223.5	9.6	27.0449
2	4.4	24	91	334.4	9.6	25.9152
1	4.3	21	71	228.7	10.6	9.88147
3	4.3	23	71	228.8	10.9	9.99177
2	4.7	130	28	205.8	11.3	23.1479
1	4.3	22	71	225.4	11.6	21.8161
2	5.0	91	39	124.3	12	16.6623
3	4.4	18	66	229.8	13.2	12.5343
2	4.5	55	84	0.7	13.6	15.245
2	4.7	142	16	198.3	13.7	15.625
1	4.4	17	66	225	13.7	19.7018
1	4.4	17	66	225	14	14.3583
2	4.5	153	34	319.4	14.1	15.3392
2	4.3	24	71	221.3	14.2	15.3397
2	4.4	17	66	213.9	15.1	22.6518
2	4.4	19	66	220.4	15.3	16.0187
1	4.4	18	66	227.5	15.8	18.0508
2	4.3	21	71	216.3	16.8	17.9309
2	5.0	215	115	97.8	18.5	19.078
2	5.9	257	31	194.3	18.7	18.1491
2	5.4	66	22	95.9	19.4	25.3534
2	7.0	197	70	301	21.9	18.2608
3	4.5	72	28	178.2	22.4	18.9785
2	4.5	139	22	205.4	22.8	13.1206
2	4.4	145	28	203.3	24.7	18.4447
1	4.4	145	28	204.2	24.9	18.6157
2	4.8	199	100	105.2	25	19.5855
3	4.5	58	84	358.9	25	20.0945
2	4.1	76	45	226	25.2	20.019
1	4.3	89	87	187.1	25.2	24.6785
2	4.4	125	43	205.8	26.4	20.5835
2	4.4	159	42	59.1	27.4	18.6835
1	5.1	131	3	208.6	27.6	21.4809
2	4.6	196	16	202.3	27.8	21.0391
1	5.5	133	16	194.7	28	20.7699
3	4.5	156	34	319.5	28.2	16.8668
1	5.1	131	3	209.5	28.3	18.3968
2	5.1	134	3	208.5	28.6	23.2015
2	4.7	141	16	197.2	28.9	26.0774
1	4.5	58	84	1.1	29	22.4802
3	4.7	138	63	140.1	29	22.7262
1	4.3	130	50	156.2	29	24.807
2	4.5	57	84	3.4	29.2	23.0177
1	4.8	195	100	105	29.4	23.448
2	6.8	136	84	12.4	29.9	25.4705
2	4.5	73	28	174.8	30.4	24.3231

Tabla A (continuación)

Nodos de entrada V					Nodos de salida V	
<i>Clase de suelo</i>	<i>M</i>	<i>De (Km)</i>	<i>Pf (Km)</i>	<i>Az (°)</i>	<i>D_{FI}(s)</i>	<i>D_{RNA} (s)</i>
2	4.3	116	63	72.7	30.5	24.0411
1	4.3	114	63	70.7	30.5	24.4054
1	4.5	72	28	177.4	30.6	22.7122
1	5.6	129	8	191.9	30.8	25.0452
3	4.7	140	16	199.3	31.5	24.3031
1	5.1	132	3	209	31.6	25.0415
1	5.1	147	115	31.3	31.8	24.445
1	4.9	141	45	206	31.8	24.473
2	5.7	188	66	115.6	31.9	24.651
2	4.7	143	7	179.8	31.9	25.2341
2	4.7	130	109	60.6	35.6	25.7326
2	4.9	141	45	204.7	32.4	25.322
1	5.6	128	8	192.3	32.4	26.6614
2	7.6	130	16	195.5	32.4	26.1823
3	4.8	194	100	105	32.5	25.8618
1	4.9	140	45	206.5	33.1	27.3591
2	4.6	194	16	201.5	33.1	27.8086
1	4.5	58	84	0	33.4	18.8955
1	4.7	132	109	59.1	33.5	28.0988
3	5.6	129	8	192.9	33.6	18.1842
2	5.4	477	141	107.1	33.7	27.9851
1	4.7	140	16	198.9	34	22.3646
1	5.1	147	115	31	34.1	28.5754
3	5.7	185	66	115.1	35.7	20.1703
2	5.5	134	16	193.7	34.5	29.7619
3	4.9	142	45	206.8	34.6	28.8816
1	5.6	129	8	192.4	34.9	20.9488
3	5.5	133	16	195.9	34.9	30.865
1	4.7	132	109	59.9	35.1	29.2689
1	5.8	165	10	227.2	35.5	32.5024
2	4.5	130	30	220.2	35.5	27.7738
3	5.1	133	3	209.7	34.4	29.9003
2	5.1	132	3	207.5	36.5	29.5954
2	5.8	167	10	226.8	36.8	30.6188
1	5.7	188	66	114.8	37.1	30.724
3	6.4	491	20	125.3	37.1	29.6428
2	4.3	90	87	185.6	26.4	30.3583
2	4.8	160	10	178.7	37.4	31.8609
2	7.0	212	24	245.3	37.4	23.8659
2	4.6	181	25	261.5	37.5	24.8242
1	4.4	82	135	78	37.8	24.0417
2	5.1	145	115	31.7	37.8	37.2528
1	4.7	120	11	188.9	37.8	32.2308
3	5.1	146	115	30.6	38.3	32.6927
2	4.6	218	134	74.9	38.3	34.4248
2	7.3	246	22	250.3	38.4	34.6339

