



**UNIVERSIDAD NACIONAL AUTÓNOMA  
DE MÉXICO**

---

---

**FACULTAD DE CIENCIAS**

**UN MODELO NEURONAL ARTIFICIAL PARA LA  
ESTIMACIÓN DE LA RESPUESTA SÍSMICA DEL  
TERRENO**

**T E S I S**

**QUE PARA OBTENER EL TÍTULO DE:**

**LICENCIADO EN CIENCIAS DE LA  
COMPUTACIÓN**

**P R E S E N T A :**

**JUAN JOSÉ HERRERA BRITO**



**DIRECTOR DE TESIS:  
DR. LEONARDO ALCÁNTARA NOLASCO  
2019**



Universidad Nacional  
Autónoma de México

Dirección General de Bibliotecas de la UNAM

**Biblioteca Central**



**UNAM – Dirección General de Bibliotecas**  
**Tesis Digitales**  
**Restricciones de uso**

**DERECHOS RESERVADOS ©**  
**PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL**

Todo el material contenido en esta tesis esta protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.

## Hoja de Datos del Jurado

### 1. Datos del alumno

Apellido paterno	Herrera
Apellido materno	Brito
Nombre(s)	Juan José
Teléfono	56422882
Universidad	Universidad Nacional Autónoma de México
Facultad	Facultad de Ciencias
Carrera	Ciencias de la Computación
Número de Cuenta	307188423

### 2. Datos del tutor

Grado	Dr
Nombre(s)	Leonardo
Apellido paterno	Alcántara
Apellido materno	Nolasco

### 3. Datos del sinodal 1

Grado	Dr
Nombre(s)	Pedro Eduardo
Apellido paterno	Miramontes
Apellido materno	Vidal

### 4. Datos del sinodal 2

Grado	Dr
Nombre(s)	Gustavo
Apellido paterno	De la Cruz
Apellido materno	Martínez

### 5. Datos del sinodal 3

Grado	Dr
Nombre(s)	Verónica Esther
Apellido paterno	Arriola
Apellido materno	Ríos

### 6. Datos del sinodal 4

Grado	L en C C
Nombre(s)	Sergio
Apellido paterno	Hernández
Apellido materno	López

### 7. Datos del trabajo escrito

Título	Un modelo neuronal artificial para la estimación de la respuesta sísmica del terreno
Número de páginas	77 p
Año	2019



## AGRADECIMIENTOS

Este trabajo es la culminación de una etapa de mi vida, y no sería posible sin el apoyo de muchas personas que nunca quitaron el dedo del renglón por mí, por ello quiero agradecerle:

A mis padres, por brindarme cariño y apoyo incondicional en todo momento aún antes de haber nacido, por regalarme valores y enseñanzas que me guiaron a ser la persona, de la cual espero sientan orgullo de llamar hijo.

A mis hermanos, por cuidarme, apoyarme, educarme y en ocasiones regañarme; cada uno con sus respectivas cualidades, las cuales para mí son un modelo a seguir, “ahora somos más hermanos que antes”.

A mi Menita, por conocer mis miedos, ser parte de mis alegrías, por ser mi amiga, mi maestra, compañera de viaje y por qué nunca, nunca me dejó solo, gracias por enseñarme a no rendirme, “aunque el frío queme, aunque el miedo muerda”.

A la Familia Martínez Sánchez porque muchas veces han sido una segunda familia para mí.

Al Doctor Leonardo Alcántara que, sin su paciencia, su tiempo, y sus amables formas de explicar muchas cosas, nada de esto sería posible.

A la UNAM, amada casa de estudios que me ha dejado tanto, así como a la Facultad de Ciencias, donde realmente descubrí el amor por las matemáticas y lo abstracto (a veces a la mala).

Así mismo a todas las personas que han estado presentes, mis primos casi hermanos, mis tíos, a mis amigos, y a todos aquellos de los que aprendí algo a lo largo de mi vida, gracias.



INTRODUCCIÓN	1
CAPÍTULO 1. FUNCIONES COGNITIVAS	5
1.1 Neurona Artificial	6
1.2 Métodos de Aprendizaje	12
1.3 Red Neuronal Artificial	14
1.4 Arquitectura	16
1.5 Funciones de Transferencia	20
CAPÍTULO 2. SISMICIDAD	23
2.1 Conceptos Generales	23
2.2 Registro Sísmico	32
2.3 Base de Datos Sísmicos	36
CAPÍTULO 3. MODELO NEURONAL	41
3.1 Herramienta de Cómputo	41
3.2 Estructura del Modelo	43
3.3 Parámetros de entrada y salida	44
3.4 Banco de Datos	45
3.5 Procesos de Entrenamiento y Prueba	45
3.6 Resultados	48
CAPÍTULO 4. CONCLUSIONES	55
REFERENCIAS	59



## INTRODUCCIÓN

Entre los países que tienen una elevada tasa de sismicidad se encuentra México, esto se debe principalmente a que está situado en una región en la cual convergen las placas tectónicas (fig. 20): Norteamericana, Pacífico, Cocos, Caribe y Rivera. Sin embargo, el fenómeno sísmico y sus efectos en la población no son un problema reciente y con regular frecuencia la naturaleza se ha encargado de manifestarlo, muestra de ello son los sismos de San Marcos del 28 de julio de 1957 (M=7.5), 19 y 20 de septiembre de 1985 (M=8.1 y M=7.6) y muy recientemente los ocurridos el 7 y 19 de septiembre del 2017 (M=8.2 y M=7.1) (ref. 1). Si bien estos últimos dos eventos tuvieron un gran impacto, especialmente en la ciudad de México, sus efectos, aunque graves, no son comparables a los producidos por el temblor del 19 de septiembre de 1985, cuya cifra oficial indica 10000 personas muertas y cientos de estructuras afectadas, por lo que ha pasado a la historia como el evento sísmico más devastador en el país.

La observación del fenómeno sísmico en nuestro país se remonta al año de 1910 cuando se funda el Servicio Sismológico Nacional (SSN) y por lo tanto se procede a la instalación de varias estaciones sismológicas. El inicio de operaciones del SSN tiene como principal objetivo el informar a la población sobre la actividad sísmica en el país, proporcionando la ubicación epicentral y la magnitud de los eventos sísmicos. Sin embargo, el conocimiento de dichos parámetros, si bien es de vital importancia, no es suficiente para determinar porqué se dañan las estructuras; por lo que, con el objetivo de complementar las mediciones del SSN (con la Red Sismológica Nacional) a principios de los años sesenta se introducen otro tipo de equipos de medición llamados acelerógrafos, los cuales miden la aceleración a la que es sometido el suelo o una estructura. Esto ha resultado en un gran avance en el conocimiento del fenómeno y su efecto en la infraestructura, puesto que ha permitido mejorar las normas y prácticas constructivas (ref. 2).

Actualmente, diversas instituciones se han dado a la tarea de instalar y operar Redes Acelerográficas en zonas del país que cuentan con el potencial suficiente para generar sismos de gran intensidad, o que sin tenerlo pueden ser gravemente afectadas por su ocurrencia. La operación de estos sistemas de registro sísmico se ha integrado en el país mediante el proyecto conocido como Red Sísmica Mexicana, el cual tiene entre sus ejes de desarrollo: a) apoyar los sistemas de monitoreo sísmico a nivel nacional y b) promover la realización de investigaciones y acciones que coadyuven a mitigar los efectos sísmicos en la sociedad.

Con relación a los sistemas de monitoreo, la cobertura instrumental ha mejorado sustancialmente; no obstante, aún existen regiones en donde es insuficiente y otras en donde hay una carencia total. Respecto a las investigaciones que se han realizado, estas han tenido un importante impacto tanto en el ámbito de la sismología como en el de la Ingeniería. Sin embargo, debido a la propia naturaleza del fenómeno cada vez que ocurre un evento sísmico se siguen presentando catástrofes, lo cual es indicativo de que aún se tiene mucho por

investigar. Al respecto, es importante señalar que, dada la complejidad del fenómeno, muchas de las metodologías tradicionales de análisis se basan en hipótesis que han permitido lograr avances significativos en el conocimiento del fenómeno pero que aún están lejos de una comprensión total.

Derivado de lo anterior y considerando el auge que en los últimos años ha tenido la Inteligencia Artificial para la solución de una gran diversidad de problemas, la aplicación de las Redes Neuronales Artificiales (RNA) para abordar eventos de origen sísmico es cada vez más recurrente.

Tanto en la Sismología como en la Ingeniería Sísmica, la determinación de diversos parámetros sísmicos es fundamental para el estudio de los temblores; en el caso de la primera se pueden señalar la magnitud, la profundidad focal, la distancia epicentral a las poblaciones y los valores de amplitud máxima del movimiento entre otros. En el caso de la Ingeniería Sísmica, además de los anteriores, es muy importante determinar el tiempo en el que una estructura está sometida a la etapa más intensa del movimiento sísmico, debido a que este factor, más la amplitud de los movimientos, están asociados al daño potencial en la misma.

La definición de la *duración de la fase intensa* y su determinación ha sido motivo del trabajo de diversos investigadores, sin embargo, siguiendo el criterio internacional establecido por el Prof. Arturo Árias que se revisará en el capítulo 2, en esta tesis se propone una metodología para su determinación utilizando información de sismos y registros obtenidos en territorio mexicano.

## Objetivo

Determinar un modelo neuronal, con capacidad predictiva, para estimar la *Duración de la Fase Intensa* del movimiento sísmico, utilizando acelerogramas obtenidos en diferentes tipos de suelo de la ciudad de Oaxaca.

## Contenido

Después de la Introducción, en el capítulo 1 se presenta un breve recorrido sobre determinados aspectos de la Inteligencia Artificial, incluidas algunas definiciones e historia. En el mismo capítulo se aborda el tema de la Redes Neuronales Artificiales, su concepción, arquitecturas y métodos de aprendizaje.

Debido a que esta tesis está estrechamente vinculada a los sismos, en el capítulo 2 se describen las regiones de mayor potencial sísmico en el planeta y en particular la condición sísmica que prevalece en el país. Se incluyen algunas definiciones sobre sismicidad y parámetros sísmicos y además se detalla el banco de datos que será utilizado en el desarrollo del modelo neuronal.

En el capítulo 3, se presenta el modelo neuronal propuesto con base en los resultados obtenidos de la exploración sobre diferentes arquitecturas y ciclos de entrenamiento. También se muestran los resultados de las etapas de entrenamiento y prueba, y se evalúa la capacidad predictiva mediante la postulación de diversos sismos que eventualmente pudieran presentarse. Finalmente, en el capítulo 4 se incluyen las conclusiones de la tesis.



## CAPÍTULO 1. FUNCIONES COGNITIVAS

El ser humano cuenta con actividades cerebrales conocidas como *funciones cognitivas*, en donde se encuentran el sentido de orientación, el reconocimiento del lenguaje, así como la representación y procesamiento de elementos en un entorno espacial, entre otros. Estas características, han destacado a la hora de desarrollar su inteligencia y su sentido de supervivencia, debido a que, con el tiempo, ha ido aprendiendo más de su entorno y de sí mismo.

Las funciones cognitivas han servido al ser humano para procesar y analizar información, que le permita reaccionar o no ante una determinada situación en la que se encuentre, con base en el conocimiento adquirido a lo largo de la vida.

Las capacidades cognitivas son esas competencias relacionadas con la cognición, aceptando a esta, como facultad consciente o inconsciente, de tomar la información que se recibe y se procesa con base en el conocimiento previamente adquirido. Por lo que puede entender a las Funciones Cognitivas como los procesos mentales que facultan al ser humano a llevar a cabo cualquier tarea, haciendo posible que el sujeto tenga un papel activo en los procesos de recepción, selección, transformación, almacenamiento, elaboración y recuperación de la información, lo que le permite desenvolverse en el mundo que lo rodea.

Las principales Funciones Cognitivas son (ref. 3):

- a) Percepción. La primera función cognitiva que se pone en marcha para poder obtener cualquier tipo de información del medio ambiente es la percepción.
- b) Atención. Otra función cognitiva que juega un papel fundamental en la entrada de información al cerebro es la atención. En el momento de recibir información, tan importante es la forma en la que se advierte, como los elementos a los que se les presta atención; es decir, la atención modula los componentes que se perciben.
- c) Compresión. Esta implica una serie de procesos como son: el análisis, la crítica o la reflexión, los cuales están articulados por la mente en una forma interactiva.
- d) Memoria. Es un proceso o conjunto de procesos que permiten codificar, almacenar y recuperar la información, una vez que ésta “ha entrado” en las neuronas.
- e) Lenguaje. Es la capacidad de relacionar un sistema de códigos, con significados de objetos del mundo exterior, así como sus acciones,

cualidades y relaciones entre los mismos. Por lo que el lenguaje podría ser considerado como una forma especial de memoria, que permite recordar de manera automática la relación entre una palabra y un significado.

- f) Orientación. Se entiende así al conjunto de funciones psíquicas, que permiten percibir, en todo momento, la situación real en la que se encuentra un individuo. Dicho de otra forma, las experiencias y recuerdos hacen posible que se tenga conciencia sobre la propia persona y de su situación en el espacio y el tiempo. Sin embargo, la orientación no es un simple recuerdo, es la conjunción de múltiples recuerdos y conocimientos.
- g) Praxis. Es la capacidad que se tiene para realizar movimientos voluntarios, intencionados y organizados.
- h) Funciones ejecutivas. Son aquellas que conjuntan las capacidades cognitivas, puesto que se encargan de poner en marcha, organizar, integrar y manejar el resto de las funciones que posee el cerebro.
- i) Razonamiento. Con él se es capaz de realizar funciones organizadoras relacionadas con la lógica, la estrategia, la planificación o la resolución de problemas. Esto permite integrar la información almacenada en las neuronas, de manera que se puedan “adquirir nuevos conocimientos a través de lo ya conocido”. Con esta capacidad cognitiva aparecen las ideas, los juicios o las conclusiones.

## 1.1 Neurona Artificial

### Inteligencia Artificial

La Inteligencia Artificial (IA) ha sido concebida con el propósito de lograr que una máquina piense como humano y además que realice actividades consiguiendo resultados precisos. Un agente que cuente con IA busca y encuentra opciones que son aproximadas a un resultado real, cumpliendo con parámetros suficientes para solucionar un determinado problema. Así es posible predecir el comportamiento de ciertos fenómenos naturales, lo cual resultaría muy difícil o hasta imposible de hacer mediante el uso de algoritmos deterministas, entre estos casos se pueden señalar la exploración de terrenos desconocidos, la respuesta a preguntas aleatorias o inclusive simular el comportamiento humano, etc.

En la tabla 1, se incluyen algunas definiciones sobre la IA, de acuerdo a los siguientes enfoques:

Tabla 1. Definiciones de Inteligencia Artificial (ref. 4).

Sistemas que piensan como humanos	Sistemas que piensan racionalmente
<p><i>El nuevo y excitante esfuerzo de hacer que los computadores piensen... máquinas con mentes, en el más amplio sentido literal. (ref. 5)</i></p> <p><i>La automatización de actividades que vinculamos con procesos de pensamiento humano, actividades como la toma de decisiones, resolución de problemas, aprendizaje... (ref. 6)</i></p>	<p><i>El estudio de las facultades mentales mediante el uso de modelos computacionales. (ref. 7)</i></p> <p><i>El estudio de los cálculos que hacen posible percibir, razonar y actuar. (ref. 8)</i></p>
Sistemas que actúan como humanos	Sistemas que actúan racionalmente
<p><i>El arte de desarrollar máquinas con capacidad para realizar funciones que cuando son realizadas por personas requieren de inteligencia. (ref. 9)</i></p> <p><i>El estudio de cómo lograr que los computadores realicen tareas que, por el momento, los humanos hacen mejor. (ref. 10)</i></p>	<p><i>La Inteligencia Computacional es el estudio del diseño de agentes inteligentes. (ref. 11)</i></p> <p><i>IA... está relacionada con conductas inteligentes en artefactos. (ref. 12)</i></p>

El enfoque que sigue la ideología de este trabajo es el de los Sistemas que actúan racionalmente al contar con un agente que trata de alcanzar el mejor resultado posible, con base en la conducta y el pensamiento humano (ref. 13).

A continuación, un poco de la historia sobre la evolución de la IA (ref. 14):

Los primeros autores reconocidos en IA fueron Warren *McCulloch* y Walter *Pitts* en el año de 1943, ellos propusieron un modelo constituido por neuronas artificiales. En 1949 *Donald Hebb* propuso y demostró la regla conocida aprendizaje *Hebbiano*, para modificar las intensidades de las conexiones entre neuronas. Más tarde *Marvin Minsky* y *Dean Edmonds* construyeron el primer computador a partir de una red neuronal en 1951.

*Alan Turing* revolucionó el campo de la IA en 1950 cuando articuló primero una visión de la IA en su artículo *Computing Machinery and Intelligence* en donde introdujo la prueba de *Turing*, el aprendizaje automático, los algoritmos genéricos y el aprendizaje por refuerzo.

Luego *Allen Newell* y *Herbert Simón* inventaron un programa de computación capaz de “pensar” de manera no numérica y después uno que imitara protocolos de resolución de problemas como lo harían los seres humanos.

Más tarde entre el año 1952 y 1956 en *IBM* un grupo de colegas desarrollaron programas de IA, entre ellos *Herbert Gelernter* con su demostrador de teoremas de geometría y *Arthur Samuel* con programas para el juego de damas, entre otros.

*John McCarthy* definió el lenguaje *Lisp* en 1958, que es el lenguaje de IA más usado, también publicó un artículo de nombre *Programs with Common Sense* que podría considerarse como el primer sistema de IA completo, el cual podría aceptar nuevos axiomas sin necesidad de reprogramación.

Luego, una serie de estudiantes supervisados por *Marvin Minsky* crearon programas limitados con necesidad de inteligencia, estos fueron llamados micromundos, el más conocido fue el mundo de los bloques creado por *Terry Winograd*. Este último junto con *Cowan*, creó la regla en donde una representación de un elemento podría ser representado con varios de forma colectiva.

Fue en 1962 cuando el aprendizaje de *Hebb* retomó fuerza gracias a las aportaciones de *Bernie Widrow* y *Frank Rosenblatt* quienes utilizaron las redes *Adaline* y *Perceptrón* respectivamente.

Después, en una época difícil para la IA, se siguió trabajando en distintos campos, entre ellos las redes neuronales. De estas, en el año 1969, *Minsky* y *Papert* en su trabajo *Perceptrons* demostraron que una red neuronal simple, como los perceptrones, tiene la capacidad de modelar muchas situaciones reales, aunque su capacidad de representación es muy limitada. En este mismo año, el programa *DENDRAL* se creó en *Stanford* siendo uno de los primeros sistemas basados en conocimiento y además el primero de conocimiento intenso, este infería una estructura molecular basándose en información recopilada por un espectrómetro de masas. Después en la misma universidad, *Feigenbaum* junto con otros investigadores se enfocan en el campo de los sistemas expertos en su Proyecto de Programación Heurística.

Por otra parte, entre 1977 y 1983 *Schank* y sus estudiantes trataron de crear programas que entendieran y pudieran entender la comprensión del lenguaje natural. A partir de este punto se crearon varios lenguajes que servían para la representación y el razonamiento como lo son *prolog* y *planner*.

Más tarde, alrededor de los años 80 hasta la actualidad surgió un gran incremento de la IA en la industria, desde el primer sistema experto conocido como R1 creado por *McDermontt* para la *Digital Equipment Corporation*, programa que se encargaba de la elaboración de pedidos de nuevos sistemas informáticos. Para 1988 esta empresa ya habría distribuido 40 sistemas expertos, inspirando a otras compañías de Estados Unidos a tener sus propias áreas de IA en donde principalmente se desarrollarían sistemas expertos, para convertirse en una industria de billones de dólares.

Por su parte, las redes neuronales tuvieron una evolución considerable debido al trabajo de *Rumelhart* y *McClelland* sobre temas de conexionismo y de procesamiento distribuido en paralelo alrededor del año de 1986. Más recientemente se han producido investigaciones y metodologías en la IA, sobre todo desarrollándose sobre teorías ya existentes, que cuenten con evidencias sólidas experimentales. Con base en estos desarrollos se creó la técnica de la minería de datos.

