



**UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO**

---

**FACULTAD DE INGENIERÍA**

**Modelo neuronal para estimar  
aceleraciones durante la ocurrencia  
de microsismos en el Valle de  
México**

**TESIS**

Que para obtener el título de  
**Ingeniero Geofísico**

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

Axel Eduardo Ayala Anzaldo

**DIRECTOR DE TESIS**

Dr. Leonardo Alcántara Nolasco



Ciudad Universitaria, Cd. Mx., 2026



**PROTESTA UNIVERSITARIA DE INTEGRIDAD Y  
HONESTIDAD ACADÉMICA Y PROFESIONAL  
(Titulación con trabajo escrito)**



De conformidad con lo dispuesto en los artículos 87, fracción V, del Estatuto General, 68, primer párrafo, del Reglamento General de Estudios Universitarios y 26, fracción I, y 35 del Reglamento General de Exámenes, me comprometo en todo tiempo a honrar a la institución y a cumplir con los principios establecidos en el Código de Ética de la Universidad Nacional Autónoma de México, especialmente con los de integridad y honestidad académica.

De acuerdo con lo anterior, manifiesto que el trabajo escrito titulado MODELO NEURONAL PARA ESTIMAR ACELERACIONES DURANTE LA OCURRENCIA DE MICROSISMOS EN EL VALLE DE MEXICO que presenté para obtener el título de INGENIERO GEOFÍSICO es original, de mi autoría y lo realicé con el rigor metodológico exigido por mi Entidad Académica, citando las fuentes de ideas, textos, imágenes, gráficos u otro tipo de obras empleadas para su desarrollo.

En consecuencia, acepto que la falta de cumplimiento de las disposiciones reglamentarias y normativas de la Universidad, en particular las ya referidas en el Código de Ética, llevará a la nulidad de los actos de carácter académico administrativo del proceso de titulación.

---

**AXEL EDUARDO AYALA ANZALDO**  
Número de cuenta: 316052371

## **Agradecimientos.**

Al Dr. Leonardo Alcántara Nolasco, por su asesoramiento y guía durante mi último año en la universidad, gracias por su paciencia y por sus ganas de compartir su conocimiento conmigo.

A mis sinodales el Dr. Jorge Aguirre, Dr. Josué Tago, Dr. Jorge Alvis y M.C. Manuel Ortiz, por el tiempo, la disposición y el interés que mostraron en mí y en el presente trabajo.

Agradecemos al Gobierno de la Ciudad de México, a través del Instituto para la Seguridad de las Construcciones en la Ciudad de México (ISC) y al Centro de Instrumentación y Registro Sísmico, A. C. (CIRES) por el apoyo para utilizar el acervo de datos de la Red Acelerográfica de la Ciudad de México (RACM).

A la Universidad Nacional Autónoma de México y a la Facultad de Ingeniería por proporcionarme los medios para desarrollarme como estudiante y como futuro profesional.

## **Dedicatoria**

*A Dios por toda mi vida, por todo lo bueno presente, por las personas que ha enviado a mi vida, por cuidar de mí, por mi hermosa familia y por acompañarme en cada paso de mi camino.*

*A mi padre Juvenal: Gracias por tu trabajo, sudor y cansancio, con el cual buscaste darme lo mejor posible. Gracias por permitirme crecer como un niño al que nunca le faltó nada y que; siempre tuvo el amor y la tranquilidad de tener un hogar y una familia. Gracias por cuidar de mí, de mi madre y de mis hermanos.*

*Sin ti no estaría en donde estoy.*

*A mi madre Janet: gracias por tu inmenso amor, un amor tan grande que te impulsó a siempre dar el máximo por mí, a sacrificarte y a buscar mi bienestar. Espero algún día llegar a ser un guerrero como tú, una persona que afronta las dificultades y que, aunque tenga un gran dolor, tiene aún más valor para luchar.*

*Gracias por ser mi mayor ejemplo en la vida.*

*A mis hermanos Luis y Caleb: a Luis por ser mi mejor amigo, por nunca dejarme solo y por ser mi compañero durante toda mi vida; a Caleb por ser una nueva luz en mi vida, y llenar nuestro hogar de alegrías. Los tres somos hermanos favoritos.*

*A mis abuelitos Francisca y Juvenal: Gracias por dejarme dormir con ustedes cuando era niño, por las carnicas, por las gelatinas, por las tortas, por todo el cariño y amor que me han dado, gracias por cuidarme, y por ser mi hogar.*

# Índice

<b>1. INTRODUCCIÓN</b>	<b>1</b>
<b>2. MARCO GEOLÓGICO</b>	<b>5</b>
2.1. Morfología y Estratigrafía de la Cuenca del Valle de México	8
2.2 Suelos de la Ciudad de México	13
<b>3. SISMICIDAD EN EL VALLE DE MÉXICO</b>	<b>18</b>
3.1. Zonas sismogénicas y grandes sismos	18
3.2. Características de la sismicidad en la Cuenca del Valle de México	19
3.3. Tectónica y sistema de fallas en la Cuenca del Valle de México	24
<b>4. REDES NEURONALES ARTIFICIALES</b>	<b>27</b>
4.1. Inteligencia artificial	27
3.2. Redes Neuronales Artificiales.	30
3.3. Redes Neuronales Multicapa	38
<b>5. MODELO NEURONAL</b>	<b>46</b>
5.1. Descripción de la base de datos	46
5.2. Análisis estadístico de los parámetros sísmicos	53
5.3. Arquitectura del modelo neuronal	60
5.3. Conjuntos de Entrenamiento y Prueba	62
5.3. Entrenamiento del modelo	63
<b>6. RESULTADOS</b>	<b>68</b>
<b>7. CONCLUSIONES</b>	<b>80</b>

## Resumen.

Los microsismos en el Valle de México representan un problema actual que ha causado daños estructurales y preocupación en la ciudadanía. El objetivo de este trabajo fue desarrollar y evaluar tres modelos basados en redes neuronales artificiales (RNA) para estimar la aceleración máxima del terreno ( $A_{max}$ ) a partir de 95 registros. Los tres modelos fueron de tipo Perceptrón Multicapa, usando el algoritmo de retropropagación, Utilizando los parámetros de magnitud, profundidad, distancia epicentral, azimut y periodo fundamental. El mejor desempeño lo obtuvo la red de la componente EW, con un error cuadrático medio (RMSE) de 4.61 [cm/s<sup>2</sup>] y un coeficiente de correlación de 0.87 en el conjunto de prueba. Los resultados demuestran que las RNA tienen la capacidad de estimar las aceleraciones del terreno ya que se logró estimar adecuadamente la  $A_{max}$  incluso con un número limitado de eventos. Se concluye que, con una base de datos más amplia, estos modelos podrían alcanzar una fiabilidad mayor y que el presente trabajo puede ser útil como punto de partida para futuros proyectos.

# 1. Introducción

Los llamados sismos locales o microsismos ocurridos en la Ciudad de México son un fenómeno que ha cobrado especial relevancia en los años recientes, debido a un aparente incremento en su ocurrencia e intensidad, han causado preocupación entre la población e inquietud entre los especialistas. Es un problema que afecta a una parte importante de la ciudad y si bien ha generado mayor pánico al poniente de la capital, su ocurrencia no se limita únicamente a esa zona.

Estos sismos se caracterizan por ser eventos de magnitudes menores a 4 ubicados dentro de la Ciudad de México, sismos de corta duración, especialmente intensos en las zonas aledañas al epicentro, que han provocado pequeños daños dentro de las viviendas y daños estructurales menores. Pero sobre todo han causado que la ciudadanía tema por su seguridad y por la condición de sus hogares, y lugares de trabajo.

Existe una incertidumbre sobre la magnitud de los daños y pérdidas que estos sismos pueden generar, los especialistas tienen opiniones divididas sobre cómo afrontar mediática y prácticamente el problema. Es por lo anterior que, la cantidad de medidas tomadas para entender el fenómeno han incrementado, la instalación de estaciones de registros, la elaboración de artículos y la realización de foros que hablan sobre el tema son algunos ejemplos. Esto indica que se trata de una problemática actual, que requiere la participación de geofísicos, geólogos, civiles y cualquier otro especialista involucrado en el área.

Aunque la sismicidad dentro de la cuenca no es en absoluto un fenómeno nuevo, sí es uno que se ha relegado y no ha sido del todo estudiado. A pesar de la instrumentación sísmica presente en la capital, esta ha sido insuficiente para comprender el fenómeno, por lo que se requiere la colaboración conjunta de la comunidad científica para abordarlo de manera multidisciplinaria. Por ello surgió la idea de utilizar herramientas de inteligencia artificial, específicamente redes neuronales artificiales, para contribuir a la comprensión del fenómeno, mitigar el riesgo e impulsar el uso de nuevas técnicas para su estudio.

La inteligencia artificial es una herramienta cuya adaptabilidad le permite aplicarse a la resolución de diferentes situaciones en múltiples disciplinas, aunque aún enfrenta cierta resistencia respecto a su efectividad y confiabilidad. Sin embargo, se ha demostrado que, con la metodología adecuada, puede ser de enorme utilidad y servir como herramienta de apoyo para encontrar las soluciones adecuadas a cada problema.

Las redes neuronales artificiales son modelos computacionales inspirados en la estructura y funcionamiento de las neuronas humanas. Son capaces de aprender patrones complejos a partir de un conjunto de datos y de un proceso de entrenamiento. Las redes neuronales se organizan en diferentes capas o niveles, cada uno de los cuales incrementa su complejidad, amplía sus alcances y mejora la calidad de los resultados que puede ofrecer. Debido a su gran capacidad de adaptación, las redes neuronales se han convertido en una herramienta novedosa y confiable para las ingenierías, ya que permiten estudiar fenómenos multifactoriales y de alta variabilidad.

Mediante el uso de una red neuronal artificial es posible realizar predicciones de futuros eventos de interés. La predicción no se realiza al azar o sin un soporte matemático detrás, la red se encarga de, mediante una base de datos, extraer de ellos un patrón real, significativo y representativo del problema, para que estas predicciones respondan a la física del problema y puedan recrearlo de manera precisa para poder realizar una estimación cercana a la real.

Mediante el uso de las redes neuronales artificiales, se pretende entrenar tres modelos neuronales, que puedan extraer los patrones necesarios para poder recrear el fenómeno de la microsismicidad en el valle, realizando pruebas con sismos ya ocurridos. Un parámetro utilizado para medir los daños que estos sismos locales provocan es la medición de la aceleración máxima, la cual se denomina  $A_{max}$  o *PGA* por sus siglas en inglés.

El contenido del trabajo se desarrolla a lo largo de 7 capítulos, cada uno comprende las diferentes etapas que permitieron desarrollar una metodología capaz de estudiar un fenómeno tan complejo.

El capítulo 2 presenta las bases geológicas que caracterizan la Cuenca del valle de México, describe su contexto geológico y morfológico; así como su estratigrafía, además de presentar algunos aspectos geotécnicos relevantes.

En el capítulo 3 se presenta una reseña general sobre la sismicidad a la que el Valle de México está expuesto. Se identifican las principales zonas sismogénicas y se analizan las características de la sismicidad local. Asimismo, se analizan una serie de registros y estudios previos que, a lo largo del tiempo, han abordado el comportamiento sísmico de la región. Finalmente, se discuten las posibles causas de dicha sismicidad y el sistema de fallas que controla el régimen tectónico de la capital.

Por su parte, en el capítulo 4 se describen los fundamentos de las redes neuronales artificiales, iniciando con una pequeña revisión histórica de la inteligencia artificial y de los procesos que condujeron al desarrollo de dichas redes. Asimismo, se explica su

estructura, los elementos que las conforman y los procesos involucrados en su funcionamiento.

El capítulo 5 describe toda la metodología involucrada en la construcción de la red neuronal. Se explica el criterio de selección de los datos y aquellos parámetros utilizados que sirven para describir el fenómeno: magnitud, distancia epicentral, profundidad focal, azimut y el periodo fundamental del suelo. Finalmente se describen todas las etapas del proceso, desde la elaboración de la base de datos y el análisis estadístico, hasta el desarrollo y entrenamiento de los tres modelos neuronales.

El capítulo 6 muestra los resultados obtenidos de los respectivos conjuntos de entrenamiento y prueba. Se evalúa el éxito o fracaso de la red considerando el coeficiente de correlación, la raíz del error cuadrático medio y de manera cuantitativa el desempeño que tiene la red para estimar las aceleraciones seleccionadas.

El capítulo 7 finaliza con las conclusiones, como fue el desempeño de los modelos, se presentan las limitaciones de estos y se realizan recomendaciones para futuros proyectos.

## **Objetivo general:**

Implementar un modelo neuronal para estimar el movimiento del terreno ante la ocurrencia de microsismos en el Valle de México.

## **Objetivos específicos:**

- a) Generar una base de datos que contenga la información de los microsismos ocurridos dentro de la Ciudad de México, con información obtenida por la red de instrumentos sísmicos operada por el Centro de Instrumentación y Registro Sísmico (CIRES).
- b) Evaluar la calidad de los registros sísmicos y descartar aquellos que no presenten condiciones adecuadas para el análisis.
- c) Realizar un análisis estadístico de los datos, para conocer de manera general el comportamiento de los datos.
- d) Generar tres redes neuronales capaces de estimar la aceleración máxima del terreno en las direcciones norte-sur, este-oeste y vertical.
- e) Analizar los resultados, describir las características del modelo y realizar recomendaciones para futuros trabajos.

Los objetivos planteados permiten estructurar de manera lógica el desarrollo de la investigación. La generación de una base de base de datos específica del fenómeno, libre de registros deficientes, asegura que el análisis es realizado con información de calidad.

El análisis estadístico ayuda a comprender el conjunto de datos de manera general, comprender su comportamiento, tendencias y patrones, además de identificar valores atípicos y la relevancia que estos tienen para describir el fenómeno, así como evaluar la independencia entre los parámetros seleccionados.

Finalmente, el análisis de los resultados y la elaboración de recomendaciones permiten evaluar el desempeño del modelo y establecer bases para investigaciones futuras. Las redes neuronales permiten abordar el problema de manera no convencional, considerando la complejidad de la tarea y los múltiples factores involucrados, es por lo que fue seleccionada como la herramienta para llevar a cabo el presente trabajo.

## 2. Marco Geológico

La Ciudad de México se asentó y se ha desarrollado y expandido sobre lo que hoy se conoce como Valle de México (VM), una región de gran relevancia para los habitantes del país, moldeada a lo largo del tiempo por la interacción de diversos y complejos procesos geológicos, climáticos y antropológicos. La zona metropolitana del Valle de México es el territorio más poblado del país, con una población cercana a los 22 millones de habitantes de distintas localidades, se incluyen 16 alcaldías de la Ciudad de México y 105 municipios del Estado de México, Hidalgo, Puebla y Tlaxcala. Tiene una extensión aproximada de 18 229  $km^2$  incluyendo sierras, valles y lagos; es, además, el centro cultural, económico y político de México (Peña-Díaz, 2019).

El VM se encuentra ubicado en la región centro oriental de la Faja Volcánica Transmexicana (FVTM) en las coordenadas 19° 25'10" N y 99° 08'44" W a una altitud promedio de 2242 msnm. La región se encuentra rodeada por diversas cadenas montañosas cuya estructura de mayor relevancia es el Volcán Popocatepetl con una elevación aproximada de 5500 msnm.

La FVTM es el arco volcánico del Neógeno más grande de Norteamérica con una extensión de 1000 km de longitud, recorre México de este a oeste desde el Pacífico hasta el Golfo de México (Figura 1). Tiene una edad aproximada de 20 millones de años, construida sobre formaciones magmáticas del Cretácico y Cenozoico, además sobreyace un basamento de terrenos estratigráficos de distintas edades y litologías (Ferrari *et al.*, 2011).

La génesis de la FVTM se debe a la subducción de las placas de Rivera y Cocos debajo de las placas de Norteamérica y Caribe a lo largo de la Trinchera Mesoamericana. Una de las particularidades de la FVTM es que la alineación de los principales estratovolcanes y calderas presenta una orientación oblicua respecto al rumbo de subducción, además de encontrarse a una distancia considerable de la costa.

Este patrón se atribuye a variaciones en la tasa de convergencia y en el ángulo de subducción de la Placa de Cocos (Husker, 2009), a través de imágenes de tomografía basadas en la inversión del tiempo de viaje de ondas P, determinó que la placa viaja de forma plana desde la costa hasta antes de la Ciudad de México para después buzar con un ángulo de 75°.



*Figura 1: Ubicación geográfica de la Cuenca de México, en rojo la Faja Volcánica Transmexicana, en blanco la Cuenca del Valle de México (Méndez-Sánchez, 2003).*

La Cuenca del Valle de México (CVM) es una estructura geomorfológica que ha sido moldeada por distintos periodos de actividad volcánica y tectónica. Cubierta por las rocas volcánicas, se oculta la unidad de rocas carbonatadas del Cretácico, las cuales han sido encontradas por distintos pozos (Pérez-Cruz, 1988; Arce *et al.*, 2015). Según varios autores estas calizas marinas pueden ser una clara evidencia de que, el centro del país en algún momento estuvo cubierto por un mar somero, para después cerrarse por los distintos eventos tectónicos y volcánicos.

Una fuerte actividad volcánica ha sido observada en los distintos pozos durante los últimos 20 millones de años con la formación de la FVTM. En sus comienzos la Cuenca de México drenaba hacia el sur hasta el océano Pacífico, sin embargo, esta se cerró con la formación de la Sierra del Chichinautzin en el Cuaternario Superior hace aproximadamente 700,000 años (Mooser y Montiel-Rosado, 1989). Posterior a su cierre, se formó un gran lago que con el tiempo se dividió en cinco cuerpos principales: Zumpango, Xaltocan, Texcoco, Xochimilco y Chalco. En la actualidad, tan solo quedan pequeños cuerpos de agua, debido al proceso natural de desecación y a los diversos proyectos de drenaje, entre los que destacan el Tajo de Nochistongo y el Gran Canal del Desagüe.

Fisiográficamente, en la cuenca existen dos elementos morfológicos que predominan y condicionan su forma: 1) Las partes elevadas que delimitan y rodean el valle, al oeste

la Sierra Nevada, al sur la Sierra del Chichinautzin, al oriente la Sierra de las Cruces y finalmente la Sierra de Pachuca al norte (González Torres *et al.*, 2015; Enciso-De la Vega, 1992) (Figura 2) y 2) Las grandes planicies lacustres y valles con estructuras monogenéticas aisladas como el cerro de la Estrella y el Peñón del Marqués (Enciso-De la Vega, 1992).

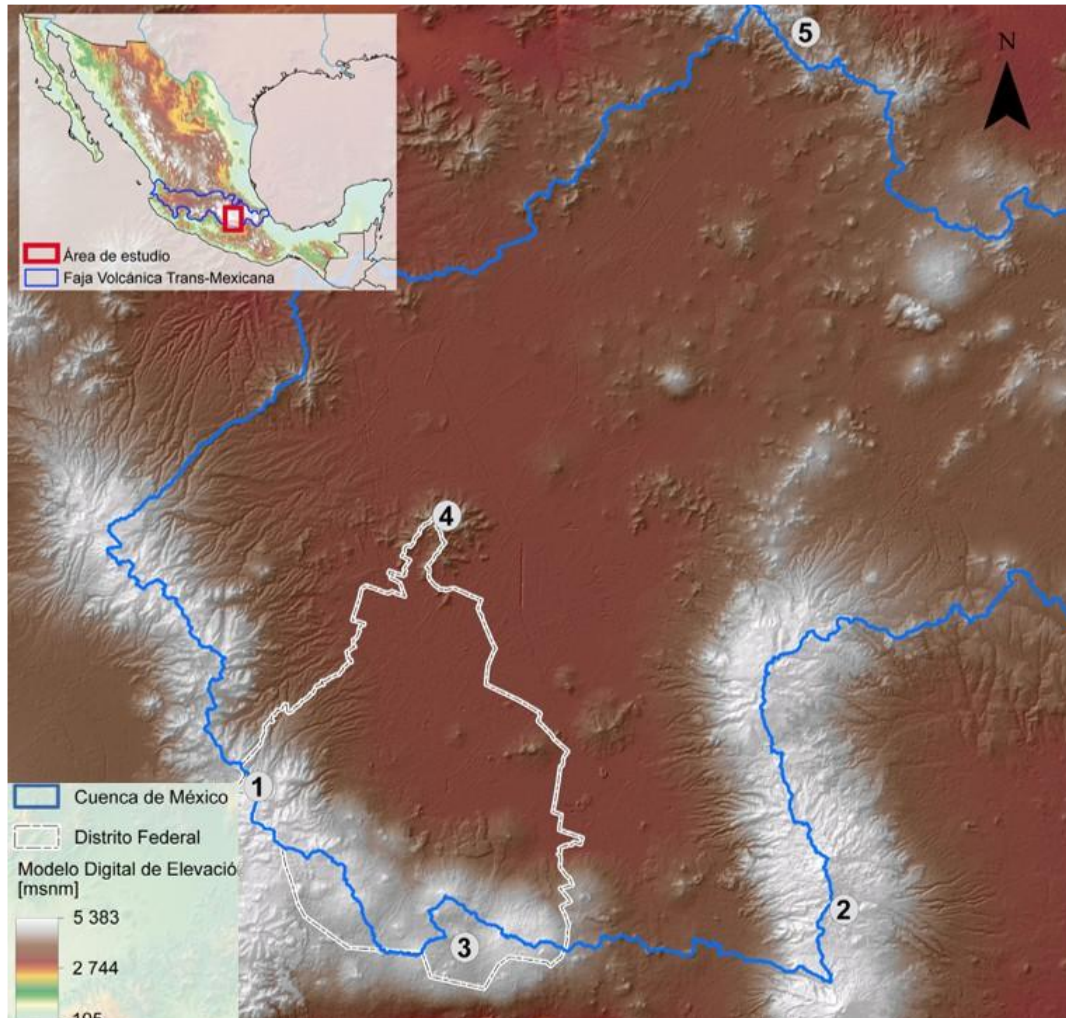


Figura 2: Forma de la Ciudad de México en comparación con la Cuenca de México. 1. Sierra de las Cruces. 2. Sierra Nevada y Río Frío. 3. Sierra Chichinautzin. 4. Sierra de Guadalupe. 5. Sierra de Pachuca.

## 2.1. Morfología y Estratigrafía de la Cuenca del Valle de México

Existen 4 grandes sierras principales que rodean la cuenca:

**a) Sierra de las Cruces.** Se localiza al poniente, dividiendo la cuenca de México y la cuenca de Toluca, tiene una longitud de 110 km y cuenta con 8 estratovolcanes principales: Zempoala, La Corona, San Miguel, Salazar, Chimapla, Iturbide, La Bufa y la Catedral; además, de diversas estructuras menores como el Ajusco. Se caracterizó por tener una actividad volcánica efusiva y explosiva importante durante el Plioceno y Pleistoceno, está conformada por extensos derrames de lava y domos de composición andesítico-dacítica y afinidad cacialcalina (García-Palomo *et al.*, 2008; Gunn y Mooser, 1970). Además de, una alternancia con flujos piroclásticos, oleadas piroclásticas, flujos de pómez y colapsos que originaron depósitos de avalanchas de escombros (García-Palomo *et al.*, 2008).

**b) Sierra de Pachuca.** Se ubica al norte y se caracteriza por sus grandes recursos minerales (Fries, 1966), además se encuentra acompañada por la Sierra de Tepetzotlán y los cerros de Xalpa y Sincoque (Enciso-De la Vega, 1992).

**c) Sierra Nevada.** Tiene una orientación general N-S a lo largo de 45 km, formada por los volcanes Popocatepetl, el Complejo Volcánico Iztaccíhuatl y los volcanes Telapón y Tlaloc al norte de la sierra alineados en dirección NE-SW (García-Tovar y Martínez-Serrano, 2011; Boudal y Robin, 1989; Enciso-De la Vega, 1992).

**d) Sierra Chichinautzin.** Compuesta por más de 120 volcanes monogenéticos, con dirección EW, que comienza en las faldas del Volcán Popocatepetl y termina en el Nevado de Toluca (Mooser y Montiel-Rosado, 1989; Siebe *et al.*, 2004; Enciso-De la Vega, 1992; Fries, 1966) cuya formación, hace 700,000 años cerró la cuenca y cuyo evento más reciente generó los enormes derrames basálticos que cubren la zona del Pedregal.

También existen estructuras individuales dentro de las grandes planicies lacustres, entre las que se encuentra la Sierra de Santa Catarina. Lugo-Hubp *et al.* (1994) realizaron una descripción geomorfológica detallada y la describen como un conjunto de seis conos volcánicos cuaternarios nombrados Yuhualixqui, Xaltepec, Tocón, Mazatepec, Tecuatzi, Guadalupe y La Caldera, tienen una orientación de NE-SW con una extensión de 12 km de longitud y menos de 20,000 años. A pocos kilómetros hacia el poniente se encuentra otra estructura monogenética, el Cerro de la Estrella, un volcán escudo, una estructura independiente a la sierra, aunque se encuentran relativamente

cercanos, ya que presenta características morfológicas diferentes (Lugo-Hubp *et al.*, 1994; Arce *et al.*, 2015). Diversas estructuras se distribuyen a lo largo de la cuenca, el Xico, el Peñón del Marquez y el cerro de Chapultepec son otros ejemplos. La Figura 3 se presenta a manera de síntesis la morfología y geología general de la CVM.




Figura 3: Geología y morfología de la CVM. (Santoyo-Villa *et al.*, 2005)

Uno de los primeros estudios sobre la geología y estratigrafía de la CVM fue presentado por Fries (1960), quien realizó descripciones de las rocas más antiguas encontradas y nombró las diferentes formaciones, posteriormente Mooser (1963, 1975) propuso que la configuración del relieve de la cuenca es el resultado de la evolución de siete fases

volcánicas. Por su parte, Marsal y Mazari presentaron una síntesis de trabajos geológicos previos (Marsal y Mazari, 2016).

Después del sismo de 1985 la comunidad civil comprendió la necesidad de conocer la estructura geológica del subsuelo capitalino, por lo que, se comenzaron a realizar más estudios (Cserna *et al.*, 1988; Pérez-Cruz, 1988; Mooser, 1987; Mooser y Montiel-Rosado, 1989), además se perforaron los pozos profundos Mixhuca-1 y Tulyehualco-1 (PEMEX, 1988), que permitieron comprobar y enriquecer la información previa, posteriormente, para llegar a un consenso en los nombres, descripciones y características de los paquetes geológicos se realizaron distintas propuestas de nomenclatura estratigráfica (Vázquez-Sánchez y Jaimes-Palomera, 1989; Enciso-De la Vega, 1992).

A continuación, se describen de manera general las cuatro unidades estratigráficas propuestas por Pérez-Cruz (1988) (Figura 4), agregando las descripciones realizadas por Enciso-De la Vega (1992) y Vázquez-Sánchez y Jaimes-Palomera (1989).

#### **a) Basamento calcáreo Cretácico:**

Fries (1960) describió y nombró las unidades más antiguas encontradas, comenzando con la Formación Xochicalco que aflora en el límite sudoccidental de la cuenca, “una secuencia de calizas principalmente calcilitíticas y calcilimolíticas... que se depositó durante el Aptiano en ambientes marinos de cuenca relativamente profunda”; cubriéndola discordantemente, se encuentra la Formación Morelos, constituida por calizas y dolomías diagenéticas que afloran al sur de la Sierra Chichinautzin, la cual es la unidad más antigua encontrada en la cuenca en los pozos Mixhuca-1 y Tulyehualco-1 (PEMEX, 1988). El paquete de calizas se encuentra compuesto también por la Formación Doctor y la Formación Cuautla, esta última fue encontrada a profundidades de 1575 m y 2 100 m en los pozos Mixhuca-1 y Tulyehualco-1 respectivamente, para finalizar con las rocas del Cretácico la Formación Mexcala.