Tabla A (continuación)

Nodos de entrada V					Nodos de salida V	
<i>Clase de suelo</i>	<i>M</i>	<i>De (Km)</i>	<i>Pf (Km)</i>	<i>Az (°)</i>	<i>D_{FI}(s)</i>	<i>D_{RNA} (s)</i>
2	4.3	132	50	155.8	38.6	34.234
2	5.3	132	106	89.3	39	34.5889
2	4.7	122	11	187.1	39.2	37.4613
2	4.7	128	28	204.7	31.4	36.3707
2	4.6	172	131	71.3	39.6	36.8563
2	5.1	147	115	32.6	39.8	37.3342
1	5.3	132	106	88.2	40.2	37.9565
2	5.7	190	66	115	40.5	37.5208
2	5.8	165	10	226.3	40.6	35.2454
1	5.3	91	10	130.7	40.6	38.7249
1	4.6	173	131	70.1	40.7	35.3938
1	4.6	173	131	70.6	40.7	36.2444
2	5.3	94	10	131.6	40.8	38.3282
1	5.8	165	10	227.5	40.9	37.4702
3	5.3	91	10	131.1	41	38.9519
2	5.0	178	84	227.9	41.1	39.9891
2	5.2	176	10	240.5	41.8	40.8184
3	5.3	130	106	88.1	41.9	41.2273
1	5.3	91	10	130	42	40.3063
3	7.6	848	10	278.4	42	32.6606
2	4.6	202	133	80.3	42.5	40.2109
2	4.4	218	145	79	42.8	42.0296
3	7.5	128	16	196.6	42.9	41.4193
2	4.9	218	150	78.1	43.2	40.6327
2	4.4	123	43	204.6	43.3	41.0704
1	6.0	220	20	233.6	43.9	41.3629
2	5.3	95	10	130.1	45.4	42.1053
2	5.3	135	106	89	45.4	42.1158
1	6.3	371	36	115.5	45.5	41.4951
2	7.0	148	69	324.1	46.4	42.8454
1	5.4	218	142	80.5	47.4	42.0101
2	5.4	217	142	81.1	47.5	42.4922
2	5.3	275	33	149.2	47.7	43.463
2	6.4	496	20	125.2	47.9	42.6402
2	5.4	220	142	81.1	48.2	43.5925
1	5.4	218	142	80.1	48.8	44.7818
1	4.3	89	87	187.8	48.9	48.5244
1	5.4	219	142	80.5	49.3	47.0689
2	5.0	283	116	103.7	52.1	49.1363
3	6.3	370	36	115.5	52.4	48.466
2	5.3	382	210	98.8	52.9	47.5279
2	6.3	375	36	115.5	53.1	47.7637
2	6.0	391	70	119	54.3	47.956
2	5.9	261	47	294.5	56.8	52.4747
3	7.0	151	69	324.1	64.8	53.5349

Tabla B. Conjunto de prueba Fase Intensa ciudad de Oaxaca

Nodos de entrada N-S					Nodos de salida N-S	
<i>Clase de suelo</i>	<i>M</i>	<i>De (Km)</i>	<i>Pf (Km)</i>	<i>Az (°)</i>	<i>D_{FI}(s)</i>	<i>D_{RNA} (s)</i>
1	4.4	18	66	227.5	15.6	14.5013
1	4.4	17	66	225	15.7	14.508
1	4.3	21	71	228.7	16.4	14.5526
2	5.4	66	22	95.9	16.5	37.8593
2	4.4	17	66	213.9	17.8	17.9272
1	4.3	128	50	156.6	19.3	30.5984
1	4.3	89	87	187.1	19.8	45.6142
1	5.5	132	16	195.4	19.9	29.3613
2	5.7	188	66	115.6	21	34.6665
1	4.9	141	45	206.4	23.1	27.5569
1	4.4	145	28	204.2	26	25.4211
1	5.7	188	66	114.8	27.1	26.1033
1	4.3	130	50	156.2	27.7	30.4295
2	5.1	132	3	207.5	28.2	34.1953
2	5.1	134	3	208.5	28.5	34.5984
1	4.7	138	63	139.8	28.8	36.9745
1	5.5	133	16	195.1	29.2	29.3855
1	5.6	129	8	191.9	30.3	28.8097
1	5.6	129	8	191.9	31	28.8097
1	4.5	72	28	177.4	31.6	38.4125
2	4.8	160	10	178.7	31.6	33.5678
2	4.7	142	63	139.2	31.7	32.4615
2	4.4	123	43	204.6	32.2	32.9829
2	4.6	194	16	201.5	32.6	33.5051
2	4.7	123	11	188.5	33.6	32.9611
2	5.8	167	10	226.8	33.8	44.5161
3	5.5	133	16	195.9	34.9	40.8949
1	4.7	132	109	59.7	35	41.9962
1	5.1	147	115	31	37.2	48.0799
2	5.2	176	10	240.5	37.4	40.63
1	5.3	91	10	130.7	37.8	41.6135
1	4.6	173	131	70.1	44.2	43.9707
2	4.6	218	134	74.9	44.7	45.0788
1	5.4	219	142	80.5	48.6	47.4203