Más tarde *Judea Pearl* publicó su trabajo *Probabilistic Reasoning in Intelligent Systems* en 1988 en el cual se aceptan a la probabilidad y la teoría de decisión como parte de la IA gracias a lo cual se pudieron crear las redes de *Bayes*. Estas sirvieron para la representación eficiente y el razonamiento riguroso en situaciones de incertidumbre, en este enfoque se facilita el aprendizaje basado en la experiencia. Este trabajo sirvió de guía para los sistemas expertos normativos que actúan racionalmente sin intentar imitar las etapas del razonamiento.

Luego se trataron de resolver derivados del problema del agente total, como es el caso de *SOAR* creado por *Allen Newell*, *John Laird* y *Paul Rosenbloom*. Actualmente estos sistemas con agentes inteligentes son muy populares debido a la facilidad con la que se puede acceder a internet, programas como motores de búsqueda, sistemas de recomendación o la asistencia para la creación de portales Web.

Después de tantos años de investigación se podría decir que la IA ha alcanzado muchas áreas de conocimiento, como la planificación autónoma, los juegos, el control autónomo, la diagnosis, la planificación logística, el reconocimiento de lenguaje, la resolución de problemas y la robótica. Estas tecnologías se han mezclado tanto con la vida cotidiana de los seres humanos que en ocasiones no se dan cuenta que la mayoría de los objetos tecnológicos tienen al menos un pequeño módulo que implementa IA.

## Origen de las Redes Neuronales Artificiales

En un principio se plantearon las similitudes que tienen las redes neuronales biológicas con los circuitos digitales, teniendo una percepción más simple de los procesos del cerebro humano. Con el paradigma de aprendizaje de *Hebb*, se crearon muchos algoritmos de aprendizaje utilizados en la actualidad. *Frank Rosenblatt* logró grandes avances con su modelo del Perceptrón modificado, además de demostrar cómo éste converge a una solución en caso de existir. Después, gracias a *David Everett Rumelhart* y la reinención del algoritmo de Retropropagación, las redes neuronales retomaron fuerza con nuevos algoritmos de aprendizaje y nuevas arquitecturas (refs.14 y 15).

## La neurona biológica

Las neuronas, en esencia son células que se comunican unas con otras intercambiando elementos químicos y cargas eléctricas por medio de zonas de contacto denominadas sinapsis.

Una neurona biológica se compone principalmente de tres elementos (fig. 1).

Las dendritas de aproximadamente un milímetro de longitud reciben una señal proveniente de otras neuronas e incluso de algunos órganos para después concentrar estas señales mediante sus abundantes ramificaciones en el cuerpo.

El cuerpo también conocido como soma es el de mayor extensión dentro de la neurona, puede medir varios metros, con terminales nerviosas gruesas conocidas como placas sinápticas, en él, mediante procesos electroquímicos se maneja la información obtenida y según su evaluación puede o no enviar un impulso nervioso a través del axón.

Entonces el axón manipula la información para hacerla llegar a alguna otra neurona, músculo o glándula del cuerpo mediante sus aproximados 10 centímetros de longitud (ref. 16).

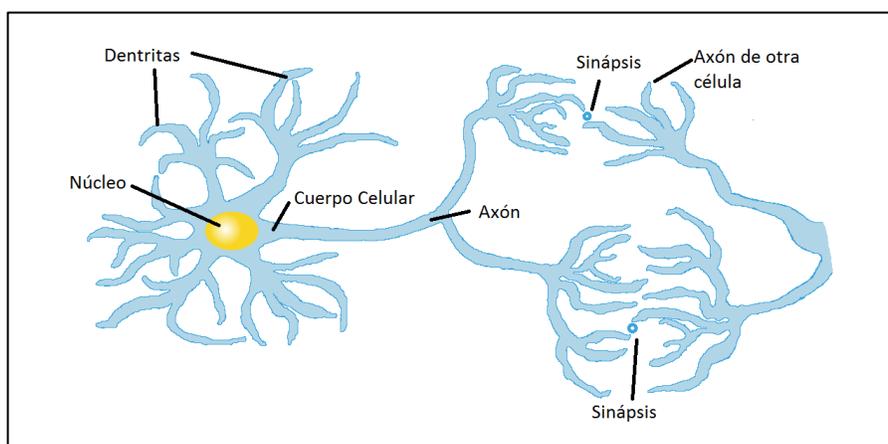


Figura 1. Estructura básica de una Neurona Biológica.

Las neuronas están organizadas en tres grupos principales según su función, las receptoras le permiten al cuerpo reaccionar ante distintos hechos de la vida cotidiana (los 5 sentidos), convirtiendo la información recibida en impulsos eléctricos, donde las neuronas de tipo intermedio dan forma a la señal de entrada para que las neuronas de salida se encarguen de notificar a los órganos (ref. 17).

## El modelo Artificial

Cada neurona artificial está compuesta por tres elementos principales, estos están inspirados en las dendritas, soma y axones de las neuronas biológicas, y son las entradas, el cuerpo y las salidas respectivamente.

En un modelo artificial de la neurona se tienen  $n$  entradas de información, conocidas como vector de entrada, funciona como se describe a continuación basado en la figura 2 y con funciones como las descritas en las referencias 18 y 19.

Los pesos en un principio son aleatorios para después ajustarse poco a poco en cada ciclo recorrido en su red neuronal.

El aprendizaje que sigue una neurona artificial en una red neuronal comienza con un conjunto de entradas  $x_1, x_2, x_n$ , además cada una tiene asociada un peso  $w_{ij}$ , los cuales al ser modificados logran que la red se adapte a diferentes problemas. Estos pesos asocian la neurona que recibe la información  $j$  y las neuronas que envían dicha información  $i$ .

Luego sumando el producto de los valores de entrada y sus pesos se obtienen las entradas ponderadas, de manera que en la neurona  $j$ , con  $n$  entradas, se obtendría la ecuación (1), a esta se le llama función de entrada.

$$y_j = \sum_j^n x_i w_{ij} \quad (1)$$

Después, mediante una regla de propagación previamente definida en la ecuación (2), usando las entradas y los pesos, se obtiene un valor potencial de salida de la neurona.

$$n_j(t) = \sigma[w_{ij}, x_j(t)] \quad (2)$$

El valor de salida de esta neurona es pasado por una función de transferencia en (3), la cual se encarga de evaluar, y distribuir los valores al proceso de evaluación de los nodos, misma con la cual es posible acotar su crecimiento numérico y conseguir un valor razonable.

$$Y_j(t) = f_j[n_j(t)] \quad (3)$$

Por último, al valor devuelto por la función de transferencia, llamado comúnmente estado de activación  $a_j(t)$ , se le evalúa con una función de salida  $F_i$ , usando la función identidad por ser la de uso más común, la función de transferencia termina siendo considerada como la propia salida de la neurona:

$$y_j(t) = F_j[a_j(t)] = a_j(t) \quad (4)$$

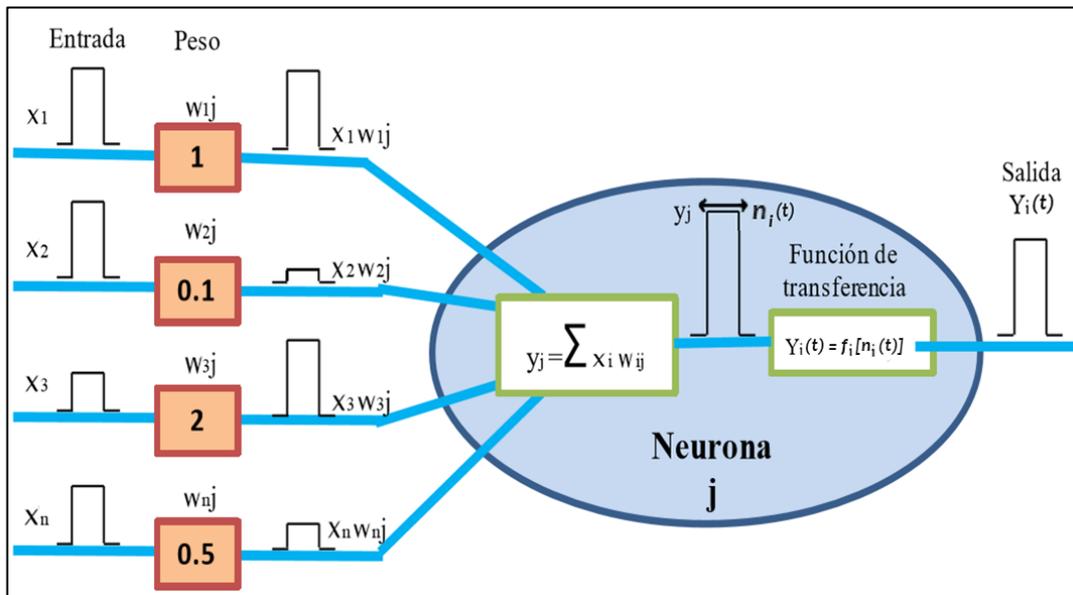


Figura 2. Estructura general de una neurona artificial (ref. 19).

## 1.2 Métodos de Aprendizaje

Las redes neuronales utilizan técnicas para mejorar su comportamiento modificando su arquitectura y los valores de los pesos, llamándole a este proceso aprendizaje, estos modifican los pesos para cada red, tomando como base datos previos, conocidos como conjunto de entrenamiento, por tanto, se les conoce como **proceso de entrenamiento o acondicionamiento**.

Existe una clasificación importante para los tipos de aprendizaje (refs. 20, 21 y 22), y estos pueden ser:

- a) Supervisados. El aprendizaje supervisado se da cuando se tiene marcado un objetivo de salida y se tienen los parámetros necesarios para medirlo. Un flujo general de esto se puede apreciar en la figura 3, todo comienza con entradas en la red, mismas que regresan una salida. La salida obtenida se compara con objetivos fijos de los resultados, al ser evaluados en calidad, se obtiene un vector de error, que representará qué

tanto se tiene que modificar los tipos de entrada, para tener algunas mejoras. Estas entradas de mayor calidad son obtenidas por el mecanismo de aprendizaje que se haya establecido para la red neuronal.

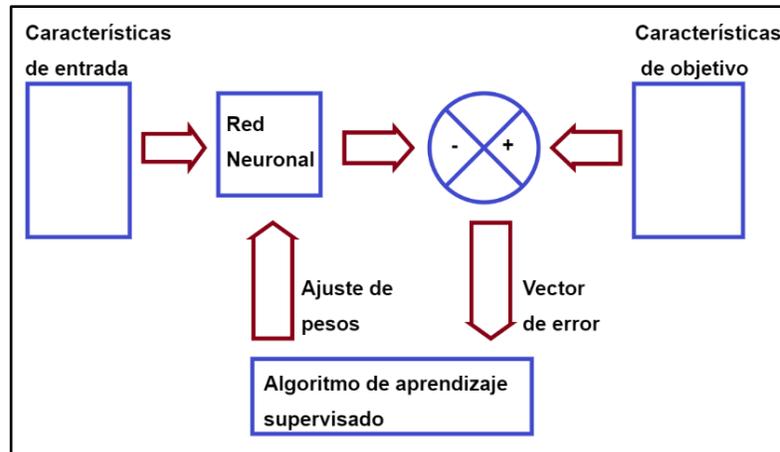


Figura 3. Algoritmo de aprendizaje supervisado (ref. 22).

- b) No Supervisado. Un método de aprendizaje no supervisado, no cuenta con parámetros con los cuales se pueda comparar la salida, pues se basa en patrones de entrada dados a un agente, que sirven como guías para el correcto aprendizaje. A esta propiedad se le conoce como auto organización.
- c) Aprendizaje por refuerzo. Basándose en el entrenamiento, se desea que el agente aprenda la diferencia entre las acciones que se deben tomar en diferentes estados y a evitar situaciones que no contengan recompensas, tratando de obtener una recompensa mayor inmediata y a largo plazo.
- d) Competitivo. En este método se tienen varias neuronas en la capa de salida. Por ciclo, cuando una salida esté más cercana al objetivo que las demás, los valores de entrada que lo consiguieron serán almacenados como dominantes en una capa oculta extra llamada capa competitiva. Al final se compararán con un vector patrón, y la neurona más parecida será la ganadora.

El método de aprendizaje usado en este trabajo será el de Retropropagación, propuesto por *Paul Werbos* en 1994, siendo un caso de aprendizaje supervisado. Esta técnica es usada para entrenar una red neuronal del tipo Perceptrón multicapa y consta de dos etapas. La primera es la que avanza, esta inicializa los pesos de cada capa (incluyendo las ocultas), se hace uso de un vector de aprendizaje y la salida del Perceptrón para medir el error, durante esta etapa se produce un costo escalar. La segunda etapa del algoritmo consiste en retroceder sobre las capas y reasignar los pesos mediante la evaluación del error obtenido

en las etapas anteriores. Esta etapa hace uso de la información del costo escalar para calcular el gradiente con respecto a los pesos. El aprendizaje ocurre desde que se asignan los vectores de aprendizaje en la primera etapa hasta que finaliza la segunda. Es importante mencionar que los optimizadores con base en el gradiente conducen a una función a un valor muy chico, haciendo uso del costo escalar (refs. 23 y 24).

### 1.3 Red Neuronal Artificial

En las redes neuronales artificiales se consideran las acciones y los procesos que se realizan en el cerebro humano, usando las neuronas y su comportamiento como inspiración para crear modelos que puedan aprender con base en un conocimiento previo y sean capaces de emular capacidades del mismo. Las redes neuronales de este tipo se pueden definir como *un nuevo sistema para el tratamiento de la información, cuya unidad básica de procesamiento está inspirada en la célula fundamental del sistema nervioso humano: la neurona* (ref. 25). Una red neuronal se compone de elementos simples conectados entre sí que procesan la información para mandar señales al exterior.

El Perceptrón simple (el modelo de neurona artificial mostrado anteriormente) es una de las redes neuronales más sencillas, cuenta con una sola capa, entradas y una salida (para este caso es solo una).

Una red neuronal contiene neuronas artificiales que funcionan almacenando e intercambiando información, conectadas unas a otras, forman una red donde algunas se encargan de recibir datos (capa de entrada), otras (capa oculta) calculan las características intermedias necesarias para generar un mensaje como resultado final (en la capa de salida) a el proceso que realizó la red. A continuación, se mencionarán algunas otras características que llegan a tener las redes neuronales.

Con base en la diversidad de problemas es natural que exista una gran variedad de tipos de redes, con diferencias que las hacen especiales o con diseños específicos para resolver una gama de problemas, que, de hacerlo con una red neuronal general, el costo sería considerablemente mayor al de una red especializada.

Además de las diversas variaciones que pueden tener las redes, estas cuentan con los siguientes elementos:

- a) La regla de propagación. Establece la forma en que se transmite la información entre los nodos de las diferentes capas.
- b) La función de transferencia. Sirve para evaluar la condición de un nodo, cuando ha procesado información de entrada, para determinar si la misma deberá ser transmitida o no de acuerdo a la regla de propagación.
- c) El proceso de aprendizaje. Cuando a un modelo neuronal le son presentados diversos patrones de entrada y sus correspondientes salidas, se le requiere establezca las relaciones existentes entre estos datos de entrada-salida y por lo tanto haga una estimación propia de las salidas. Si al hacerlo, se presentan discrepancias al respecto, es decir existe un error, éste debe ser reducido hasta un valor aceptable mediante el ajuste del peso de las conexiones entre los nodos. Al reducirse el error se dice que el modelo está aprendiendo, es decir, está obteniendo conocimiento. Una vez que un modelo ha sido entrenado deberá ser valorado y probar su desempeño para que evalúe un conjunto de patrones entrenada-salida que no fueron utilizados durante el entrenamiento (fig. 4).

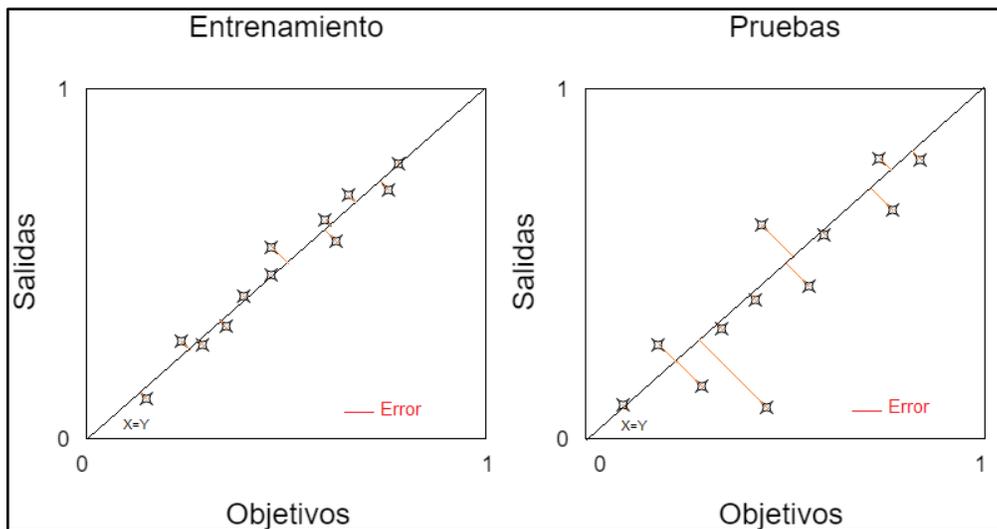


Figura 4. Etapas de aprendizaje y prueba.

Un problema frecuente es el **sobre-entrenamiento** que surge de dos formas, una sucede al realizar un número muy grande de iteraciones durante el entrenamiento donde el modelo en lugar de aproximarse a la solución tiende a divergir y por lo tanto a incrementar el error; se le relaciona con la memorización de datos y la pérdida de generalización en la respuesta. La otra forma es debida a valores inadecuados en los parámetros del algoritmo de entrenamiento, para distinguir entre las dos se necesita un conjunto de pruebas sin sesgos.

El ajuste pobre y el sobre ajuste, como se le conoce al sobre-entrenamiento, se da también sobre el espacio de hipótesis, suceden cuando no se eligen las características correctas del problema para representarlo, muy pocas podrían no lograr representar el problema, y muchas podrían representar muy bien el entrenamiento pero fallar al tratar de generalizar nuevos ejemplos.

En general, cada red neuronal tiene su propia regla de propagación, funciones de transferencia y tipo de aprendizaje; lo que determina la forma en que los nodos hacen o no sinapsis y por lo tanto el propagar o no la información procesada.

## 1.4 Arquitectura

La arquitectura de una red neuronal está determinada por su número de capas (entrada, ocultas y salida), por el grado de conexiones y por la forma en que la información es propagada. Entre las arquitecturas más utilizadas se encuentran (ref. 26):

- a) Redes de Función de Base Radial. Estas cuentan con tres capas, una de entrada, una oculta y una de salida, además emplean una función de transferencia para la segunda y tercera capa. Su característica principal es que en la capa oculta cada nodo tiene representada una función de base Gaussiana, con la primicia de reducir la distancia entre los puntos de entrada y un punto central en cada iteración de entrenamiento. Han sido utilizadas en el procesamiento de imágenes para diagnósticos médicos entre otros.
- b) Redes Neuronales Recurrentes. Estas se caracterizan por tener conexiones entre los nodos de salida, y los de entrada (aunque esto no limita la conexión entre cualquier par de nodos de distintas capas). Lo anterior, les permite simular el almacenamiento de la información de salida, y su reutilización al ingresarla como nodo de entrada. Un ejemplo se muestra en la figura 5 donde la salida Y2 pasa a ser la entrada X3 para entrar de nueva cuenta en la red neuronal; durante este proceso suele ocurrir un cierto retraso. Un ejemplo del uso de este tipo de redes es en los sistemas de detección de redes (IDS por sus siglas en ingles), programas que ayudan a detectar accesos sin autorización a un equipo o una red, ya que su capacidad predictiva basada en entradas anteriores al sistema, le proporciona un beneficio a su seguridad.