#### **b) Serie Volcánica Inferior (SVI).**

Cubriendo discordantemente las formaciones geológicas del Cretácico se encuentran los conglomerados calcáreos del Eoceno pertenecientes al grupo Balsas. En el Eoceno temprano comienza un periodo de alta intensidad volcánica, comenzando con la primera de las siete fases de actividad volcánica que rellenaron la cuenca y que fueron descritas por Mooser (1975). Esta primera fase originó rocas volcánicas que no afloran en superficie, sin embargo, la segunda ocurrida en el Oligoceno Medio se presentó con varias coladas de lava de

composición intermedia y ácida. A este conjunto de rocas se les conoce como Rocas Volcánicas del Oligoceno Tardío-Mioceno Temprano, integradas por secuencias de tobas líticas, cristalinas y vítreas, brechas tobáceas y aglomerados. Posteriormente, se depositó el Supergrupo Pachuca, una unidad volcánica que registra la actividad del Oligoceno al Plioceno, que comprende a su vez las formaciones Santiago, Cortés, Pachuca, Real del Monte, Santa Gertrudis, Vizcainza Cerezo y Tezuantla; estas se describen como secuencias de derrames volcánicos de composición andesítica y dacítica, intercalados con brechas y tobas.

Durante el oligoceno superior aparecen estructuras monogenéticas, el Peñón de los Baños, Chapultepec, Tlapacoya y Zacaltépetl caracterizados por rocas de composición ácida y por depósitos de dacitas y riolitas, además de que en este periodo se generan las bases de la Sierra de las Cruces y de la Sierra Nevada. En el Mioceno ocurre la cuarta fase, la Sierra de Guadalupe nace al norte de la cuenca.

### **c) Serie Volcánica Superior (SVS).**

La serie volcánica superior está compuesta por 4 grupos principales, que fueron generados por las últimas fases volcánicas, en orden cronoestratigráfico se conforma por:

Grupo Anáhuac. Está compuesto por la Formación Otomí, vulcanitas del Plioceno Tardío que afloran al noroeste de la Sierra de las Cruces nombrada como Sierra de Monte Alto, formada por depósitos piroclásticos en forma de flujos lobulados. Además de las llamadas Rocas Volcánicas Maficas y la Formación las Cruces, que son rocas de composición basáltica a andesítica del Plioceno Tardío definida como el paquete de rocas volcánicas que forman la Sierra de las Cruces y Monte alto, esta formación es el conjunto de tres volcanes alineados NS, siendo un ejemplo del vulcanismo del Plioceno Tardío.

Grupo Taranguense. El vulcanismo de la sexta fase, ya en el Cuaternario, durante el Pleistoceno, donde los materiales eran de composición andesítico-basáltico principalmente. Las formaciones que componen el grupo son: Llano Grande que aflora en la Sierra Nevada, El Pino cuyas rocas volcánicas formaron el Cerro de la Estrella, el Peñón del Marqués, el Cerro Gordo y los Cerros de Chimalhuacán y Chiconautla y la Formación Tlaloc e Iztaccíhuatl, que afloran en la Sierra Río Frío

y son productos del volcán Iztaccíhuatl. El grupo Taranguense abarca el intervalo entre 2.6 Ma hasta 0.6-0.8 Ma.

Grupo Popocatépetl. Se compone por las rocas volcánicas formadas por el volcán que sobreyace discordantemente a la formación Iztaccíhuatl, se conforma por cuatro secuencias eruptivas, con una edad del Pleistoceno Tardío al Holoceno.

Grupo Chichinautzin. La séptima y última fase de actividad volcánica termina al comienzo del Holoceno con la formación de la Sierra de Chichinautzin, que cerró la cuenca aproximadamente hace 700, 000 años y que aflora al sur.

#### **d) Serie Lacustre.**

En la cima de la columna se encuentran los mayores depósitos de sedimentos lacustres y fluviales. Formados por la erosión de las sierras y por el aporte de diferentes productos transportados por los cuerpos de agua, que se fueron depositando, formando planicies lacustres a lo largo de la CVM. Compuesta por distintos tipos de sedimentos pluviales como limos arcillas y arenas, estas arcillas son altamente compresibles. Los espesores de la serie lacustre son muy variables, mientras que, en las partes centrales de la cuenca alcanzan hasta los 200 m, en las orillas los menores espesores son de 30 m.

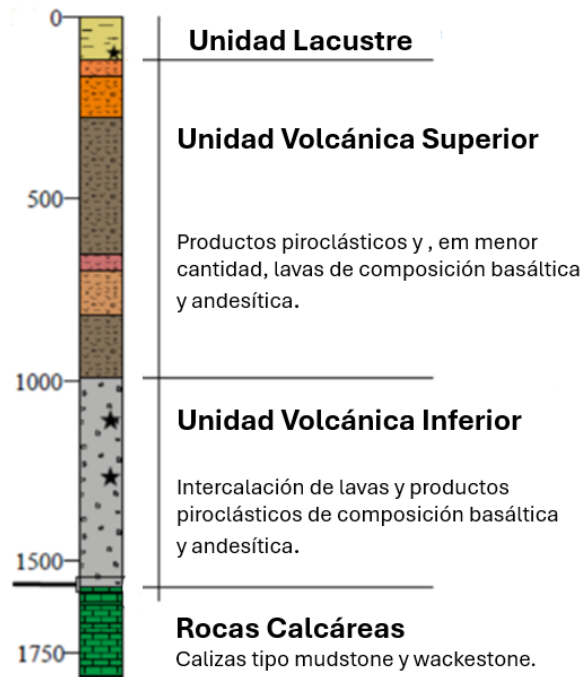


Figura 4: Columna estratigráfica con las 4 unidades propuestas por Pérez- Cruz,1988. (Vásquez-Serrano et al. 2019)

## 2.2 Suelos de la Ciudad de México

Con el cierre de la cuenca debido a la formación de la Sierra del Chichinautzin los procesos de meteorización, erosión, azolvamiento y acarreo fluviales se intensificaron, la cuenca se fue cubriendo con los sedimentos generados por estos mecanismos. Los productos piroclásticos, especialmente la ceniza formó un suelo arcilloso muy compresible; además, posteriores eventos volcánicos, alteraciones climáticas, sequías e inundaciones formaron una serie lacustre conformada por capas de arcilla blanda con intercalaciones de lentes duros de limos, arcillas arenosas y costras secas, además de arenas basálticas causadas por el vulcanismo ocasional (Santoyo-Villa *et al.*, 2005).

Santoyo-Villa *et al.* (2005) realizaron una recopilación de investigaciones, estudios geológicos, geofísicos y geotécnicos de distintos autores sobre la estratigrafía de la cuenca, con lo que describen a detalle la estratigrafía de las zonas de lago, de transición y de loma. A continuación, se presenta una síntesis sobre lo mencionado por dicho documento.

La estratigrafía de la zona de lago se puede clasificar en:

**a) Costra superficial.**

Estrato de materiales naturales ocultos por diferentes tipos de rellenos, subdividido en tres subestratos, el más superficial consiste en rellenos artificiales de cascajo y otro tipo de desechos, su espesor varía desde los 15 metros en la zona más densa y de 1 a 7 metros en distintas zonas de la ciudad, hasta prácticamente desaparecer a las orillas de la CVM. Subyaciendo un estrato aluvial de suelos blandos que es el fondo del último lago existente, finalmente el subestrato más profundo es una costra altamente consolidada formada por sedimento lacustre expuesto a la luz solar.

**b) Formación arcillosa superior.**

Compone la mayor parte de la serie lacustre superior, es una capa de arcillas blandas, muy uniforme, presente en gran parte de la cuenca con espesores de entre 25 y 50 metros, a su vez se divide en 4 subestratos que varían principalmente por el efecto que han provocado las cargas superficiales y la extracción de agua.

La capa más somera llamada arcilla preconsolidada superficial ha sido consolidada por secado solar, ascenso capilar del agua, las raíces de los árboles que absorben humedad y por el peso de los rellenos artificiales. Subyaciendo se encuentra la arcilla consolidada profunda cuya intensa consolidación se debe al bombeo profundo. También se encuentran por toda la formación secuencias de lentes duros, costras de arena basáltica y vidrio pómez de espesores que van desde pocos centímetros hasta los 2 metros.

**c) Capa Dura.**

Intercalado dentro de la arcilla, dividiendo la Serie Lacustre Superior y la Serie Lacustre Inferior se encuentra una capa de suma importancia geotécnica, ya que es utilizada para cimentaciones profundas y sirve como apoyo para distintos tipos de pilotes. La capa dura es un depósito de ceniza volcánica densa y cementada, se encuentra a una profundidad promedio de entre 30 y 50 metros, tiene una cementación y un espesor irregulares que se encuentran a lo largo de la cuenca.

**d) Formación arcillosa inferior.**

Serie de arcillas que contiene intercalaciones de lentes duros, con un espesor de 15 metros en el centro y cuya presencia en las orillas del lago es casi inexistente.

**e) Depósitos Profundos.**

La parte más profunda de la secuencia lacustre está constituida principalmente por una serie de arenas y gravas aluviales limosas, cementadas con arcillas duras y carbonatos de calcio.

La estratigrafía de la zona de transición (Figura 5) se caracteriza divide en:

**a) Transición interestratificada.**

El transporte fluvial produjo la acumulación de sedimentos que descendieron de las lomas a la planicie, predominantemente presente alrededor de la CVM a las faldas de las grandes sierras. Formada por intercalaciones de arcillas lacustres con arenas y gravas de río.

**b) Transición abrupta.**

Característica del límite entre la planicie lacustre y las estructuras monogenéticas presentes en la cuenca, ubicada en los alrededores el Peñón del Marqués, el cerro de la Estrella y el Peñón de los Baños. Cuya estratigrafía está compuesta por la serie arcillosa lacustre interrumpida por lentes duros.

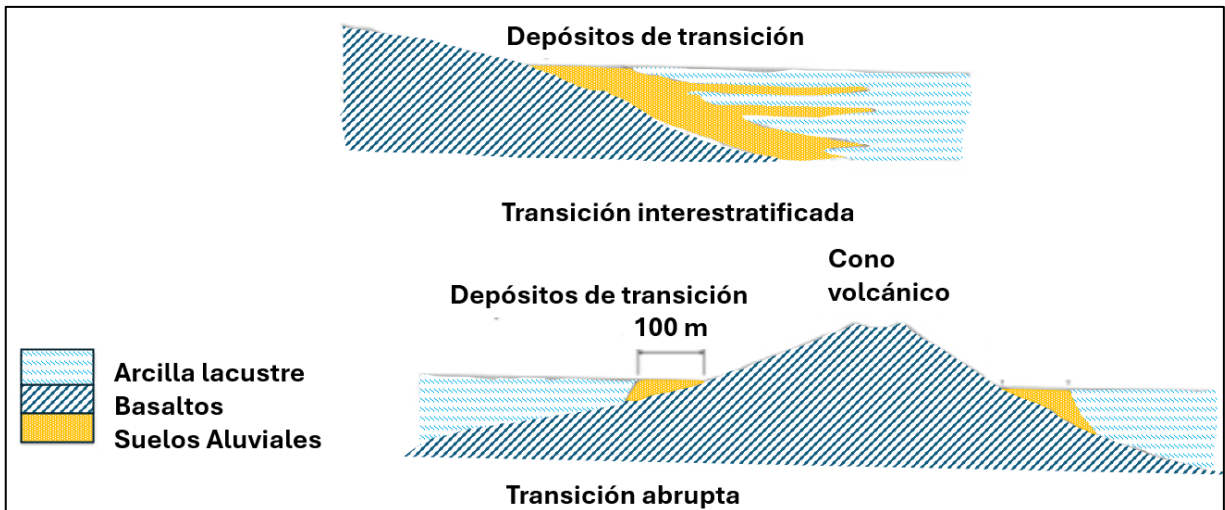


Figura 5: Tipos de depósitos de transición (Santoyo-Villa et al., 2005).

La estratigrafía de la zona de lomas.

a) Se describe de manera breve como aquella presente al norte en la Sierra de Guadalupe, al poniente de la ciudad, al sur cerca de las faldas de la Sierra Chichinautzin, y en la Sierra de Santa Catarina. En la zona de lomas también están presentes barrancas, galerías de minas, túneles, además de rellenos artificiales. Donde se ha descrito en mayor medida la litología es al poniente donde se presentan elementos generados por la erupción de los diversos volcanes. Una gran parte está compuesta por los derrames basálticos generados por el Xitle.

### **Zonificación geotécnica.**

Marsal y Mazari (2016) elaboraron un mapa de zonificación geotécnica para la zona metropolitana del Valle de México, el cual fue posteriormente incorporado en las Normas Técnicas Complementarias para el Diseño y Construcción de Cimentaciones. Con base en más de 10,000 sondeos geotécnicos, y considerando propiedades mecánicas, origen y espesor, la Ciudad de México se dividió en tres zonas principales: Zona I (Lomas), Zona II (Transición) y Zona III (Lago) (Figura 6).

**a) Zona I, Lomas.** Se compone por rocas y suelos firmes, que no fueron depositados en el ambiente lacustre característico de la cuenca, además de la presencia de estratos y limo arenosos blandos. Se encuentra en las zonas altas de la CVM, tanto en las sierras mayores como en el Cerro de la Estrella o la Sierra de Santa Catarina, también se encuentra presente al sur de la capital debido a los derrames basálticos del Xitle.

**b) Zona II, Transición.** La frontera entre la transición y la zona lacustre fue marcada por la desaparición de la serie arcillosa inferior. Se componen de estratos de arcilla lacustre cuyo espesor varía entre menos de 2.5 metros en la zona alta, en el límite con la zona de Lomas y desde los 2.5 a los 20 metros en el límite con la zona de Lago.

**c) Zona III, Lago o Lacustre.** Donde se encuentran los mayores espesores de arcillas, intercaladas con capas de limo y arenas. Se caracteriza por su alta compresibilidad y de tener espesores de hasta 50 metros.



## 3. Sismicidad en el Valle de México

### 3.1. Zonas sismogénicas y grandes sismos

La población de la Ciudad de México ha sido históricamente afectada por sismos de gran magnitud. Estos eventos han provocado una gran destrucción, incluyendo la pérdida de miles de vidas humanas. Por ello, el conocimiento sobre el origen de los sismos resulta fundamental para la protección de sus habitantes. Debido a las condiciones geológicas particulares sobre las que se asienta la ciudad, los sismos representan una amenaza constante, y en ese contexto, la mitigación del riesgo se convierte en la estrategia más eficaz para enfrentar sus impactos.

Durante décadas se consideró que la zona de subducción, donde la Placa de Cocos subduce bajo la Placa de Norteamérica, representaba el principal riesgo sísmico, debido a la gran cantidad de sismos ocurridos en la zona, pero mayormente por el devastador sismo del 19 de septiembre de 1985, que ocasionó la muerte de miles de personas y el colapso de más de 300 edificios en la ciudad. Sin embargo, 32 años después, un sismo ocurrido el 19 de septiembre de 2017, esta vez con epicentro en el estado de Puebla, evidenció que otras regiones también pueden generar eventos sísmicos catastróficos, al causar daños estructurales y pérdidas humanas similares a las de 1985.

Rosenblueth *et al.* (1987) realizaron una descripción de las zonas sismogénicas a las que está expuesta la Ciudad de México, a continuación, se describen brevemente (Figura 7).

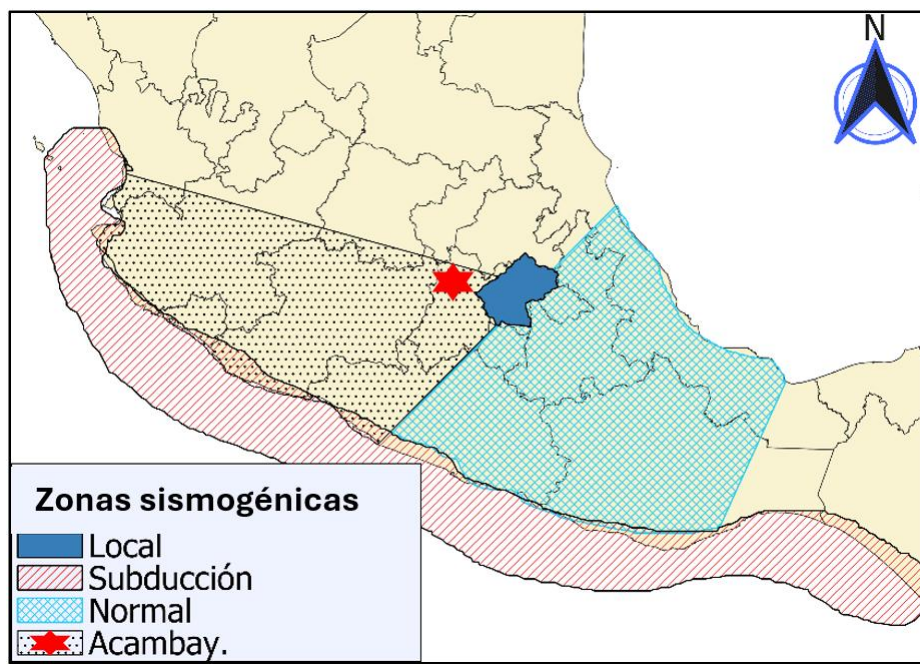
**a) Zona de subducción de la Placa de Cocos bajo la Placa Norteamericana.**

En esta es en donde se genera la mayor tasa de sismicidad del país y también en donde se han registrado dos de los sismos de mayor magnitud, el temblor de Jalisco de 1982 (M8.2) y Michoacán de 1985 (M8.0). Su correspondiente trinchera Mesoamericana se extiende desde el estado de Jalisco hasta el de Chiapas en una longitud aproximada de 1,500 km.

**b) Zona de Acambay.** Nombrada así por el sismo de magnitud M=7.0 ocurrido en 1912 en la localidad del mismo nombre, al norte de la Ciudad de México. El evento fue provocado por la liberación de energía producida por los esfuerzos acumulados en el graben de Acambay.

**c) Zona Normal.** Se refiere a los sismos producidos al interior de la Placa de Cocos, los cuales se caracterizan por tener un mecanismo de falla normal y profundidades intermedias de 50 a 100 [km] y cuyas magnitudes aumentan hacia la zona de trinchera.

**d) Zona Local.** Son sismos que se generan debajo de la CVM y alrededores, aunque son de magnitudes relativamente pequeñas, las intensidades que han producido han causado alarma en la ciudadanía, en la siguiente sección se describe con mayor detalle.



*Figura 7: Las zonas sísmicas que afectan la CVM (Reynoso, 2007).*

### 3.2. Características de la sismicidad en la Cuenca del Valle de México

Aunque los sismos son una preocupación constante para los habitantes de la Ciudad de México, en años recientes ha surgido una nueva fuente de alarma, los llamados microsismos, es decir, eventos con magnitudes menores a Mw 4.

El 16 de julio de 2019 en la alcaldía Miguel Hidalgo un evento de Mw 3.2 causó pánico en la población de las cercanías al epicentro, el movimiento tan intenso generó las aceleraciones más grandes jamás registradas en la Ciudad de México. El evento produjo aceleraciones de hasta  $314 \text{ cm/s}^2$ , lo anterior fue inesperado ya que fue una intensidad mayor a las producidas por los sismos de septiembre de 1985 y 2017 (Singh *et al.*, 2020).

Figuroa (1971) describió la sismicidad del VM como “Estos movimientos se caracterizan por un periodo corto, que por lo general no excede de 0.5 seg ... son también de corta duración”, con información obtenida de la estación Tacubaya. Según sus reportes, colectados entre 1909 y 1968, se producían, en promedio, 1900 microsismos al año en la ciudad. También documentó la ocurrencia de enjambres sísmicos durante varios días consecutivos y presentó un mapa con la localización aproximada de los epicentros, donde se nota una mayor presencia al poniente. Finalmente, el autor señala la insuficiencia de estaciones de monitoreo y espacios de registro, y recomienda ampliar la red de instrumentación sísmica y realizar más estudios específicos en la zona.

Un enjambre sísmico ocurrido entre el 4 y 15 de febrero de 1981 al poniente de la capital en la zona de Mixcoac, fue estudiado por Havskov, 1982. Se analizaron los 5 eventos mayores, cuyas magnitudes estuvieron entre 2.7 y 3.2 a una profundidad promedio de 1.2 [km]. El enjambre generó un gran interés porque, hasta aquel momento, fue el mejor registrado. Con la ayuda de un evento ocurrido en la misma zona, un año antes, se obtuvo un plano de falla con rumbo SE y echado subvertical de mecanismo normal. Havskov consideró que la causa de los sismos es el régimen tensional cercano, sin embargo, agregó que el hundimiento de la ciudad puede causar más tensión lo que a su vez funciona como disparador de sismos.

Rodríguez *et al.* (1984) realizaron un estudio del microsismo más fuerte ocurrido, hasta esos años, en la Sierra del Chichinautzin cerca del poblado Juchitepec. El evento tuvo una magnitud de 3.7 a 17 km de profundidad, y generó una intensidad de grado VI en el poblado de Juchitepec. La instalación de una red cerca del epicentro permitió el registro de 39 réplicas.

Manzanilla (1986) realizó un catálogo de los sismos que se han sentido dentro de la CVM desde mitad del siglo XV hasta 1985, donde describe la fecha en que ocurrieron, las características del movimiento y los daños provocados.

Alberro y Hernández (1991) propusieron la hipótesis de que los microsismos ocurren debido a tres factores: la elevación del nivel freático en la Sierra de las Cruces debido a las lluvias, la filtración de agua que recarga el acuífero del valle de México, así como el

incremento de esfuerzos cortantes por efecto de las fuerzas de filtración; además, indican una relación positiva entre las precipitaciones y el número de temblores.

El 21 de enero de 1995 se registró un evento sísmico de magnitud 3.9, el más alto registrado ocurrido dentro de la ciudad (UNAM *and* CENAPRED *Seismology Group*, 1995). En la localidad de Milpa Alta a 12 km de profundidad, se describe como un sismo de fallamiento normal, donde resaltan que el incremento en el número de estaciones sísmicas en el Valle de México fue fundamental para poder detectar y analizar el evento.

Singh *et al.* (1998) realizaron un análisis estadístico con los sismos registrados en la Ciudad de México desde 1920 hasta 1995, en el que se concluyó que los sismos ocurridos en la zona de subducción mexicana de  $M_w > 7$  provocan un aumento significativo en la sismicidad local en la CVM.

Chavacán (2007) con la información de distintos autores elaboró un catálogo de 218 sismos ocurridos en la cuenca, con magnitudes entre 0.8 y 4.4. Finalmente realizó un mapa donde se muestran las zonas sismogénicas en la cuenca (Figura 8).

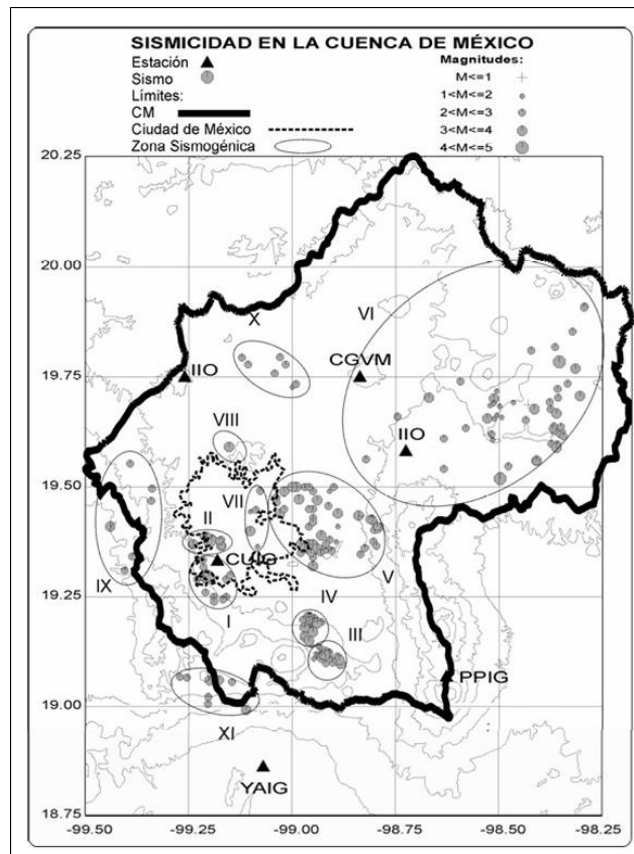


Figura 8: Distribución espacial de la sismicidad en la CMV (Chavacán, 2007)

Lermo *et al.* (2016) realizaron un análisis de 14 microsismos ocurridos en la zona de lomas, enfocado en el cálculo de parámetros de atenuación espectral de ondas sísmicas. Obtuvieron un valor del parámetro  $\kappa \approx 0,0457$ , un factor de calidad  $Q(f) = 72f^{0,83}$  y una liberación de tensión promedio de 5 MPa. Los altos valores de atenuación espectral explican las bajas aceleraciones registradas en esta zona por sismos locales en la cuenca.

Posteriormente Jaimes *et al.* (2016) utilizaron estos parámetros para formular un modelo de predicción de movimiento sísmico. En junio de 2019 se registraron una serie de sismos al poniente de la Ciudad de México. El evento de mayor magnitud alcanzó una  $M_w$  3.2 y generó una fuerte reacción social. En las zonas cercanas al epicentro, fue percibido como un movimiento muy intenso. Aunque no causó daños estructurales, la estación sísmica más cercana (TACY) registró aceleraciones máximas de 101, 314 y 305  $\text{cm/s}^2$ , las más altas jamás detectadas en la ciudad (Singh *et al.*, 2020).

El Código de Construcción de la Ciudad de México considera que el evento sísmico máximo esperable en la región es de magnitud  $M_w$  4.7 (Rosenblueth *et al.*, 1987). Sin

embargo, Singh *et al.* (2020), mediante simulaciones con la Función Empírica de Green, estima que un sismo de hasta Mw 5.0 es perfectamente posible, y que podría generar intensidades sísmicas importantes en la zona de lago, además el autor resalta la necesidad de reevaluar el peligro sísmico que estos microsismos pueden ocasionar en la ciudad.

En 2021 el gobierno de la Ciudad de México lanzó una iniciativa que integró las 5 redes sismológicas operativas en la capital, creando así la Red Sísmica de la Ciudad de México, que busca monitorear completamente la actividad sísmica de la ciudad, además de la recolección de información beneficiosa para todos. La red consta de 169 estaciones de registro, 81 acelerógrafos de la Red Acelerométrica de la Ciudad de México, 28 sismómetros ultrasensibles y 12 acelerómetros de la Red Sismológica del Valle de México, el Red Acelerográfica del Instituto de Ingeniería aporta 24 acelerómetros, 11 de la Red de Observación Sísmica, y finalmente la Universidad Autónoma Metropolitana aporta 5 instrumentos (Grupo de Trabajo de la Red Sísmica de la Ciudad de México, 2021).

Quintanar *et al.* (2024) estudiaron otro microsismo que reportó una sacudida notoria para los habitantes de Mixcoac, San Ángel y Coyoacán, con una magnitud de 3.2. El evento cobró gran relevancia debido a que, a altas frecuencias, sobrepasó los espectros de diseño de construcciones de la Ciudad de México (Figura 9). La estación ubicada dentro de las instalaciones de la Escuela Nacional Preparatoria 8 de la UNAM, registró aceleraciones de (152, 139 y 178  $cm/s^2$ ) y aunque el evento generó pánico cerca del epicentro, ninguna estructura sufrió daños visibles.




Figura 9: Comparación de la aceleración espectral entre los sismos Mw 3.2 de 2019 (Azul) y 2023 (Rojo) con respecto al espectro de diseño para la Ciudad de México (Quintanar et al. 2024).

Aguilar-Velázquez *et al.* (2025) mediante técnicas con *InSAR* estudio el mismo enjambre detectado en 2023, las imágenes satelitales detectaron deformaciones en dos zonas epicentrales. Una región estable cuyo movimiento, es en su mayoría asísmico debido a que las fallas se encuentran enterradas, y una parte inestable que genera los sismos, disparados por el movimiento de la parte estable, así como grandes sismos producidos en la zona de subducción mexicana.