Tabla B (continuación)

Nodos de entrada E-W					Nodos de salida E-W	
<i>Clase de suelo</i>	<i>M</i>	<i>De (Km)</i>	<i>Pf (Km)</i>	<i>Az (°)</i>	<i>D_{FI}(s)</i>	<i>D_{RNA} (s)</i>
2	4.4	19	66	220.4	14	25.3945
1	4.4	17	66	225	14.1	17.1002
1	4.3	22	71	225.4	15	15.4297
1	4.9	141	45	206	19.9	28.5682
2	5.5	135	16	194.9	20.2	26.4293
3	4.5	72	28	178.2	21.5	21.6196
2	4.4	159	42	59.1	21.8	25.1266
2	5.7	188	66	115.6	22.7	37.1304
1	5.7	187	66	114.9	24.8	31.5284
2	4.4	125	43	205.8	25.3	29.3996
2	4.4	123	43	204.6	26.5	30.0847
2	4.7	143	7	179.8	26.7	30.8702
2	4.9	141	45	204.7	27.4	31.1806
1	4.3	130	50	156.6	27.7	25.1872
2	4.9	143	45	205.7	27.9	27.52
1	5.5	133	16	194.7	28.9	25.9323
1	5.1	131	3	209.5	30.2	32.5229
2	4.5	73	28	174.8	30.3	33.8329
1	4.8	196	100	104.9	30.4	23.4193
1	5.1	132	3	209	32	32.8016
2	4.7	123	11	188.5	32.1	36.3973
2	7.0	212	24	245.3	32.6	34.9801
1	4.5	130	30	222	32.9	27.8963
1	5.5	133	16	195.1	33.5	26.8279
1	4.7	132	109	59.7	33.9	35.5662
1	5.3	91	10	130	33.9	26.2712
1	5.3	91	10	130.7	37.8	26.2834
2	5.8	165	10	226.3	38	37.0389
2	5.3	94	10	131.6	39.8	41.3975
2	4.6	172	131	71.3	40.8	42.665
1	4.6	173	131	70.6	41.2	43.6074
2	5.3	132	106	89.3	42.2	48.9557
2	5.1	147	115	32.6	42.3	41.2814
2	4.6	218	134	74.9	44.6	47.3333

Tabla B (continuación)

Nodos de entrada V					Nodos de salida V	
<i>Clase de suelo</i>	<i>M</i>	<i>De (Km)</i>	<i>Pf (Km)</i>	<i>Az (°)</i>	<i>D_{FI}(s)</i>	<i>D_{RNA} (s)</i>
2	5.5	135	16	194.9	26.3	27.6275
2	4.7	123	11	188.5	37.3	21.371
1	4.4	118	13	219.3	26.9	21.7784
1	4.4	122	43	205.8	27.3	37.649
1	4.9	141	45	206	27.7	33.489
2	4.7	180	8	161.3	28.5	22.3355
1	5.5	132	16	195.4	28.9	27.7313
1	4.3	128	50	156.6	30.5	37.2535
2	4.9	143	45	205.7	30.9	35.8954
1	5.6	129	8	191.9	38.6	33.7606
2	5.6	130	8	190.6	31.6	33.2157
1	4.8	196	100	104.9	32	26.8748
2	4.4	85	135	79.1	32	28.4385
1	4.5	130	30	222	32.2	30.1037
1	4.3	130	50	156.6	32.4	29.0097
2	5.6	131	8	191.8	33.1	32.8394
1	5.7	187	66	114.9	34.2	36.0054
1	4.7	138	63	139.8	34.3	33.9215
1	4.7	128	28	206.6	35.7	30.2532
1	5.7	188	66	115	34.4	36.0465
2	6.4	159	33	166.1	34.5	26.8778
1	5.5	133	16	195.1	34.8	40.7975
2	4.6	124	27	203.3	32	35.0049
2	4.7	142	63	139.2	35.7	32.9052
3	4.7	130	109	59.2	35.7	41.036
1	4.7	132	109	59.7	34.4	34.201
1	4.9	141	45	206.4	35.8	34.1497
2	4.7	133	109	61	35.9	40.1538
1	4.6	193	16	202.3	36.1	42.9155
1	5.3	132	106	88.5	39.8	41.8693
1	5.8	165	10	227.9	40.2	43.8471
1	5.3	133	106	88.2	41.6	49.2444
2	4.7	175	131	71.4	41.7	41.8567
2	6.0	219	20	232.6	43.5	46.2214