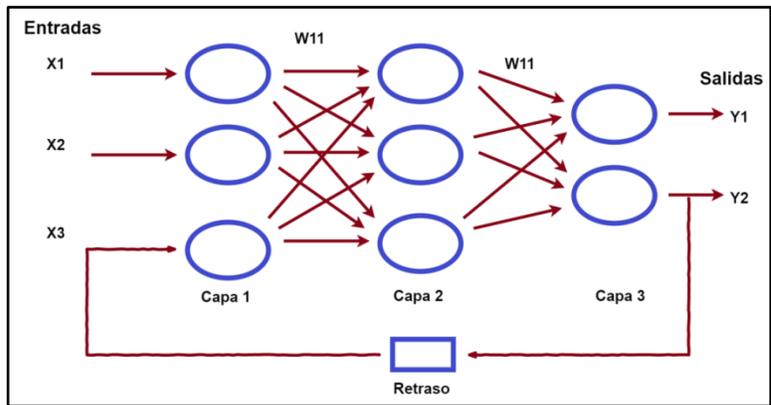


Figura 5. Red neuronal recurrente.

c) Redes neuronales de *Hopfield*. Simulando una memoria auto asociativa, conectando a todas las neuronas con las demás (en teoría de grafos, a estas se le conocen como gráficas completas) y en algunas son permitidas incluso las conexiones consigo mismas (un bucle, en teoría de grafos) (fig. 6). Existen también 4 variaciones sobre la arquitectura de *Hopfield*, las binarias manejan conexiones bidireccionales con el mismo peso de ida y de regreso, teniendo conexiones con todas las neuronas, menos consigo misma. Una de las características más importantes es que pueden transmitir la información de manera síncrona o asíncrona. Las continuas guardan la misma estructura que las binarias, pero estas mantienen los números que maneja dentro del rango de los reales que va desde -1 a 1 y comúnmente involucran ecuaciones. Las continuas de tiempo se caracterizan por usar una ecuación diferencial para manipular la función de transferencia. Por último, las discretas manejan la regla de *Hebb* y sus vectores en determinados estados convergen en su estado inicial a un error mínimo.

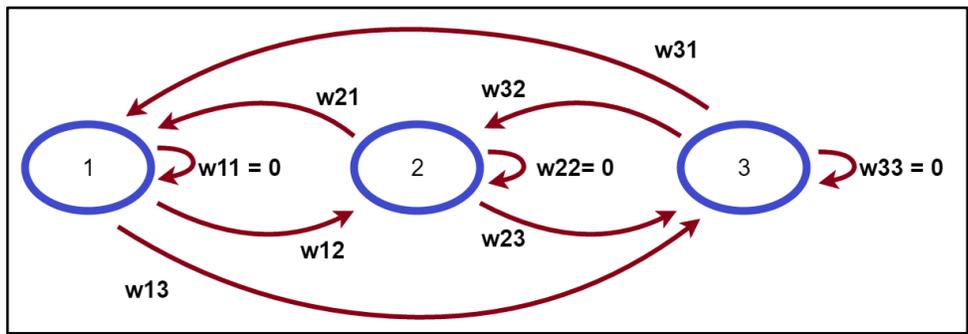


Figura 6. Red Neuronal de *Hopfield*.

- d) Redes Neuronales con propagación hacia adelante. Estas son las de uso más común, pues cuentan con una mejor capacidad de adaptación. Siendo la red neuronal más sencilla después de la que está constituida por solo una neurona, sus características son: Flujo de información exclusivamente en una dirección, de ahí que su nombre sugiera a una alimentación hacia adelante. Un ejemplo de una red neuronal común puede ser apreciado en la figura 7. Estas redes son las más sencillas y han mostrado buen desempeño en la identificación y clasificación de patrones en donde no se requiera la retención de información de eventos anteriores.

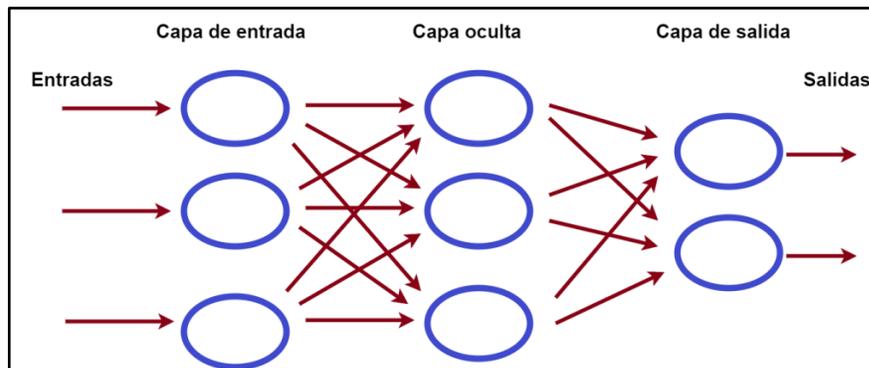


Figura 7. Red Neuronal con propagación hacia adelante.

El Perceptrón Multicapa es una red neuronal artificial construida sobre una red neuronal con propagación hacia adelante, es una generalización del perceptrón simple, éste puede aproximarse a cualquier función continua en un espacio  $R^n$ , con al menos una capa oculta de neuronas. Dos desventajas de su uso son que: ante un gran número de variables el proceso de aprendizaje puede ser muy largo y no es fácil de analizar debido a parámetros no lineales.

Un Perceptrón cuenta con neuronas agrupadas en tres conjuntos: el de la capa de entrada que se encarga de recibir señales del exterior y distribuirlas a las neuronas de la siguiente capa sin actuar de la forma común en la que lo hace una neurona; las capas ocultas procesan los datos recibidos de forma no lineal, teniendo desde 1 a  $m$  capas ocultas ( $m$  es un número natural mayor o igual a 1); y por último, la capa de salida se encarga de entregar la respuesta de la red. En la figura 8 se ilustra la estructura general de un Perceptrón Multicapa donde es posible usar más de una neurona en la capa de salida, y distinto número de nodos por capa, las conexiones guardan una dirección de alimentación hacia adelante (de ahí su nombre en inglés *feedforward*), y todas las neuronas de una capa esta conectadas con las de la capa siguiente, a lo que se le conoce como conectividad total.

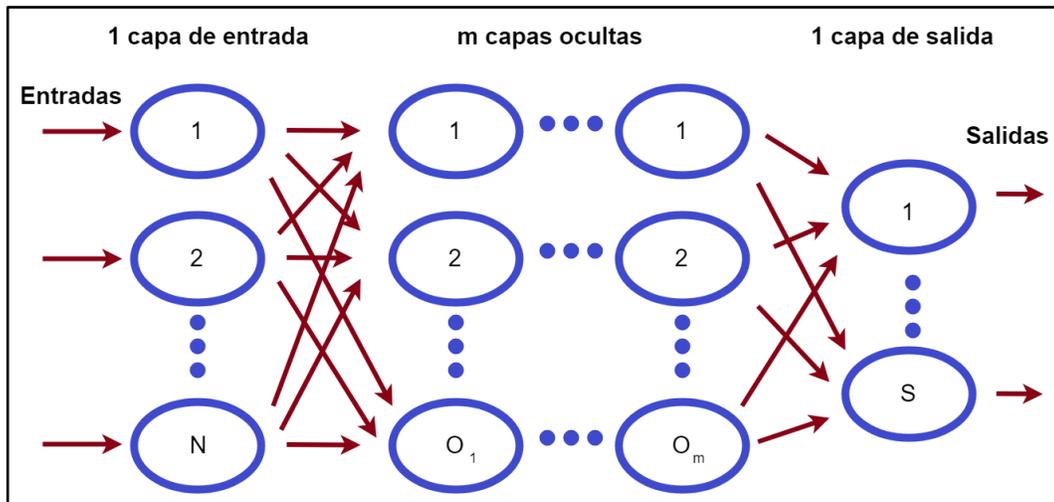


Figura 8. Estructura del Perceptrón multicapa, donde: N y S son el número de Nodos en la capa de entrada y salida respectivamente y  $O_i$  el número de nodos en la capa oculta  $i$ .

A pesar de lo antes mencionado, existen dos modelos que entran también en esta categoría, como las son redes con conexiones a capas posteriores no inmediatas, o las redes donde la conexión de una neurona a otra de la capa siguiente no existe.

Para resolver un problema con este tipo de redes primero se tiene que determinar la función de transferencia (la cual no determina la capacidad de una red para resolver problemas), la arquitectura como la cantidad de capas ocultas o neuronas por capa, como los parámetros de entrada y salida. Para elegir estos, no existe un método o técnica generales.

Para las capas ocultas regularmente se hace prueba y error, variando el número de nodos y capas ocultas esperando al menos una solución. Es común que el parámetro de salida esté definido intrínsecamente por el problema, con el conocimiento de la solución que se busca obtener. En cuanto a la elección de parámetros de entrada, es posible tener problemas donde las variables de entrada son fáciles de elegir, de lo contrario es necesario tener bien estudiado el problema, de ser posible aplicar un análisis previo a las variables, pues tener algunas irrelevantes sería equivalente a un mayor número de conectividad, mayor tiempo de aprendizaje y por lo tanto una mayor dificultad al resolver el problema.

La elección de la arquitectura es importante porque aunque diferentes arquitecturas pueden resolver el mismo problema, algunas los resuelven de maneras más efectivas.

El algoritmo de aprendizaje de una red es el método por el cual una red adapta o mejora sus capacidades, el Perceptrón Multicapa usa el algoritmo de Retropropagación, modificando sus parámetros para que las salidas se aproximen a un resultado deseado, siendo este un método de aprendizaje supervisado. En este se propaga el error hacia atrás mediante las capas, y a su vez por cada neurona, buscando minimizar el error obtenido.

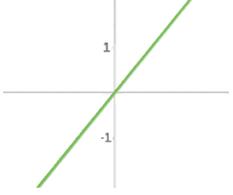
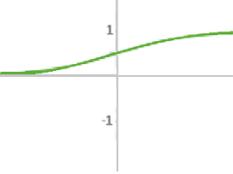
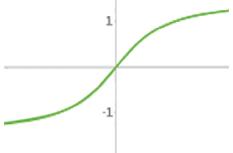
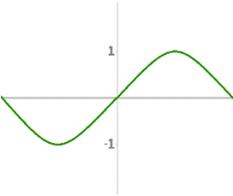
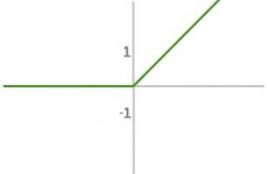
## 1.5 Funciones de Transferencia

Para establecer la comunicación entre valores, las entradas y salidas de una RNA se hace uso de las funciones de transferencia. Cada neurona procesa la información recibida y con base en la evaluación de la función elegida, se elige una respuesta o activación (interpretación de las salidas).

Entre las funciones más usadas, destacan la ReLU, sigmoidea y la arcotangente donde sus imágenes son los intervalos continuos en  $[0, 1]$  y  $[-1, 1]$  respectivamente. Además de estas, otros ejemplos de uso regular se muestran en la tabla 2.

La función de transferencia puede ser elegida para cada neurona de la red, sin embargo, es común que se elija una sola función para todas. Dependiendo del problema a resolver se puede llegar a elegir una función para las neuronas de la capa de salida. En realidad, la variación en la elección de estas funciones para la toma de decisiones está ligada al número de parámetros que se pueden entrenar, a las decisiones o experiencia del diseñador de la RNA, y al umbral de valores de activación que se determine alcanzar.

Tabla 2. Funciones de Transferencia.

Nombre	Expresión Matemática	Gráfica
Escalón	$f(x) = \begin{cases} 0 & \text{si } x < \theta \\ 1 & \text{si } x \geq \theta \end{cases}$	
Identidad	$F(X) = X$	
Sigmoidea	$f(x) = \frac{1}{1 + e^{-x}}$	
Arcotangente	$\text{Arctang}(X)$	
Seno	$\text{Sin}(X)$	
ReLU	$\text{Max}(X,0)$	



## CAPÍTULO 2. SISMICIDAD

### 2.1 Conceptos Generales

En general se puede decir que un sismo es una perturbación repentina de la Corteza Terrestre, que provoca vibraciones o movimiento en la misma. Las perturbaciones pueden tener un origen natural o artificial, las ocasionadas por fuentes naturales regularmente están ligadas con el movimiento de las placas tectónicas, pero también pueden surgir por otros eventos como el deslizamiento de laderas, el colapso de cavernas, la actividad volcánica y el impacto de meteoritos. Los artificiales son causados por la actividad humana y en este caso se encuentran: las explosiones nucleares, el llenado de embalses, el derrumbe de un edificio, etc. (ref. 27).

La estructura de la Tierra (fig. 9) está integrada por (ref. 28):

- a) Núcleo. Está formado de una parte interna y otra externa; la primera es sólida con un radio de 1278 km, la cual se encuentra sometida a presiones muy grandes y a temperaturas que alcanzan los 6700 grados Celsius. La externa es líquida y el flujo metálico que genera dota a la Tierra de su campo magnético, tal núcleo externo tiene un espesor aproximado de 2200 km.
- b) Manto. Tiene un espesor aproximado de 2900 km y está formado básicamente por silicatos, en su parte inferior, en la frontera con el núcleo externo se encuentra la discontinuidad de *Gutenberg*. Por otra parte, en su lado superior, donde se une con la corteza, se encuentra la discontinuidad de *Mohorovic*. En el manto la diferencia de temperaturas entre sus regiones genera corrientes de convección.
- c) Corteza. Es la región más superficial de la Tierra, integrada por una región Continental y otra Oceánica, la cual tiene un espesor que varía de 5 km en el fondo del océano a 70 km en las zonas montañosas. La corteza al ser frágil ha dado lugar a la formación de diversas placas tectónicas. La región formada por la corteza y por la zona más externa del manto residual (la cual flota sobre una capa blanda conocida como astenosfera) es conocida como litosfera.

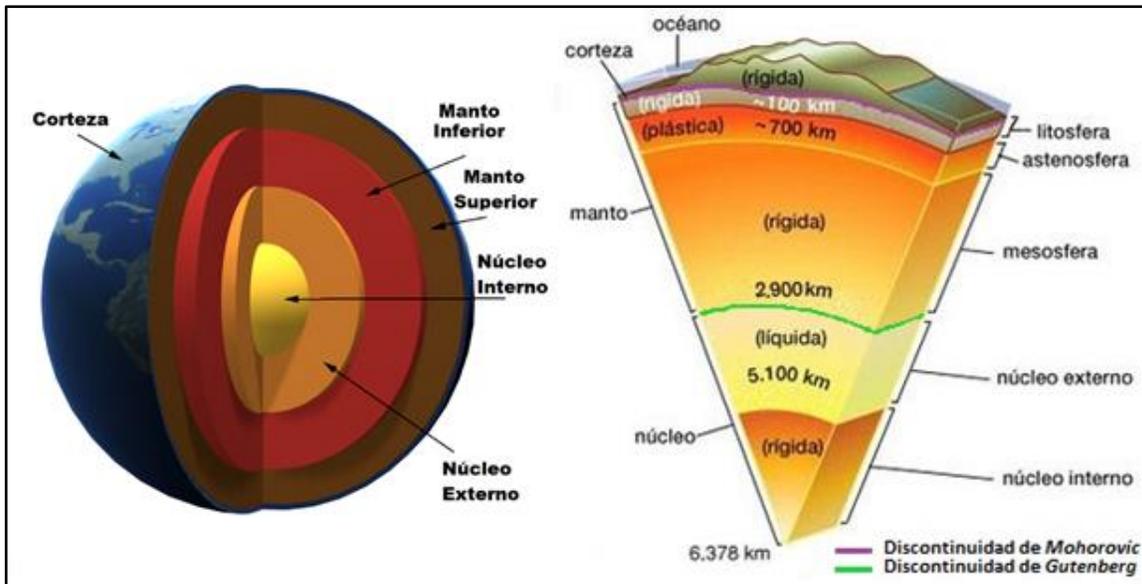


Figura 9. Estructura interna de la Tierra. Núcleo, manto, corteza (refs. 29 y 30).

## Deriva Continental

*Alfred Wegener* en 1912 presentó la teoría de la Deriva Continental, en la cual se plantea que hace 300 millones de años los continentes se encontraban unidos formando un súper-continente conocido como Pangea (ref. 31). Dicha teoría se basó en: a) la Geografía, dada la gran coincidencia en cuanto a la forma de regiones como las de Sudamérica y África, b) la Geología, puesto que existen formaciones rocosas que datan de un mismo periodo en diferentes continentes, c) el Paleoclima, dada la distribución que determinadas rocas sedimentarias tienen en distintos continentes y cuyo origen se encuentra asociado a un clima en específico, d) la Paleontología, que permitió determinar fósiles de una misma especie en continentes distintos y separados por grandes masas de agua.

No obstante, las pruebas que *Wegener* ofreció en su teoría, esta no fue aceptada por la comunidad científica y fue hasta 1960, cuando con la teoría de la Tectónica de Placas se comprobó que el movimiento al que hacía referencia *Wegener* ha existido desde hace millones de años, debido a las corrientes de convección producidas en el manto y que tienen efectos en la litosfera. En la figura 10 se ilustra la transformación de la corteza terrestre desde hace 225 millones de años hasta nuestros días.

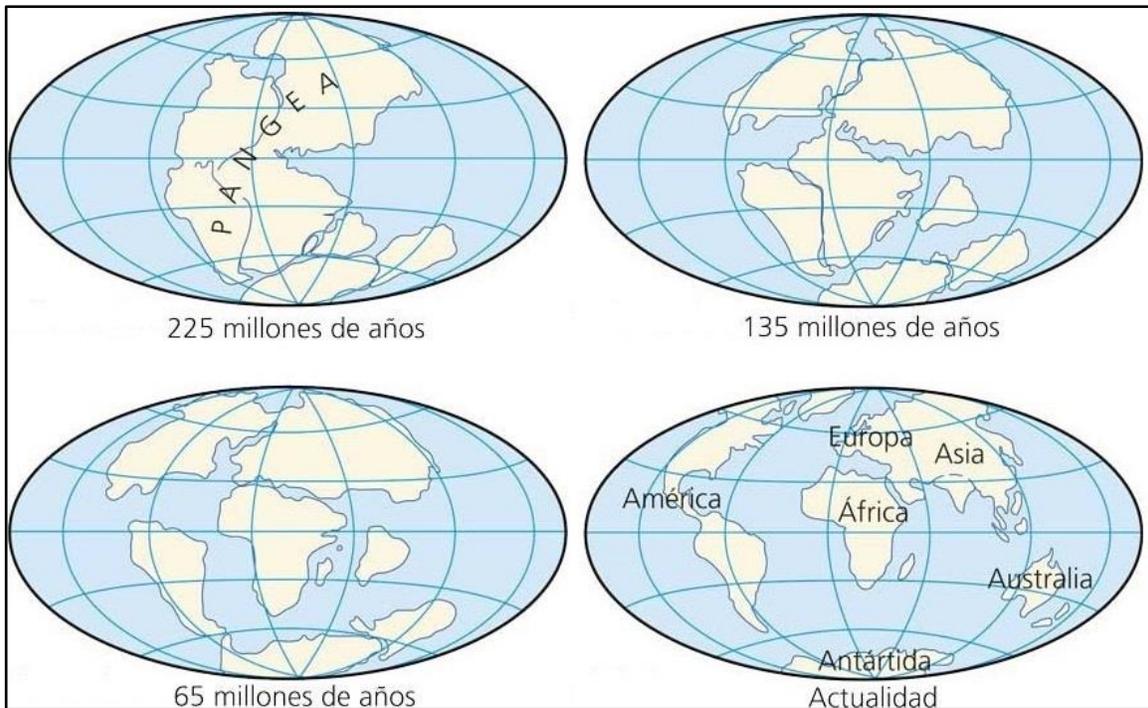


Figura 10. Deriva Continental (ref. 32).