### 3.3. Tectónica y sistema de fallas en la Cuenca del Valle de México

Al encontrarse dentro del FVTM, la CVM está sometida a un estado de esfuerzos extensionales, por lo que, la mayoría de las principales fallas que la atraviesan son de mecanismo normal (Figura 10).

Al sur de la cuenca sobre la Sierra del Chichinautzin con orientación este-oeste se encuentra una parte del sistema de fallas Aztlán (Campos-Enríquez *et al.*, 2015). Un sistema activo con al menos 100 [km] de longitud del Oligoceno-Mioceno, que comienza desde la cuenca de Toluca y se extiende por debajo de la Sierra Chichinautzin. Del sistema forman parte: al sur de la sierra la falla La Pera (PE) (Delgado-Granados *et al.*, 1995; García-Palomo *et al.*, 2008; Cserna *et al.*, 1988), la falla Azteca (AZ) en la parte

central de la sierra y las fallas mapeadas por García-Palomo *et al.* (2008), las fallas Xochimilco (XO) y Xicomulco (XI) al norte de la sierra, todas tienen un fallamiento normal.

Dentro de la cuenca se encuentran los otros dos sistemas de fallas, al oriente el sistema de fallas Chalco (CH) que presentan buzamiento al norte y al sur formando un pequeño *graben*, la fosa de Santa Catarina formada por dos fallas paralelas en dirección noreste sureste (Arce *et al.*, 2015), siendo limitada al oeste por la Falla Mixhuca que presenta un fallamiento normal y un buzamiento al suroeste (Pérez-Cruz, 1988).

Al oeste de la cuenca se encuentran los sistemas Contreras (CO) y el sistema Ixtlahuaca y Otomí (IX) los dos presentan un fallamiento normal. Al noreste de la cuenca las fallas Tizayuca y Texcoco, además al costado de la Sierra Nevada la Falla Apan-Tlaloc.

Distintos autores han descrito que es posible que el sistema de fallas en la cuenca explique la sismicidad de esta. De acuerdo con la distribución espacial de los sismos, los mecanismos focales calculados e hipocentros coinciden con la orientación de las fallas, especialmente el sistema activo Aztlán cuya actividad sísmica es constante (Campos-Enríquez *et al.*, 2015; Havskov, 1982).

Se han propuesto y discutido diversas causas para explicar la sismicidad en la cuenca; las más aceptadas en la literatura son las siguientes:

- a) La presencia de los varios sistemas de fallas dentro del régimen extensivo del centro de la FVTM. De acuerdo con Suter *et al.* (2001) la parte central de la FVTM se está colapsando debido a una compensación isostática dada su gran altura, ya que el punto más alto se encuentra en el Ajusco a  $\approx 3900$  msnm y los más bajos a  $\approx 2200$  msnm.
- b) El hundimiento de la Ciudad de México.
- c) La reactivación de antiguas fallas locales.
- d) Los grandes sismos que sirven como detonadores.




Figura 10: Mapa de la Cuenca del Valle de México que muestra los sistemas de fallas. Las fallas principales son: Texcoco (TE), Tizayuca (TI), Apan-Tláloc (AP), Ixtlahuaca y Otomí (XI), Contreras (CO), Mixhuca (MI), Chalco (CH), Xicomulco (XI), Xochimilco (XO), Azteca (Az).

## 4. Redes Neuronales Artificiales

### 4.1. Inteligencia artificial

La Inteligencia Artificial (IA) es una herramienta, que se concibió desde el inicio de la computación, y aunque en un principio era un área no muy utilizada, recientemente ha experimentado un crecimiento enorme, potenciado principalmente por dos factores, primero la mejora significativa de la capacidad computacional, tanto a nivel de *software* como de *hardware*, y en segundo lugar, el hecho de que se vive la era de la información, donde los aspectos sociales, económicos y culturales se cimentan en el manejo de información a través del *Internet* como estructura clave.

Estos dos elementos han beneficiado el desarrollo de la Inteligencia Artificial, ya que la confiabilidad de distintas áreas de la IA se basa en la cantidad de información disponible. Si bien el uso de la IA recientemente ha pasado de ser una herramienta computacional reservada únicamente para los especialistas, a estar al alcance de prácticamente cualquier persona con acceso a *Internet*, existen múltiples ejemplos, el popular *ChatGPT*, un modelo de inteligencia artificial conversacional capaz de generar textos de forma coherente y contextual sobre prácticamente cualquier tema, otros ejemplos son aquellos programas de imitación de voz y generadores de imágenes.

#### **Historia de la Inteligencia Artificial.**

En 1936 con la publicación del artículo *On Computable Numbers, with Application to the Entscheidungs problem* (Turing, 1937), donde el matemático inglés *Alan Turing* presentó el concepto teórico sobre el cual se construyó la computación moderna, la idea de una computadora universal que, con el suficiente tiempo y recursos, puede realizar cualquier tarea computable. Lo anterior, sentó las bases para entender los principios fundamentales de los algoritmos, así como los límites y capacidades de la computación y que, posteriormente, fue materializada en una de las primeras computadoras electrónicas.

Fue el mismo Turing (1950) quien se planteó la pregunta: ¿Pueden las máquinas pensar? Para responder, propuso lo que más tarde se conocería como la Prueba de

Turing, la cual consiste en, si un humano mantiene una conversación escrita con una máquina sin ser capaz de poder distinguir si interactúa con otro humano o con una máquina, entonces esta se considera inteligente.

Por otro lado, el término inteligencia artificial fue propuesto como disciplina durante la Guerra Fría, en la conferencia de Dartmouth, donde se definió como “la ciencia e ingeniería de hacer máquinas inteligentes” (McCarthy, 2006).

La motivación principal para la creación de las primeras computadoras fue la necesidad de resolver cálculos de forma rápida y precisa. Resolver un solo problema matemático mediante métodos manuales requería una gran cantidad de personas, así como semanas o incluso meses de trabajo, además de estar expuesto a errores humanos. En contraste, una computadora electrónica como la *ENIAC (Electronic Numerical Integrator and Computer)* era capaz de calcular trayectorias balísticas en cuestión de segundos, lo que representaba un avance significativo en términos de eficiencia y confiabilidad.

Sin embargo, aunque estas máquinas tienen una capacidad extraordinaria para resolver problemas matemáticos que resultan difíciles para los humanos, presentan grandes desafíos al enfrentarse a tareas que, para nosotros, resultan simples, como el distinguir objetos cotidianos como rostros, animales o la voz de una persona.

Esto ha requerido el desarrollo de técnicas específicas para que la inteligencia artificial pueda abordar problemas difíciles de describir matemáticamente. En estos casos, el enfoque consiste en lograr que las computadoras aprendan, identifiquen y desarrollen por sí mismas los métodos o patrones necesarios para resolver el problema. A este proceso se le denomina aprendizaje automático, o ML por sus siglas en inglés (*Machine Learning*).

El ML se puede dividir en diferentes tipos:

#### **a) Aprendizaje supervisado.**

Este tipo de aprendizaje se basa en conjuntos de datos etiquetados, donde tanto las entradas como las salidas esperadas están claramente definidas. El modelo aprende a generalizar una función que relacione ambas. Entre los algoritmos más comunes se encuentran la regresión lineal, los árboles de decisión y el algoritmo de los K vecinos más cercanos (*K-Nearest Neighbors*).

#### **b) Aprendizaje no supervisado.**

En este caso, los datos no tienen etiquetas, por lo que el algoritmo debe explorar la estructura subyacente por sí mismo. El objetivo principal es descubrir patrones ocultos o agrupaciones naturales dentro de los datos. Una técnica representativa es el análisis

de clústeres, que agrupa los elementos según su similitud. La agrupación probabilística es una técnica que resuelve problemas de estimación de densidad, donde los valores se agrupan de acuerdo con la probabilidad de que pertenezcan a una distribución.

### **c) Aprendizaje por refuerzo.**

Aquí, un agente interactúa con un entorno mediante acciones, y aprende a tomar decisiones óptimas a través de un sistema de recompensas y penalizaciones.

El Aprendizaje Profundo (*Deep Learning*) es un subconjunto del aprendizaje automático (*Machine Learning*) que utiliza principalmente redes neuronales artificiales para aprender a partir de grandes volúmenes de datos. Su principal característica es que puede mejorar su desempeño sin intervención humana directa, ajustando automáticamente sus parámetros internos a medida que procesa la información.

Las Redes Neuronales Artificiales (RNA) son una herramienta inspirada en el funcionamiento del cerebro humano. Está compuesta por múltiples capas de nodos conectados entre sí, que permiten detectar patrones complejos en los datos y estimar una salida deseada a partir de una entrada dada, resaltando su gran capacidad para resolver, principalmente, problemas no lineales. La Figura 11 muestra la representación de las capas de IA.

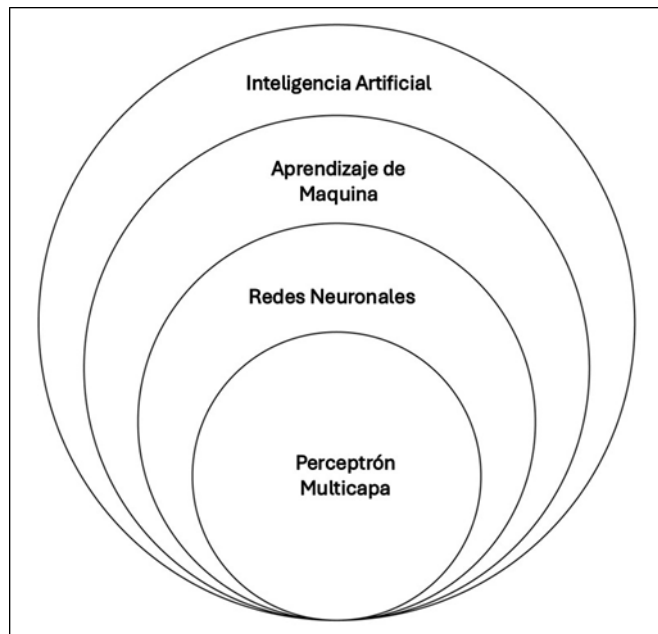


Figura 11: Diagrama de Venn que representa el subconjunto de la IA donde se encuentran las RNA.

### 3.2. Redes Neuronales Artificiales.

#### La neurona biológica.

Si bien se tiene la creencia popular que *Deep Learning*, y en especial las RNA, emulan el funcionamiento del cerebro humano, se resaltan sus similitudes, y diferentes autores citan a la neurociencia como fuente de inspiración, el DL reúne elementos de distintas disciplinas, incluyendo álgebra lineal, métodos numéricos, probabilidad, optimización numérica, y toma la idea más simple del funcionamiento del cerebro como elemento base.

El cerebro humano está compuesto por millones de células especializadas, las neuronas, células cuya característica principal radica en su capacidad de, a través de la propagación de señales eléctricas y químicas, comunicarse unas con otras (sinapsis), creando una compleja red de neuronas, debido a que una neurona puede conectarse con hasta 10,000 neuronas vecinas (Carter y Frith, 2002).

Una neurona se compone por un cuerpo celular o soma que funciona como procesador de información y del cual surgen las ramas que las conectan entre sí, las dendritas, son

una arborización compleja que se encargan de recibir la información proveniente de otras neuronas. Finalmente, la última parte es el axón, una fibra larga que al final se ramifica para transmitir la información a las siguientes neuronas (Figura 12). La sinapsis es un proceso por el cual una neurona se conecta con otra, este contacto no es físico, existe un pequeño espacio por el cual un agente químico llamado neurotransmisor activa la célula, formando conexiones (Martín-del-Brío y Sanz, 2006).




Figura 12: Estructura general de una neurona. (Martín-del-Brío y Sanz, 2006)

### **Aprendizaje.**

El proceso de aprendizaje en el ser humano es extremadamente complejo y, aún en la actualidad, no se ha comprendido del todo. Por ello, describirlo a profundidad se aleja de los propósitos del presente trabajo. A continuación, se presenta de manera general cómo ocurre este proceso.

De acuerdo con la función que desempeñan, el sistema nervioso cuenta con neuronas sensitivas, interneuronas y neuronas motoras. Las neuronas sensitivas se encargan de recibir información del exterior y transmitirla al sistema nervioso. Las interneuronas conectan las neuronas dentro del sistema nervioso, permitiendo la comunicación interna. Finalmente, las neuronas motoras sirven como puente entre el sistema nervioso y distintos músculos o glándulas (Purves *et al.*, 2018). Es así como, el golpe de un martillo en la rodilla (estímulo externo) se transforma en una serie de impulsos eléctricos que activan (o no) determinadas neuronas, lo que genera como respuesta una extensión de la pierna (respuesta motora).

Establecido lo anterior, se puede introducir el proceso mediante el cual el cerebro humano aprende. La plasticidad neuronal es la capacidad del cerebro para modificar su

estructura y funcionamiento en respuesta a estímulos externos y condiciones del entorno. Este proceso puede afectar el número de neuronas, la cantidad de conexiones entre ellas, el tamaño y la fuerza de la sinapsis, e incluso provocar la creación o muerte de neuronas (Rosenzweig *et al.*, 2001).

Así es como un ser vivo, a partir de la adquisición de experiencia, moldea su cerebro y al enfrentarse a nuevas situaciones reacciona de cierta manera, según una serie de parámetros influenciados por el entorno y sus experiencias previas.

### Modelo artificial.

Después de lo descrito, se observa porque el cerebro ha sido utilizado como fuente de inspiración para el aprendizaje profundo. Desde un punto de vista puramente funcional, las neuronas son procesadoras de información, reciben una o varias variables de entrada (estímulos) del exterior o de otra neurona, después esta información es procesada, y finalmente una respuesta es emitida. Si se toman estas neuronas como unidad fundamental, es posible crear un arreglo de neuronas que forman una capa, varias capas componen una red neuronal (Figura 13).




Figura 13: Neurona artificial estándar. (Martín-del-Brío y Sanz, 2006)

McCulloch y Pitts (1943) se consideran los precursores de lo que hoy se conoce como RNA, crearon el modelo matemático de una neurona, este era capaz de separar datos de entrada dependiendo de si una función  $f(x,w)$  es positiva o negativa. Años después, apareció el Perceptrón (Rosenblatt, 1958) el primer modelo capaz de, sin intervención

humana, reconocer patrones simples y aprender de las muestras proporcionadas de diferentes categorías.

El siguiente modelo en presentarse fue *ADALINE* (*adaptive linear element*) que, a través de una función lineal, ajustando los pesos para minimizar el error, realizar una estimación bastante cercana de un parámetro (Widrow y Hoff, 1960). *ADALINE* es un modelo lineal que sigue siendo uno de los más utilizados, además de introducir el algoritmo de optimización descenso del gradiente para adaptar los pesos sinápticos.

Los elementos que integran una neurona artificial se describen brevemente (Martín-del-Brío y Sanz, 2006):

- a) **Entradas.** Son los parámetros con los que la red es alimentada  $\mathbf{x}_j(t)$ .
- b) **Pesos sinápticos.** De la neurona  $i$  y se representa como  $w_{ij}$ , indican la fuerza de la conexión entre la neurona presináptica (neurona emisora)  $j$  y la neurona postsináptica (neurona receptora)  $i$ , además también se introduce el concepto de **umbral**  $\theta$ , definido como el nivel mínimo necesario para que se active una neurona (umbral de disparo).
- c) **Regla de propagación.**  $\sigma(w_{ij}, x_j(t))$  proporciona el valor del potencial postsináptico de la neurona  $i$  en función de sus pesos y entradas  $h_i(t) = \sigma(w_{ij}, x_j(t))$ .
- d) **Función de activación o transferencia.** Según el potencial sináptico, los pesos sinápticos y el estado inicial de la neurona  $a_i(t - 1)$ , determina su nuevo estado  $a_i(t) = f_i(a_i(t - 1), h_i(t))$ .
- e) **Función de salida.** Proporciona el resultado, una función de salida de la neurona  $y_i(t) = F_i(a_i(t))$  que depende de su estado de activación.

Finalmente se puede describir una neurona artificial con el siguiente modelo matemático.

$$y_i(t) = F_i \left( f_i \left[ a_i(t - 1), \sigma_i \left( w_{ij}, x_j(t) \right) \right] \right) \quad (3.1)$$

A continuación, se describen los conceptos antes mencionados a mayor profundidad.

**a) Entradas y salidas.**

Estas pueden ser de tipo binarias o digitales o bien continuas o analógicas, para problemas de clasificación, por ejemplo, se obtendrían salidas digitales 0,1, mientras que, para problemas de tipo analógicos, las salidas pueden encontrarse entre un rango de valores.

**b) Regla de Propagación.**

Permite obtener el valor del potencial postsináptico  $h_i$  de la neurona (Ecuación 3.2), teniendo como factores a considerar las entradas y los pesos sinápticos.

$$h_i(t) = \sigma_i(\omega_{ij}, \lambda_i) \quad (3.2)$$

Existen diferentes funciones, tanto lineales como no lineales, la más utilizada es la suma ponderada, formalmente es el producto escalar entre los vectores de entrada y los pesos sinápticos (Ecuación 3.3).

$$h_i(t) = \sum_j \omega_j x_j = w_j^T \cdot x \quad (3.3)$$

Con  $W_j^T$  como el vector transpuesto de los N pesos que llegan a la j neurona, y siendo  $x$  la i entrada de la j neurona. Los pesos sinápticos indican la intensidad de la conexión sináptica entre las neuronas emisora y receptora; cuando se recibe una entrada, si el peso es positivo, la neurona receptora tenderá a ser excitada, por el contrario, un peso negativo, actúa como inhibidor en la neurona postsináptica.

Si se requieren reglas de propagación no lineal, estas son especialmente utilizadas por neuronas de orden superior o neurona *sigma-pi* (Rumelhart, 1986) (ec 3.4) que implica la multiplicación de las entradas y los pesos, lo que conlleva una mayor complejidad.

$$h_i(t) = \sum_{j_1 j_2 \dots j_p} \omega w_{i j_1 j_2 \dots j_p} \cdot x_{j_1 j_2 \dots j_p} \quad (3.4)$$

Para redes con funciones de base Radial (RBF), mapas de Kohonen o cualquier otro tipo de red basado en distancias vectoriales se utiliza la distancia euclidiana:

$$h_i(t) = \sqrt{\sum_j (x_j - w_{ij})^2} \quad (3.5)$$

La entrada neta o potencial postsináptico que recibe una neurona se encuentra formado por el efecto acumulado de las neuronas presinápticas, se realiza una suma ponderada de las entradas, agregando además un umbral  $\theta_j$ . Este parámetro puede o no ser utilizado por las neuronas, se debe restar al potencial postsináptico, y se puede interpretar como el nivel mínimo que debe superar  $h_i$  para que una neurona se active, de tal forma que el argumento de la función correspondiente queda definido como:

$$h_i(t) = \sum_j \omega_{ij} x_j - \theta_i \quad (3.6)$$

### c) Función de Activación o de transferencia.

Proporciona el estado de activación actual  $a_i(t)$  a partir del potencial postsináptico  $h_i(t)$ , y del estado anterior, es decir,  $a_i(t - 1)$ , matemáticamente se describe como:

$$a_i(t) = f_i(a(t-1), h_i(t)) \quad (3.7)$$

Distintos modelos neuronales no consideran el estado previo, solamente el estado actual por lo que se reduce a:

$$a_i(t) = f_i \left[ \sum_{i=0}^N \omega_i(t) \cdot X_i(-L) \right] \quad (3.8)$$

Si bien existen varias funciones de transferencia, a continuación, se describen brevemente las consideradas clásicas según Martín-del-Brío y Sanz (2006) y Flórez-López y Fernández-Fernández (2008). Además, por practicidad se cambió la nomenclatura, donde  $x = h_i(t)$  es el potencial postsináptico; y  $y = f(x)$  es el estado de activación.

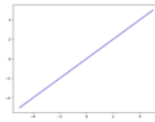
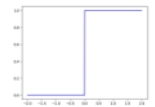


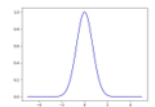
- a) Función lineal. Generalmente es utilizada en redes neuronales básicas, como ADALINE, la activación es proporcionada por el potencial postsináptico  $h_i(t)$ .
- b) Función escalón. Se utiliza en problemas de respuesta binaria, ya que, presenta en determinado momento un cambio abrupto, como un interruptor se enciende en un instante y se queda prendido. Aunque es sencilla de implementar y fue empleada en modelos clásicos como el Perceptrón simple y la neurona de McCulloch-Pitts, presenta una gran limitación ya que únicamente puede resolver problemas de clasificación binaria.
- c) Función mixta o lineal a trozos. Es una función lineal saturada en los extremos, cuya respuesta es más similar al comportamiento biológico, a mayor estímulo, mayor es la activación neuronal. En los extremos, la activación se mantiene constante al superar un valor límite tanto inferior como superior, mientras que, si el estímulo se encuentra entre ambos límites, la activación sigue una relación lineal.
- d) Función sigmoide. Existen modelos neuronales que requieren que la función de activación sea derivable, lo cual puede facilitar el aprendizaje, especialmente con el algoritmo de retropropagación (*Backpropagation*). La función sigmoidea se satura si el argumento es extremo, ya sea positiva o negativamente, lo que la vuelve prácticamente insensible a pequeños cambios en la entrada.
- e) Función Gaussiana. Una función altamente versátil, se utiliza en compañía de reglas de propagación basadas en distancias vectoriales, como la euclidiana,

además de que suelen ser utilizadas en redes profundas con más de 2 capas ocultas.

- f) Función sinusoidal. Para modelos que requieran una periodicidad temporal que genere intervalos entre [-1,1].

En la Tabla 1 se ilustran las funciones de transferencia antes descritas.

Tabla 1. Funciones de activación.

	Función	Rango	Gráfica
Identidad	$y = x$	$[-\infty, \infty]$	
Escalón	$y = \text{signo}(x)$ $y = H(x)$	$[-1,1]$ $[0,1]$	
Mixta	$y = \begin{cases} -1, & \text{si } x < -l \\ x, & \text{si } -l \leq x \leq +l \\ +1, & \text{si } x > +l \end{cases}$	$[-1,1]$	
Sigmoide	$y = \frac{1}{a+e^{-x}}$	$[0,1]$ $[-1,1]$	
Gaussiana	$y = Ad^{-Bx^2}$	$[0,1]$	

**d) Función de Salida.**

Cada neurona tiene asociada una función de salida global  $y_i(t)$ , definida en función de su estado de activación actual  $a_i(t)$ . En la mayoría de los modelos, la función de salida corresponde a la función identidad, es decir,  $f(x) = x$ . Por lo tanto, la salida de la neurona

coincide directamente con su estado de activación, esto ocurre en modelos como el Perceptrón Multicapa (MLP) o ADALINE.

$$y_i(t) = F_i(a_i(t)) = a_i(t) \quad (3.9)$$

### 3.3. Redes Neuronales Multicapa

La arquitectura de una red neuronal artificial (RNA) está determinada por las características que la forman, incluyendo la estructura, la cantidad de neuronas, la manera en que estas se conectan, el número de capas, entradas y salidas, regla de propagación y funciones de activación. Al igual que las neuronas biológicas las conexiones entre neuronas ocurren únicamente en un sentido, van de la neurona presináptica a la postsináptica, a este tipo de redes son llamadas unidireccionales o *feedforward*. O bien pueden ser bidireccionales o recurrentes (*feedback*) permitiendo la conexión hacia atrás entre capas. Por otro lado, las conexiones sinápticas pueden ser o bien excitadoras, si el peso sináptico es positivo, o inhibitoria si es negativo lo que repercute directamente en la activación de la neurona en cuestión (Martín-del-Brío y Sanz, 2006).

Existen tres tipos de capas: la Capa de Entrada se encarga de recibir la información del entorno, la serie de parámetros que describen un fenómeno. La Capa de Salida se encarga de proporcionar una respuesta. Existen una serie de capas intermedias llamadas Capas Ocultas debido a que los procesos computacionales ejecutados no son accesibles al usuario, sirven como conexión entre la capa de entrada y la de salida (Figura 14).




Figura 14: Representación visual de una red neuronal. (Martín-del-Brío y Sanz, 2006)

### El Perceptrón Simple.

Uno de los primeros modelos neuronales es el Perceptrón Simple, ideado por Rosenblatt (1958), cuya evolución generó el Perceptrón Multicapa, que es el modelo que se utilizó en el presente documento y que se explicará más adelante.

El perceptrón simple original era un modelo neuronal que consistía únicamente de dos capas, una de entrada y otra de salida. Un modelo unidireccional que se encargaba, mediante una señal binaria, clasificar una serie de datos, con una función de activación del tipo escalón. La operación del Perceptrón Simple con  $n$  neuronas de entrada y  $m$  neuronas de salida se puede expresar como:

$$y_i(t) = f\left(\sum_{j=1}^n (\omega_{ij} - \theta_i)\right) \quad (3.10)$$

El perceptrón simple adquirió importancia debido a la forma en que la red se entrena, el algoritmo de aprendizaje que utiliza es un método de corrección de errores que ajusta de manera automática los pesos sinápticos proporcionalmente a la diferencia entre salida estimada y la objetivo, el método asegura la convergencia con independencia en los pesos de partida. El principal problema del Perceptrón es que solo permite

discriminar entre dos clases linealmente separables, es decir, no es aplicable a problemas cuya clasificación no pueda ser separado por una ecuación lineal (Figura 15).




Figura 15: Clasificadores: (A) Lineal y (B) No lineal.

Para evadir las limitaciones que presenta el perceptrón simple, como lo puede ser el problema de la función XOR, una operación lógica que recibe dos entradas binarias, cuya salida es igual a 1 cuando las entradas son diferentes y 0 cuando son iguales, siendo un problema clásico de no linealidad, se debe agregar una capa oculta, si se agregan más capas ocultas para reducir las limitaciones características del modelo, se obtiene un Perceptrón Multicapa.

### El Perceptrón Multicapa, el aproximador universal de funciones.

Se considera al grupo (Rumelhart, 1986; Rumelhart *et al.*, 1986) como los precursores de la herramienta, ya que su trabajo tuvo una mayor trascendencia y reconocimiento entre la comunidad especialista.

De manera generalizada el Perceptrón Multicapa es una extensión del Perceptrón simple, con una Capa de Entrada, una de Capa de Salida y al menos una Capa Oculta. De manera estándar se asume que es una red unidireccional donde todos los nodos (neuronas) de una capa se conectan con todos los nodos de la siguiente.

Si se considera que  $x_i$  son las entradas,  $y_i$  a las salidas de la capa oculta,  $z_k$  a las salidas globales,  $t_k$  las salidas objetivo,  $w_{ij}$  los pesos de la capa oculta y sus respectivos umbrales  $\theta_j$ , además  $w_{ij}^*$  los pesos de la salida  $\theta_k^*$  sus umbrales, un Perceptrón Multicapa con una capa oculta se puede describir como:

$$z_k(x) = \sum_j \omega_{kj}^* y_j - \theta_k^* = \sum_j \omega_{kj}^* f(\sum_i \omega_{ji} x_i - \theta_j) - \theta_k^* \quad (3.11)$$

Cybenko (1989) mostró que cada clase de región compleja (no lineal) puede aproximarse tan bien como se desee con RNA unidireccionales, con solo una capa oculta y cualquier función de activación sigmoidea continua. Hornik (1991) extendió y generalizó el resultado mostrando que, no solo la función sigmoidea sirve para ese propósito.