## Tectónica de Placas

La Tectónica de placas es la teoría que explica cómo la litosfera se encuentra fragmentada en varias piezas rígidas llamadas placas tectónicas, que se mueven e interactúan unas con otras y cuyo desplazamiento anual promedio es de 2.5 cm. También se detalla su influencia en la generación de: terremotos, volcanes, fosas marinas y cordilleras entre otros; y el por qué dichos rasgos fisiográficos y fenómenos naturales se presentan en determinadas regiones específicas del planeta. La Teoría explica cómo las placas se desplazan debido a las corrientes de convección en el Manto, lo cual es posible gracias a que la densidad de la Astenosfera es mayor que la de la litosfera.

Existen otras formas por las cuales las placas se desplazan, pero estas no han sido aprobadas ni verificadas del todo, como ejemplo, se encuentran las diferencias en la topografía y densidad de la corteza del fondo oceánico por la variedad de zonas de subducción, las fuerzas gravitacionales, de arrastre, o de succión vertical, como también la posibilidad de que la luna y el sol con las fuerzas de marea, junto con la rotación terrestre participen en el movimiento de las placas tectónicas.

La figura 11 presenta las placas tectónicas más importantes del planeta, las cuales son: Norteamericana, Euroasiática, Australiana, Filipina, Pacífica, Juan de Fuca, Cocos, Nazca, del Caribe, Sudamericana, Escocesa, Africana, Arábica, Indica y Antártica.

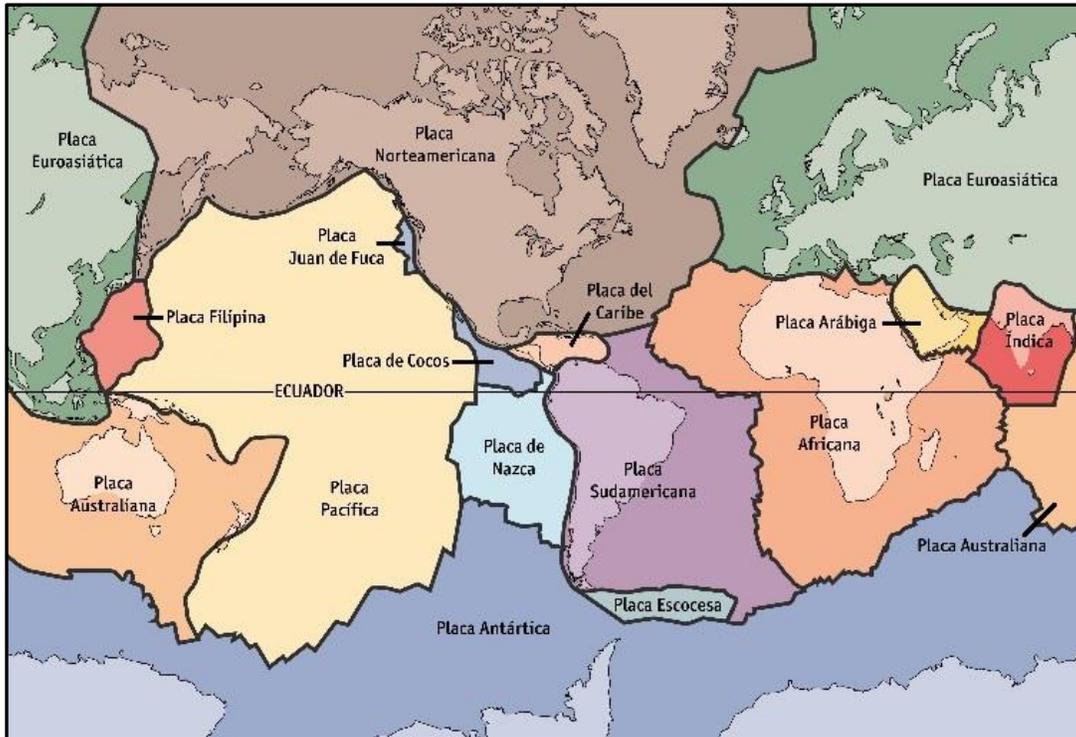


Figura 11. Placas Tectónicas (ref. 33).

Los límites entre las placas tectónicas son zonas de falla y cuyo origen es función del desplazamiento de las propias placas (ref. 34). Tal movimiento puede ser: divergente, convergente, transcurrente o una combinación de los anteriores (fig. 12).

- a) Divergente. Las placas se mueven en sentido opuesto propiciando la salida de magma y por consiguiente la formación de nueva corteza oceánica, un caso muy característico son las conocidas dorsales oceánicas. Por otra parte, el mismo tipo de movimiento puede dar origen a la formación de una fosa tectónica o graben debido al colapso de bloques de corteza.
- b) Convergente. Si dos placas se mueven en la misma dirección, la presión que se genera hace que estas se compriman y deformen, dando lugar a la formación de cadenas montañosas; en ocasiones la presión acumulada, en la capa deformada, provoca la expulsión de magma dando origen a la

formación de estructuras volcánicas. Adicionalmente, si una de las dos placas en colisión tiene una densidad mucho mayor, al ser una estructura más antigua, se produce el conocido movimiento de subducción al penetrar bajo la otra. Este proceso hace que la capa que penetra se reintegre al Manto y coloquialmente podría decirse que es corteza que está muriendo.

- c) Transcurrente. Este movimiento se presenta cuando dos placas se mueven en direcciones opuestas, pero de forma lateral, de tal manera que el desplazamiento es paralelo a la superficie de falla. Un caso característico es la famosa falla de San Andrés en California.

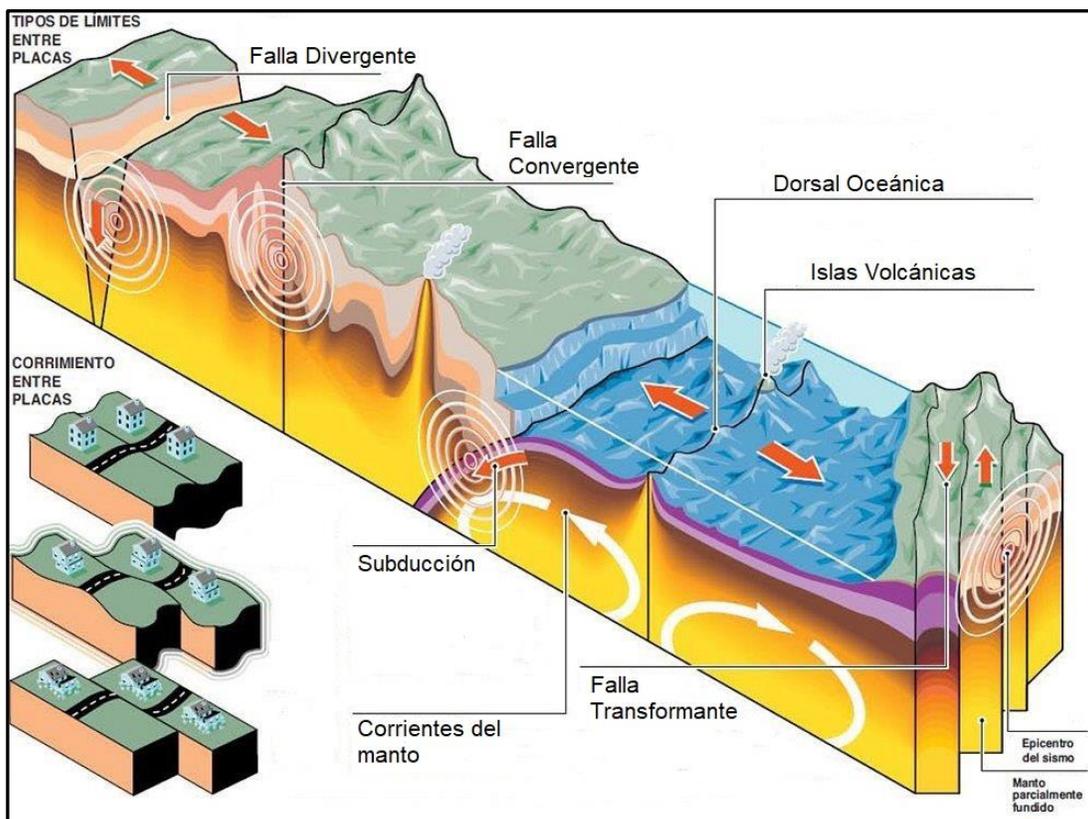


Figura 12. Tipos de fallas (ref. 35).

Como se indicó un sismo es una vibración repentina de la masa de suelo y su origen natural está asociado a los movimientos descritos de las placas tectónicas. Al estar en contacto las placas, se generan fuerzas de fricción entre estas, que impiden el desplazamiento en una determinada zona, produciendo una acumulación de energía que alcanzará su límite cuando se venza la fuerza resistente de la roca. Al ocurrir lo anterior, se presenta una liberación repentina de la energía y por lo tanto un movimiento súbito que se conoce como sismo o temblor.

Se denomina sismicidad al estudio de la actividad sísmica en una región determinada. En particular se estudian los mecanismos de fuente sísmica, los epicentros y la frecuencia de los sismos en una región determinada.

El Cinturón de Fuego del Pacífico es una zona situada alrededor del Océano Pacífico con una extensión de más de 40,000 kilómetros, que pasa por Nueva Zelanda, las costas del este de Asia y Alaska, el noroeste de Norteamérica y Centroamérica, hasta la costa oeste de Sudamérica. Alrededor del 90 % de la sismicidad del planeta y el 80 % de los sismos más grandes se producen a lo largo del Cinturón de Fuego, el cual además concentra las zonas de subducción más importantes que existen (fig. 13).



Figura 13. Cinturón de Fuego del Pacífico (ref. 36).

## Sismicidad en México

La actividad sísmica en México es debida a la interacción entre las placas de: Norteamérica, Pacífico, Cocos, Caribe y Rivera (ref. 37); siendo en sus respectivas fronteras las regiones en donde se localiza la mayor tasa de sismicidad del país.

Los mecanismos que generan estos temblores son función del desplazamiento entre las placas, en la figura 14 se ilustran los movimientos correspondientes. La frontera de color verde manifiesta la zona en donde se presenta un movimiento transcurrente entre las placas como se observa en la región del golfo de California, en una de las fronteras entre las placas de Rivera y del Pacífico, así como entre las placas del Caribe y Norteamericana. Por otra parte, el color rojo indica un movimiento de extensión debido a la tensión que se presenta en las regiones respectivas de contacto de las placas de Rivera y Cocos con la del Pacífico. Finalmente, el movimiento de compresión, indicado por el color azul, ha dado origen a la región de mayor tasa de sismicidad en el país, conocida como la zona de subducción Mexicana. En ella la placa de Cocos penetra (subduce) a la Norteamericana y un poco más hacia el sur a la del Caribe.

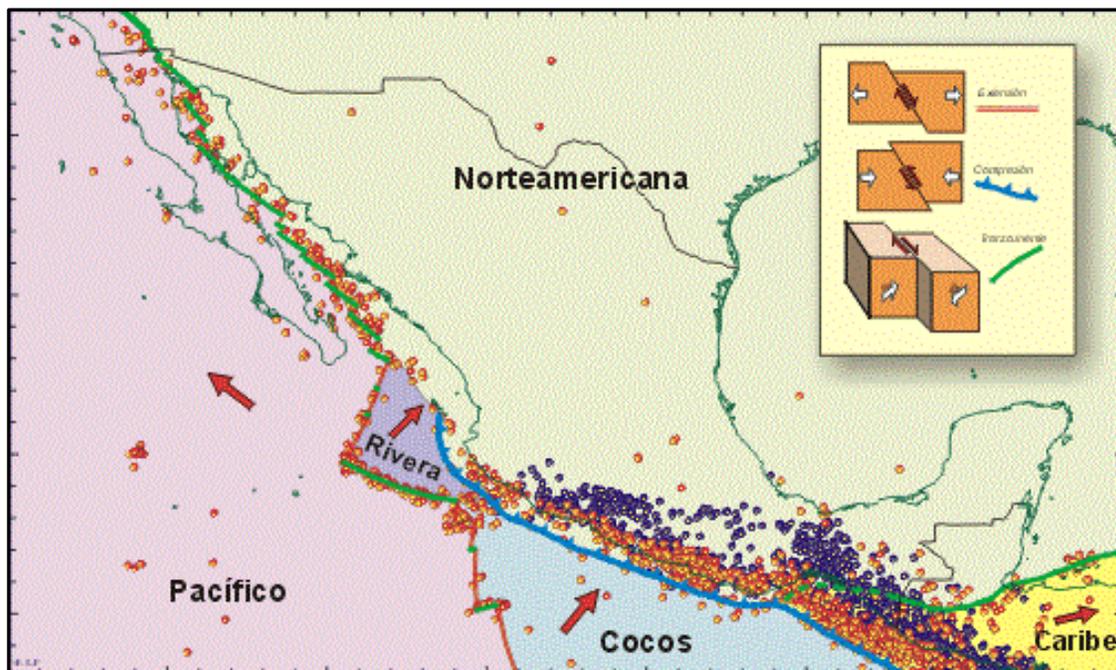


Figura 14. Fuentes Sísmicas en México (ref. 38).



En la figura anterior también se incluyen otros sismos representados por estrellas rojas y azules, los primeros son sismos más profundos que los de subducción y se generan por el rompimiento de la propia placa subducida (sismos intraplaca). Con respecto a los eventos con estrella azul, estos están asociados a fallas de la propia Corteza Terrestre (sismos corticales). En lo general estos eventos no alcanzan las grandes magnitudes de los sismos de subducción, pero al estar muy próximos a grandes núcleos de población suelen tener efectos muy graves como fueron los casos de los eventos del 7 y 19 de septiembre de 2017 cuyas correspondientes magnitudes fueron  $M=8.2$  y  $M=7.1$ .

De acuerdo con el monitoreo que el Servicio Sismológico Nacional realiza en el país (fig. 16), durante el año de 2017 se registraron 26413 sismos, de ellos prácticamente el 50 % fueron localizados en el estado de Oaxaca, el 23 % en Chiapas, 12 % en Guerrero y el 15 % final en el resto del territorio. De ellos destacan los sismos del: 14 de junio ( $M=7$ ), 7 de septiembre ( $M=8.2$ ), 19 de septiembre ( $M=7.1$ ) y 23 de septiembre ( $M=6.1$ ). La gráfica de barras de la misma figura indica un aumento importante en la tasa de sismicidad a partir del mes de septiembre debido especialmente a las réplicas asociadas al sismo del 7 de septiembre.

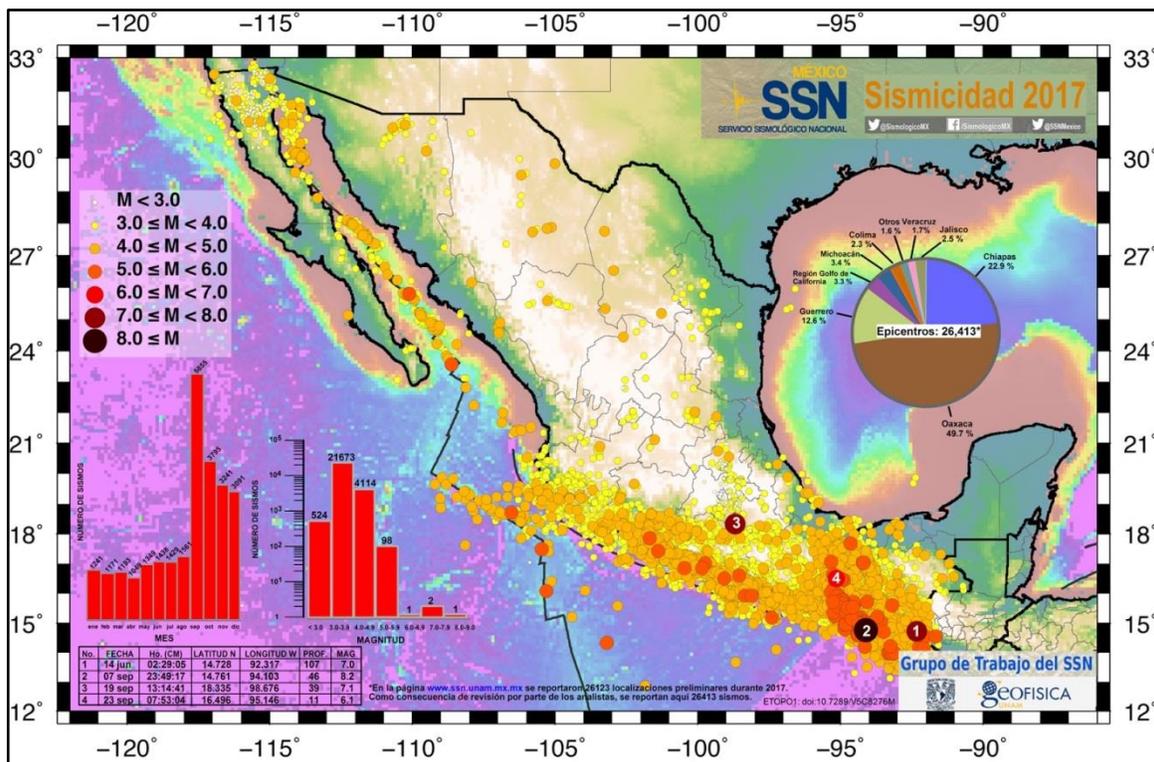


Figura 16. Sismicidad en México en 2017 (ref. 41).

## 2.2 Registro Sísmico

El registro de los temblores es de vital importancia para el estudio del fenómeno sísmico, los datos que se recaban durante su ocurrencia, permiten ubicar las zonas en donde se producen y los procesos tanto de liberación como de propagación de la energía acumulada durante un determinado periodo. Históricamente se cuenta con información de temblores desde 1460 (ref. 42), algunos casos son: Cocula (Jalisco) 27 de diciembre de 1568, Jalisco y México 25 de agosto de 1611, Oaxaca 9 de marzo de 1845 (M=8), Oaxaca-Guerrero 29 de enero de 1899 (M=8.4), Jalisco 20 de enero de 1900 (M=8.3), Jalisco 7 de junio de 1911 (M=8), Pinotepa Nacional Oaxaca 17 de junio de 1928 (M=8), Puerto Escondido Oaxaca 9 de octubre de 1928 (M=8.9) y Jalisco 3 de junio de 1932 (M=8.2).

El Servicio Sismológico Nacional (SSN), del Instituto de Geofísica de la Universidad Nacional Autónoma de México (UNAM), fundado en 1910, es el órgano del Gobierno Federal encargado de proporcionar información oportuna sobre la ocurrencia de sismos en el territorio mexicano, tales como su epicentro y magnitud. Adicionalmente, el SSN coadyuva con actividades que permitan mejorar la capacidad para evaluar y prevenir el riesgo sísmico y volcánico en el ámbito nacional. Hoy en día, tanto su red sismológica de banda ancha como sus redes complementarias permiten realizar tales actividades. La figura 17 presenta la cobertura de la red sismológica integrada por sismógrafos cuyo parámetro de registro es la velocidad del movimiento.



Figura 17. Red de banda ancha del SSN (ref. 43).

Si bien la red de banda ancha es adecuada para los fines establecidos por el SSN, presenta algunas desventajas para los estudios de la ingeniería sismo-resistente. Por ejemplo, ante la ocurrencia de eventos de mediana a gran intensidad, los sismómetros, ubicados a distancias cercanas al epicentro, ven saturada su escala de registro; por otra parte, la distribución espacial de los equipos de dicha red no es suficiente para realizar investigaciones sobre la respuesta de suelos y estructuras. En el caso de los primeros debido a que su composición varía con la distancia y la profundidad, con respecto a las estructuras, porque el movimiento se amplifica con la altura de estas.

El sismo del 28 de julio de 1957 (ref. 44) que causó el colapso de estructuras y la pérdida de vidas humanas, cambió la filosofía del registro sísmico. En esa época, los ingenieros mexicanos establecieron la necesidad de contar con instrumentación complementaria a la sismológica y por tal motivo en 1960 se instalan en la ciudad de México los primeros dos acelerógrafos, cuyo parámetro de registro es la aceleración del movimiento del terreno. Durante el temblor del 19 de septiembre de 1985 ( $M=8.1$ ) se obtuvo una importante colección de registros de aceleración o acelerogramas. En la figura 18 se muestra como en una misma región los movimientos pueden ser totalmente diferentes tanto en intensidad como en duración. Los acelerogramas corresponden a diferentes sitios en la ciudad de México con condiciones del subsuelo distintas. Los registros en suelos duros como los de Madín y Ciudad Universitaria observaron amplitudes del movimiento mucho menores que las experimentadas en la Secretaría de Comunicaciones y Transportes y en Tláhuac en donde prevalecen suelos muy deformables.

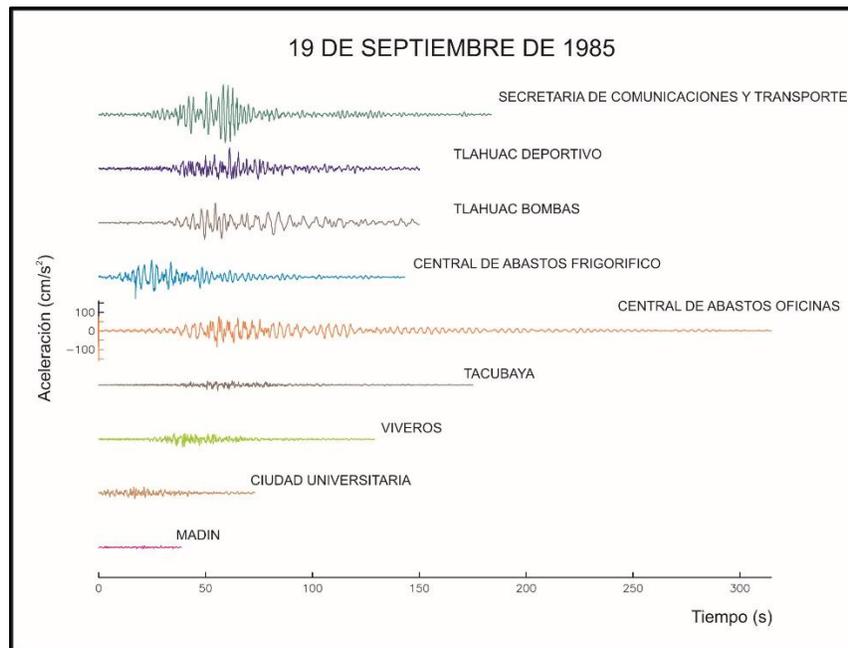


Figura 18. Acelerogramas del sismo del 19 de septiembre de 1985 (ref. 45).

## Parámetros Sísmicos

La localización de un sismo está definida por los parámetros: Hipocentro, Epicentro y Profundidad Focal (fig. 19).

- a) Hipocentro o Foco. Es el punto físico en la corteza terrestre (regularmente en el interior) en donde se considera inicia la ruptura de la roca que genera un sismo.
- b) Epicentro. Es la proyección del Hipocentro en la superficie terrestre, considerando una línea imaginaria trazada desde el centro de la Tierra que pasa por el Hipocentro.
- c) Profundidad Focal. Es la distancia entre el Epicentro y el Foco.

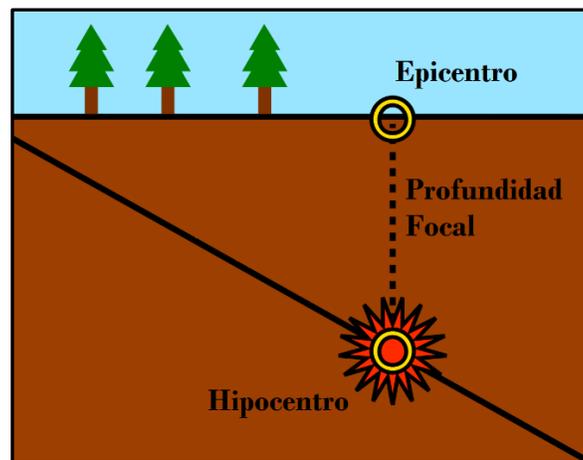


Figura 19. Parámetros que definen la localización de un sismo (ref. 46).

Además de los parámetros indicados existen otros que permiten caracterizar un sismo con relación a la energía liberada o a los efectos tanto en seres humanos como en estructuras, entre ellos se definen los siguientes:

- a) Magnitud. Es una medida de la energía sísmica liberada, en forma de ondas sísmicas, por un terremoto (ref. 47). El cálculo de este parámetro ha evolucionado con el tiempo a partir de una primera escala establecida por *Charles Richter* ( $M_L$ ). Otro tipo de magnitudes como  $m_b$  y  $M_s$  son determinadas por la máxima amplitud de las ondas de cuerpo o de las ondas superficiales respectivamente; por otra parte, la magnitud  $M_c$  o de coda se basa en la duración del registro sísmico. La determinación de las diversas magnitudes presenta ventajas y limitaciones, no obstante, la

Magnitud  $M_w$  de momento sísmico es la más utilizada hoy en día y está determinada por la expresión:

$$M_w = \frac{2}{3} \left( \log_{10} \frac{M_0}{N \cdot m} - 9,1 \right) = \frac{2}{3} \left( \log_{10} \left( \frac{M_0}{\text{dina} \cdot \text{cm}} \right) - 16,1 \right) \quad (5)$$

$M_w$  es un valor adimensional,  $N$  es la unidad de medida de fuerza (*Newton*) y  $M_0$  está definido por:

$$M_0 = \mu A u \quad (6)$$

en donde:

$\mu$  = Módulo de deformación de las rocas.

$A$  = Área de ruptura a lo largo de la falla geológica donde ocurrió el sismo.

$u$  = Desplazamiento promedio de  $A$ .

- b) Intensidad. Es una medida de los efectos causados por un sismo en un lugar determinado de la superficie terrestre (ref. 47). Cuando ocurre un sismo, los efectos en la región del epicentro son diferentes a los observados a distancias mayores y aún a una misma distancia, la intensidad depende de las condiciones tanto del subsuelo como del tipo de estructura afectada. Para medir la intensidad, las escalas más utilizadas son: *MSK* (en la Europa occidental y la Unión Soviética), *JMA* (en Japón) y la *MM* conocida como escala modificada de *Mercalli* (en el continente Americano).
- c) Distancia Epicentral. Se define como la distancia existente entre el epicentro y un punto de observación sobre la superficie terrestre.
- d) Amplitud máxima del movimiento. La amplitud del movimiento también representa un valor de la intensidad del mismo y puede ser asociado a una determinada escala. El valor de la amplitud depende del instrumento con que se registre un determinado sismo y por lo tanto se puede hablar de: aceleración, velocidad o desplazamiento máximos ( $A_{max}$ ,  $V_{max}$  y  $D_{max}$  respectivamente).
- d) Duración de la Fase Intensa. Para establecer el valor de este parámetro sísmico es necesario definir lo que se entiende por duración; así, por ejemplo, podría hablarse del tiempo de ruptura de la falla (en la propia fuente sísmica), o de la duración de un registro en específico (lo que haría que el valor dependiera de las características técnicas del instrumento). Sin embargo, con fines de aplicación en la ingeniería sísmica, es conveniente considerar el intervalo de tiempo en el que se concentra un alto porcentaje de la energía del movimiento registrado en un sitio determinado. Para ello se hará uso de la definición de Intensidad de Árias ( $I_A$ ) la cual está determinada por la ecuación 7, misma que representa la acumulación del

cuadrado de la aceleración durante el intervalo (0, T) y como queda ilustrado en la curva de la imagen inferior de la figura 20.

$$I_A = \frac{\pi}{2g} \int_0^T a^2(t) dt \quad (7)$$

en donde:

- $a(t)$  = historia tiempo-aceleración (acelerograma)
- $g$  = aceleración de la gravedad
- $T$  = duración completa del registro

La duración de la fase intensa queda definida como el intervalo de tiempo  $t_{95} - t_5$  en donde estos representan los valores de energía asociados al 95 % y 5 % de la Intensidad de Árias  $I_A$ .

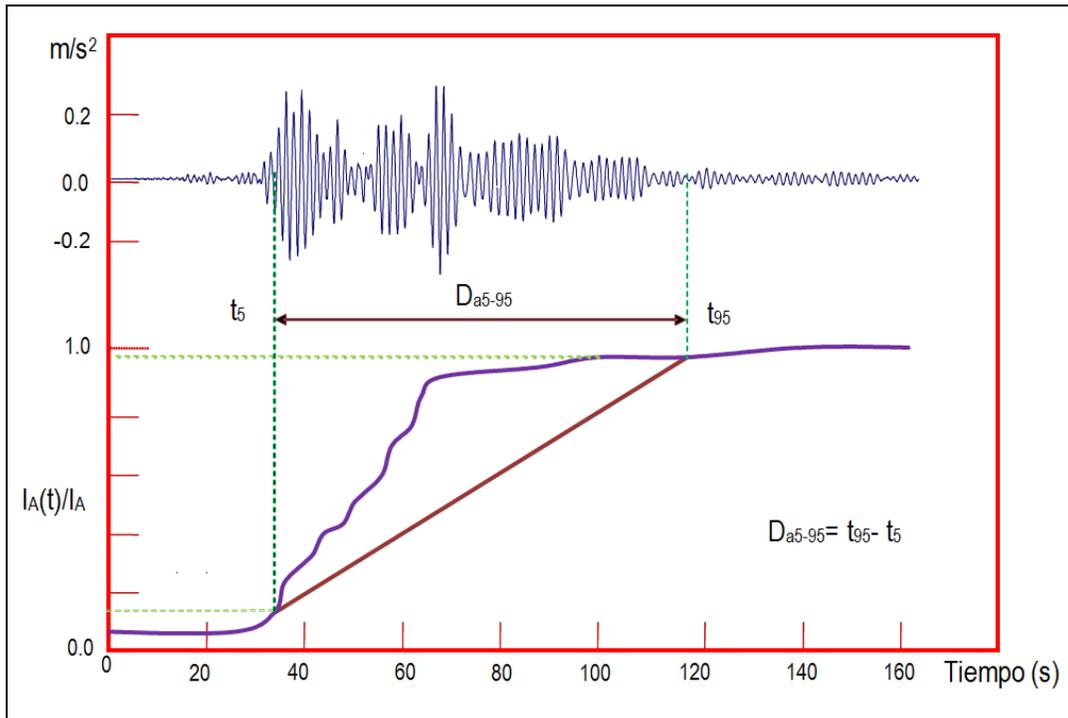


Figura 20. *Duración de la Fase Intensa* de un acelerograma (ref. 48).

### 2.3 Base de Datos Sísmicos

El Instituto de Ingeniería de la UNAM opera una vasta red de registro sísmico integrada por acelerógrafos. Esta red, está ubicada en regiones del país que tienen el potencial sísmico suficiente, para generar temblores de gran intensidad o

en otras que sin tenerlo pueden verse afectadas en forma importante. Entre estas regiones se ubica la ciudad de Oaxaca, la cual históricamente ha sido vulnerada por la ocurrencia de importantes sismos. Por lo que en ella se encuentra operando la Red Acelerográfica de la ciudad de Oaxaca (RACO).

Debido a que el modelo neuronal que se describirá en el capítulo 3 utiliza información de la RACO, en lo siguiente se hará una descripción tanto de esta como de la base de datos sísmicos existente y en la cual se incluye información de los sismos registrados, así como de los acelerogramas obtenidos.

Considerando las diferentes condiciones del subsuelo existentes en el valle de Oaxaca, se han instalado 9 estaciones acelerográficas en: el Instituto Tecnológico de Oaxaca (OXTO), la Facultad de Arquitectura de la Universidad Autónoma Benito Juárez (OXCU), la Alameda de León (OXAL), las primarias Múgica y Benito Juárez (OXPM y OXBJ respectivamente), en la población de Las Canteras (OXLC), en las oficinas de la Unidad de Protección Civil (OXPC), el aeropuerto (OXAE) y la zona de la fuente de la Siete Regiones (OXFM). Con excepción de la estación OXLC, que se encuentra desplantada sobre roca, el resto están sobre depósitos de suelo, en la figura 21 se ilustra la ubicación geográfica de las mismas.

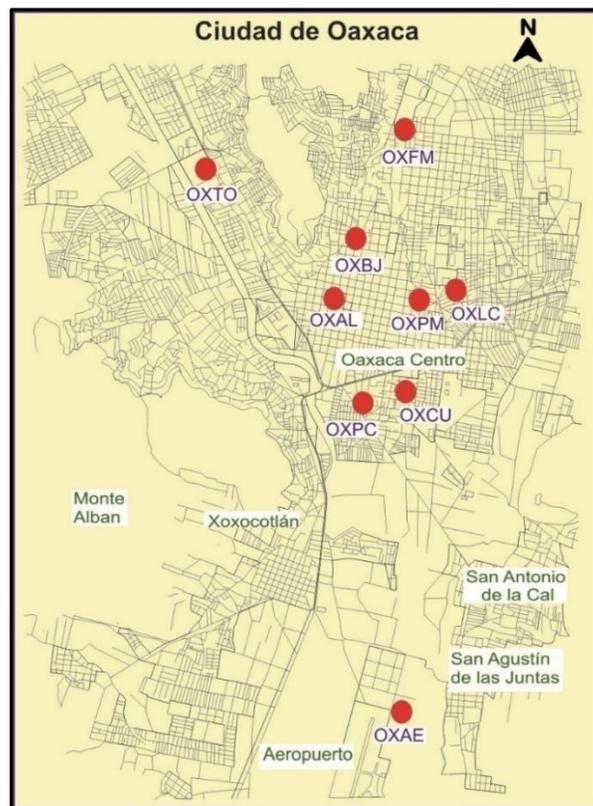


Figura 21. Red Acelerográfica en la ciudad de Oaxaca (ref. 49).

En la figura 22a se presenta una estación típica de campo libre, la cual recibe este nombre debido a que el movimiento sísmico que registra se encuentra sobre la superficie del terreno y fuera de la influencia de alguna estructura. La estación está constituida de una base de concreto sobre la cual se encuentra una caja metálica que alberga al acelerógrafo; a un costado existe una pequeña torre que soporta un par de paneles solares para el suministro de energía. En el interior de la caja metálica, en la figura 22b, se encuentra el equipo de registro, el cargador de energía y las baterías.



Figura 22. a) Estación acelerográfica de campo libre.  
b) Acelerógrafo.

## Sismos registrados en la ciudad de Oaxaca

La ciudad de Oaxaca ha sido afectada por sismos de diversas fuentes, los más comunes son aquellos generados en la zona de Subducción Mexicana, en la costa Oaxaqueña. Afortunadamente, este tipo de eventos, aunque algunos contaron con gran magnitud ( $M > 7.5$ ), se han localizado a distancias mayores a los 140 km lo que hace que su impacto en esa ciudad disminuya. En el caso de eventos generados hacia el interior del continente, aunque de magnitud menor ( $6 < M < 7$ ), a los producidos en la costa, su impacto suele ser muy importante debido a su cercanía con la ciudad. El banco de datos considerado está integrado por 66 temblores cuyas magnitudes van de 4.3 a 7.5 como se presenta en la tabla 3. La columna “Sismo” especifica la fecha de ocurrencia del evento en el formato AAAAMMDD, en donde AAAA es el año, MM el mes, DD el día y E en número de evento del día. La columna M indica el valor de la magnitud determinada por el Servicio Sismológico Nacional y la última columna indica la clave de las estaciones acelerográficas que registraron el evento.

## Acelerogramas

El acelerógrafo es un instrumento que censa la historia tiempo-aceleración del movimiento sísmico, y los correspondientes registros son conocidos como acelerogramas. El equipo está continuamente evaluando la amplitud de las señales sísmicas y es programado para que a partir de un umbral establecido realice el almacenamiento de la información. El registro se realiza en tres direcciones ortogonales, dos horizontales (N-S y E-O) y una vertical. De acuerdo con los sismos registrados se tiene un total de 147 acelerogramas con registro en tres componentes en las estaciones OXAL, OXFM, OXLC, OXPM, OXTO, las restantes no fueron consideradas.

Tabla 3. Sismos registrados en la ciudad de Oaxaca (ref. 50).

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



## CAPÍTULO 3. MODELO NEURONAL

La *duración de la fase intensa* del movimiento sísmico, es un parámetro muy importante para establecer el potencial daño que un temblor puede ocasionar en suelos y estructuras; por lo que en este capítulo se propone un modelo neuronal para estimar el valor de tal parámetro. El modelo cuyo objetivo es estimar la *duración de la fase intensa* del movimiento sísmico ( $D_{IA}$ ), se implementará mediante los fundamentos de las Redes Neuronales Artificiales utilizando los registros de aceleración o acelerogramas que se han obtenido en algunas de las estaciones que integran la Red Acelerográfica de la ciudad de Oaxaca.

### 3.1 Herramienta de Cómputo

El modelo será implementado utilizando el programa *Thinks pro* (ref. 51), el cual es una herramienta especializada en redes neuronales y entre cuyas características se destacan su flexibilidad para el aprendizaje con la posibilidad de elegir: diversas arquitecturas, funciones de procesamiento, transferencia, y error, así como algoritmos de aprendizaje. Adicionalmente está dotado de herramientas de visualización y control, lo que facilita los procesos de entrenamiento y prueba.

Para iniciar un proyecto es necesario importar los conjuntos de entrenamiento y prueba, como se aprecia en la figura 23a. En la pantalla correspondiente se pueden visualizar ambos conjuntos (figs. 23b y 23c).

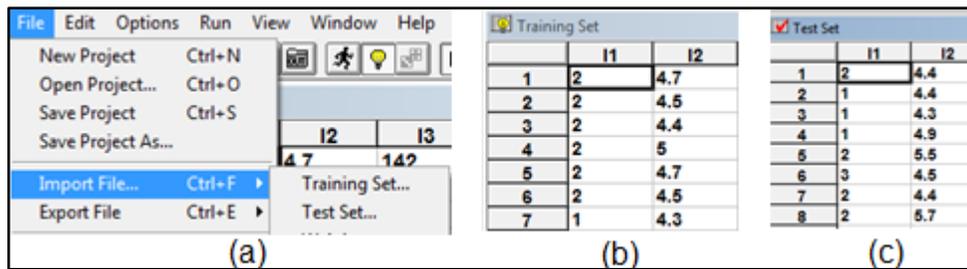


Figura 23. a) Menú de proyectos y archivos.  
b) Conjunto de entrenamiento.  
c) Conjunto de prueba.

Una vez que los datos han sido cargados al sistema, hay tres aspectos importantes a considerar: la arquitectura de la red neuronal, los parámetros de las fases de entrenamiento y prueba; así como la visualización de los procesos (en tiempo real) y sus resultados (figs. 24a, 24b y 24c respectivamente).

- Arquitectura de la Red Neuronal. Se selecciona el número de nodos de las capas de entrada y salida; el número de capas ocultas y los nodos

asociados a cada una. Finalmente, se definen las funciones de transferencia para cada capa y la regla de aprendizaje correspondiente.

- b) Parámetros para ejecución. En la sección de ejecución se cuentan con configuraciones para el entrenamiento y pruebas de la red como son: el número de iteraciones, semilla inicial para definir el valor de los pesos de cada nodo de entrada, y la condición de detención del proceso entre otros.
- c) Visualización de los procesos. Se deben configurar los parámetros respectivos que permitan definir el tipo de gráfica de control que se pretenda, como pueden ser las variaciones de los errores en entrenamiento o prueba o de los errores máximos con respecto al número de iteraciones del proceso. Aquí es vital definir adecuadamente el tamaño del eje de las ordenadas.