Por lo que se puede afirmar que un Perceptrón Multicapa puede aproximar cualquier función continua en un intervalo (Ecuación 3.12), y si bien no se recomienda un número de capas ocultas o un número de neuronas, estos pueden variar dependiendo del problema y podría requerir modificaciones en las características predeterminadas de un Perceptrón.

$$g_k^*(x) = \sum_j \omega_{kj}^* f(\sum_i \omega_{ji} x_i - \theta_j) - \theta_k^* \quad (3.12)$$

## Entrenamiento con retropropagación

Para entrenar el sistema de manera automática, Rumelhart *et al.* (1986) idearon el algoritmo de retropropagación (*Backpropagation*), es un proceso iterativo que ajusta los pesos de las conexiones en una red neuronal para minimizar el error. Considerando un arreglo de con una sola capa oculta, se puede describir el proceso dividiéndolo en dos etapas.

- *Inicio.* Al comienzo del proceso, aleatoriamente se seleccionan los pesos  $w_{ij}$  y los umbrales  $\theta_j$  de los diferentes nodos, se define una función de activación  $a_i$  derivable, generalmente sigmoidea; además, de una función de costo  $L$ , el error cuadrático medio (MSE) es el más utilizado para problemas de regresión.
- *Fase hacia adelante (Forward phase).* Las entradas alimentan la red, con los parámetros iniciales, se realizan los cálculos, que devuelven una salida global  $z_k$  son comparadas con las esperadas  $t_k$ , finalmente se calcula el error.

- Fase hacia atrás (*Backward phase*). El principal objetivo es conocer el gradiente de la función de costo en función de los diferentes pesos, tanto de la capa oculta como de la capa de salida, para que se pueda establecer cuál es la dirección en la que se encuentra el error mínimo, finalmente actualiza los pesos. Todo esto se realiza comenzando en la capa de salida y de reversa hasta la capa de entrada.

Este proceso se realiza de forma iterativa hasta obtener un error aceptable o bien, después de un determinado número de iteraciones.

A continuación, se describe el proceso de retropropagación. Teniendo como objetivo obtener el mínimo error posible de la función de coste  $L$ :

$$L = \frac{1}{2} \sum_a (t_k - y_k^*) \quad (3.13)$$

$t_k$  es la salida objetivo  
 $y_k^*$  -> salida estimada

La red es alimentada por una entrada neta  $n$  en cada una de las neuronas de la capa siguiente:

$$n_j = \sum_i \omega_{ij} x_i + \theta_j \quad (3.14)$$

Esta entrada neta es procesada por cada neurona y produce una salida  $y_i$ , mediante su función de transferencia  $f$ :

$$y_j = f\left(\sum_i \omega_{ij} x_i + \theta_j\right) \quad (3.15)$$

Esta nueva salida producida por la capa oculta se utiliza como entrada neta en la capa de salida, obteniendo la salida estimada de la red.

Aquí comienza la fase hacia atrás, donde se actualizan los pesos de tal forma que se reduzca el error, para lo cual se utiliza del algoritmo del descenso del gradiente. El gradiente  $\nabla f$  de una función evaluada en un punto cualquiera, proporciona la dirección de máxima pendiente, si se sigue la trayectoria opuesta, es decir,  $-\nabla f$  se encuentra la posición donde la función se minimiza. Si se repite este proceso varias veces, se llegará al mínimo de la función.

Analizando el gradiente de la función de coste, con este algoritmo, el mínimo es aquel que presenta un menor error en la red. La función gradiente para la capa oculta y la de salida se describe como:

$$\Delta\omega_{ij} = -\mu \frac{\partial L}{\partial \omega_{ij}} \quad (3.16)$$

$$\Delta\omega_{ij}^* = -\mu \frac{\partial L}{\partial \omega_{ij}^*} \quad (3.17)$$

La tasa de aprendizaje  $\mu$  es un parámetro que regula el tamaño de paso del gradiente, es crucial para lograr un entrenamiento eficiente, un valor muy alto puede no converger y evitar un mínimo, mientras que un valor muy pequeño genera que el aprendizaje se vuelva lento y podría quedar atrapado en un mínimo local.

Para obtener  $\frac{\partial L}{\partial w_{ij}}$  hay que formar una composición de funciones, por lo que es necesario calcular las derivadas parciales intermedias:

$$\frac{\partial L}{\partial w_{ij}} = \frac{\partial L}{\partial n_i} \frac{\partial n_i}{\partial w_{ij}} \quad (3.18)$$

Cada neurona realiza una contribución a la respuesta final, por lo que, si existe un error, cada neurona también realiza un aporte al error, el error de cada neurona se define como:

$$\delta = \frac{\partial L}{\partial n_i} \quad (3.19)$$

Para las capas ocultas se tiene que:

$$\frac{\partial L}{\partial w_{ij}} = \frac{\partial L}{\partial n_i} \frac{\partial n_i}{\partial w_{ij}} = S_i x_i \quad (3.20)$$

La sensibilidad  $S_i$  para las capas ocultas se obtiene con:

$$S_i = \frac{\partial L}{\partial n_i} = \frac{\partial L}{\partial \delta_i} \cdot \frac{\partial \delta_i}{\partial y_i} \cdot \frac{\partial y_i}{\partial n_i} = (-1)\delta_i f^*(n_i) \quad (3.21)$$

Al reemplazar la ecuación 3.20 en 3.21 se obtiene:

$$\frac{\partial L}{\partial \omega_{ij}} = -\delta_i f^*(n_i) y_i \quad (3.22)$$

$$-\Delta L = \delta_i f^*(n_i) y_i \quad (3.23)$$

Ahora con el valor del gradiente es posible actualizar los pesos de la red después de cada iteración:

$$w_{k+1} = w_k + \delta f^*(n_i) y_i \quad (3.24)$$

## **5. Modelo neuronal**

Como se indicó en el capítulo 2 la Ciudad de México es una urbe expuesta a distintas fuentes sísmicas, estando en estas las que han producido los denominados microsismos. Para estudiar la respuesta de suelo, ante estos eventos sísmicos, particularmente el valor de la aceleración máxima que se produce ante su ocurrencia, se propone el uso de la Inteligencia Artificial estableciendo un modelo neuronal basado en la Redes Neuronales Artificiales.

### **5.1. Descripción de la base de datos**

La Base de Datos está integrada por 678 acelerogramas obtenidos de agosto de 1991 a febrero de 2024. Los registros fueron producidos por 52 microsismos cuyo epicentro fue localizado en el valle de México (Tabla 2). El banco de datos compilado consideró 62 estaciones de la Red Acelerográfica del valle de México (RAVM) las cuales son operadas por el Centro de Instrumentación y Registro Sísmico AC (CIRES).

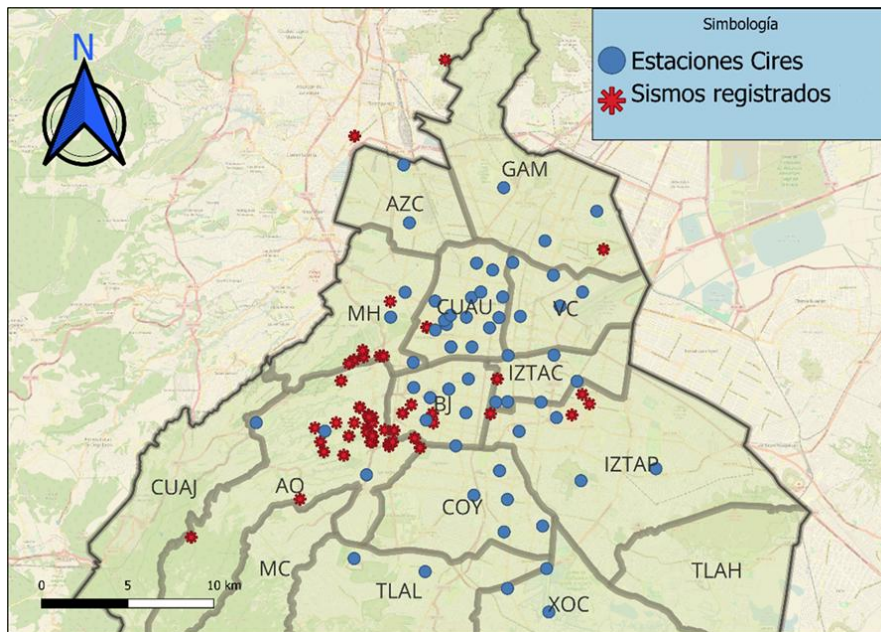
En la Figura 16 se muestra la distribución espacial de los epicentros de los microsismos y de las estaciones de la RAVM, se puede observar una concentración de microsismos hacia el poniente de la ciudad de México.

Tabla 2. Sismos registrados

Fecha	Tiempo Local	M	h [km]	Lat (°)	Long (°)
1991-08-18	07:18:12	3.8	3.8	19.33	-99.24
2001-09-14	12:13:15	2.9	2.9	19.31	-99.3
2001-11-15	16:18:22	3.5	3.5	19.56	-99.16
2002-02-01	19:29:11	2.6	2.6	19.52	-99.21
2004-09-13	15:58:34	3.1	3.1	19.42	-99.17
2014-12-01	02:50:06	3.4	3.4	19.353	-99.2158
2014-12-01	03:12:16	2.1	3	19.3428	-99.2032
2014-12-01	04:02:13	2.3	2.3	19.3673	-99.2317
2014-12-01	04:45:47	2.2	2.2	19.36	-99.2287
2018-02-13	15:39:38	3.3	3.3	19.4608	-99.0723
2018-09-14	11:07:57	2.1	2.1	19.3748	-99.1347
2018-10-05	09:59:27	2.4	2.4	19.375	-99.1833
2019-07-12	07:38:28	2.5	2.5	19.4049	-99.1959
2019-07-12	10:08:04	2.4	2.4	19.4049	-99.1939
2019-07-13	11:39:20	2.4	2.4	19.392	-99.2173
2019-07-16	01:36:44	2.5	2.5	19.4045	-99.2049
2019-07-17	22:59:16	3.3	3.3	19.4079	-99.2054
2019-07-17	23:10:52	2.6	2.6	19.4028	-99.2102
2019-07-17	00:45:53	2.4	2.4	19.401	-99.213
2020-06-07	09:45:21	2.9	2.9	19.374	-99.2022
2020-07-04	22:05:16	2.1	2.1	19.385	-99.084
2020-07-04	02:37:18	2.2	2.2	19.385	-99.084
2021-12-09	07:16:10	2.1	2.1	19.37	-99.1663
2023-01-17	03:08:51	1.1	1.1	19.375	-99.1667
2023-01-29	12:49::10	1.3	1.3	19.3795	-99.1785
2023-02-07	08:46:38	1.5	1.5	19.357	-99.1737
2023-03-15	03:48:28	2	2	19.38	-99.08
2023-03-15	04:21:22	2.8	2.8	19.3742	-99.0897
2023-03-29	07:34:39	1.9	1.9	19.3578	-99.1907
2023-04-11	22:02:10	1.7	1.7	19.4335	-99.1902

Tabla 3 (Continuación): Sismos registrados

Fecha	Tiempo Local	M	h [km]	Lat (°)	Long (°)
2023-04-20	15:04:24	2.6	2.6	19.3592	-99.1907
2023-04-21	10:39:56	1.8	1.8	19.36	-99.1888
2023-05-11	22:20:07	3	3	19.36	-99.2
2023-05-11	22:21:20	1.3	1.3	19.373	-99.2
2023-05-11	22:29:47	2.3	2.3	19.3637	-99.201
2023-05-11	22:34:52	1.8	2.3	19.3637	-99.201
2023-05-11	01:43:22	2	1.8	19.3673	-99.203
2023-05-11	09:05:30	2.2	2	19.366	-99.188
2023-05-11	09:58:09	1.3	2.2	19.365	-99.203
2023-06-03	19:12:03	2.3	1.3	19.36	-99.201
2023-07-18	15:05:33	2.1	2.3	19.362	-99.1767
2023-08-09	11:19:52	1.9	2.1	19.3663	-99.1932
2023-12-03	18:29:02	2	2	19.37	-99.22
2023-12-12	11:06:27	2.8	2.8	19.363	-99.2
2023-12-12	11:07:52	3	3	19.363	-99.2
2023-12-12	11:08:53	2.4	2.4	19.363	-99.2
2023-12-14	14:13:14	3.2	3.2	19.363	-99.2
2023-12-26	07:35:44	1.7	1.7	19.37	-99.2
2024-02-04	03:17:22	2.3	2.3	19.363	-99.213
2024-02-14	06:42:13	2.8	2.8	19.378	-99.207
2024-02-14	06:43:02	1.8	1.8	19.373	-99.202
2024-02-16	09:35:23	2	2	19.37	-99.21



*Figura 16: Distribución espacial de las estaciones de la RACM (en color azul) y de los 52 microsismos considerados en la base de datos (en color rojo).*

La Base de Datos incluye estaciones de superficie, pozo y sobre alguna estructura; sin embargo, para el estudio se utilizaron únicamente los acelerogramas de las estaciones de superficie. Es importante señalar que no todos los acelerogramas tienen la calidad necesaria para distinguir entre la señal producida por el evento sísmico y aquella generada por el denominado ruido ambiental. La Figura 17 ilustra la diferencia entre un acelerograma considerado de buena calidad (imagen superior) y otro en el cual la relación señal ruido es muy baja (imagen inferior).

Según el criterio de Junger (1964), para evaluar si un registro de un acelerograma tiene buena calidad se seleccionan dos tramos: uno de ruido previo al sismo y otro con la señal del evento. Se calcula la densidad espectral de potencia de cada tramo. Luego, se comparan la de la señal con la del ruido; si la densidad espectral de la señal es al menos el doble que la del ruido (es decir, la relación señal/ruido es mayor que 2), entonces se considera que el registro tiene buena calidad.




Figura 17: Comparación entre dos registros producidos por el mismo sismo en dos estaciones acelerográficas. La imagen superior muestra un acelerograma de buena calidad, mientras que en la imagen inferior no se distingue la señal sísmica del ruido ambiental y por lo tanto se considera de mala calidad.

De acuerdo con lo anterior, mediante este criterio se eliminaron los acelerogramas con baja relación señal-ruido, por lo que el banco de datos final quedó integrado por 410 acelerogramas con registro en tres direcciones ortogonales (Tabla 3).

Tabla 3. Registros por estación.

Estación	Número	Estación	Número
CO47	24	JA43	6
IM40	17	PE10	6
ES57	16	TL08	6
CS78	15	TL55	6
AU46	12	TP13	6
SS60	12	VM29	6
EO30	11	AU11	5
CI05	10	BL45	5
CS66	10	CA59	5
MT50	10	GA62	5
BA49	9	GC38	5
CJ03	9	GR27	5
CJ04	9	JC54	5

Tabla 3 (continuación). Registros por estación.

Estación	Número	Estación	Número
AO24	8	ME52	5
SI53	8	RM48	5
UI21	8	SP51	5
AL01	7	PD42	4
CH84	7	RI76	4
CO56	7	UC44	4
DX37	7	XP06	4
FJ74	7	BO39	3
LI58	7	DR16	3
VG09	7	MI15	3
XO36	7	CA20	2
AP68	6	CB43	2
CI03	6	CP28	2
CI04	6	DM12	2
EX09	6	LV17	2
EX12	6	AR14	1
HJ72	6	CC55	1
IB22	6	MY19	1

### Parámetros Sísmicos.

Debido a que el objetivo del Modelo Neuronal a implementar es determinar la aceleración máxima ( $A_{max}$ ) producida por microsismos en el valle de México, se consideraron 5 parámetros que influyen en forma determinante en el valor de  $A_{max}$  (Alcántara, 2013; Günaydın y Günaydın, 2008; García de Aquino, 2017) tales parámetros son: Magnitud ( $M$ ), profundidad focal ( $P_f$ ), distancia epicentral ( $D_e$ ), Azimut ( $A_z$ ) y el periodo fundamental de vibrar del sitio ( $T_s$ ) en donde se ubica la estación acelerográfica  $\square$ .

**a) Magnitud de coda ( $M_c$ )**

La magnitud de un sismo es la medida logarítmica de la fuerza o energía liberada por un evento, existen diferentes tipos de escalas, el CIRES utiliza la magnitud de coda  $M_c$ .

La magnitud de coda utiliza la duración de la coda de un sismo, es decir, la parte final de un registro sísmico, cuando ya han pasado las ondas principales, una parte de la señal decrece gradualmente con el tiempo hasta regresar al estado anterior al sismo. La magnitud de coda se calcula como lo propuso González y García-A. (1986).

$$M_c = -0.85 + 2.24 \log_{10}(T_c) \quad (5.1)$$

Donde  $T_c$  es la duración de coda en segundos.

**b) Profundidad Focal ( $P_f$ ).**

Es el valor de la distancia medida perpendicularmente hacia la superficie desde el punto en la corteza donde ocurre la primera ruptura del sismo.

**c) Distancia epicentral ( $D_e$ ).**

Es la distancia que existe entre el epicentro y el aparato de registro, es decir, la distancia entre la proyección vertical hacia la superficie del sismo y la estación sismológica.

Para calcular la distancia entre dos puntos de la superficie terrestre conociendo su latitud y longitud se utiliza la fórmula de Haversine (Sinnott, 1984):

**d) Azimut ( $A_z$ ).**

El ángulo que existe entre la línea que conecta el epicentro y la estación de registro con respecto al norte geográfico (Figura 18).

**e) Período fundamental del sitio ( $T_s$ ).**

Corresponde al tiempo en el que ocurre una oscilación, en la cual el depósito de suelo presenta la máxima amplificación dinámica ante una excitación sísmica.




Figura 18: Parámetros característicos de un sismo (García de Aquino, 2017).

## 5.2. Análisis estadístico de los parámetros sísmicos

Se realizó un análisis estadístico sobre los parámetros, se obtuvieron los histogramas y diagramas de caja correspondientes a los parámetros sísmicos  $M$ ,  $P_f$ ,  $D_e$ ,  $A_z$  y  $T_s$ , en la Figura 19 se presenta la distribución de cada uno, mientras que en la Tabla 4 se muestran los respectivos estadísticos.

Con relación al parámetro  $M$ , se observa que el 50% de los datos se encuentra entre 2.4 y 3, el sismo más pequeño registrado es de  $M_c$  1.5 mientras que el más grande es un  $M_c$  3.8, por otro lado, fuera de la zona conocida como “bigotes” se encuentra, un valor atípico con magnitudes de 1.3, el promedio de magnitudes es de 2.71.

La profundidad muestra que más de 200 sismos ocurrieron a un 1 [km], debido a lo anterior cualquier valor diferente a 1 es considerado como un dato atípico, el valor máximo del conjunto es de 14 [km].

La distancia tiene un diagrama de caja ligeramente asimétrico positivo, hacia la parte inferior de la distribución. El promedio es de 7.31 [km], con un rango que va de 0.45 a 18.46 [km].

El azimut presenta una gran cantidad de valores atípicos, un rango Inter-cuartil que va desde los  $210.56^\circ$  a  $262.3^\circ$ , el histograma muestra un pequeño sesgo hacia la izquierda,

la desviación estándar de el parámetro es el más grande de todo el conjunto de datos, con un valor de 74.7°.

Finalmente, el periodo muestra una distribución más uniforme, con un valor atípico de 4 segundos, alrededor del 50% de los datos se encuentran entre 1 y 2 segundos.

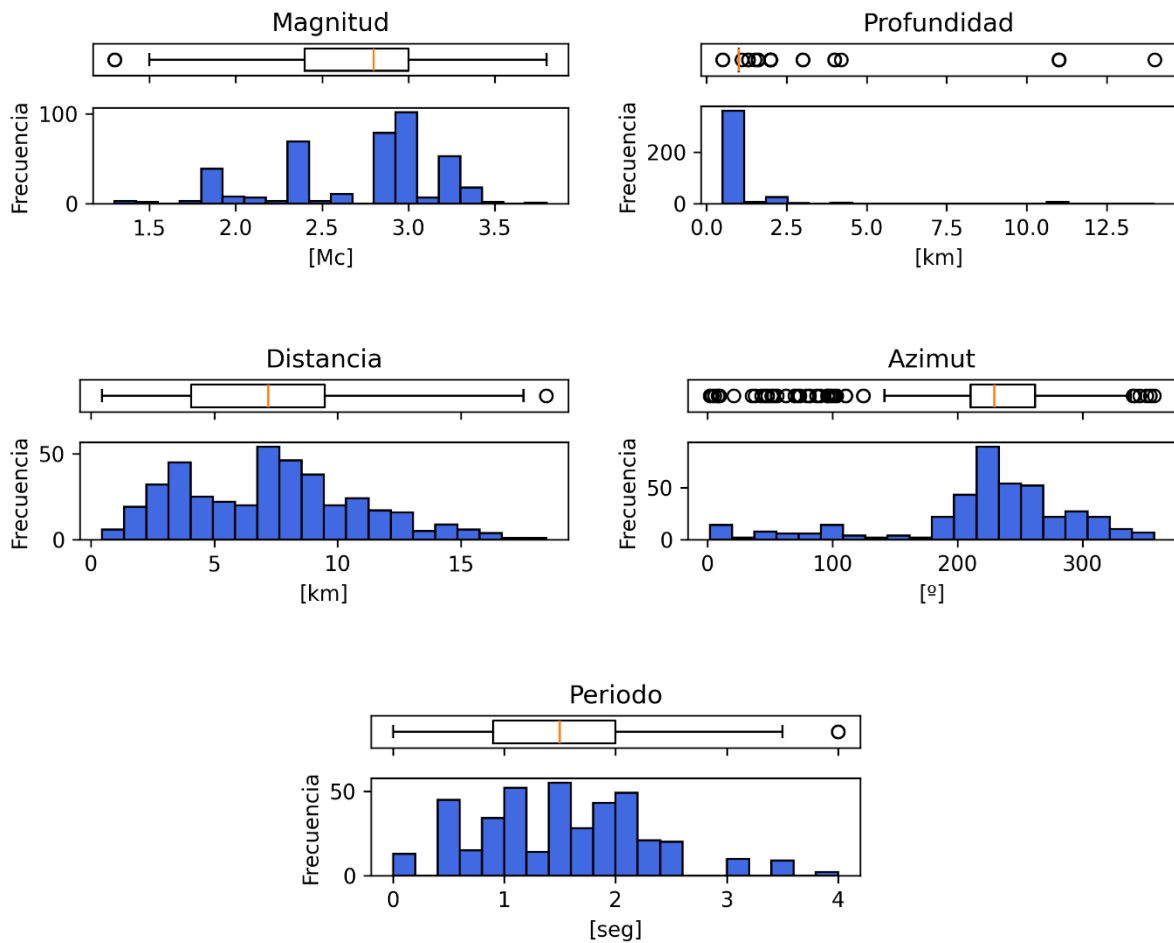


Figura 19: Diagrama de caja y "bigotes" (superior) e histograma (Inferior) de los parámetros de entrada.

Tabla 4. Estadísticos de los parámetros de entrada

	Magnitud [Mc]	Profundidad [km]	Distancia [km]	Azimut [°]	Periodo [s]
<b>Media</b>	2.71	1.32	7.31	221.17	1.50
<b>Mediana</b>	2.80	1.00	7.20	229.32	1.50
<b>Desviación est.</b>	0.47	1.49	3.62	74.70	0.76
<b>Valor Min</b>	1.30	0.50	0.45	2.05	0.00
<b>25%</b>	2.40	1.00	4.07	210.56	0.90
<b>50%</b>	2.80	1.00	7.20	229.32	1.50
<b>75%</b>	3.00	1.00	9.49	262.30	2.00
<b>Valor Max</b>	3.80	14.00	18.46	357.21	4.00

Las mismas herramientas descriptivas fueron generadas para los parámetros a estimar (Figura 20). Los histogramas de las tres componentes muestran un comportamiento muy parecido entre sí, una distribución sesgada hacia la derecha muy marcada.

La componente NS muestra una media de 4.29 [cm/s<sup>2</sup>], la aceleración máxima registrada es de 60.32 [cm/s<sup>2</sup>], un rango Inter-cuartil entre 1.35 y 4.34 [cm/s<sup>2</sup>], lo anterior provoca que aceleraciones mayores a 8 [cm/s<sup>2</sup>] (fin de los “bigotes”) sean considerados como valores atípicos.

Como se observa en la Tabla 5, la componente EW presenta valores muy similares a la otra componente horizontal, sin embargo, la aceleración más grande registrada en esta componente es de 46.67 [cm/s<sup>2</sup>].

La componente Vertical (V) se comporta de manera ligeramente diferente, el rango de aceleraciones es menor de 0.098 a 25.59 [cm/s<sup>2</sup>], el término de los “bigotes” es menor, a partir de los 6.015 [cm/s<sup>2</sup>] cualquier valor mayor se considera como atípico.

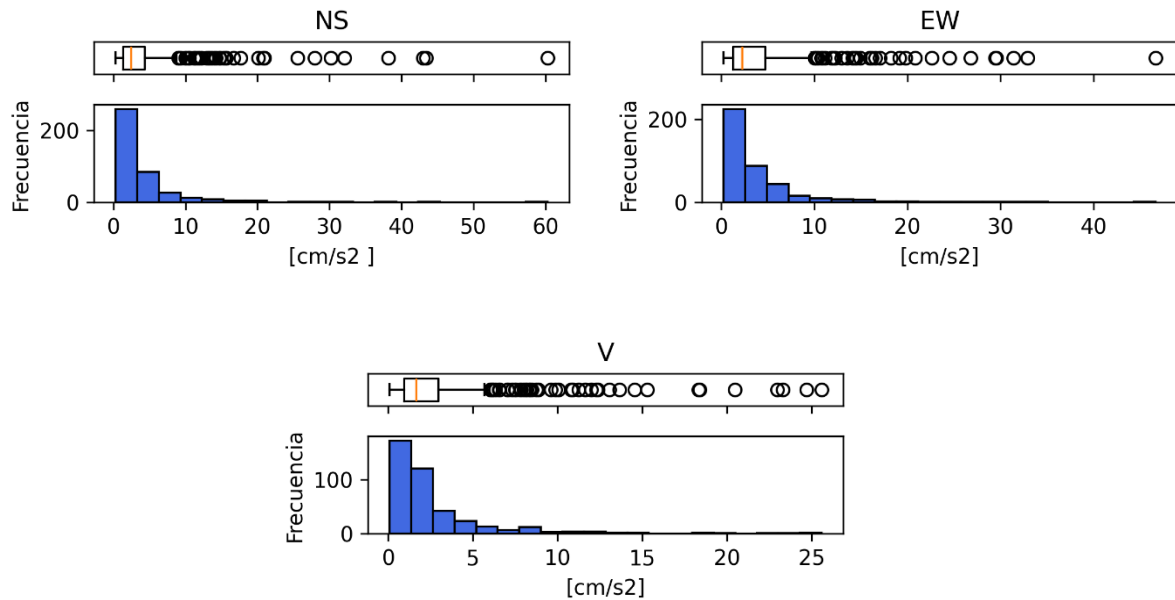


Figura 20: Histogramas y diagrama de caja para los parámetros a estimar

Tabla 5. Estadísticos de los parámetros a estimar

	NS [cm/s <sup>2</sup> ]	EW [cm/s <sup>2</sup> ]	V [cm/s <sup>2</sup> ]
<b>Media</b>	4.29	4.10	2.86
<b>Mediana</b>	2.46	2.09	1.66
<b>Desvi. est.</b>	6.11	5.22	3.62
<b>Valor min.</b>	0.29	0.27	0.09
<b>25%</b>	1.35	1.31	0.94
<b>50%</b>	2.46	2.29	1.66
<b>75%</b>	4.34	4.76	2.97
<b>Valor max.</b>	60.32	46.67	25.59

El análisis estadístico proporcionó una idea general del comportamiento del fenómeno, lo que nos permite concluir varias cosas. Si nos concentramos en los parámetros NS, EW y V observamos que existe una enorme cantidad de datos que son menores a los 10 [cm/s<sup>2</sup>]. Por otro lado, como se observa en la Tabla 3 la enorme mayoría de las estaciones no registraron al menos 10 sismos.