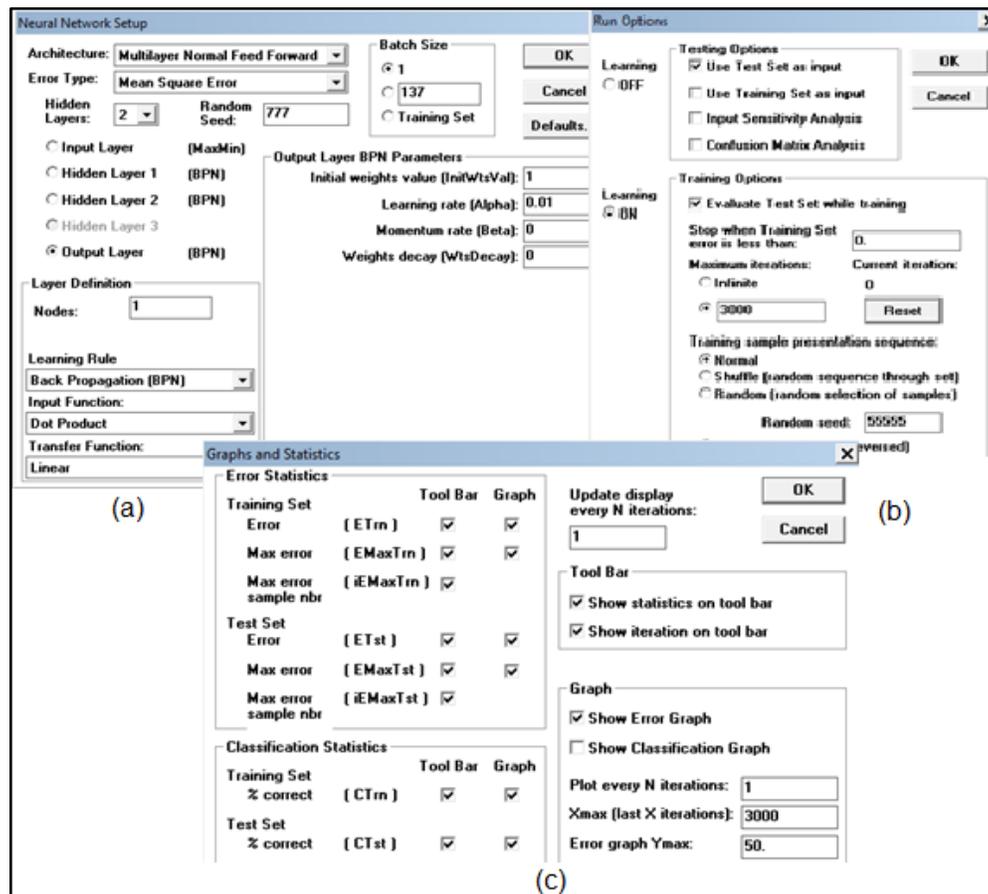


Figura 24. Menú de configuración de:  
 a) Red neuronal.  
 b) Gráficas y estadísticas.  
 c) Ejecución.

## 3.2 Estructura del Modelo

El modelo neuronal elegido considera las características siguientes (figura 25):

- Perceptrón multicapa con propagación hacia adelante desde la capa de entrada hasta la de salida.
- Está prohibida la comunicación lateral entre nodos de una misma capa.
- La capa de entrada está integrada por 5 nodos: Condiciones del subsuelo ( $C_s$ ), Magnitud del sismo ( $M$ ), Distancia epicentral ( $D_e$ ), Profundidad focal ( $P_f$ ) y Azimut ( $A$ ).
- Una a dos capas ocultas con variaciones en el número de nodos. No se usan más capas ocultas, debido a que no aumentaría la efectividad de la red y se incrementaría el tiempo de procesamiento.
- Una capa de salida con un solo nodo definido por el valor de la *duración de la fase intensa* ( $D_{IA}$ ) cuyo cálculo se realizó de acuerdo con el criterio de Árias.
- Se definió la Función de Transferencia Sigmoide para todas las capas excepto la de salida, en donde se eligió la Lineal.
- Se estableció como método de aprendizaje el denominado Propagación hacia atrás con descenso por el gradiente.

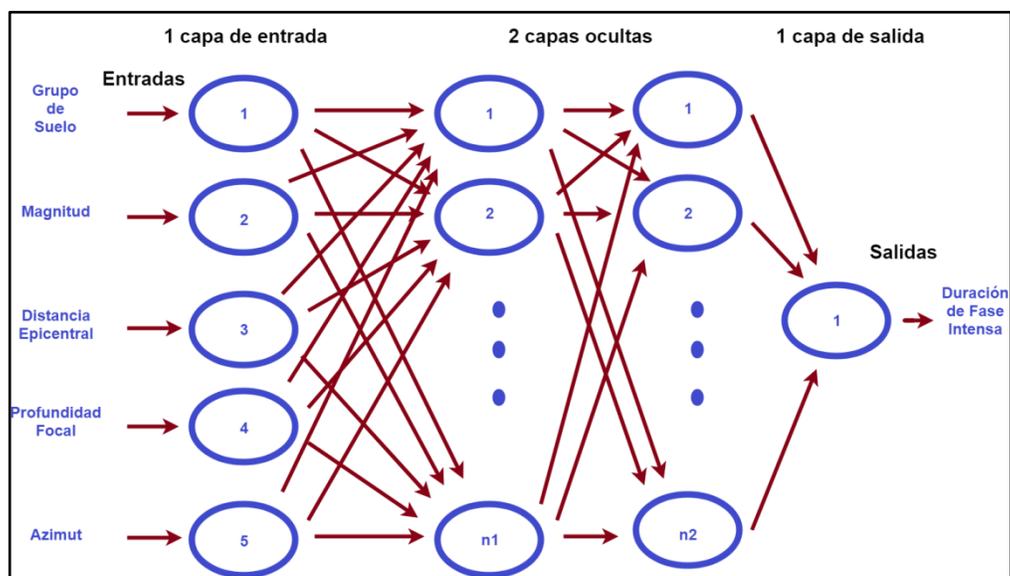


Figura 25. Estructura del Modelo Neuronal.

### 3.3 Parámetros de entrada y salida

Se considera que los parámetros que tienen influencia en la *duración de la fase intensa* son: Magnitud ( $M$ ), Profundidad focal ( $P_f$ ), Distancia Epicentral ( $D_e$ ), Condiciones del subsuelo ( $C_s$ ) y el Azimut ( $A$ ).

Los valores  $M$  y  $P_f$  se tomaron de los catálogos proporcionados por el Servicio Sismológico Nacional (SSN);  $D_e$  considerada como la distancia existente entre el epicentro y el sitio de registro (estación acelerográfica), fue determinada utilizando las coordenadas epicentrales proporcionadas por el SSN y las correspondientes a la estación.

El parámetro para establecer la condición del subsuelo  $C_s$  fue asociado de acuerdo con los trabajos realizados por León y Limaymanta (refs. 52 y 53). Con relación a estos la estación OXLC se ubica en el grupo B, OXFM, OXPM, OXAL en el grupo D y finalmente OXTO en el grupo E. Una descripción somera de los grupos es la siguiente: El grupo D se caracteriza por tener suelos subrígidos cuyos espesores son menores a 10 m. Con relación al grupo E este también tiene suelos clasificados como subrígidos pero con espesores mayores a 20 m. Finalmente el grupo B es un suelo rocoso. Por lo anterior, de acuerdo con la ubicación de las estaciones acelerográficas en los grupos indicados, se les asignaron los valores siguientes:  $D=1$ ,  $E=2$  y  $B=3$ .

El último parámetro de entrada es el denominado Azimut, el cual fue definido como el ángulo formado entre el segmento AB (línea que une la estación y el epicentro) con la dirección norte y medido a partir de esta última en sentido de las manecillas del reloj, tal como se muestra en la figura 26.

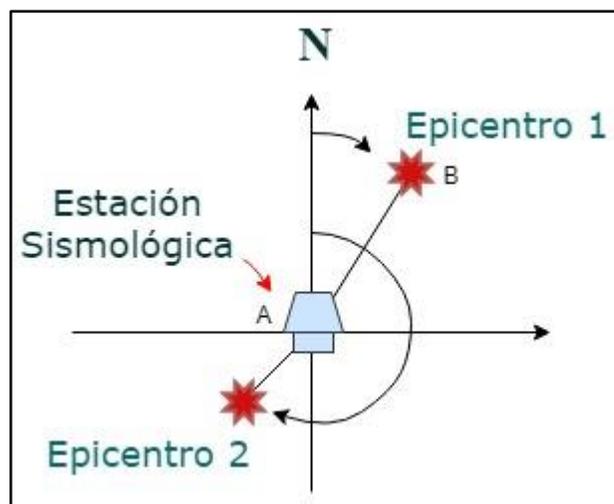


Figura 26. Definición del parámetro Azimut.

El parámetro de salida es la *duración de la fase intensa* ( $D_{IA}$ ) el cual fue calculado para cada acelerograma utilizando la herramienta de cómputo **Degtra** (ref. 54) y siguiendo el criterio del Profesor Árias (ref. 55), pero para el 3 % y el 97 % de la energía acumulada.

### 3.4 Banco de Datos

Para el desarrollo del modelo se seleccionaron 66 sismos (de magnitudes 4.1 a 7.6) que generaron 171 acelerogramas en las estaciones: Las Canteras (OXLC), Facultad de Medicina (OXFM), Alameda de León (OXAL), Primaria Mújica (OXPM) e Instituto Tecnológico (OXTO), todas ubicadas en diferentes condiciones de suelo de la ciudad de Oaxaca. Por lo que los parámetros del Banco de Datos se integran de la forma siguiente: los valores de  $M$  y  $P_f$  se obtienen del correspondiente sismo,  $C_s$  se establece de acuerdo con la condición del subsuelo en donde se encuentra la estación de registro,  $D_e$  y  $A$  se calculan considerando la ubicación de la estación y el epicentro del sismo. Finalmente,  $D_{IA}$  se determina con la componente EW del acelerograma siguiendo el criterio de Árias para el 3 % y 97 % de la energía total.

De acuerdo con lo arriba descrito, el Conjunto de Datos quedó integrado por 5 parámetros de entrada y 1 de salida. Para las etapas de entrenamiento y prueba se seleccionaron 137 y 34 registros respectivamente del Banco de Datos, mismos que se separan en dos tablas en el apéndice A, nombradas A1 y A2, cada una enumera los registros sísmicos con los parámetros mencionados en el párrafo anterior que lo describen.

### 3.5 Procesos de Entrenamiento y Prueba

Una vez determinados los conjuntos de entrenamiento y prueba, se procede a establecer una configuración de la Red Neuronal, en la cual ya se tiene definido el número de nodos tanto de la capa de entrada (5 nodos) como de la capa de salida (1 nodo), solo resta establecer el número de capas ocultas y sus correspondientes nodos. Por lo que la estructura quedaría definida por:  $5 \times O_i \times 1$  en donde 5 es el número de nodos de entrada y 1 el de la salida;  $O_i$  es para las capas ocultas en donde  $i=1$  ó  $2$ . El proceso general que se siguió para entrenar a la Red Neuronal fue el siguiente (fig. 27):

- a) Definida la arquitectura inicial de la Red Neuronal se establecen las funciones de transferencia para cada capa y se fija un valor de error tolerable. Para iniciar el entrenamiento, se asocia a cada parámetro de entrada un peso ( $W_{ij}$ ) en forma aleatoria.

- b) La propagación de la información es hacia adelante hasta llegar a un valor de la duración de la fase intensa estimada ( $D_{IAE}$ ) por la RNA.
- c) Se evalúa  $D_{IAE}$  con respecto el valor objetivo  $D_{IAR}$  utilizando una diferencia normalizada obteniendo el correspondiente error E. Si dicho error resulta ser menor que el establecido, el proceso se detiene y se almacena la configuración propuesta del modelo de Red Neuronal. Si el error no es tolerable se procede a realizar un ajuste de los pesos  $W_{ij}$  en todas las etapas del proceso.
- d) El ajuste de los pesos  $W_{ij}$  es realizado considerando para cada nodo su contribución relativa al error total. El ajuste se realiza de la capa de salida hasta la de entrada (de ahí el nombre retropropagación).
- e) El proceso se repite en forma iterativa hasta que se cumpla la condición en donde el valor del error E es aceptado.
- f) El proceso anterior se ejecuta con los datos del conjunto de entrenamiento, pero simultáneamente se evalúa el mismo con los datos del conjunto de pruebas sin sesgos. Es importante señalar que este último no se utiliza en ninguna etapa del entrenamiento.
- g) El proceso se detiene, como se indicó cuando se alcanza un valor tolerable o mediante observación de la reducción del error con respecto al número de iteraciones.

Si los resultados de la evaluación del modelo neuronal no son satisfactorios, se define una nueva configuración para la RNA y se repite el proceso. En la elección de la nueva arquitectura se consideraron los siguientes criterios:

- a) Se inició con solo una capa oculta y con un valor base de 20 nodos, las modificaciones a la arquitectura de la red se basaron únicamente en un incremento del número de nodos, el cual dependió de los resultados observados, pero teniendo un valor límite de 240 nodos.
- b) En la siguiente fase se consideraron dos capas ocultas con un valor inicial de 60 y 20 nodos respectivamente. En esta fase la variación del número de nodos de cada capa fue diferente dependiendo también de los resultados observados, pero teniendo un límite de 240 nodos para ambas capas.

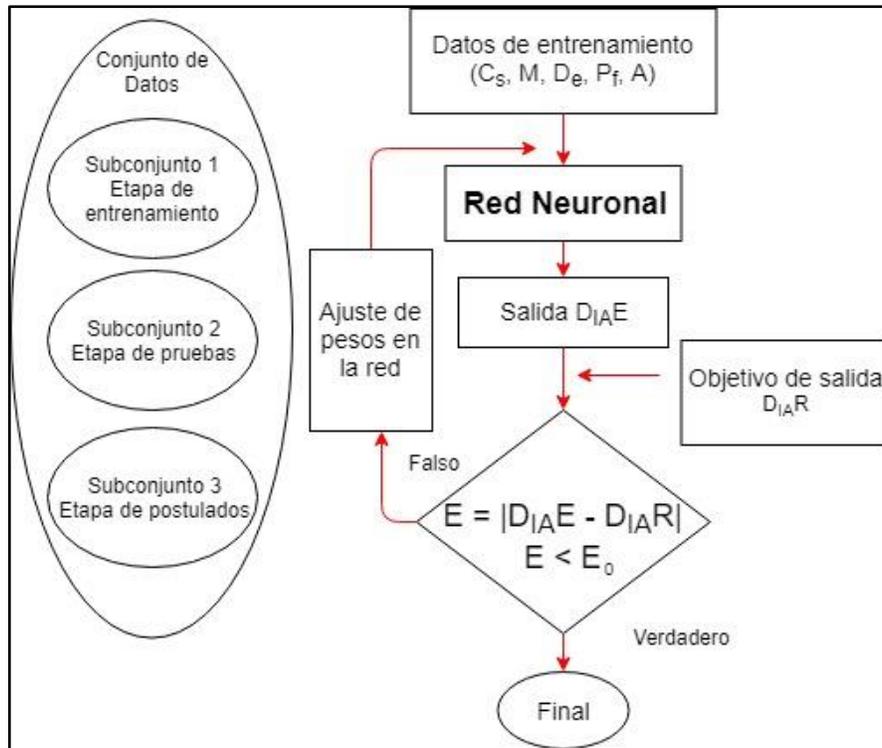


Figura 27. Flujo del entrenamiento de la Red Neuronal.

### Coeficiente de Correlación

El coeficiente de correlación (R) es una medida numérica que sirve para saber que tanta similitud hay entre dos o más variables. Los valores que puede tomar van desde 0 en donde no existe correlación hasta +1, -1 en donde se tendría la mejor correlación posible (ref. 56).

Para calcular el coeficiente de correlación de dos conjuntos de datos X y Y donde los dos conjuntos tienen la misma cantidad de datos (n), lo primero que se necesita hacer es conseguir  $\bar{x}$  y  $\bar{y}$ , como en la ecuación 8, siendo el promedio de cada conjunto respectivamente.

$$\bar{x} = \frac{\sum_1^n x_i}{n} \quad \bar{y} = \frac{\sum_1^n y_i}{n} \quad (8)$$

Luego directamente se obtiene el valor de R con la ecuación 9, tomando en cuenta que  $x_j$  y  $y_j$  son los elementos j de los conjuntos X y Y respectivamente, lo mismo sucede con  $x_i$  y  $y_k$ , donde sus índices son i y k.

$$R = \frac{\sum_1^n (x_j - \bar{x})(y_j - \bar{y})}{\sqrt{\sum_1^n (x_i - \bar{x})^2} \sqrt{\sum_1^n (y_k - \bar{y})^2}} \quad (9)$$

Este parámetro se usará para saber que tan acertado es el modelo neuronal, al momento de evaluar los resultados.

### 3.6 Resultados

Considerando los criterios expuestos para definir el modelo neuronal, en la tabla 4 se incluyen algunas configuraciones de un total de 50 y cuyo formato 5x0x1 indica los números de los nodos de: la capa de entrada (E=5; C<sub>s</sub>, M, P<sub>f</sub>, D<sub>e</sub>, A), O de la(s) capa(s) oculta(s) y de la capa de salida (D<sub>IA</sub>=1; *duración de la fase intensa*). Para cada configuración se incluyen los valores de correlación tanto para el conjunto de entrenamiento (R<sub>E</sub><sup>2</sup>) como para el de prueba (R<sub>P</sub><sup>2</sup>).

En la tabla 4 se aprecian dos grupos, el primero contiene solo dos casos con una capa oculta (5x50x1 y 5x100x1) y el segundo que presenta 13 configuraciones con dos capas ocultas. Al respecto, es importante señalar que, de las diversas propuestas de configuración, cuando se seleccionó sólo una capa oculta (grupo A), variando su número de nodos, los valores de correlación siempre fueron muy bajos aun cuando se incrementara el número de iteraciones, lo que llevó a la conclusión de que el problema no podría resolverse con una sola capa oculta. Por lo que la exploración se centró en el uso de dos capas ocultas con diferente número de nodos y variando el número de iteraciones.

Considerando la conclusión arriba expresada, se crearon diversas configuraciones con dos capas ocultas y se establecieron los grupos B, C y D.

Para el grupo B se consideraron variaciones en el número de nodos de las dos capas ocultas, para la primera se hizo de 60, 80 y 140 y en la segunda de 20, 40 y 80. Por lo que, como se ilustra en la tabla, se obtuvieron 6 configuraciones y para las cuales se ejecutaron procesos cuyo número de iteraciones varió de 500, 1000, 3000 y 6000. En esta etapa se encontró una mejoría sustancial tanto en los procesos de entrenamiento como de prueba, de tal manera que para el modelo de 5x60x40x1 con 6000 iteraciones se alcanzaron valores de correlación en entrenamiento de R<sub>E</sub><sup>2</sup> = 0.84 y en prueba R<sub>P</sub><sup>2</sup> = 0.65. Lo anterior condujo a incrementar el número de nodos de ambas capas ocultas, como lo fue para la estructura de 5x140x80x1; sin embargo, los valores de correlación en ningún caso mejoraron a los ya obtenidos.

De acuerdo con la experiencia obtenida, se generó el grupo C con una sola estructura en la cual, las dos capas ocultas se definieron con 140 nodos es decir 5x140x140x1, pero considerando el número de iteraciones siguientes: 500, 1000, 3000, 10000, 12500, 15000, 18000. Para 12500 iteraciones se obtuvieron las mejores correlaciones con R<sub>E</sub><sup>2</sup> = 0.88 y R<sub>P</sub><sup>2</sup> = 0.72. Para 15000 y 18000

iteraciones los valores son prácticamente los mismos para  $R_E^2$  pero ligeramente menores en prueba, por lo que se confirma que el hecho de incrementar el número de iteraciones no necesariamente mejora el entrenamiento, por el contrario puede conducir a un sobre-entrenamiento del modelo y por consiguiente una pérdida en su capacidad de generalización.

Finalmente, considerando que el uso de dos capas ocultas más el incremento en su número de nodos proporcionaba mejores resultados, se decidió crear el grupo D; en el cual, para la primera capa oculta se consideraron dos valores del número de nodos, 180 y 240; y para la segunda capa oculta se realizaron variaciones con 20, 80 y 160 nodos. Los procesos se ejecutaron con 500, 1000 y 3000 iteraciones y en algunos casos hasta 6000. La mejor correlación se obtuvo para la configuración 5x180x160x1 con valores de  $R_E^2 = 0.82$  y  $R_p^2 = 0.63$ , valores inferiores a los ya indicados para el grupo C y que resultaron ser los mejores de todas las configuraciones propuestas.

En la figura 28 se presenta, para la mejor configuración del modelo, la variación de los errores de entrenamiento y prueba con relación al número de iteraciones. Se observa claramente que estos disminuyen progresivamente hasta unas 3,000 iteraciones. Posterior a este valor, se presentan una serie de fluctuaciones, pero con tendencia a la reducción de los errores. Obsérvese como después de 10000 y hasta unos 12500 ciclos los errores permanecen prácticamente constantes. Continuar con el proceso causaría únicamente un sobre entrenamiento del modelo, por lo que se determinó detenerlo en esa etapa.

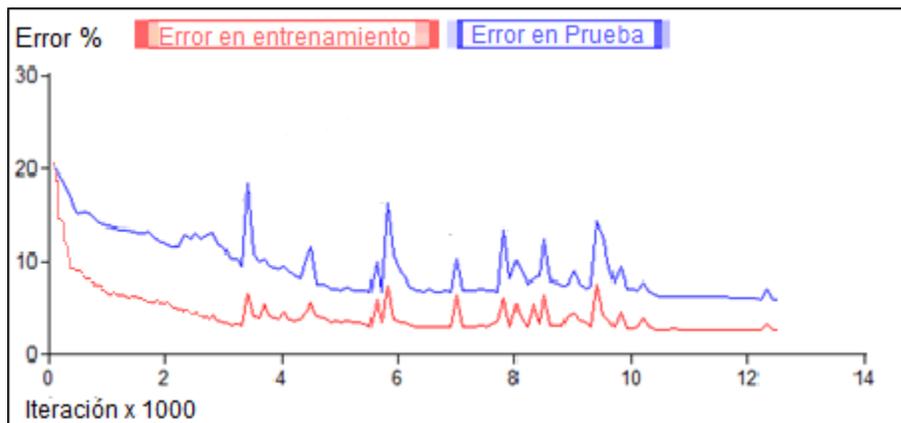


Figura 28. Variación de los errores de entrenamiento y prueba en función del número de iteraciones.

Tabla 4. Configuraciones del Modelo Neuronal para estimar la duración de la fase Intensa del movimiento sísmico.

Grupo	Configuración	Iteración	$R_E^2$	$R_P^2$
A	5x50x1	500	0.4007	0.3968
		1000	0.4741	0.4015
		3000	0.3501	0.5057
	5x100x1	500	0.4389	0.4426
		1000	0.4589	0.4844
		3000	0.7324	0.3293
B	5x60x20x1	500	0.4389	0.4426
		1000	0.4589	0.4844
		3000	0.7324	0.3293
	5x60x40x1	500	0.5683	0.3077
		1000	0.6821	0.5165
		3000	0.8214	0.5297
		6000	0.8438	0.6498
	5x80x20x1	500	0.5727	0.4669
		1000	0.6821	0.573
		3000	0.7375	0.4525
	5x140x20x1	500	0.8182	0.5926
		1000	0.5374	0.4299
		3000	0.5565	0.5073
	5x140x40x1	500	0.6308	0.5036
		1000	0.609	0.4287
		3000	0.6861	0.4915
	5x140x80x1	500	0.7498	0.5703
		1000	0.6257	0.32
3000		0.6572	0.2739	
C	5x140x140x1	500	0.7703	0.4293
		1000	0.7083	0.1623
		3000	0.7289	0.1671
		10000	0.7829	0.5924
		12500	0.865	0.7296
		15000	0.8804	0.7147
		18000	0.8804	0.6904
		18000	0.8805	0.6981
D	5x180x20x1	500	0.459	0.2417
		1000	0.5568	0.507
		3000	0.7075	0.5702
	5x180x80x1	500	0.641	0.2905
		1000	0.675	0.3994
		3000	0.7936	0.5964
	5x180x160x1	500	0.7071	0.2712
		1000	0.7369	0.2011
		3000	0.2703	0.4797
	5x240x20x1	6000	0.8201	0.6262
		500	0.3301	0.2512
		1000	0.3902	0.3503
	5x240x80x1	3000	0.536	0.5525
		6000	0.5984	0.5855
		500	0.6589	0.3983
	5x240x160x1	1000	0.681	0.2972
		3000	0.7423	0.4722
		500	0.7096	0.186
		1000	0.7414	0.2546
		3000	0.7757	0.3987

En la figura 29 se presentan los resultados del Modelo Neuronal para una configuración de 5x140x140x1 (dos capas ocultas de 140 nodos cada una). Las imágenes superiores (a y b) corresponden a las etapas de entrenamiento y prueba para un proceso que considera 10000 iteraciones. Con relación a las imágenes inferiores estas corresponden a un proceso de 12500 iteraciones.

En las etapas de entrenamiento se obtuvieron valores de  $R_E^2$  del orden de 0.8, para diferente número de iteraciones. Tal valor de correlación se consideró aceptable en ambos casos. Sin embargo, en la etapa de prueba se observa que para 12500 iteraciones el valor de correlación disminuye ligeramente. Se aprecia claramente como el modelo, en los dos casos, sobreestima los valores de la *duración de la fase intensa*.

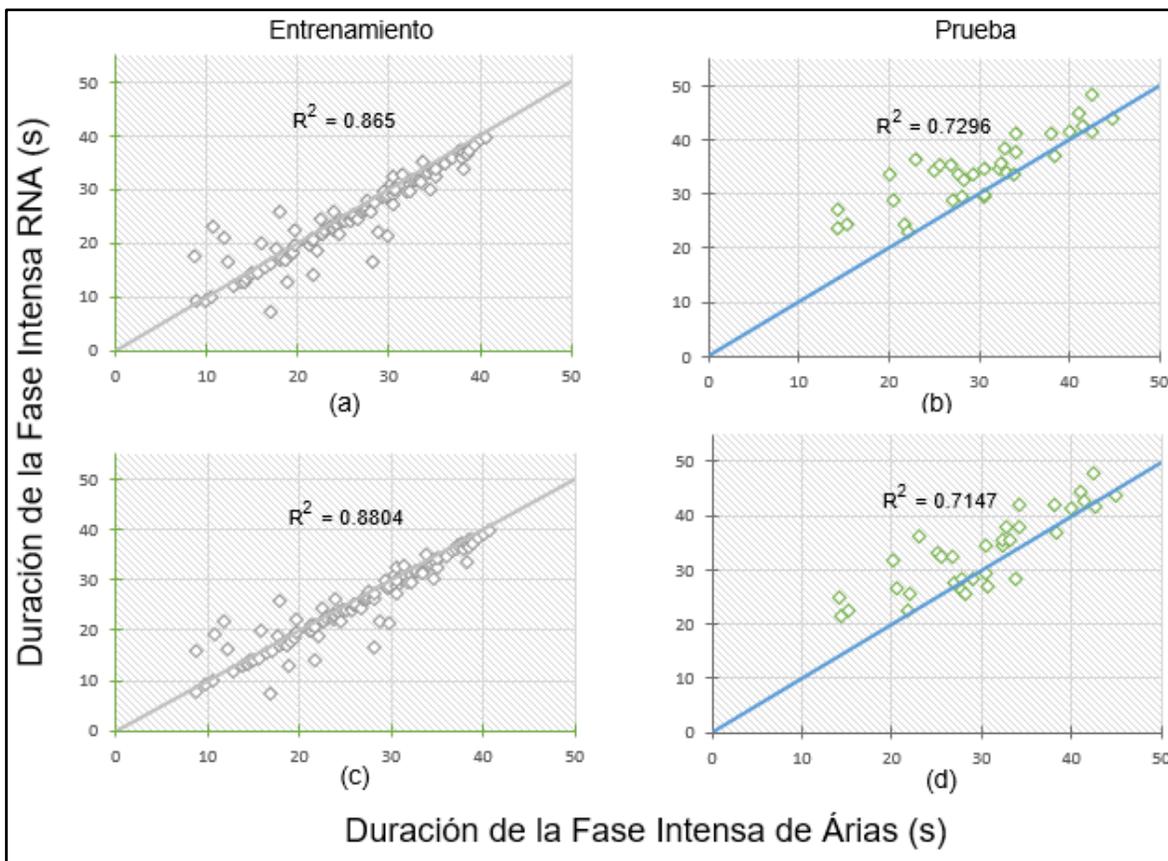


Figura 29. Modelo Neuronal para estimar la *duración de la fase intensa*  
 Caso 1: (a) y (b) 10000 iteraciones.  
 Caso 2: (c) y (d) 12500 iteraciones.

El diseño del modelo neuronal y los parámetros de entrada seleccionados dotan a la red de capacidad predictiva ante futuros eventos, por lo que una vez consideradas satisfactorias las etapas de entrenamiento y prueba se postularon 8 potenciales sismos que pudieran ocurrir de acuerdo a condiciones sismogénicas reales que existen en nuestro país.

En la figura 30 se indica la ubicación epicentral de los temblores propuestos e indicados con las letras A - H. De los eventos postulados en la costa del Pacífico (A, C y E) el primero corresponde a un sismo como el ocurrido el 7 de septiembre de 2017 ( $M=8.2$ ), el segundo a un evento costero con la distancia epicentral más cercana a la ciudad de Oaxaca, y el tercero representa a un sismo generado en la potencialmente peligrosa brecha de Guerrero. Los eventos B, D y F representan temblores que pudieran generarse continente adentro, pero al sur de la ciudad de Oaxaca y pretende representar, especialmente el D, al sismo del 14 de enero de 1931 ( $M=7.8$ ). Finalmente, los eventos G y H son eventos más profundos que representan a los sismos que ocurren hacia la región norte del estado de Oaxaca.

La magnitud establecida para cada evento está asociada como se indicó de acuerdo al potencial existente en cada región. En la tabla 5 se incluyen los parámetros asociados a los sismos postulados: tipo de suelo  $C_s$ , Magnitud  $M$ , Distancia epicentral  $D_E$ , Profundidad focal  $P_f$  y Azimut  $A$ . El conjunto de parámetros propuestos considera las tres condiciones de suelo, en la ciudad de Oaxaca, para las cuales el modelo neuronal hará una estimación de la duración de la fase intensa del movimiento sísmico.

Los resultados de la predicción del modelo neuronal se incluyen en la tabla A3 del apéndice A. No obstante, dichas estimaciones no pueden ser verificadas, debido a que se trata de temblores que pudieran presentarse, si se puede indicar que las duraciones de la fase intensa para cada caso se encuentran dentro de un intervalo aceptable de acuerdo a lo observado para sismos que ya han ocurrido. Considerando lo anterior se puede establecer que tanto los parámetros de entrada como el conjunto de datos de entrenamiento del modelo son adecuados, pero deberán hacerse más pruebas que permitan ajustar el modelo para incrementar el coeficiente de correlación tanto en entrenamiento como en prueba. Los ajustes al modelo deberán hacerse considerando variaciones en la configuración de las RNA, así como incluir en el banco de datos nuevos registros de temblores. La inclusión de nuevos datos no implica necesariamente incrementar el tamaño del banco de datos, más bien se debe buscar una mejor representación de los sismos tanto en magnitud como en ubicación. Lo anterior se debe a que se tienen pocos sismos de mediana a gran magnitud debido a que los periodos de recurrencia de estos suelen ser de 30 a 100 años y en algunos casos aún más. Al momento de integrar la base de datos solo se contaba con 8 temblores de magnitud igual o mayor a 7 lo que representa alrededor de un 5% del total, tal situación refuerza el comentario anterior en cuanto a la representatividad del fenómeno.



Figura 30. Epicentros de los sismos postulados.

Tabla 5. Parámetros de entrada para los sismos postulados.

#	Epicentro	$C_s$	M	$D_e$ (km)	$P_f$ (km)	A (°)
1	A	3	7.6	292	25	138
2	A	2	7.6	292	25	138
3	A	1	7.6	292	25	138
4	B	3	7.2	146	50	138
5	B	2	7.2	146	50	138
6	B	1	7.2	146	50	138
7	C	3	7	150	30	170
8	C	2	7	150	30	170
9	C	1	7	150	30	170
10	D	3	8	70	60	170
11	D	2	8	70	60	170
12	D	1	8	70	60	170
13	E	3	8.1	390	35	268
14	E	2	8.1	390	35	268
15	E	1	8.1	390	35	268
16	F	3	7.8	195	40	268
17	F	2	7.8	195	40	268
18	F	1	7.8	195	40	268
19	G	3	6.6	144	50	326
20	G	2	6.6	144	50	326
21	G	1	6.6	144	50	326
22	H	3	6.9	72	50	326
23	H	2	6.9	72	50	326
24	H	1	6.9	72	50	326



## CAPÍTULO 4. CONCLUSIONES

- a) La Tierra es un ente dinámico que seguirá produciendo diversos fenómenos naturales, entre ellos los sismos. Hoy en día, se han identificado diversas regiones del planeta en donde se generan, siendo el denominado Cinturón de Fuego del Pacífico el que presenta la mayor actividad sísmica. México se encuentra ubicado precisamente a lo largo de dicho Cinturón y su alta tasa de sismicidad se debe a la interacción de las placas de: Norteamérica, Pacífico, Cocos, Caribe y Rivera. Aun cuando los sismos de gran magnitud suelen ocurrir en la denominada Zona de Subducción Mexicana; otros de menor magnitud, producidos en una región diferente, pueden representar un grave riesgo para las poblaciones debido a su cercanía.
- b) Históricamente, México ha sido afectado por diversos temblores, pero la mayor catástrofe hasta hoy registrada ocurrió el 19 de septiembre de 1985 cuando un sismo de magnitud 8.1 produjo una gran cantidad de muertos y un grave daño a la infraestructura del país. Lamentablemente la lección no ha sido aprendida y nuevamente la tragedia azotó el país durante los eventos del 8 y 19 de septiembre de 2017. Por lo anterior, y considerando el alto potencial que existe en la costa del Pacífico mexicano para generar sismos de gran magnitud, especialmente en la denominada Brecha de Guerrero en donde se estima que ocurrirá un sismo de magnitud mayor a ocho; es necesario impulsar la investigación sobre el fenómeno sísmico y su aplicación a medidas tendientes a mitigar su impacto en la sociedad.
- c) Los estudios que hoy en día se han hecho sobre el fenómeno sísmico, han representado importantes avances en su conocimiento, pero aún no son suficientes para reducir su impacto en forma significativa. Si bien se está muy lejos de predecir con certitud su ocurrencia, sí se pueden realizar acciones para contar con herramientas que coadyuven a reducir su impacto. Normalmente, estas acciones han estado sustentadas en el uso de teorías tradicionales y rígidas, que dada la complejidad del fenómeno en muchas ocasiones están lejos de ser buenos estimadores de la realidad. Por tal motivo es necesario buscar respuestas, mediante el uso de otras alternativas como lo es la Inteligencia Artificial.
- d) La Inteligencia Artificial entendida como aquella que pretende modelar la inteligencia humana en sistemas computacionales, ha evolucionado en

forma muy significativa y actualmente está presente en muchas de las actividades del ser humano. Su naturaleza y origen deriva de la necesidad para percibir, entender, predecir y manipular el entorno en el que habita mediante la construcción de entidades inteligentes. Un elemento importante para ello ha sido el desarrollo de las Redes Neuronales Artificiales las cuales son modelos de Inteligencia Artificial basados en datos y que pretenden de forma simple imitar el proceso cognitivo de los seres humanos. A diferencia de los métodos tradicionales, estos modelos buscan aprender las relaciones existentes en la información que se les presenta mediante patrones de entradas-salida.

- e) Considerando que la *duración de la fase intensa* es un parámetro fundamental debido a que tiene una gran influencia en la respuesta de suelos y estructuras ante la acción sísmica; se implementó un Modelo, basado en la teoría de las RNA, para estimar la *duración de la fase intensa* del movimiento sísmico. El modelo se desarrolló utilizando información obtenida en la Red de Acelerógrafos de la ciudad de Oaxaca.
- f) Los parámetros de la capa de entrada de la RNA quedaron definidos por la Magnitud (M), la Profundidad focal ( $P_f$ ), la Distancia epicentral ( $D_e$ ), las condiciones del subsuelo ( $C_s$ ) y el Azimut (A); y como único parámetro de la capa de salida la *duración de la fase intensa* ( $D_{IA}$ ) de acuerdo al criterio del profesor Arturo Árias.
- g) Es importante señalar el carácter predictivo del modelo puesto que los parámetros de entrada no dependen de la ocurrencia del sismo. Esto tiene gran relevancia puesto que se puede postular en evento sísmico y estimar cual sería la *duración de la fase intensa* en alguno de los suelos de la ciudad de Oaxaca.
- h) La mejor arquitectura del modelo fue para la RNA con la configuración de 5X140x140x1 (una capa de entrada con 5 nodos, dos capas ocultas con 140 nodos cada una y una capa de salida con un nodo). Para esta arquitectura se obtuvieron factores de correlación en entrenamiento  $R_E^2 = 0.8$  en prueba  $R_p^2 = 0.72$ . En lo general los valores del Modelo sobreestiman en un promedio del 5.4% los valores reales.
- i) En el establecimiento del modelo es necesario destacar la importancia que tiene: a) el conocimiento del fenómeno para poder establecer los parámetros de la capa de entrada, b) la integración de los conjuntos de prueba y entrenamiento, c) la selección de la arquitectura, así como de las

funciones de transferencia y la regla de aprendizaje y finalmente d) un cierto nivel de experiencia en el entrenamiento de esos sistemas.

- j) Los resultados estimados por el modelo neuronal, incluso para los sismos postulados, se pueden considerar aceptables y de gran ayuda para disminuir el impacto de sismos venideros, sin embargo, un banco de datos de mejor calidad podría permitir mejorar los factores de correlación. Un banco con tal característica no implica un mayor número de datos de entrenamiento y prueba, más bien considera un valor suficiente de patrones que representen adecuadamente las fronteras en las cuales el fenómeno se puede desarrollar.



## REFERENCIAS

1. Nava A (1999), *Terremotos*, México, Fondo de Cultura Económica, pp. 3-8.
2. Servicio Sismológico Nacional (2016), *Historia*, México, disponible en: <http://www.ssn.unam.mx/acerca-de/historia/>, (último acceso 2019 01 14).
3. Íñigo F (2015), *Funciones cognitivas*, España, disponible en: <https://www.neuronup.com/es/areas/functions>, (último acceso 2017 02 02).
4. Russell S, Norvig P (2004), *Inteligencia Artificial. Un Enfoque Moderno*, Madrid: Pearson Education, S.A, p. 2.
5. Haugeland J (1985), *Artificial Intelligence: The Very Idea*, Cambridge, Massachusetts: MIT Press.
6. Bellman R (1978), *An Introduction to Artificial Intelligence: Can Computers Think?*, Boyd & Fraser Publishing Company, San Francisco.
7. Charniak E, McDermott D (1985), *Introduction to Artificial Intelligence*, Addison-Wesley, Reading, Massachusetts.
8. Winston P (1992), *Artificial Intelligence (Third edition)*, Addison-Wesley, Reading, Massachusetts.
9. Kurzweil R (1990), *The Age of Intelligent Machines*, MIT Press, Cambridge, Massachusetts.
10. Rich E, Knight K (1991), *Artificial Intelligence (second edition)*, McGraw-Hill, New York.
11. Poole D, Mackworth A, Goebel R (1998), *Computational Intelligence: A logical approach*, Oxford, UK.
12. Nilsson N (1998), *Artificial Intelligence: A New Synthesis*, Morgan Kaufmann, San Mateo, California.
13. Russell S, Norvig P, *Op. cit*, pp. 3-6.
14. Russell S, Norvig p, *Ibidem*, pp. 19-32.
15. Spector L (2006), *Evolution of artificial intelligence*, Hampshire College, USA, Elsevier.
16. Russell S, Norvig P, *Op. cit*, p. 13.
17. Baidyk T, Kussul E (2009), *Redes neuronales, visión computacional y micromecánica*, México, D. F. Itaca.
18. Manjarrez L (2014), *Relaciones neuronales para determinar la atenuación del valor de la aceleración máxima en superficie de sitios en roca para zonas de subducción*, Tesis de Maestría, Facultad de Ingeniería, UNAM, p. 24.
19. Bonetti C (2013), *Estimación de la variación de la resistencia al corte en suelos marinos usando Redes Neuronales*, Tesis de Maestría, Facultad de Ingeniería, UNAM, pp. 30-31.
20. Russell S, Norvig P, *Op. cit*, pp. 740-741, 867-891.
21. Sáncho F (2019), *Aprendizaje por refuerzo: algoritmo Q Learning*, España, disponible en: <http://www.cs.us.es/~fsancho/?e=109>, (último acceso 2019 07 08).
22. Yadav N, Yadav A, Kumar M (2015), *An Introduction to Neural Network Methods for Differential Equations*, Dordrecht, Heidelberg, New York, London: Springer, p. 33.
23. Yadav N, Yadav A, Kumar M, *Ibidem*, p. 35.