Es por lo anterior que se decidió considerar para el entrenamiento del modelo las estaciones que cuentan con un mayor número de registros, además, se tomó en consideración que el rango de aceleraciones coincida, en la manera de lo posible, con el rango de aceleraciones del conjunto total. Es decir que la estación cuente con registros de diferentes magnitudes de aceleración. Lo anterior garantiza una mejor representatividad a lo largo del rango de aceleraciones, y evita la excesiva representación observada en los datos de valores menores a los 10 [cm/s<sup>2</sup>]. En la Tabla 6 se observan las estaciones que, de acuerdo con este criterio fueron seleccionadas aptas para el entrenamiento, reduciendo el número de datos de 410 a 95.

*Tabla 6. Estaciones seleccionadas para el entrenamiento*

<b>Estación</b>	<b>No. Registros</b>
CO47	24
IM40	17
ES57	16
CS78	15
AU46	12
EO30	11

Se realizó un nuevo análisis estadístico para el subconjunto de datos. De manera general, para los parámetros de entrada, no hay cambios significativos en sus respectivos histogramas y diagramas de caja. Los histogramas de los parámetros magnitud y profundidad prácticamente no sufren modificaciones (Figura 21).

Los cambios se presentan en el Azimut, ya que, en el conjunto original valores menores a las 120° se clasifican como atípicos, en el seleccionado todos entran dentro de los bigotes del diagrama, con una distribución ligeramente asimétrica.

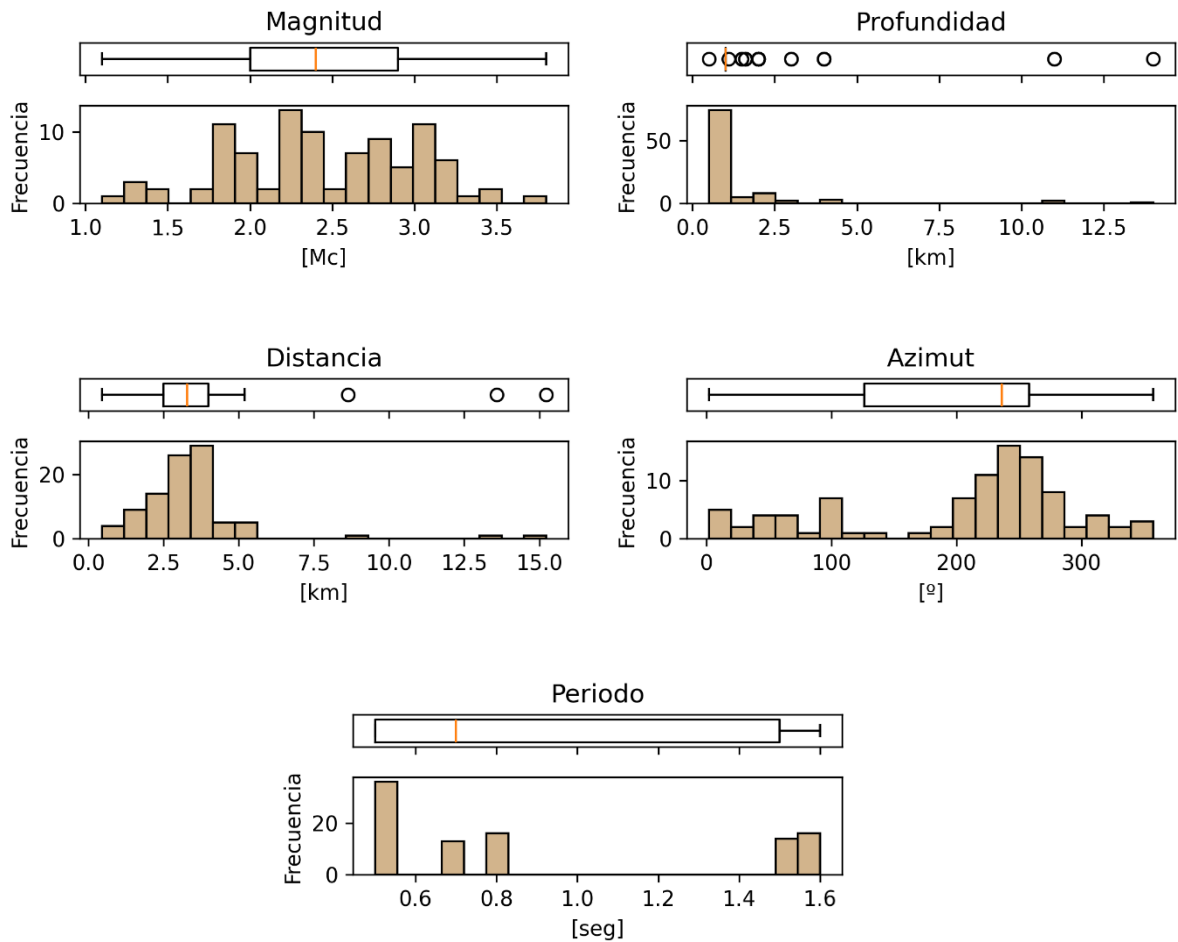


Figura 21: Histogramas y diagramas de caja del subconjunto de datos.

Los mayores cambios se observan en las variables de salida (Tabla 7), en la Figura 22 se aprecia cómo han cambiado los histogramas. La distribución hacia la derecha se mantiene, lo cual es una buena señal ya que, conserva el comportamiento y la frecuencia de ocurrencia del fenómeno, donde las aceleraciones pequeñas son las más comunes y las grandes aceleraciones son esporádicas.

El mayor beneficio, es que el conjunto seleccionado tiene una mayor representatividad a lo largo del dominio de aceleraciones, ya no existe una sobrerrepresentación de aceleraciones menores a los 10 [cm/s<sup>2</sup>].

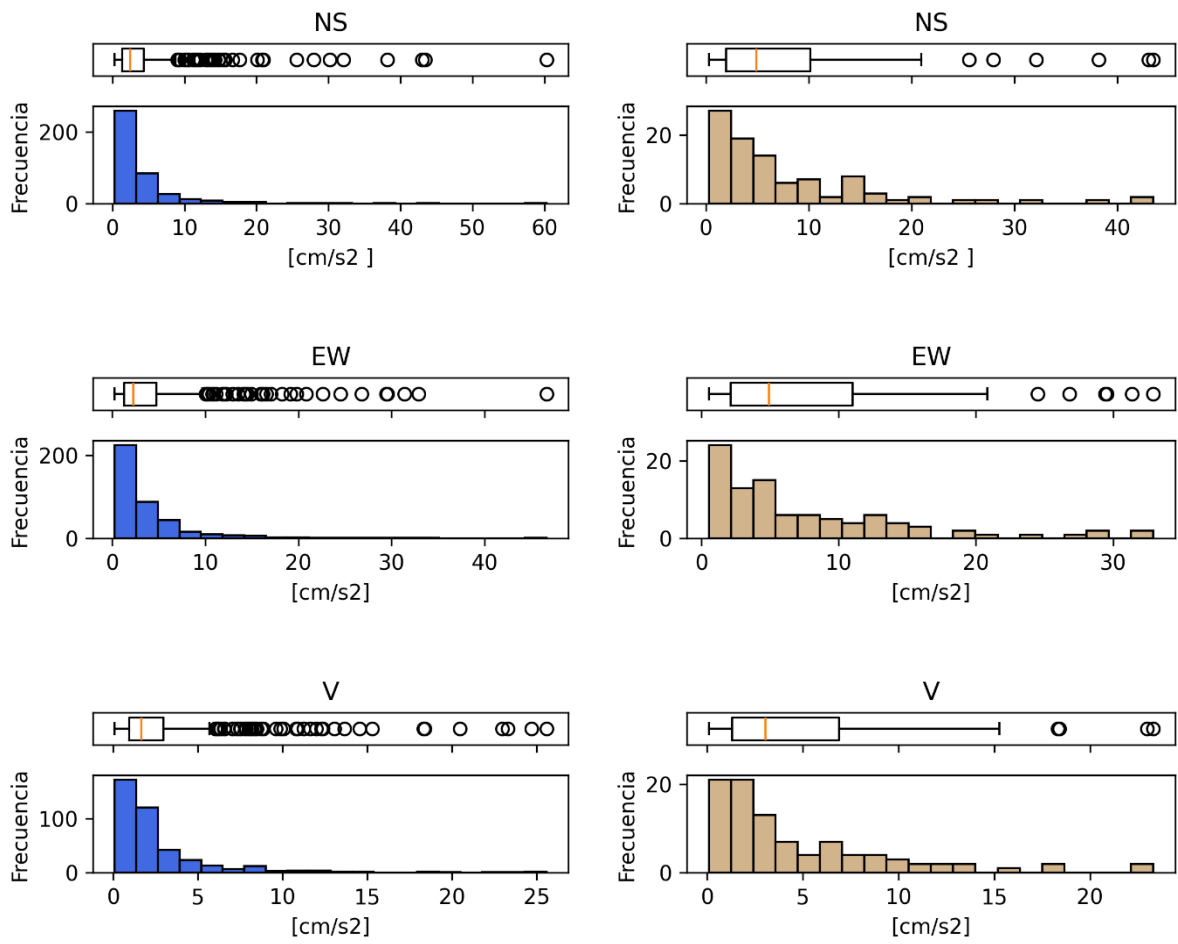


Figura 22: Comparación de los valores a estimar. Original (Izquierda) y seleccionado (derecha)

Tabla 7. Comparación estadísticos de ambos conjuntos

	Original			Muestra		
	NS	EW	V	EW	EW	V
<b>Media</b>	4.29	4.10	2.86	7.65	7.649365	4.829412
<b>Mediana</b>	2.46	2.09	1.66	4.89	4.93	3.04
<b>Desv. est.</b>	6.11	5.22	3.62	7.51	7.51	4.89
<b>Valor min.</b>	0.29	0.27	0.09	0.53	0.53	0.09
<b>25%</b>	1.35	1.31	0.94	2.14	2.13	1.29
<b>50%</b>	2.46	2.29	1.66	4.93	4.93	3.04
<b>75%</b>	4.34	4.76	2.97	11.01	11.016	6.90
<b>Valor máx.</b>	60.32	46.67	25.59	32.91	32.91	23.29

### 5.3. Arquitectura del modelo neuronal

El desarrollo de un modelo neuronal capaz de estimar la Aceleración Máxima (Amax) constituye una tarea compleja, ya que requiere la definición cuidadosa de múltiples parámetros. El modelo seleccionado fue un Perceptrón Multicapa (MLP) unidireccional, una arquitectura ampliamente utilizada en problemas de regresión.

Este modelo opera mediante la propagación de la información en una sola dirección, desde la capa de entrada hasta la capa de salida, por lo que la comunicación entre nodos de la misma capa no está permitida. La capa de entrada recibe las variables consideradas más relevantes, en este caso son la Magnitud M, profundidad Pf, distancia epicentral De, azimut Az y periodo fundamental Ts. Después esta información es transmitida a un conjunto de neuronas organizadas en capas ocultas, donde se lleva a cabo el procesamiento mediante funciones de activación, con el objetivo de generar una respuesta.

Para determinar la estructura del Perceptrón Multicapa, tales como regla de propagación, función de transferencia, de salida, y la regla de aprendizaje, no existe una metodología establecida. El uso de trabajos previos (Alcántara, 2013; García, 2017; 2017; Kerh,2005) puede proporcionar información relevante para tener un punto de partida, además el determinar la arquitectura de una red suele ser un proceso difícil y extenso debido a la gran cantidad de opciones, una forma de abordarlo es mediante la prueba y error, buscando aquella que proporcione los mejores resultados.

Según lo anterior la arquitectura estará formada por 5 parámetros de entrada, al menos 1 capa oculta cuya cantidad de nodos será determinada por su desempeño, que finalmente retorna una salida, la aceleración máxima de la forma  $5 \times N \times N \times N \times 1$  (Figura 23).

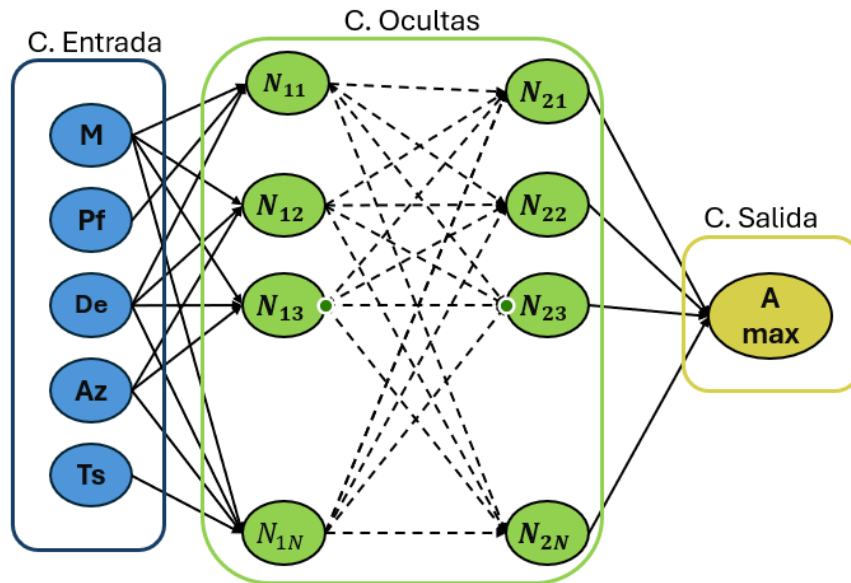


Figura 23: Arquitectura del modelo neuronal establecido

La regla de aprendizaje seleccionada fue la retropropagación, debido a su simplicidad y efectividad, por otro lado, la función de transferencia usada fue la sigmoide para las capas ocultas, mientras que para la de salida se utilizó una función lineal.

La función de costo que proporcionará el parámetro mediante el cual el modelo, buscará actualizar los respectivos pesos y umbrales, para encontrar el mínimo error posible.

Se utilizó la raíz del error cuadrático medio (RMSE) (ec. 5.2) que devuelve el error en las mismas unidades del problema.

$$E = \sqrt{\frac{\sum (y_k - t_k)^2}{M}} \quad (5.2)$$

*E= Raiz del error cuadrático medio*

$y_k$  -> Salida deseada

$t_k$  -> Salida estimada

$M$  -> Número de datos

Se pueden resumir las características de los tres modelos neuronales como:

- a) Tipo: **Perceptrón Multicapa unidireccional.**
- b) Variables de entrada: **M, Pf, De, Az, Ts.**
- c) Preprocesamiento: **Min-Max y normalización z.**
- d) Regla de aprendizaje: **Retropropagación.**
- e) Función de transferencia: **Sigmoide.**
- f) Función de coste: **Error Cuadrático Medio**
- g) Salida: **Aceleración máxima del terreno  $A_{max}$ .**

### 5.3. Conjuntos de Entrenamiento y Prueba

Después de discriminar los datos iniciales, el conjunto final, que será utilizado para el entrenamiento, está conformado por un total de 95 muestras. Para modelar un Perceptrón Multicapa se requiere la partición del conjunto de datos en dos subconjuntos: el de entrenamiento y el de prueba. El primero se utiliza para encontrar los parámetros ideales del modelo, mediante el transcurso de épocas iterativas. Por su parte el conjunto de prueba permite evaluar el desempeño predictivo y la capacidad de generalización de la red frente a datos no observados durante el ajuste.

Por convención el conjunto de entrenamiento y de prueba son seleccionados de manera aleatoria en una proporción 80/20, sin embargo, esto es recomendado únicamente cuando la base de datos es lo suficientemente grande, después del remuestreo se tienen 95 registros, por lo que, una selección aleatoria no sería la opción más apropiada.

Debido al escaso número de muestras, para garantizar que el rango de estas sea amplio y no esté concentrado en uno pequeño, se establecieron tres estratos de aceleración, a partir de los cuales se realizó la repartición entre los subconjuntos. Los estratos se separan de la siguiente forma: aceleraciones menores a  $10 \text{ cm/s}^2$ , aceleraciones entre  $10$  y  $20 \text{ cm/s}^2$  y finalmente aceleraciones mayores a los  $20 \text{ cm/s}^2$ , considerando este criterio el tamaño del conjunto de entrenamiento es de 72 registros y para el conjunto de prueba son 23 registros (Figura 24).

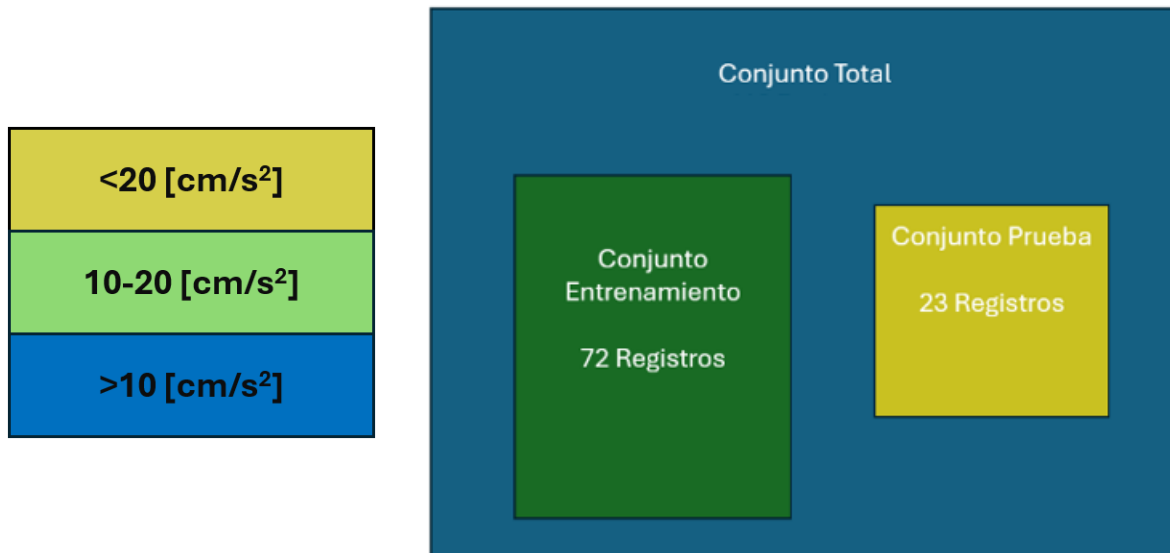


Figura 24: Rangos de aceleración y distribución de los datos para entrenamiento (72) y prueba (23).

### 5.3. Entrenamiento del modelo

Realizada la selección de ambos conjuntos se realiza un preprocesamiento de los datos antes de comenzar con el entrenamiento, este consiste en un conjunto de técnicas aplicadas a los datos crudos, con el objetivo de acelerar la convergencia y aumentar el desempeño de la red, para lo que se utilizaron dos métodos.

El preprocesamiento Min-Max (ec. 5.3) consiste en realizar una transformación, para que todos los parámetros estén entre un rango de 0 y 1, ya que, de otra forma, al tener distintos rangos de valores, la red dará mayor importancia y peso a las magnitudes más grandes, menospreciando la influencia de las variables cuyo rango de magnitudes es pequeño en comparación.

El proceso de normalización z (ec. 5.4), transforma los datos originales restándoles su media y dividiéndolos por su desviación estándar, con el objetivo de centrar la variable en cero y escalar su dispersión a una unidad. Como resultado, los valores quedan expresados en términos de cuántas desviaciones estándar se encuentran respecto al promedio, lo que elimina diferencias de escala entre variables y mejora la estabilidad numérica y la eficiencia del entrenamiento en modelos como las redes neuronales.

Este paso permite que la red converja de manera más rápida, más estabilidad y proporcionará mejores resultados.

$$x_{esc} = \frac{x_i - ((x_{max} - x_{min})/2)}{x_{max} - x_{min}} \quad (5.3)$$

$$x_{esc} = \frac{x_i - \bar{x}}{desv\ est} \quad (5.4)$$

La red neuronal fue creada a través del software *Thinks Pro* (Logical Designs ,1996), el *software* proporciona los elementos necesarios para desarrollar una red neuronal artificial, cuenta con una gran variedad de opciones para modificar la red, así como el monitoreo constante de su desempeño (Figura 25).

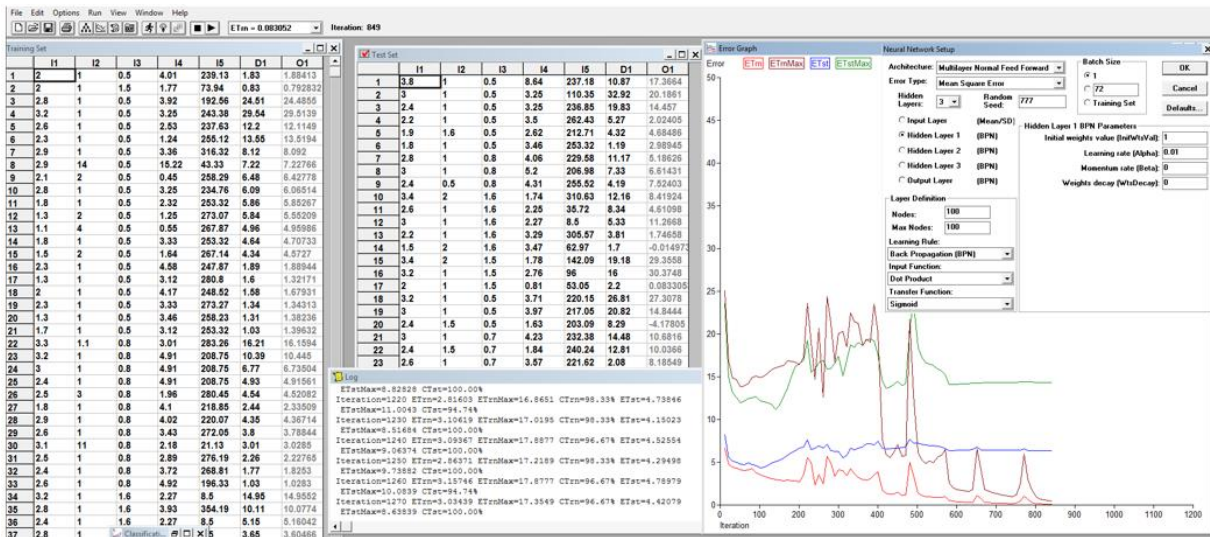


Figura 25: Interfaz del software *ThinksPro* (Logical Designs ,1996).

Establecidas las características de la red neuronal, y seleccionados los conjuntos de entrenamiento y prueba (Anexo), con un preprocesamiento que vario entre Min-Max y estandarización z.

La metodología empleada para el entrenamiento de los tres modelos consistió en las siguientes etapas. En primer lugar, se realizó el preprocesamiento de los datos. Posteriormente, se definió la arquitectura de la red neuronal, especificando el número de entradas, salidas, capas y nodos por capa.

Al inicio del entrenamiento, los pesos y umbrales de las neuronas se inicializaron de forma aleatoria. Durante cada época, las muestras del conjunto de entrenamiento fueron propagadas hacia adelante a través de la red, donde, mediante la función de activación correspondiente, se obtuvo una predicción en la capa de salida.

La salida estimada fue comparada con el valor esperado, calculándose el error a partir de la función de costo. Con base en el gradiente de dicha función, los pesos y sesgos se ajustaron mediante el algoritmo de retropropagación, actualizando iterativamente los parámetros en dirección descendente del gradiente.

De forma paralela después de cada época, con los pesos establecidos en ese momento, el desempeño del modelo es evaluado con el conjunto de prueba, este proceso no afecta de forma alguna el entrenamiento, pero nos permite monitorear su capacidad de generalización.

Este procedimiento se repitió de manera iterativa hasta que se cumpliera alguno de los siguientes criterios de parada: alcanzar un error previamente establecido o completar el número máximo de épocas definido (1500), considerando en todos los escenarios que no se alcance un sobreentrenamiento.

Para evaluar el desempeño del modelo se realizó un monitoreo constante del RMSE, de ambos conjuntos de manera gráfica, buscando la que el error se disminuya de manera constante hasta que sea estable (Figura 26).

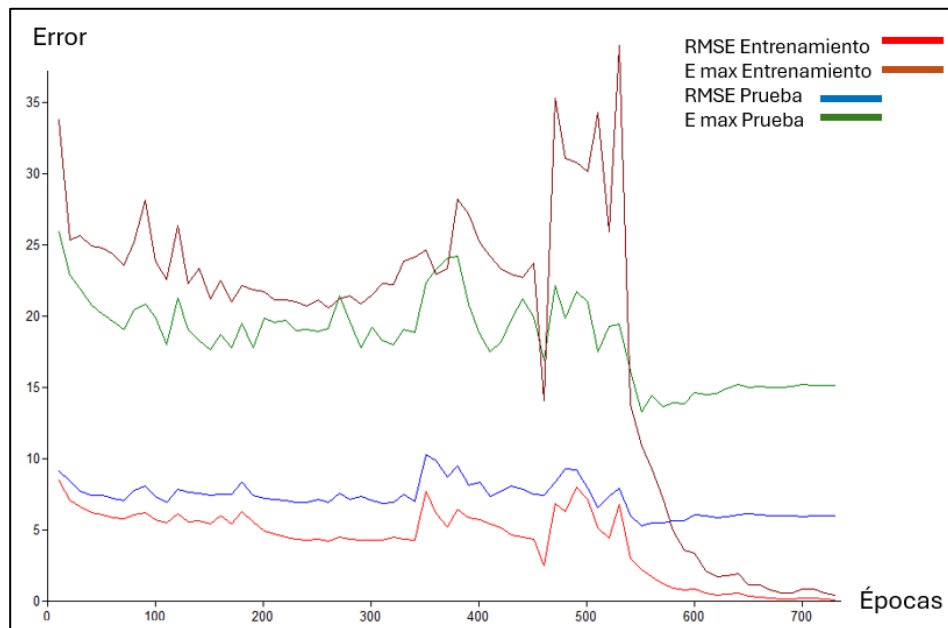


Figura 26: Gráficas de error para monitoreo.

La selección de la arquitectura se realizó de manera progresiva. Inicialmente se probaron configuraciones con un mayor número de neuronas por capa, con el objetivo de garantizar suficiente capacidad de representación, generalización y para favorecer la convergencia del modelo. Después, se fue reduciendo de manera progresiva el número de neuronas de la red, incluyendo pruebas con un menor número de capas ocultas, con el fin de identificar la arquitectura que ofreciera el mejor balance entre precisión y capacidad de generalización.

La evaluación del desempeño de los modelos se efectuó mediante: la raíz del error cuadrático medio (RMSE) y el coeficiente de correlación entre los valores estimados por la red y los valores observados. Estas métricas se calcularon tanto para el conjunto de entrenamiento como para el conjunto de prueba. Sin embargo, para la selección final del modelo se dio mayor peso a los resultados obtenidos en el conjunto de prueba, ya que estos reflejan la capacidad del modelo para generalizar a datos no utilizados durante el proceso de entrenamiento.

Es fundamental realizar un monitoreo contante del proceso de entrenamiento, ya que, aunque se hayan definido criterios de parada previamente establecidos, resulta

necesario supervisar la capacidad de generalización del modelo. Esta puede observarse comparando el comportamiento del error en los conjuntos de entrenamiento y prueba.

Cuando ambos errores presentan valores similares y evolucionan de manera parecida, se puede inferir que el modelo mantiene un equilibrio entre ajuste y generalización. En contraste, si el error en el conjunto de entrenamiento disminuye de forma significativa mientras que el error en el conjunto de prueba comienza a incrementar, existe un fenómeno de sobreentrenamiento.

En este escenario, la red neuronal deja de capturar los patrones generales subyacentes en los datos y comienza a ajustar de manera excesiva el conjunto de entrenamiento, comprometiendo su capacidad predictiva ante datos no observados (Figura 27).

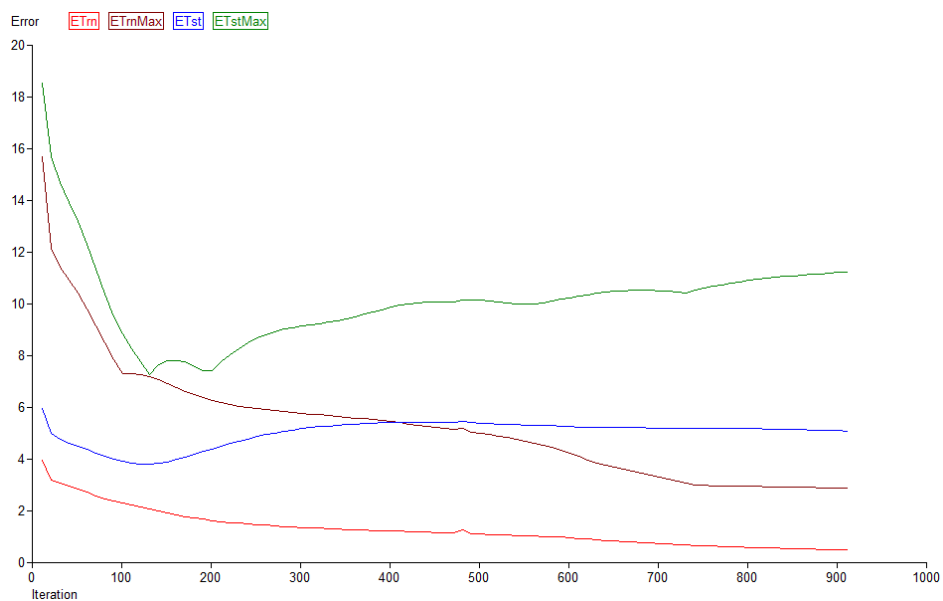


Figura 27: Sobreentrenamiento de un modelo neuronal. Donde el error del conjunto de entrenamiento (rojo) se reduce mientras que el del conjunto de prueba (azul) aumenta.

## 6. Resultados

De acuerdo con la metodología antes mencionada, se realizó el entrenamiento de tres modelos neuronales independientes para cada una de las componentes NS, EW y V. Cada modelo fue configurado con una arquitectura diferente, comenzando con tres capas ocultas y de manera paulatina se fueron reduciendo hasta quedar con una sola capa.

Se realizaron pruebas con alrededor de 50 arquitecturas. Durante el entrenamiento se realizó un monitoreo constante para evitar el sobreentrenamiento del modelo. A continuación, se muestran las arquitecturas que según los siguientes criterios tuvieron un mejor desempeño.

Criterios de Evaluación:

- a) RMSE menor a  $5 \text{ m/s}^2$  y un factor de correlación mayor a 0.75 para el conjunto de entrenamiento.
- b) RMSE menor a  $10 \text{ m/s}^2$  para el conjunto de prueba.

### Componente Norte-Sur (NS).

En la Tabla 8 se muestran las arquitecturas con mejor desempeño, de acuerdo con las métricas antes establecidas. En la Figura 28 se muestra la comparación entre el valor de aceleración real y el estimado por la red, con la arquitectura con mejor desempeño  $5 \times 20 \times 10 \times 1$ , además se señala la recta ideal.

Para el entrenamiento de la red neuronal se estableció un límite de 1500 épocas, dado que el modelo requería continuar el proceso de optimización para alcanzar un mejor desempeño. En particular, los modelos entrenados con el método de normalización Min-Max mostraron dificultades para ajustar los pesos de manera óptima, lo que se refleja en errores del orden de  $5 \text{ cm/s}^2$  y coeficientes de correlación que oscilan entre 0.71 y 0.9.

A pesar de que durante el entrenamiento los modelos normalizados con Min-Max alcanzaron un desempeño razonable, en la etapa de prueba se evidenció una clara falta de generalización, que se observa en errores elevados y coeficientes de correlación bajos (con un mínimo de 0.61). Esto indica que ninguno de estos modelos cumple con los estándares requeridos para un buen entrenamiento.

En los modelos entrenados utilizando normalización z, se observó, en términos generales, una mejor convergencia del error durante el proceso de entrenamiento. Con excepción del modelo de tres capas ocultas, las demás arquitecturas presentaron valores bajos de RMSE y coeficientes de correlación altos, alcanzando valores de hasta 0.97 en el conjunto de entrenamiento.

Si bien estos resultados indican un ajuste adecuado del modelo a los datos de entrenamiento, dicha mejora no se refleja con la misma proporción en el conjunto de prueba, donde los errores se mantienen en valores similares a los obtenidos con Min-Max. Este comportamiento sugiere que la reducción del error en entrenamiento no necesariamente implica una mejora equivalente en la capacidad de generalización del modelo.

El mejor modelo fue el entrenado por normalización z de arreglo 5x20x10x1 con un RMSE de 2.51 [cm/s<sup>2</sup>] y coeficiente de 0.96 para el entrenamiento, y al ser probado los resultados fueron de 4.64 [cm/s<sup>2</sup>] y 0.83, lo cual indica un buen desempeño.

Tabla 8. Arquitecturas con mejor desempeño componente NS

Min-Max		Entrenamiento		Prueba	
Arquitectura	No. Épocas	RMSE [cm/s <sup>2</sup> ]	Coef. Corr.	RMSE [cm/s <sup>2</sup> ]	Coef. Corr.
5x5x5x1	1000	5.49	0.81	6.2	0.7
5x10x10x10x1	1042	6.55	0.71	6.3	0.61
5x10x5x1	1000	5.78	0.79	8.83	0.45
5x20x20x1	1500	4.52	0.88	6.2	0.68
5x50x20x1	1500	4.08	0.9	7.09	0.64

Normalización Z		Entrenamiento		Prueba	
Arquitectura	No. Épocas	RMSE [cm/s <sup>2</sup> ]	Coef. Corr.	RMSE [cm/s <sup>2</sup> ]	Coef. Corr.
5x20x10x1	1414	2.51	0.96	4.64	0.83
5x10x10x10x1	1500	5.22	0.83	8.87	0.52
5x10x5x1	1500	3.03	0.94	6.82	0.72
5x20x20x1	760	2.20	0.97	5.4	0.74
5x50x20x1	791	2.19	0.97	5.62	0.68

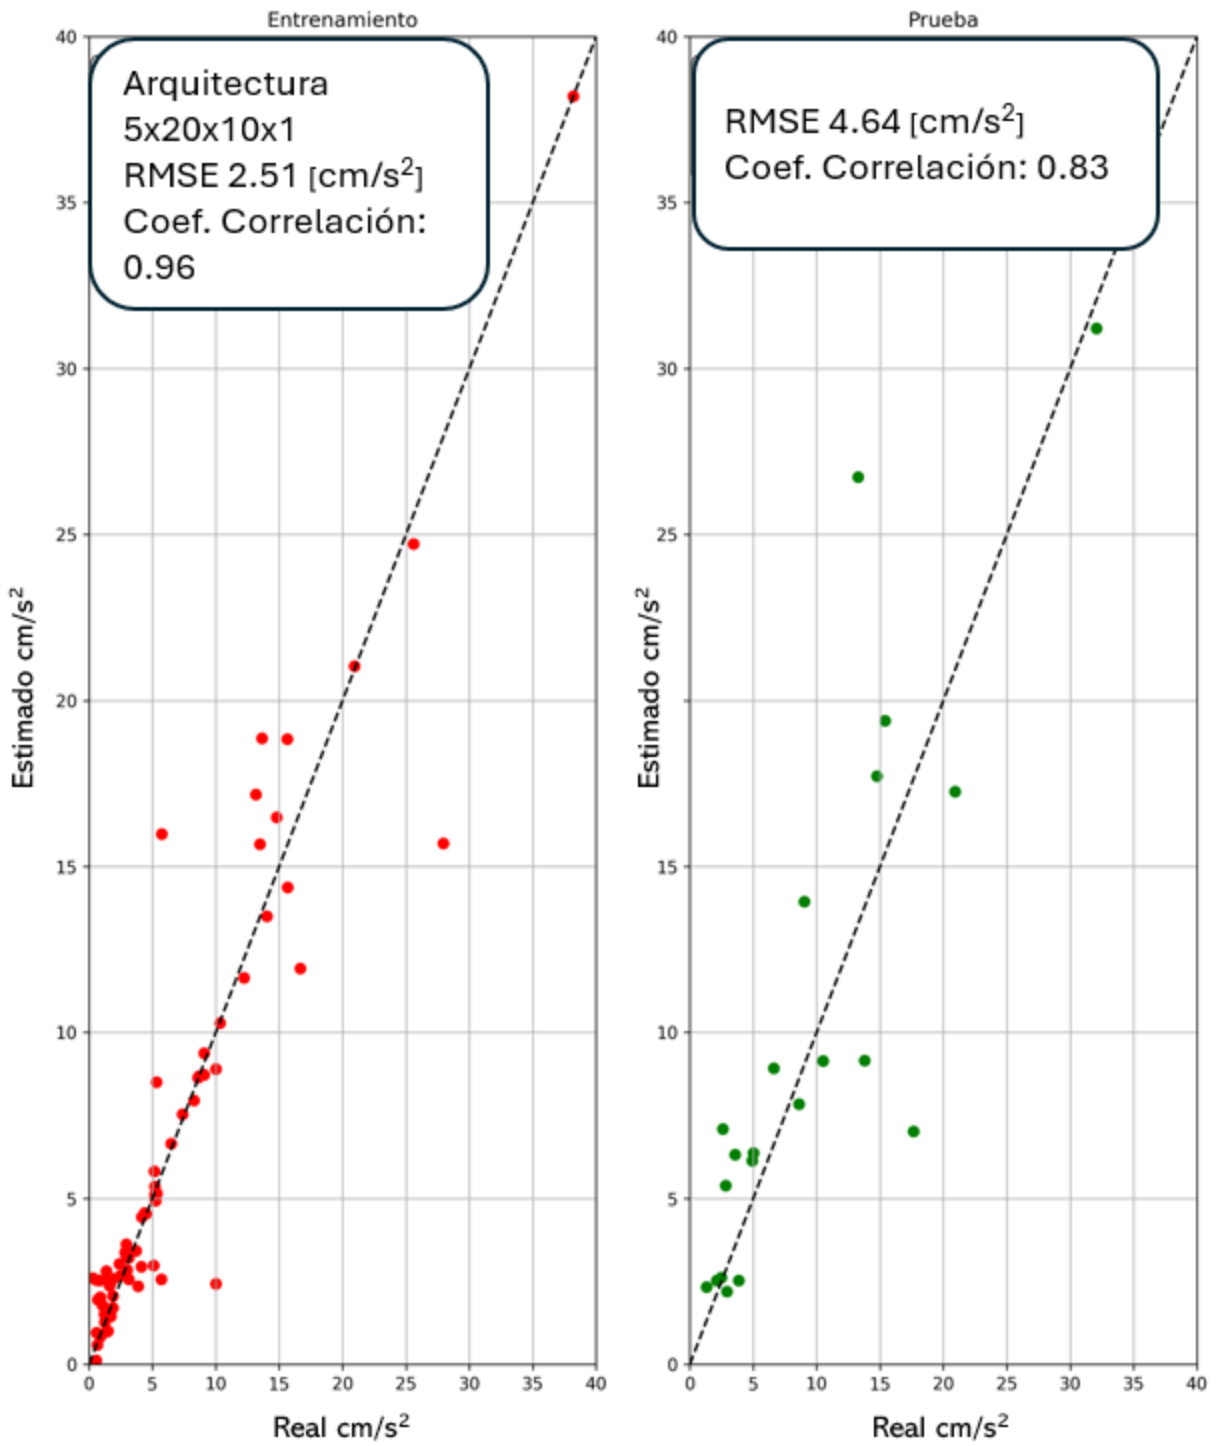


Figura 28: Distribución de los estimados vs reales NS

### **Componente Este-Oeste (EW).**

El modelo generado para la componente EW fue entrenado, en la Tabla 9 se muestran los resultados obtenidos por las arquitecturas con mejor desempeño.

Aquellas entrenadas con un preprocesamiento Min-Max, para el conjunto de entrenamiento se observa que no superan las 1000 épocas antes de presentarse un sobreentrenamiento, ninguna logra reducir el RMSE a menos de los 2 [cm/s<sup>2</sup>], y los coeficientes de correlación se encuentran entre 0.85 y 0.92.

Cuando se ponen a prueba estos modelos su RMSE aumenta, en algún caso llegando hasta los 6 [cm/s<sup>2</sup>], pero los coeficientes de correlación no son del todo malos, un coeficiente de correlación de 0.85 puede indicar una relación fuerte entre valor estimado y el real, acompañado de un error de 4.44 [cm/s<sup>2</sup>], puede indicar el éxito de la arquitectura 5x100x70x20x1.

De manera general se observa que para el método Min-Max, la reducción de nodos y capas no favorece del todo al entrenamiento.

Los modelos entrenados con la normalización z, en comparación necesitaron menos épocas para alcanzar errores más pequeños, es evidente que estos modelos ajustan de mejor forma las muestras utilizadas en el entrenamiento, ya que los coeficientes de correlación de 0.99 y 0.97, acompañados de errores pequeños menores a 1.8 [cm/s<sup>2</sup>].

El modelo creado para la componente EW con arquitectura 5x10x10x1, tuvo un comportamiento excelente, el modelo logra identificar un patrón generalizable y representativo del fenómeno, logra una fuerte relación entre las aceleraciones estimada y las reales. El modelo es considerado excelente, muestra todas las señales de un buen entrenamiento, realiza estimaciones adecuadas de manera homogénea para los tres rangos de aceleraciones seleccionados (Figura 29). Un error de 1.71 [cm/s<sup>2</sup>] y un coeficiente de correlación de 0.97 muestran un buen entrenamiento, acompañado de un error de 4.61 [cm/s<sup>2</sup>] y 0.87 para el conjunto de prueba, confirma lo anterior, un entrenamiento exitoso.

Tabla 9. Arquitecturas con mejor desempeño para la componente EW

Min-Max		Entrenamiento		Prueba	
Arquitectura	No. Épocas	RMSE [cm/s <sup>2</sup> ]	Coef. Corr.	RMSE [cm/s <sup>2</sup> ]	Coef. Corr.
5x100x70x20x1	792	3.53	0.86	4.44	0.85
5x10x70x20x1	902	2.84	0.91	4.44	0.8
5x30x30x30x5	644	2.79	0.92	5.38	0.79
5x10x10x1	531	3.25	0.88	6.42	0.7
5x5x1	1000	3.6	0.85	5.64	0.75
Normalización Z		Entrenamiento		Prueba	
Arquitectura	No. Épocas	RMSE [cm/s <sup>2</sup> ]	Coef. Corr.	RMSE [cm/s <sup>2</sup> ]	Coef. Corr.
5x100x70x20x1	384	0.9	0.99	7.47	0.62
5x20x20x20x1	397	1.65	0.97	5.28	0.81
5x10x10x1	681	1.71	0.97	4.61	0.87
5x5x5x1	755	1.72	0.97	6.05	0.85
5x10x1	1000	1.7	0.97	7.01	0.79

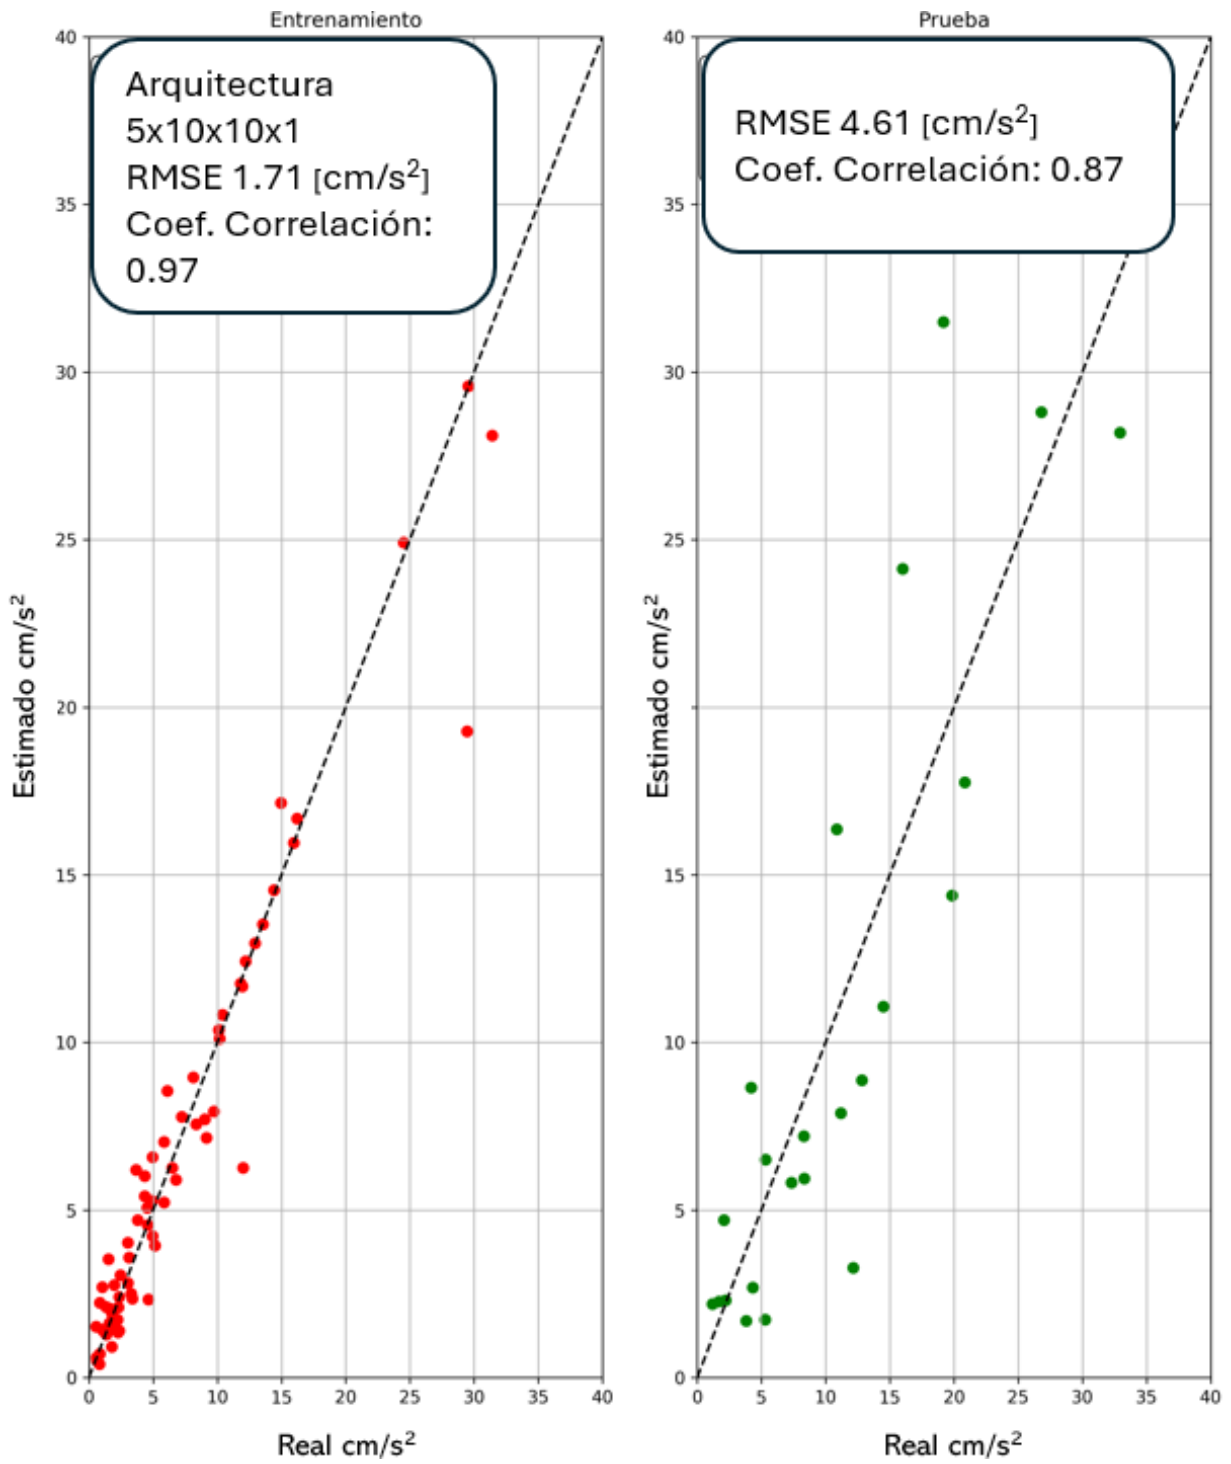


Figura 29: Distribución de los estimados vs reales EW

### **C) Componente Vertical (V).**

El modelo empleado para la componente vertical fue entrenado de la misma forma que los modelos anteriores, a primera vista se observa que los coeficientes de correlación en comparación, con los modelos para las otras componentes es peor (Tabla 10).

En esta componente se observan mayor número de casos donde, aunque se trató de evitarlo, este es evidente, se observa un error muy pequeño de 0.79 [cm/s<sup>2</sup>] y un coeficiente de 0.99, pero cuando el modelo es puesto a prueba el error aumenta hasta los 4.06 [cm/s<sup>2</sup>], y el coeficiente es de 0.68.

El mejor modelo de acuerdo con el criterio establecido fue el modelo con el método Min-Max de arreglo 5x10x20x10x1, con un coeficiente de 0.91 para el entrenamiento y de 0.8 para la prueba (Figura 30).

Tabla 10. Arquitecturas con mejor desempeño para la componente V

Min-Max		Entrenamiento		Prueba	
Arquitectura	No. Épocas	RMSE [cm/s <sup>2</sup> ]	Coef. Corr.	RMSE [cm/s <sup>2</sup> ]	Coef. Corr.
5x100x100x100x1	1425	1.95	0.91	3.97	0.71
5x20x10x10x1	1500	2.69	0.82	3.26	0.8
5x40x40x1	724	2.55	0.83	4.3	0.64
5x10x10x1	1101	2.56	0.83	5.21	0.63
5x10x1	621	2.64	0.82	4.94	0.62
Normalización z		Entrenamiento		Prueba	
Arquitectura	No. Épocas	RMSE [cm/s <sup>2</sup> ]	Coef. Corr.	RMSE [cm/s <sup>2</sup> ]	Coef. Corr.
5x60x80x1	642	0.79	0.99	4.06	0.68
5x12x6x1	600	2.35	0.86	3.68	0.76
5x50x40x40x1	526	1.63	0.94	5.1	0.58
5x10x10x10x1	691	1.89	0.91	5.27	0.56
5x5x1	1391	2.45	0.85	4.31	0.65

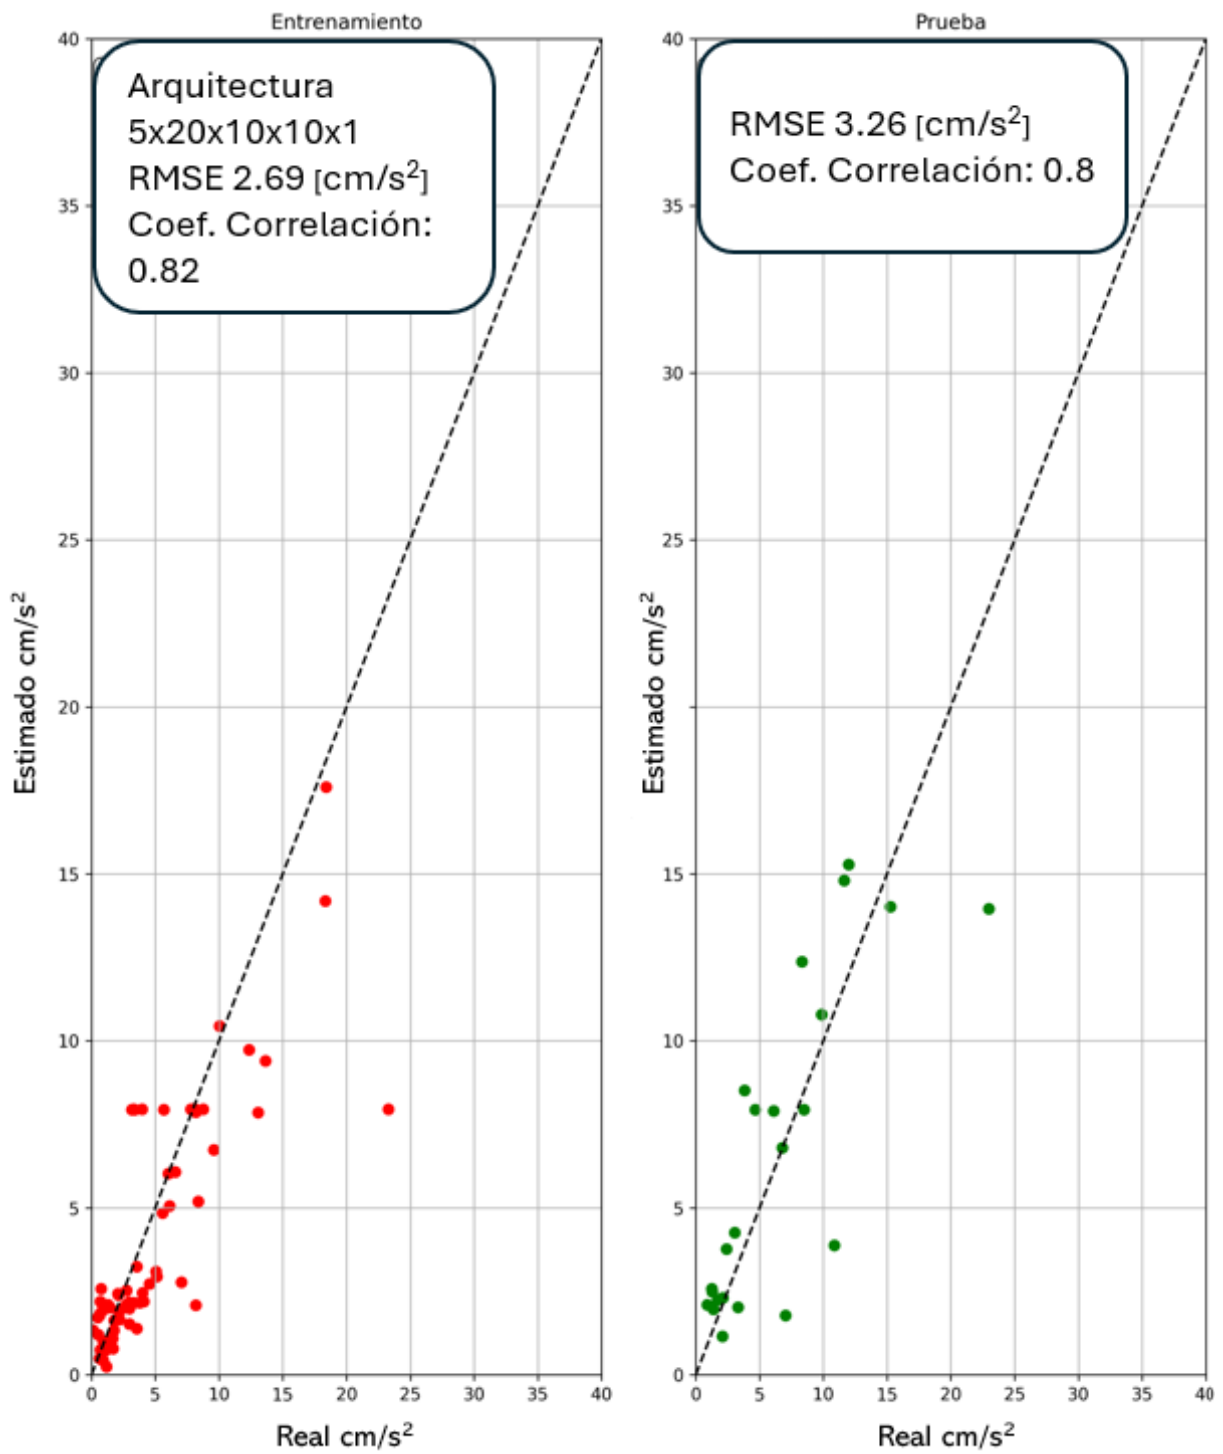


Figura 30: Distribución de los esperados vs reales V

Los pesos que producen un mejor resultado son encontrados por la red neuronal, debido a que estos son determinados para cada uno de los nodos presentes en cada capa oculta. Se tienen alrededor de 183 pesos para la componente EW, y de 451 para la componente V. Los pesos de los tres modelos se presentan en el Anexo, a modo representativo se muestra la matriz de pesos de la primera capa oculta del modelo generado para la componente EW (Tabla 11). Cada fila representa los pesos y valor de sesgo para cada uno de los nodos, en este caso se muestra el peso de los 5 parámetros y de sesgo para los 10 nodos de la primera capa del modelo EW cuya arquitectura 5x10x10x1.