24. Bengio Y, Courville A, Goodfellow I (2016), *Deep Learning*, Cambridge, Massachusetts: MIT Press, pp. 177-204.
25. Matich D (2001) *Redes Neuronales Conceptos Básicos y Aplicaciones*, Argentina Rosario, Facultad Nacional Rosario, p. 4.
26. Matich D, *Ibidem*, pp. 27-28.
27. Nava A, *Op. cit*, pp. 17-28.
28. Tarbuck E, Lutgens F (2005), *Ciencias de la Tierra, Una introducción a la geología física*, Madrid, Pearson Educación. pp. 16-19.
29. Acuña S (2017), *La Geosfera: Estructura y composición de corteza, manto y núcleo*, España, disponible en: <https://elblogverde.com/la-geosfera-estructura-y-composicion-de-corteza-manto-y-nucleo/>, (último acceso 2018 05 02).
30. Portaleducativo (2014), *Estructura interna de la Tierra*, Chile, disponible en: <https://www.portaleducativo.net/cuarto-basico/746/Estructura-interna-de-la-Tierra>, (último acceso 2017 02 02).
31. Tarbuck E, Lutgens F, *Op. cit*, pp. 34-41.
32. Oxford University (2014), *La deriva continental de Alfred Wegener*, España, disponible en: [https://www.blinklearning.com/Cursos/c778100\\_c39950010\\_\\_La\\_deriva\\_continental\\_de\\_Alfred\\_Wegener.php](https://www.blinklearning.com/Cursos/c778100_c39950010__La_deriva_continental_de_Alfred_Wegener.php), (último acceso 2017 02 02).
33. Choi C (2012), *Earth began recycling crust 3 billion years ago*, Miami, disponible en: <https://www.livescience.com/31257-earth-began-recycling-crust.html>, (último acceso 2017 02 02).
34. Nava A, *Op. cit*, pp. 22-50.
35. Peet J (2011), *En Infografía, todo sobre los terremotos*, Cuba, disponible en: <http://www.cubadebate.cu/noticias/2011/03/12/en-infografia-todo-sobre-los-terremotos/>, (último acceso 2017 02 02).
36. Zarins G (2013), *Fuerte actividad sísmica en todo el mundo*, Letonia, disponible en: <https://citadapasaule.com/2013/04/06/speciga-seismiska-aktivitate-visa-pasaule/>, (último acceso 2017 02 02).
37. Kearey P, Klepeis K, Vine F (2009), *Global Tectonics*, UK, Wiley-BlackWell.
38. Kostoglodov V, Francisco J (2000), *Cien años de sismicidad en México*, México, disponible en: <http://usuarios.geofisica.unam.mx/vladimir/sismos/100a%F1os.html>, (último acceso 2017 02 02).
39. Espinosa-Aranda J, Cuellar A, Garcia A, Ibarrola G, Islas R, Maldonado S, Rodriguez F (2009). *Evolution of the Mexican Seismic Alert System (SASMEX)*. México, disponible en: <https://rallen.berkeley.edu/pub/2009srl/EspinosaArandaEtAISRL2009.pdf>, (último acceso 2019 03 28). p. 702.
40. Vladimir C, Pacheco J (1999), *Cien años de sismicidad en México*, Instituto de Geofísica, UNAM, tríptico-mapa, primera edición, México.
41. Servicio Sismológico Nacional (2018), *Mapas de sismicidad anual*, México, disponible en: <http://www.ssn.unam.mx/sismicidad/mapas-de-sismicidad-anual/>, (último acceso 2017 02 02).
42. Nava A, *Op. cit*, pp. 11-13.
43. Servicio Sismológico Nacional (2018), *Red sismológica nacional*, México, disponible en: <http://www.ssn.unam.mx/acerca-de/estaciones/#RedBandaAncha>, (último acceso 2017 02 02).

44. Figueroa J (1957), *El macrosismo del 28 de julio de 1957, Anales del Instituto de Geofísica, UNAM*, III, 55-38.
45. Alcántara L, Almora D, Macías M, Castro G, Velasco J, Vázquez E, Ayala M, Torres M, Pérez C, Vázquez R, Sandoval H, Delgado R, Ruiz A (2005), *Evolución de la red de observación sísmica del Instituto de Ingeniería de la UNAM*, Congreso Chileno de Sismología e Ingeniería Antisísmica IX Jornadas, A02-03, Concepción, Chile.
46. Sam H (2014), *Epicenter Diagram*, Wikipedia, disponible en: [https://en.wikipedia.org/wiki/File:Epicenter\\_Diagram.svg](https://en.wikipedia.org/wiki/File:Epicenter_Diagram.svg) , (último acceso 2019 04 12).
47. Nava A, *Op. cit*, pp. 57-60.
48. Alcántara L (2014), *Neural estimation of strong ground motion duration, Geofísica Internacional*, 53-3: pp. 221-239.
49. Alcántara L (2013), *Análisis de movimientos sísmicos en las ciudades de Oaxaca y Puebla con redes neuronales*, Tesis Doctoral, Facultad de Ingeniería, UNAM. p. 25.
50. Alcántara L, *Ibidem*, p. 78.
51. Logical Designs Consulting Inc (2015), *ThinksPro Neural Networks for Windows*, CA, disponible en: <http://www.logicaldesigns.com/ThinksPro.html>, (ultimo acceso 2017 02 02).
52. León J L (1976), *Información general acerca del subsuelo de 17 ciudades de México, VIII Reunión Nacional de Mecánica de Suelos, SMMS 157–170*, México.
53. Limaymanta M, Lermo J, Alcántara L (2008), *Evaluación de los efectos de sitio y la caracterización de los terrenos de cimentación con fines de diseño sísmico*. Estudios en tres ciudades mexicanas, XIII Congreso Latinoamericano de Geología y XIV Congreso Nacional de Geología, Lima, Perú.
54. Ordaz M, Montoya C (2012), *Sistema DEGTRA v9.0*, Instituto de Ingeniería de la Universidad Nacional Autónoma de México.
55. Árias A (1970), *A measure of earthquake intensity, R K Hansen, ed. Seismic Design of Nuclear Power Plants MIT Press*, Cambridge, Mass, pp. 438-483.
56. Juan M (2007) *Análisis de correlación lineal. Los procedimientos Correlaciones bivariadas y Correlaciones parciales*, Universidad Carlos III, Madrid, disponible en: <http://halweb.uc3m.es/esp/Personal/personas/jmmarin/esp/GuiaSPSS/17corlin.pdf>, (ultimo acceso 2019 03 20).
57. Alcántara L, *Op. cit*, pp. x-xxiv.



## APÉNDICE A

- Tabla A1. Conjunto de entrenamiento para la componente EW (ref. 57).
- Tabla A2. Conjunto de prueba para la componente EW (ref. 57).
- Tabla A3. Datos de pruebas sin sesgos con Duración de Fase Intensa obtenida con red entrenada en 10000 y 12500 iteraciones para sismos postulados.

Tabla A1. Conjunto de entrenamiento para la componente EW (ref. 57).

#	C <sub>s</sub>	M	D <sub>e</sub> (km)	P <sub>f</sub> (km)	A (°)	D <sub>IA</sub> (s)
1	2	4.7	142	16	198.3	8.3
2	2	4.5	139	22	205.4	8.4
3	2	4.4	24	91	334.4	9.5
4	2	5	91	39	124.3	10.2
5	2	4.7	130	28	205.8	10.4
6	2	4.5	55	84	0.7	11.5
7	1	4.3	21	71	223.5	12
8	2	4.5	153	34	319.4	12.5
9	3	4.4	18	66	229.8	13.4
10	2	5	215	115	97.8	13.8
11	2	4.7	180	8	161.3	14
12	2	4.3	90	87	185.6	14.4
13	1	4.4	17	66	225	14.7
14	1	4.4	18	66	227.5	15.2
15	1	4.3	128	50	156.6	15.6
16	2	5.4	66	22	95.9	16
17	2	4.7	141	16	197.2	16.5
18	2	5.9	257	31	194.3	16.7
19	2	4.3	24	71	221.3	17.3
20	3	4.3	23	71	228.8	17.5
21	1	4.3	89	87	187.1	17.5
22	3	4.7	138	63	140.1	17.9
23	2	4.1	76	45	226	18.3
24	1	4.3	21	71	228.7	18.4
25	2	4.8	199	100	105.2	18.6
26	2	4.4	17	66	213.9	18.8
27	1	4.8	195	100	105	19
28	2	7	197	70	301	19.2
29	1	4.4	118	13	219.3	19.3
30	1	4.9	141	45	206	19.3
31	3	5.7	185	66	115.1	20.7
32	2	4.8	160	10	178.7	20.8
33	3	4.7	140	16	199.3	21.1
34	3	4.8	194	100	105	21.3
35	2	4.4	85	135	79.1	21.4
36	2	4.7	128	28	204.7	21.4
37	2	4.3	21	71	216.3	21.7
38	2	4.3	116	63	72.7	22
39	1	5.5	132	16	195.4	22
40	1	4.3	114	63	70.7	22.4
41	1	4.4	122	43	205.8	22.6
42	3	5.6	129	8	192.9	23.2

Tabla A1. (Cont.)

#	C <sub>s</sub>	M	D <sub>e</sub> (km)	P <sub>f</sub> (km)	A (°)	D <sub>IA</sub> (s)
43	2	4.7	142	63	139.2	23.4
44	2	5.5	134	16	193.7	23.5
45	1	5.6	128	8	192.3	23.6
46	2	6.8	136	84	12.4	23.6
47	3	4.5	58	84	358.9	23.9
48	1	5.7	188	66	115	24
49	1	4.9	140	45	206.5	24.1
50	1	4.6	193	16	202.3	24.3
51	2	4.3	132	50	155.8	24.5
52	3	4.9	142	45	206.8	24.8
53	3	5.5	133	16	195.9	25.4
54	1	4.4	145	28	204.2	25.4
55	1	4.4	82	135	78	25.6
56	1	4.5	72	28	177.4	25.7
57	2	7.6	130	16	195.5	25.8
58	1	5.6	129	8	191.9	26.3
59	2	5.4	477	141	107.1	26.5
60	2	5.1	132	3	207.5	26.5
61	1	4.7	140	16	198.9	26.7
62	2	5.6	130	8	190.6	27.1
63	3	4.5	156	34	319.5	27.2
64	2	4.4	145	28	203.3	27.3
65	1	4.7	120	11	188.9	27.7
66	2	4.5	57	84	3.4	27.8
67	2	5.1	134	3	208.5	27.9
68	1	4.3	130	50	156.2	28.5
69	2	5.6	131	8	191.8	28.9
70	2	4.6	196	16	202.3	29
71	2	5.3	382	210	98.8	29.3
72	3	5.1	133	3	209.7	29.5
73	2	4.6	124	27	203.3	29.5
74	1	4.5	58	84	0	29.9
75	1	5.7	188	66	114.8	30.1
76	1	4.7	132	109	59.1	30.1
77	1	4.9	141	45	206.4	30.1
78	1	5.1	131	3	208.6	30.1
79	1	4.7	138	63	139.8	30.2
80	2	4.7	133	109	61	31
81	1	4.5	58	84	1.1	31.6
82	1	4.7	128	28	206.6	31.9

Tabla A1. (Cont.)

#	C <sub>s</sub>	M	D <sub>e</sub> (km)	P <sub>f</sub> (km)	A (°)	D <sub>IA</sub> (s)
83	1	5.6	129	8	192.4	31.9
84	2	6.4	159	33	166.1	32.2
85	2	4.5	130	30	220.2	32.5
86	2	4.6	194	16	201.5	33
87	2	4.7	122	11	187.1	33.1
88	1	5.8	165	10	227.2	33.4
89	3	4.7	130	109	59.2	34.1
90	1	5.6	129	8	191.9	34.2
91	3	5.3	91	10	131.1	34.3
92	2	5.7	190	66	115	34.5
93	2	4.7	130	109	60.6	34.7
94	2	7.3	246	22	250.3	34.8
95	2	5.8	167	10	226.8	35.7
96	1	6.3	371	36	115.5	36.4
97	3	6.4	491	20	125.3	36.7
98	1	5.1	147	115	31.3	37.1
99	3	7.5	128	16	196.6	37.4
100	2	4.6	181	25	261.5	37.6
101	1	4.7	132	109	59.9	37.8
102	2	5.2	176	10	240.5	37.9
103	1	5.8	165	10	227.5	38.2
104	2	6	219	20	232.6	38.3
105	2	6.3	375	36	115.5	38.4
106	1	5.8	165	10	227.9	38.6
107	1	5.1	147	115	31	39.1
108	2	5	178	84	227.9	39.8
109	2	5.1	145	115	31.7	40.2
110	2	4.6	202	133	80.3	40.7
111	2	5.3	95	10	130.1	40.8
112	1	4.3	89	87	187.8	41
113	2	5.3	275	33	149.2	41
114	1	5.3	132	106	88.5	41.1
115	3	5.1	146	115	30.6	41.2
116	1	5.3	133	106	88.2	41.4
117	3	6.3	370	36	115.5	41.7
118	2	5.9	261	47	294.5	41.9
119	1	5.3	132	106	88.2	42
120	2	6	391	70	119	42
121	2	4.7	175	131	71.4	42.1
122	2	7	148	69	324.1	42.3
123	3	5.3	130	106	88.1	42.5
124	1	6	220	20	233.6	43.4
125	1	4.6	173	131	70.1	43.4

Tabla A1. (Cont.)

#	C <sub>s</sub>	M	D <sub>e</sub> (km)	P <sub>f</sub> (km)	A (°)	D <sub>IA</sub> (s)
126	2	6.4	496	20	125.2	43.7
127	2	5	283	116	103.7	44.2
128	2	4.4	218	145	79	44.6
129	1	5.4	218	142	80.1	45.8
130	3	7.6	848	10	278.4	47.6
131	2	5.4	217	142	81.1	47.6
132	2	5.3	135	106	89	48.3
133	1	5.4	218	142	80.5	48.3
134	1	5.4	219	142	80.5	48.4
135	2	5.4	220	142	81.1	50.3
136	2	4.9	218	150	78.1	52.6
137	3	7	151	69	324.1	53.6

Tabla A2. Conjunto de prueba para la componente EW (ref. 57).

#	C <sub>s</sub>	M	D <sub>e</sub> (km)	P <sub>f</sub> (km)	A (°)	D <sub>IA</sub> (s)
1	2	4.4	19	66	220.4	14
2	1	4.4	17	66	225	14.1
3	1	4.3	22	71	225.4	15
4	1	4.9	141	45	206	19.9
5	2	5.5	135	16	194.9	20.2
6	3	4.5	72	28	178.2	21.5
7	2	4.4	159	42	59.1	21.8
8	2	5.7	188	66	115.6	22.7
9	1	5.7	187	66	114.9	24.8
10	2	4.4	125	43	205.8	25.3
11	2	4.4	123	43	204.6	26.5
12	2	4.7	143	7	179.8	26.7
13	2	4.9	141	45	204.7	27.4
14	1	4.3	130	50	156.6	27.7
15	2	4.9	143	45	205.7	27.9
16	1	5.5	133	16	194.7	28.9
17	1	5.1	131	3	209.5	30.2
18	2	4.5	73	28	174.8	30.3
19	1	4.8	196	100	104.9	30.4
20	1	5.1	132	3	209	32
21	2	4.7	123	11	188.5	32.1
22	2	7.0	212	24	245.3	32.6
23	1	4.5	130	30	222	32.9
24	1	5.5	133	16	195.1	33.5
25	1	4.7	132	109	59.7	33.9
26	1	5.3	91	10	130	33.9
27	1	5.3	91	10	130.7	37.8
28	2	5.8	165	10	226.3	38
29	2	5.3	94	10	131.6	39.8
30	2	4.6	172	131	71.3	40.8
31	1	4.6	173	131	70.6	41.2
32	2	5.3	132	106	89.3	42.2
33	2	5.1	147	115	32.6	42.3
34	2	4.6	218	134	74.9	44.6

Tabla A3. Datos de pruebas sin sesgos con Duración de Fase Intensa obtenida con red entrenada en 10000 y 12500 iteraciones para sismos postulados.

#	Epicentro	C <sub>s</sub>	M	D <sub>e</sub> (km)	P <sub>f</sub> (km)	A (°)	Iteraciones (#)	D <sub>IRNA</sub> (s)
1	A	3	7.6	292	25	138	10000	33.574
2	A	2	7.6	292	25	138	10000	33.574
3	A	1	7.6	292	25	138	10000	33.576
4	B	3	7.2	146	50	138	10000	42.446
5	B	2	7.2	146	50	138	10000	42.443
6	B	1	7.2	146	50	138	10000	42.441
7	C	3	7	150	30	170	10000	43.940
8	C	2	7	150	30	170	10000	44.162
9	C	1	7	150	30	170	10000	44.361
10	D	3	8	70	60	170	10000	50.428
11	D	2	8	70	60	170	10000	50.449
12	D	1	8	70	60	170	10000	50.469
13	E	3	8.1	390	35	268	10000	39.933
14	E	2	8.1	390	35	268	10000	40.007
15	E	1	8.1	390	35	268	10000	40.083
16	F	3	7.8	195	40	268	10000	36.128
17	F	2	7.8	195	40	268	10000	36.129
18	F	1	7.8	195	40	268	10000	36.131
19	G	3	6.6	144	50	326	10000	41.794
20	G	2	6.6	144	50	326	10000	41.681
21	G	1	6.6	144	50	326	10000	41.567
22	H	3	6.9	72	50	326	10000	39.424
23	H	2	6.9	72	50	326	10000	39.430
24	H	1	6.9	72	50	326	10000	39.436
25	A	3	7.6	292	25	138	15000	36.337
26	A	2	7.6	292	25	138	15000	36.372
27	A	1	7.6	292	25	138	15000	36.406
28	B	3	7.2	146	50	138	12500	43.301
29	B	2	7.2	146	50	138	12500	43.269
30	B	1	7.2	146	50	138	12500	43.292
31	C	3	7	150	30	170	12500	40.877
32	C	2	7	150	30	170	12500	41.620
33	C	1	7	150	30	170	12500	42.337
34	D	3	8	70	60	170	12500	49.308
35	D	2	8	70	60	170	12500	49.306
36	D	1	8	70	60	170	12500	49.303
37	E	3	8.1	390	35	268	12500	34.973
38	E	2	8.1	390	35	268	12500	35.020
39	E	1	8.1	390	35	268	12500	35.072
40	F	3	7.8	195	40	268	12500	38.829
41	F	2	7.8	195	40	268	12500	38.831
42	F	1	7.8	195	40	268	12500	38.832

Tabla A3. (Cont.)

#	Epicentro	C <sub>s</sub>	M	D <sub>e</sub> (km)	P <sub>f</sub> (km)	A (°)	Iteraciones (#)	D <sub>IRNA</sub> (s)
43	G	3	6.6	144	50	326	12500	36.400
44	G	2	6.6	144	50	326	12500	36.346
45	G	1	6.6	144	50	326	12500	36.287
46	H	3	6.9	72	50	326	12500	39.041
47	H	2	6.9	72	50	326	12500	39.056
48	H	1	6.9	72	50	326	12500	39.071