*Tabla 11. Matriz de pesos para la primera capa oculta.*

-2.333908	-5.768762	0.84663	-2.654851	0.136973	-0.660483
-8.282536	8.923489	1.739368	3.212859	-3.34226	-0.778386
4.739797	-5.467207	1.195512	1.576692	-10.739918	-0.252292
-3.603095	9.872941	-2.688708	-3.530039	-0.600396	3.410954
-5.5871	1.049081	-0.186273	-5.054025	0.852417	8.379009
-1.620397	4.208426	-2.586593	0.451169	3.23104	-4.162406
-6.828882	1.374732	1.871263	-1.265097	-2.292424	-0.907083
-0.447753	-1.661436	-3.10765	6.776054	10.182472	14.583689
-2.817663	4.176499	4.158332	-0.983281	-6.186808	-3.590004
1.75579	-6.976875	0.423971	2.280369	3.177633	-8.638897

Para conocer la importancia e influencia relativa que tienen cada uno de los parámetros de entrada (M, De, Pf, Az, Ts) en la aceleración del terreno según el modelo neuronal, se realizó un análisis de sensibilidad, el cual permite conocer la forma en que la red neuronal utiliza la información disponible y cómo podríamos mejorar la generalización del modelo. Este proceso se lleva a cabo con los pesos de conexión finales.

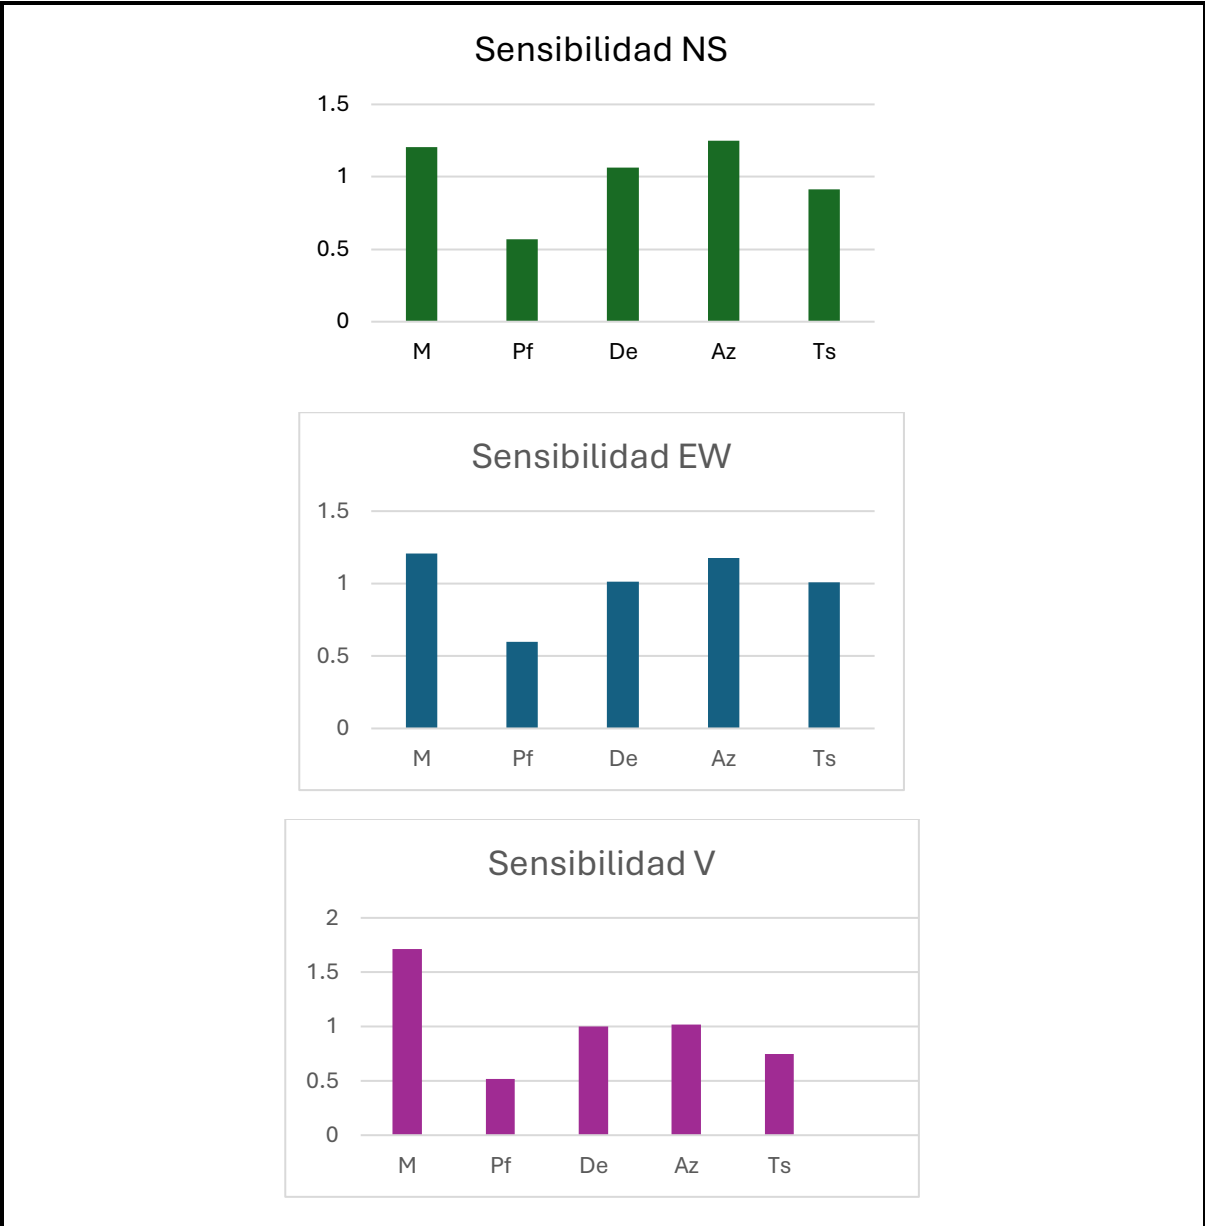


Figura 31: Análisis de sensibilidad

## 7. Conclusiones

A través de un conjunto de registros, producidos por sismos en la Ciudad de México en un radio máximo de 18.5 km y de magnitud menor a 4, detectados por la red de equipos del Centro de Instrumentación y Registro Sísmico (CIRES), se consiguió desarrollar tres modelos neuronales capaces de estimar las aceleraciones máximas registradas por seis estaciones distribuidas en la Ciudad de México.

Se analizaron más de 500 registros con la finalidad de eliminar aquellos cuya calidad no permitiera distinguir entre las aceleraciones generadas por sismos y aquellas generadas por el ruido, contando finalmente con 410 registros de superficie.

Se llevó a cabo un análisis estadístico de datos que incluyó la generación de histogramas, diagrama de caja y “bigotes”, y la obtención de sus estadísticos. Estas herramientas mostraron el comportamiento general de los datos recopilados, el análisis mostró que el número y rango de aceleraciones que presentan algunas estaciones no es representativo, problema que fue solucionado seleccionando únicamente registros de 6 estaciones, lo que provocó una reducción en el número de muestras. Finalmente, todos los modelos fueron entrenados con un total de 95 registros, 72 fueron destinados al conjunto de entrenamiento y 23 al de prueba.

Se realizaron tres modelos para cada una de las componentes: la componente Norte-Sur (NS), la componente Este-Oeste (EW) y la componente Vertical (V). Cada uno de los modelos fue entrenado con los parámetros sísmicos que se considera tienen una mayor influencia en el fenómeno. Los cuales son la Magnitud (M), la Distancia Epicentral (De), la Profundidad (Pf), el Azimut (Az) y el Periodo del sitio (Ts), estos fueron utilizados como parámetros de entrada a la red.

Para encontrar el mejor modelo, primero se entrenaron redes con tres capas ocultas, y luego se fueron reduciendo el número de capas y nodos hasta encontrar el máximo equilibrio entre ajuste y generalización. Se utilizó una función de transferencia sigmoide y el algoritmo de retropropagación como regla de aprendizaje.

Los modelos presentados cumplieron con las expectativas esperadas, ya que logran recrear el fenómeno, especialmente la componente EW, que es capaz de estimar de manera muy precisa con un coeficiente de correlación de 0.87. Lo anterior indica que, con la información disponible, la red neuronal logró realizar un ajuste en los pesos sinápticos para, de forma adecuada, estimar las aceleraciones máximas en la estación.

Los resultados obtenidos indican que estos modelos pueden servir como base para el desarrollo de futuras redes neuronales. No obstante, resulta necesario ampliar la base de datos utilizada en el entrenamiento con el fin de mejorar el desempeño y la capacidad predictiva de los modelos.

Se ha destacado la capacidad del modelo para efectuar una buena estimación; sin embargo, es de suma importancia señalar las carencias y limitaciones que los modelos presentaron, y por qué necesitan seguirse desarrollando y fortaleciendo.

- a) El pequeño número de registros. Si bien convencionalmente, las redes neuronales tienden a ser entrenadas con extensos conjuntos de datos, se pueden entrenar modelos con bases de datos más reducidas como lo demuestran diferentes autores y el presente documento; sin embargo, es recomendable tener una mayor cantidad de datos para que la red tenga más precisión y una mayor confiabilidad.
- b) El modelo no será capaz de estimar aceleraciones mayores a los 50  $\text{cm/s}^2$ . La base de datos con la que se cuenta no presenta aceleraciones mayores a los 70  $\text{cm/s}^2$ , la red es entrenada con aceleraciones aun menores. Los microsismos que han generado los mayores movimientos, arriba de los 100  $\text{cm/s}^2$ , no han generado esas aceleraciones en ninguna estación del CIRES, por lo que sería apropiado incluir otras estaciones y otras redes de monitoreo. Por ejemplo, las estaciones manejadas por el Servicio Sismológico Nacional, con esa nueva información la red podría ser capaz de estimar aceleraciones mayores.
- c) El modelo sólo es aplicable en una pequeña área al poniente de la Ciudad. Aunque en un principio, el objetivo era crear un modelo que fuera capaz de realizar predicciones en toda la Cuenca de la Ciudad de México, se presentaron inconvenientes que terminaron por reducir la región de aplicabilidad de la red, primero solo se cuentan con estaciones dentro de la Ciudad de México, y finalmente la solución ideada para resolver el desbalanceo de clases terminó por limitar el área de acción de la red a una pequeña área del poniente de la ciudad, o en su caso a un área de condiciones geológicas y geotécnicas idénticas o muy similares a la misma, por lo que, no se debe aplicar para cualquier lugar de la Ciudad de México.

Finalmente, el presente trabajo busca coadyuvar al conocimiento de los sismos locales en la capital, y promover el uso de la inteligencia artificial como herramienta que puede ser muy útil para mitigar los daños que estos fenómenos pueden causar. Resaltar el uso de nuevas metodologías con herramientas de inteligencia artificial para afrontar problemas con un enfoque nuevo, que, en otras áreas, ha probado ser eficaz, por lo que su uso debe ser incentivado.

## Referencias

- Aguilar-Velázquez, M. J., Miranda-García, P., Cruz-Atienza, V. M., Solano Rojas, D., Tago, J., Domínguez, L. A., Villafuerte, C., Espíndola, V. H., Bello Segura, D., Quintanar-Robles, L., y Pertou, M. (2025). Interplay of slow-slip faults beneath Mexico City induces intense seismicity over months. *Tectonophysics*, 230659. <https://doi.org/10.1016/j.tecto.2025.230659>
- Alberro, J. Hernández, R. (1991). *Temblores inducidos por fuerzas de filtración* (Reporte técnico No. 530). Instituto de Ingeniería, Universidad Nacional Autónoma de México.
- Alcántara, L. (2013). *Análisis de los movimientos sísmicos en las ciudades de Oaxaca y Puebla con Redes Neuronales* (Tesis de Doctorado). División de Estudios de Posgrado, Facultad de Ingeniería, Universidad Nacional Autónoma de México, México. <https://hdl.handle.net/20.500.14330/TES01000693270>
- Arce, J. L., Layer, P., Martínez, I., Salinas, J. I., Macías-Romo, M. d. C., Morales-Casique, E., Benowitz, J., Escolero, O., y Lenhardt, N. (2015). Geología y estratigrafía del pozo profundo San Lorenzo Tezonco y de sus alrededores, sur de la Cuenca de México. *Boletín de la Sociedad Geológica Mexicana*, 67(2), 123–143.
- Boudal, C. y Robin, C. (1989). Volcán Popocatepetl: recent eruptive history and potential hazards and risks in future eruption. En J. H. Latter (Ed.), *Volcanic Hazards: Assessment and Monitoring* (pp. 110–128). Springer-Verlag.
- Campos-Enríquez, J. O., Lermo-Samaniego, J. F., Antayhua-Vera, Y. T., Chavacán, M., y Ramón-Márquez, V. M. (2015). The Aztlán Fault System: control on the emplacement of the Chichinautzin Range volcanism, southern Mexico Basin, Mexico. Seismic and gravity characterization. *Boletín de la Sociedad Geológica Mexicana*, 67(2), 315–335.
- Carter, R., Frith, C. D., Aguilar, F. G., y Guardiola, P. R. (2002). El nuevo mapa del cerebro. *El Nuevo Mapa del Cerebro*. <https://dialnet.unirioja.es/servlet/libro?codigo=394284>
- Chavacán, M. R. (2007). *Catálogo de sismicidad local para la Cuenca de México* (Tesis de Maestría). Universidad Nacional Autónoma de México.
- Cserna, Z. d. (1988). *Estructura geológica, gravimetría, sismicidad y relaciones neotectónicas regionales de la Cuenca de México: proyecto de investigación desarrollado*

bajo los auspicios del Consejo Nacional de Ciencia y Tecnología (PCECCNA-040323). Inst. de Geología.

Cybenko, G. (1989). Approximation by superpositions of a sigmoidal function. *Mathematics of Control, Signals, and Systems*, 2(4), 303–314.

Delgado-Granados, H., Nieto-Obregón, J., Silva-Romo, G., Mendoza-Rosales, C., Arellano-Gil, J., Lermo-Samaniego, J. F., y Rodríguez- González, M. (1995). La Pera detachment fault system: active faulting south of Mexico City: geological evidence (II). En *Reunión Anual de la Unión Geofísica Mexicana* (p. 64). GEOS.

Drummond, C., y Holte, R. C. (2003). C4.5, class imbalance, and cost sensitivity: Why under-sampling beats over-sampling. In *Workshop on Learning from Imbalanced Datasets II* (Vol. 11, pp. 1–8). Citeseer.

Enciso-De la Vega, S. (1992). Propuesta de nomenclatura estratigráfica para la cuenca de México. *Revista del Instituto de Geología, Universidad Nacional Autónoma de México*, 10(1), 26–36.

Ferrari, L., Orozco-Esquivel, T., Manea, V., y Manea, M. (2011). The dynamic history of the Trans-Mexican Volcanic Belt and the Mexico subduction zone. *Tectonophysics*, 522-523, 122–149. <https://doi.org/10.1016/j.tecto.2011.09.018>

Figuroa, J. (1971). *Sismicidad en la cuenca del Valle de México* (Serie de Investigación No. 289). Universidad Nacional Autónoma de México, Instituto de Ingeniería, Facultad de Ingeniería, División de Investigación.

Flórez-López, R. y Fernández-Fernández, J. M. (2008). *Las Redes Neuronales Artificiales: fundamentos teóricos y aplicaciones prácticas*. Netbiblo, S.L.

Fries, C. Jr. (1960). Geología del Estado de Morelos y de partes adyacentes de México y Guerrero, Región central Meridional de México: Boletín del Instituto de Geología 60, 236

Fries, C. J. (1966). *Resumen de la geología de la Hoja Pachuca, Estados de Hidalgo y México*. Instituto de Geología, Universidad Nacional Autónoma de México.

García de Aquino, J. (2017). *Estimación de parámetros sísmicos por medio de redes neuronales artificiales*. Tesis de Licenciatura. Universidad Nacional Autónoma de México

García-Palomo, A., Zamorano, J. J., López-Miguel, C., Galván -García, A., Carlos Valerio, V., Ortega, R., y Macías, J. L. (2008). El arreglo morfoestructural de la Sierra de Las Cruces, México central. *Deleted Journal*, 25(1), 158–178.

<https://dialnet.unirioja.es/descarga/articulo/2553967.pdf>

- García-Tovar, G. P., y Martínez-Serrano, R. G. (2011). Geología y geoquímica de las lavas pleistocénicas del estratovolcán Telapón, Sierra Nevada, México. *Deleted Journal*, 28(2), 301–322. <https://dialnet.unirioja.es/descarga/articulo/3987739.pdf>
- García, Silvia R., Romo, Miguel P., & Mayoral, Juan M.. (2007). Estimation of peak ground accelerations for Mexican subduction zone earthquakes using neural networks. *Geofísica internacional*, 46(1), 51-62.
- González, J. J. y García-A., R. (1986). Escala de magnitud-coda para estaciones sismográficas en el norte de Baja California. En Memorias de la Reunión 1986 de la Unión Geofísica Mexicana, A.C. (pp. 399–406).
- Grupo de Trabajo de la Red Sísmica de la Ciudad de México. (2021, enero). Red Sísmica de la Ciudad de México. *Ciencia*, 72(1), 63–67.
- Gunn, B. M., y Mooser, F. (1970). Geochemistry of the volcanics of central Mexico. *Bulletin of Volcanology*, 34(2), 577–616. <https://doi.org/10.1007/bf02596772>
- Guo, X., Yin, Y., Dong, C., Yang, G., y Zhou, G. (2008). On the Class Imbalance Problem. *Fourth International Conference on Natural Computation, ICNC '08*, 192–201. <https://doi.org/10.1109/icnc.2008.871>
- Günaydın, K., y Günaydın, A. (2008). Peak Ground Acceleration Prediction by Artificial Neural Networks for Northwestern Turkey. *Mathematical Problems in Engineering*, 2008(1). <https://doi.org/10.1155/2008/919420>
- Hart, P. (1968). The condensed nearest neighbor rule (Corresp.). *IEEE Transactions on Information Theory*, 14(3), 515–516. <https://doi.org/10.1109/tit.1968.1054155>
- Havskov, J. (1982). The earthquake swarm of february 1981 in Mexico City. *Geofísica Internacional*, 21(2), 157–175.
- Hong, Hanping y Liu, Taojun & Lee, Chien-Shen. (2012). Observations on the application of artificial neural network to predicting ground motion measures. *Earthquake Science*. 25. [10.1007/s11589-012-0843-5](https://doi.org/10.1007/s11589-012-0843-5).
- Hornik, K. (1991). Approximation capabilities of multilayer feedforward networks. *Neural Networks*, 4(2), 251–257. [https://doi.org/10.1016/0893-6080\(91\)90009-t](https://doi.org/10.1016/0893-6080(91)90009-t)
- Husker, A., y Davis, P. M. (2009). Tomography and thermal state of the Cocos plate subduction beneath Mexico City. *Journal of Geophysical Research: Solid Earth*, 114(B4). <https://doi.org/10.1029/2008jb006039>

Jaimes, M. A., Lermo, J., y García-Soto, A. D. (2016). Ground-Motion Prediction Model from Local Earthquakes of the Mexico Basin at the Hill Zone of Mexico City. *Bulletin of the Seismological Society of America*, 106(6), 2532– 2544. <https://doi.org/10.1785/0120150283>

Junger, A. (1964). Signal-to-noise ratio and record quality. *Geophysics*, 29(6), 922–925.

Kerh, Tienfuan y Ting, S.. (2005). Neural network estimation of ground peak acceleration at stations along Taiwan high-speed rail system. *Eng. Appl. of AI*. 18. 857-866. 10.1016/j.engappai.2005.02.003.

Lermo, J., Santoyo, M. A., Jaimes, M. A., Antayhua, Y., y Chavacán, M. (2016). Local Earthquakes of the Mexico Basin in Mexico City:  $\kappa$ ,  $Q$ , Source Spectra, and Stress Drop. *Bulletin of the Seismological Society of America*, 106(4), 1423– 1437. <https://doi.org/10.1785/0120150189>

Logical Designs (1996), Thinks Pro Neural Networks for Windows, User guide,USA.

Lugo-Hubp, J., Zamorano-Orozco, J. J., Mooser, F., y Pérez-Vega, A. (1994). Geomorfología de la sierra de Santa Catarina, D.F., México. *Revista Mexicana de Ciencias Geológicas*, 11(1), 43–52. <https://repositorio.unam.mx/contenidos/4119913>

Manzanilla, L. (1986). Relación de los sismos ocurridos en la ciudad de México y sus efectos. *Revista Mexicana de Sociología*, 48(2), 265–282. <https://doi.org/10.22201/iis.01882503p.1986.2.61588>

Marsal, R. J. y Mazari, M. (2016). *El subsuelo de la Ciudad de México* (Vol. 1). Instituto de Ingeniería, UNAM.

Martin-del-Brío, B. y Sanz, A. (2006). *Redes neuronales y sistemas borrosos* (3ra ed.). Rama S.A. Editorial y Publicaciones.

McCarthy, J., Minsky, M. L., Rochester, N., y Shannon, C. E. (2006). A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence, August 31, 1955. *AI Magazine*, 27(4), 12. <https://doi.org/10.1609/aimag.v27i4.1904>

McCulloch, W. S., y Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics*, 5(4), 115–133. <https://doi.org/10.1007/bf02478259>

Mooser, F. (1963). Historia tectónica de la cuenca de México. *Boletín de la Asociación Mexicana de Geólogos Petroleros*, 15, 239–246.

- Mooser, F. (1975). Historia geológica de la Cuenca de México. En *Memoria de las obras del sistema de drenaje profundo del Distrito Federal* (Vol. 1, pp. 7–38). Departamento del Distrito Federal. [Incluye mapa geológico]
- Mooser, F. (1987). Geología. En G. Garza (Ed.), *Atlas de la Ciudad de México* (pp. 23–29). Departamento del Distrito Federal and El Colegio de México.
- Mooser, F., y Montiel, A. (1989). El relleno Post-Chichinautzin del Valle de México y su relación con la intensidad sísmica. En *Memorias del Simposio sobre Tópicos Geológicos de la Cuenca del Valle de México* (pp. X–XX). Sociedad Mexicana de Mecánica de Suelos, A.C., Ciudad de México.
- Méndez-Sánchez, E. (2003). *Aplicación de la geoinformática a la zonificación del subsuelo de la Cuenca de México* (Tesis de Maestría). Universidad Nacional Autónoma de México, Ciudad de México, México.
- NTC-DS. (2017). Normas técnicas complementarias para el diseño por sismo. Gaceta Oficial, Departamento del Distrito Federal 2017.
- PEMEX. (1988). *Cortes litológicos y registros geofísicos de los pozos profundos exploratorios Roma-1, Mixhuca-1, Tulyehualco-1 y Copilco-1*. Fundación J. Barros Sierra, A. C.
- Peña-Díaz, Salvador. (2019). Condiciones hídricas en la cuenca del Valle de México. *Tecnología y ciencias del agua*, 10(2), 98-127.
- Pérez-Cruz, G. (1988). *Estudio sismológico de reflexión del subsuelo de la Ciudad de México* (Tesis de Maestría en Ingeniería). Universidad Nacional Autónoma de México, División de Estudios de Posgrado de la Facultad de Ingeniería.
- Pozos-Estrada, Adrián, Gómez, Roberto, & Hong, H.P. (2014). Use of Neural network to predict the peak ground accelerations and pseudo spectral accelerations for Mexican Inslab and Interplate Earthquakes. *Geofísica internacional*, 53(1), 39-57.
- Purves, D., Augustine, G., Fitzpatrick, D., Hall, W. C., LaMantia, A., Mooney, R., y White, L. E. (2018). *Neuroscience* (6ta ed.). Sinauer Associates.
- Quintanar, L., Cárdenas -Ramírez, A., Bello-Segura, D. I., Espíndola, V. H., Pérez-Santana, J. A., Cárdenas-Monroy, C., Carmona-Gallegos, A. L., y Rodríguez -Rasilla, I. (2018). A Seismic Network for the Valley of Mexico: Present Status and Perspectives. *Seismological Research Letters*, 89(2A), 356–362. <https://doi.org/10.1785/0220170198>

Quintanar, L., Singh, S. K., Espíndola, V. H., Iglesias, A., Segura, D. I. B., y Arroyo, D. (2024). México City Earthquake of 11 May 2023 (Mw3.2). *Geofísica Internacional*, 63(2), 749–762. <https://doi.org/10.22201/igeof.2954436xe.2024.63.2.1757>

Reinoso, E. (2007) “Características sísmicas de la Ciudad de México: Amplificación de las ondas sísmicas en el Valle de México, características del movimiento del terreno y microzonificación de la Ciudad”.

Rodríguez, M., Lermo, J., Chávez, F., y Castro, R. (1984). *El temblor del 7 de febrero de 1984 en Juchitepec, México: Reporte preliminar* (Reporte técnico). Instituto de Ingeniería, Universidad Nacional Autónoma de México.

Rosenblatt, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6), 386–408. <https://doi.org/10.1037/h0042519>

Rosenblueth, E., Singh, S. K., Ordaz, M., y Sánchez-Sesma, F. (1987). Espectros de diseño para el Distrito Federal. En *Memorias del VII Congreso Nacional de Ingeniería Sísmica* (pp. A1–A17). Querétaro, México.

Rosenzweig, M. R., Leiman, A. L., Breedlove, S. M., Morgado Bernal, I., y Soler, J. (2001). *Psicología biológica: una introducción a la neurociencia conductual, cognitiva y clínica* (2da ed.). Editorial Ariel.

Rumelhart, D. E., Hinton, G. E., y Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323(6088), 533–536. <https://doi.org/10.1038/323533a0>

Rumelhart, D. E., y McClelland, J. L. (1986). *Parallel distributed processing: explorations in the microstructure of cognition, vol. 1: foundations*. MIT Press. <https://dl.acm.org/citation.cfm?id=104279>

Santoso, B., Wijayanto, H., Notodiputro, K. A., y Sartono, B. (2017a). Synthetic Over Sampling Methods for Handling Class Imbalanced Problems: A Review. *IOP Conference Series: Earth and Environmental Science*, 58, 012031. <https://doi.org/10.1088/1755-1315/58/1/012031>

Santoyo-Villa, E., Ovando Shelley, E., Mooser, F., y León Plata, E. (2005). *Síntesis geotécnica de la Cuenca del Valle de México*. TGC Geotecnia.

Siebe, C., Rodríguez-Lara, V., Schaaf, P., y Abrams, M. (2004). Radiocarbon ages of Holocene Pelado, Guespalapa, and Chichinautzin scoria cones, south of Mexico City: implications for archaeology and future hazards. *Bulletin of Volcanology*, 66(3), 203–225. <https://doi.org/10.1007/s00445-003-0304-z>

Singh, S. K., Anderson, J. G., y Rodríguez, M. (1998). Triggered seismicity in the Valley of Mexico from major Mexican earthquakes. *Geofísica Internacional*, 37(1), 3–15. <https://doi.org/10.22201/igeof.00167169p.1998.37.1.2155>

Singh, S. K., Quintanar-Robles, L., Arroyo, D., Cruz-Atienza, V. M., Espíndola, V. H., Bello-Segura, D. I., y Ordaz, M. (2020). Lessons from a Small Local Earthquake (Mw 3.2) That Produced the Highest Acceleration Ever Recorded in Mexico City. *Seismological Research Letters*, 91(6), 3391–3406. <https://doi.org/10.1785/0220200123>

Sinnott, R. W. (1984). Virtues of the Haversine. *Sky and Telescope*, 68(2), 159.

Suter, M., Martínez, M. L., Legorreta, O. Q., y Martínez, M. C. (2001). Quaternary intra-arc extension in the central Trans-Mexican volcanic belt. *Geological Society of America Bulletin*, 113(6), 693–703.

Torres, E. A. G., Zenteno, D. J. M., Mori, L., y Martiny, B. M. (2015). Revisión de los últimos eventos magmáticos del Cenozoico del sector norte-central de la Sierra Madre del Sur y su posible conexión con el subsuelo profundo de la Cuenca de México. *Boletín de la Sociedad Geológica Mexicana*, 67(2), 285–297.

Turing, A. (2004). *Computing Machinery and Intelligence* (1950). En *Oxford University Press eBooks* (pp. 433–464). <https://doi.org/10.1093/oso/9780198250791.003.0017>

UNAM and CENAPRED Seismology Group. (1995). The Milpa Alta earthquake Of January 21, 1995. *Geofísica Internacional*, 34(4), 355–362

Vázquez-Sánchez, E., y Jaimes Palomera, R. A. (1989). Geología de la Cuenca de México. *Geofísica Internacional*, 28(2), 133–190. <https://doi.org/10.22201/igeof.00167169p.1989.28.2.1026>

Vásquez-Serrano, A., Camacho-Rangel, R., Arce-Saldaña, J. L., y Morales Casique, E. (2019). Análisis de fracturas geológicas en el pozo Agrícola Oriental 2C, Ciudad de México y su relación con fallas mayores. *Revista Mexicana de Ciencias Geológicas*, 36(1), 38–53. <https://doi.org/10.22201/cgeo.20072902e.2019.1.871>

Widrow, B., y Hoff, M. E. (1960, agosto). Adaptive switching circuits. En *1960 IRE WESCON Convention Record, Part 4* (pp. 96–104). Institute of Radio Engineers.

# Anexos

Tabla 1A Conjunto de Prueba EW.

Tabla 1B Conjunto Entrenamiento EW.

Tabla 1C Matriz de Pesos WE

Tabla 2A Conjunto de Prueba NS.

Tabla 2B Conjunto Entrenamiento NS.

Tabla 2C Matriz de Pesos NS

Tabla 3A Conjunto de Prueba V

Tabla 3A Conjunto Entrenamiento V

Tabla 3C Matriz de Pesos V

Tabla 1A. Conjunto de entrenamiento para la variable EW

M	h [km]	T	D [km]	Az [°]	Acel Real [m/s <sup>2</sup> ]	Acel Estim [m/s <sup>2</sup> ]
2	1	0.5	4.01	239.13	1.83	1.85444
2	1	1.5	1.77	73.94	0.83	2.23499
2.8	1	0.5	3.92	192.56	24.51	24.9223
3.2	1	0.5	3.25	243.38	29.54	29.5748
2.6	1	0.5	2.53	237.63	12.2	12.4271
2.3	1	0.5	1.24	255.12	13.55	13.5243
2.9	1	0.5	3.36	316.32	8.12	8.9572
2.9	14	0.5	15.22	43.33	7.22	7.77728
2.1	2	0.5	0.45	258.29	6.48	6.26401
2.8	1	0.5	3.25	234.76	6.09	8.55114
1.8	1	0.5	2.32	253.32	5.86	7.0343
1.3	2	0.5	1.25	273.07	5.84	5.23149
1.1	4	0.5	0.55	267.87	4.96	4.22374
1.8	1	0.5	3.33	253.32	4.64	2.33759
1.5	2	0.5	1.64	267.14	4.34	5.4186
2.3	1	0.5	4.58	247.87	1.89	1.4726
1.3	1	0.5	3.12	280.8	1.6	2.06773
2	1	0.5	4.17	248.52	1.58	1.50054
2.3	1	0.5	3.33	273.27	1.34	1.29372
1.3	1	0.5	3.46	258.23	1.31	2.11464
1.7	1	0.5	3.12	253.32	1.03	2.70406
3.3	1.1	0.8	3.01	283.26	16.21	16.6777
3.2	1	0.8	4.91	208.75	10.39	10.8212
3	1	0.8	4.91	208.75	6.77	5.90001
2.4	1	0.8	4.91	208.75	4.93	5.28483
2.5	3	0.8	1.96	280.45	4.54	5.0767
1.8	1	0.8	4.1	218.85	2.44	3.05702
2.9	1	0.8	4.02	220.07	4.35	6.01734
2.6	1	0.8	3.43	272.05	3.8	4.69967
3.1	11	0.8	2.18	21.13	3.01	4.03361
2.5	1	0.8	2.89	276.19	2.26	1.34764
2.4	1	0.8	3.72	268.81	1.77	0.917659
2.6	1	0.8	4.92	196.33	1.03	1.44269
3.2	1	1.6	2.27	8.5	14.95	17.1434
2.8	1	1.6	3.93	354.19	10.11	10.3754

M	h [km]	T	D [km]	Az [°]	Acel Real [m/s <sup>2</sup> ]	Acel Estim [m/s <sup>2</sup> ]
2.4	1	1.6	2.27	8.5	5.15	3.94182
2.8	1	1.6	2.27	8.5	3.65	6.19556
1.8	1	1.6	3.36	2.15	3.29	2.50144
1.9	1.6	1.6	2.12	38.17	3.01	2.82189
2.3	4	1.6	4.04	312.34	2.22	1.73866
2.3	1	1.6	2.47	335.41	1.59	1.621
2	2	1.6	3.5	329.77	0.83	0.719057
2.1	3	1.6	2.81	298.32	0.63	0.55146
2.3	1	1.6	3.51	52.47	0.54	1.52498
3	1	1.5	2.82	102.76	29.43	19.2827
2.8	1	1.5	2.44	55.6	12	6.26342
2.9	1	1.5	2.69	69.64	9.16	7.16102
2.3	4	1.5	0.61	288.14	3.13	3.5856
1.8	1	1.5	2.67	72.04	2.3	2.09651
2.8	1	1.5	2.76	96	4.94	6.58454
2.4	1	1.5	2.76	96	3.36	2.36182
2.6	1	1.5	3.79	100.81	4.57	4.5509
2.3	1	1.5	1.41	101.79	1.97	2.76888
1.9	1.6	1.5	3.82	103.1	1.16	1.37409
2.8	1	0.5	3.34	249.52	31.39	28.109
2.9	1	0.5	3.08	238.42	9.03	7.7042
3	1	0.5	3.71	220.15	15.94	15.9518
1.8	1	0.5	3.12	236.48	8.33	7.56412
2.4	1	0.5	3.71	220.15	10.18	10.1123
2	1	0.5	4.01	239.13	1.83	1.85444
2.3	1	0.5	2.95	178.98	1.72	1.99361
1.7	1	0.5	3.15	229.3	1.53	3.53833
2.8	1	0.7	4.12	261.94	12.92	12.9644
2.4	1	0.7	4.03	236.13	9.71	7.94555
3	1	0.7	4.03	236.13	11.95	11.6774
3.2	1	0.7	4.03	236.13	14.39	14.5419
3.1	11	0.7	4.1	357.21	11.82	11.756
1.8	1	0.7	3.73	252.32	2.35	2.41099
2.3	1	0.7	2.52	200.94	2.35	1.40298
2	1	0.7	4.63	251.54	0.82	0.406237
2.3	1	0.7	4.08	237.87	0.63	0.510384
2	1	0.7	2.83	227.51	0.58	0.599231

Tabla 1B. Conjunto de Prueba para la variable EW

M	h [km]	T	D [km]	Az [°]	Acel Real [m/s <sup>2</sup> ]	Acel Estim [m/s <sup>2</sup> ]
3.8	1	0.5	8.64	237.82	10.87	16.3641
3	1	0.5	3.25	110.35	32.92	28.1948
2.4	1	0.5	3.25	236.85	19.83	14.3857
2.2	1	0.5	3.5	262.43	5.27	1.73613
1.9	1.6	0.5	2.62	212.71	4.32	2.68535
1.8	1	0.5	3.46	253.32	1.19	2.19724
2.8	1	0.8	4.06	229.58	11.17	7.89148
3	1	0.8	5.2	206.98	7.33	5.81415
2.4	0.5	0.8	4.31	255.52	4.19	8.65699
3.4	2	1.6	1.74	310.63	12.16	3.28462
2.6	1	1.6	2.25	35.72	8.34	5.93895
3	1	1.6	2.27	8.5	5.33	6.51208
2.2	1	1.6	3.29	305.57	3.81	1.69711
1.5	2	1.6	3.47	62.97	1.7	2.27572
3.4	2	1.5	1.78	142.09	19.18	31.4994
3.2	1	1.5	2.76	96	16	24.13
2	1	1.5	0.81	53.05	2.2	2.30519
3.2	1	0.5	3.71	220.15	26.81	28.8125
3	1	0.5	3.97	217.05	20.82	17.7585
2.4	1.5	0.5	1.63	203.09	8.29	7.20586
3	1	0.7	4.23	232.38	14.48	11.0709
2.4	1.5	0.7	1.84	240.24	12.81	8.87683
2.6	1	0.7	3.57	221.62	2.08	4.70871

Tabla 1C. Pesos sinápticos

Nodo	Pesos iniciales-> 1ra Capa oculta					
1	-2.333908	-5.768762	0.84663	-2.654851	0.136973	-0.660483
2	-8.282536	8.923489	1.739368	3.212859	-3.34226	-0.778386
3	4.739797	-5.467207	1.195512	1.576692	-10.739918	-0.252292
4	-3.603095	9.872941	-2.688708	-3.530039	-0.600396	3.410954
5	-5.5871	1.049081	-0.186273	-5.054025	0.852417	8.379009
6	-1.620397	4.208426	-2.586593	0.451169	3.23104	-4.162406
7	-6.828882	1.374732	1.871263	-1.265097	-2.292424	-0.907083
8	-0.447753	-1.661436	-3.10765	6.776054	10.182472	14.583689
9	-2.817663	4.176499	4.158332	-0.983281	-6.186808	-3.590004
10	1.75579	-6.976875	0.423971	2.280369	3.177633	-8.638897

Nodo	1ra Capa -> 2da Capa					
1	-0.446277	-2.692707	0.855075	-0.874055	6.724502	2.859079
	1.173506	1.106692	-11.781223	-0.299442	-4.451211	
2	-2.017725	-1.244	-2.747387	-2.381311	2.75882	1.710666
	2.300619	-1.941658	-9.520978	-1.260142	-0.940579	
3	-1.857025	0.758381	4.7152	-7.354699	2.539942	-4.113113
	2.155956	1.481831	-5.806127	-1.927532	-4.733772	
4	1.809573	-1.626494	0.557772	4.425292	0.957667	-4.703182
	6.083823	0.399807	-9.01294	2.743184	1.490524	
5	3.438992	1.097929	-1.534569	0.720515	-0.533327	1.858442
	0.183055	-1.577662	-6.51721	3.137131	-1.590165	
6	-2.219977	0.686654	0.468301	-0.81561	0.667363	-1.742441
	0.219885	0.545077	-0.92649	0.017091	-0.675456	
7	0.605005	-1.554059	-1.498793	0.658273	-1.855774	-3.275694
	-0.623039	-0.259279	6.298554	-1.300055	1.092394	
8	0.56471	-2.633047	-0.291776	-4.160519	4.233401	4.171113
	0.954412	2.770813	-11.192815	-1.156592	-4.718693	
9	-2.903183	-1.362136	5.023555	-2.916124	4.766159	-6.509773
	5.428431	-2.048867	5.069779	-4.043233	-2.052355	
10	0.003391	1.594673	6.625473	1.227261	-5.364901	-1.45392
	0.366588	1.780702	-3.208412	0.252412	0.836863	

2da Capa -> Nodo de salida					
1.97582	9.591625	-9.967349	10.761747	-10.792247	5.774973
0.961718	-3.735438	9.372966	10.43427	8.120255	

Tabla 1B. Conjunto de entrenamiento para la variable NS

M	h [km]	T	D [km]	Az [°]	Acel Real [m/s <sup>2</sup> ]	Acel Estim [m/s <sup>2</sup> ]
3	1	0.7	4.23	232.38	27.95	17.7701
3.2	1	0.5	3.71	220.15	25.6	25.4544
2.8	1	0.5	3.34	249.52	43.01	36.1154
3.2	1	1.5	2.76	96	15.66	18.0332
3.8	1	0.5	8.64	237.82	8.63	8.23229
3	1	1.5	2.82	102.76	43.47	42.5475
2.4	1	0.7	4.03	236.13	14.03	13.0283
3	1	0.7	4.03	236.13	13.64	17.3675
3.2	1	0.7	4.03	236.13	13.16	13.9642
3.1	11	0.7	4.1	357.21	7.37	7.38212
1.8	1	0.7	3.73	252.32	3.13	2.52784
2.3	1	0.7	2.52	200.94	2.39	2.99195
2	1	0.7	4.63	251.54	0.83	2.49382
2.3	1	0.7	4.08	237.87	0.67	1.94929
2	1	0.7	2.83	227.51	0.59	2.60185
2.8	1	1.5	2.44	55.6	16.65	11.4363
2.8	1	0.5	3.92	192.56	20.93	20.8195
2.9	14	0.5	15.22	43.33	9.07	9.80602
2.1	2	0.5	0.45	258.29	9.06	9.35336
2.6	1	0.5	2.53	237.63	8.6	8.85813
1.1	4	0.5	0.55	267.87	5.33	5.20153
1.8	1	0.5	2.32	253.32	5.25	4.87591
2.8	1	0.5	3.25	234.76	5.18	5.41256
2.9	1	0.5	3.36	316.32	5.16	4.89837
1.8	1	0.5	3.33	253.32	3.88	2.39192
1.3	2	0.5	1.25	273.07	3.14	3.10752
1.5	2	0.5	1.64	267.14	2.84	3.25946
1.3	1	0.5	3.12	280.8	1.72	1.44514
2.3	1	0.5	4.58	247.87	1.35	1.33945
2	1	0.5	4.17	248.52	1.24	1.20392
1.7	1	0.5	3.12	253.32	0.87	1.9838
1.3	1	0.5	3.46	258.23	0.87	0.812778
2.3	1	0.5	3.33	273.27	0.87	0.818914
3.4	2	1.5	1.78	142.09	38.2	37.2093
2.9	1	1.5	2.69	69.64	12.22	5.7703

M	h [km]	T	D [km]	Az [°]	Acel Real [m/s <sup>2</sup> ]	Acel Estim [m/s <sup>2</sup> ]
2.3	4	1.5	0.61	288.14	10.33	10.2321
1.8	1	1.5	2.67	72.04	5.71	2.52833
2.8	1	1.5	2.76	96	5.31	3.61265
2.4	1	1.5	2.76	96	4.37	3.72982
2.6	1	1.5	3.79	100.81	4.11	2.81207
2.3	1	1.5	1.41	101.79	2.43	2.55713
1.9	1.6	1.5	3.82	103.1	1.5	2.52836
2.9	1	0.5	3.08	238.42	15.63	16.0607
3	1	0.5	3.71	220.15	13.47	13.6375
1.8	1	0.5	3.12	236.48	10	2.55542
2.4	1	0.5	3.71	220.15	9.99	9.75397
2	1	0.5	4.01	239.13	1.67	1.46814
2.3	1	0.5	2.95	178.98	1.36	2.65869
1.7	1	0.5	3.15	229.3	1.04	2.55735
3.3	1.1	0.8	3.01	283.26	14.79	14.471
3	1	0.8	4.91	208.75	8.7	8.96748
3.2	1	0.8	4.91	208.75	8.26	8.35012
2.9	1	0.8	4.02	220.07	5.74	5.73361
2.4	1	0.8	4.91	208.75	5.09	5.1551
2.5	3	0.8	1.96	280.45	4.49	4.23656
3.1	11	0.8	2.18	21.13	4.15	4.07348
2.6	1	0.8	3.43	272.05	3.7	3.60382
1.8	1	0.8	4.1	218.85	2.99	2.52737
2.4	1	0.8	3.72	268.81	2.94	2.73246
2.5	1	0.8	2.89	276.19	2.94	2.83708
2.6	1	0.8	4.92	196.33	1.21	1.50579
3.2	1	1.6	2.27	8.5	6.46	6.27119
2.8	1	1.6	3.93	354.19	5.2	5.03989
1.9	1.6	1.6	2.12	38.17	3.11	2.52852
2.4	1	1.6	2.27	8.5	1.87	2.53026
2.8	1	1.6	2.27	8.5	1.86	2.93772
1.8	1	1.6	3.36	2.15	1.85	2.5163
2.3	4	1.6	4.04	312.34	1.63	1.35149
2.3	1	1.6	2.47	335.41	0.64	0.584465
2.1	3	1.6	2.81	298.32	0.59	0.986309
2	2	1.6	3.5	329.77	0.54	0.681711
2.3	1	1.6	3.51	52.47	0.3	2.53354

Tabla 2B. Conjunto de Prueba para la variable NS.

M	h [km]	T	D [km]	Az [°]	Acel Real [m/s <sup>2</sup> ]	Acel Estim [m/s <sup>2</sup> ]
3.2	1	0.5	3.25	243.38	32.08	31.2152
2.8	1	0.7	4.12	261.94	15.38	19.3934
2.4	1.5	0.7	1.84	240.24	13.78	9.15546
2.6	1	0.7	3.57	221.62	2.82	5.39181
2.4	1	0.5	3.25	236.85	17.63	7.01653
3	1	0.5	3.25	110.35	13.26	26.7354
1.9	1.6	0.5	2.62	212.71	4.9	6.1413
2.2	1	0.5	3.5	262.43	2.91	2.19578
1.8	1	0.5	3.46	253.32	1.3	2.33696
2	1	1.5	0.81	53.05	3.86	2.53216
3	1	0.5	3.97	217.05	20.92	17.2546
2.4	1.5	0.5	1.63	203.09	6.63	8.92907
2.8	1	0.8	4.06	229.58	9.03	13.9442
3	1	0.8	5.2	206.98	8.62	7.84315
2.6	2	0.8	13.59	345.48	5.02	6.37485
2.4	0.5	0.8	4.31	255.52	3.57	6.32834
3.4	2	1.6	1.74	310.63	14.74	17.7184
2.2	1	1.6	3.29	305.57	4.62	-2.06249
3	1	1.6	2.27	8.5	2.59	7.10134
2.6	1	1.6	2.25	35.72	2.48	2.62048
2.3	1	0.5	1.24	255.12	10.49	9.1502
1.5	2	1.6	3.47	62.97	2.11	2.52681

Tabla 2C. Pesos sinápticos

<b>Nodo</b>	<b>Pesos iniciales-&gt; 1ra Capa oculta</b>					
1	1.457417	-3.661848	0.635743	6.572534	2.105843	-2.056414
2	-4.048722	8.520704	0.785303	-3.814018	3.103218	1.103406
3	1.563646	-5.432027	1.851816	5.524345	2.393178	2.48583
4	-6.736962	2.12855	-0.114211	-3.732123	7.212458	-7.743392
5	-7.871074	-2.233787	0.39792	0.807182	8.534301	21.743864
6	-5.07296	1.191571	-0.26252	3.469027	4.930362	-5.08528
7	-9.060598	3.707265	1.326958	-0.413113	1.175875	4.305899
8	-2.465742	-9.42673	1.439896	1.106169	-4.393389	9.759423
9	-4.640608	0.812602	3.474072	-4.784151	-7.040012	0.824902
10	-6.519344	-6.553348	1.731189	-4.80116	-1.369967	-8.988877
11	-4.698804	-7.395464	0.857172	1.058466	-0.714076	-5.855741
12	5.203666	-10.714384	-2.318738	-9.24235	-3.624861	-16.41633
13	-0.619855	-6.650529	1.077364	0.730868	-2.556505	1.765973
14	0.071436	-1.45158	0.30915	7.508034	5.113061	13.999538
15	2.808136	-10.789159	0.817977	4.367941	-3.107028	-3.980414
16	-1.534697	-9.863963	-0.201011	-0.425038	-5.631043	-7.990113
17	1.269895	-2.994083	-0.848041	4.987492	-2.162556	-2.983865
18	-1.629086	-1.513436	4.4952	-0.367655	-4.32852	2.257241
19	2.753416	-6.368863	-0.383261	8.075979	-12.663263	7.809369
20	-1.148556	-8.271952	0.114047	-0.05664	-2.367796	-7.200187

<b>Nodo</b>	<b>1ra Capa -&gt; 2da Capa</b>					
1	-2.720163	2.730676	1.294475	-1.097117	0.971504	-5.469448
	6.921204	0.151522	-0.932728	-4.579532	-1.414446	-3.811649
	-2.855058	-0.721274	0.249119	-5.512309	-3.076433	1.03881
	-0.829979	-3.37825	-3.365685			
2	3.240291	5.113978	1.80943	4.120885	-5.30759	-9.570543
	-2.606943	-2.754551	5.308781	2.084438	-1.91738	-1.894784
	-1.161906	2.859076	-2.795644	4.362163	-3.299935	-0.790361
	2.45258	10.482876	0.859636			
3	-2.194991	-4.047102	2.366742	-3.533948	2.083836	8.257866
	5.445752	3.164988	-2.019149	-2.878877	-3.153094	-0.728671
	-12.172206	-4.1481	6.195614	-5.929709	-4.004178	0.517026
	-3.373965	2.086878	-0.898428			
4	1.038121	-3.167054	2.617113	-2.29842	8.600379	3.108822
	0.740735	2.648544	-4.375697	1.62667	-2.393351	-5.004874
	-8.53883	-2.047874	4.186823	-3.60029	-4.86417	-1.612142
	-0.996476	-2.409921	-3.344141			
5	-0.275698	-2.043406	0.195391	-4.405719	-0.160823	0.104683
	-2.00257	1.093167	-7.711687	1.068575	-7.747174	5.073303
	7.350211	-4.307513	-8.796203	-2.14256	-3.556928	0.410344
	-1.872292	4.740517	-3.109			
6	3.716376	0.016991	6.193816	-0.054078	3.759513	-5.56256
	1.772415	2.627859	4.322124	-1.111588	0.011902	-2.799953
	-4.490969	-2.705919	-1.912016	-3.766586	-5.749536	-0.82004
	-0.124454	0.052344	-3.823571			
7	-0.367992	4.219564	-2.196178	-3.723758	1.244654	-3.919211
	2.218468	1.109789	-2.64085	3.832788	-1.987726	-4.357194
	-3.764977	-2.208118	-2.68168	2.301817	-7.173928	4.395446
	2.38175	0.259064	-5.288879			
8	3.681658	3.761545	-1.371077	1.227918	-3.498161	-5.784179
	-5.304741	-1.780555	-3.082114	5.352471	-8.798869	-1.004488
	6.549482	-0.183955	-4.360054	3.544769	0.058217	2.609317
	0.978659	4.927667	-1.04965			
9	-1.94113	-1.836375	0.679191	-0.879075	1.603288	3.408432
	1.914394	3.694607	3.386978	-4.949709	-1.00817	-2.358755
	-7.547373	1.258284	4.941092	-5.024152	-2.535686	-0.723453
	-0.21475	-2.373137	-3.430634			
10	-3.396015	-1.149821	-2.785341	-0.759112	-1.210685	-1.769625
	0.179634	0.860146	1.241908	3.779143	0.145539	-2.35638
	-4.364556	-0.194511	-2.233273	0.689935	0.20588	1.387303

5.308081	-0.759321	0.092389
----------	-----------	----------

2da Capa -> Nodo de salida					
4.589187	-13.307676	-15.123863	23.147735	12.113935	12.151382
-10.445453	29.561053	13.063188	-10.814549	7.100786	

Tabla 3A. Conjunto de entrenamiento para la variable V.

M	h [km]	T	D [km]	Az [°]	Acel Real [m/s <sup>2</sup> ]	Acel Estim [m/s <sup>2</sup> ]
3	1	0.7	4.23	232.38	23.29	7.95079
2.8	1	0.7	4.12	261.94	9.6	6.74604
3	1	0.7	4.03	236.13	8.75	7.95108
3.1	11	0.7	4.1	357.21	8.38	5.19798
2.4	1	0.7	4.03	236.13	8.17	2.08267
3.2	1	0.7	4.03	236.13	3.39	7.94417
1.8	1	0.7	3.73	252.32	2.1	2.39886
2.3	1	0.7	2.52	200.94	1.75	1.32857
2	1	0.7	4.63	251.54	1.11	0.76301
2.3	1	0.7	4.08	237.87	0.62	1.78252
2	1	0.7	2.83	227.51	0.49	1.726
2.8	1	0.5	3.92	192.56	18.32	14.1855
3.2	1	0.5	3.25	243.38	13.64	9.40644
2.3	1	0.5	1.24	255.12	12.36	9.73284
2.6	1	0.5	2.53	237.63	7.04	2.77615
2.9	14	0.5	15.22	43.33	5.58	4.85388
1.8	1	0.5	2.32	253.32	4.53	2.7311
2.9	1	0.5	3.36	316.32	4.08	2.1985
1.3	2	0.5	1.25	273.07	3.53	1.38525
1.1	4	0.5	0.55	267.87	3.32	2.16758
2.8	1	0.5	3.25	234.76	3.28	7.95833
1.8	1	0.5	3.33	253.32	2.95	2.17246
1.5	2	0.5	1.64	267.14	1.69	0.788118
2.3	1	0.5	3.33	273.27	1.21	2.06937
1.3	1	0.5	3.12	280.8	1.2	-0.327957
1.3	1	0.5	3.46	258.23	1.16	0.250405
2	1	0.5	4.17	248.52	0.88	0.723776
2.3	1	0.5	4.58	247.87	0.87	2.0695
1.7	1	0.5	3.12	253.32	0.52	1.20602
2.1	2	0.5	0.45	258.29	0.09	1.33585
3	1	1.5	2.82	102.76	18.39	17.5999
2.9	1	1.5	2.69	69.64	6.13	5.06198
1.8	1	1.5	2.67	72.04	5.05	3.09876
2.6	1	1.5	3.79	100.81	3.77	2.16201
3	1	0.7	4.23	232.38	23.29	7.95079

M	h [km]	T	D [km]	Az [°]	Acel Real [m/s <sup>2</sup> ]	Acel Estim [m/s <sup>2</sup> ]
2.8	1	1.5	2.76	96	3.53	3.23835
2.3	4	1.5	0.61	288.14	2.75	2.53377
2.8	1	1.5	2.44	55.6	2.19	1.66175
2.4	1	1.5	2.76	96	2.14	1.90434
1.9	1.6	1.5	3.82	103.1	1.53	0.964967
2.3	1	1.5	1.41	101.79	1.3	2.10015
2.8	1	0.5	3.34	249.52	13.06	7.85987
3	1	0.5	3.71	220.15	10.05	10.4407
2.9	1	0.5	3.08	238.42	8.09	7.96352
2.4	1	0.5	3.71	220.15	6.57	6.07385
1.8	1	0.5	3.12	236.48	5.11	2.94732
2.3	1	0.5	2.95	178.98	1.3	1.02194
2	1	0.5	4.01	239.13	1.11	0.743481
1.7	1	0.5	3.15	229.3	0.7	0.748431
3.3	1.1	0.8	3.01	283.26	7.8	7.9501
3.2	1	0.8	4.91	208.75	5.67	7.94511
2.9	1	0.8	4.02	220.07	3.95	7.94959
3	1	0.8	4.91	208.75	3.17	7.94708
2.4	1	0.8	4.91	208.75	2.97	1.52961
2.5	3	0.8	1.96	280.45	2.71	2.09527
3.1	11	0.8	2.18	21.13	2.28	1.95349
1.8	1	0.8	4.1	218.85	1.66	1.09595
2.6	1	0.8	3.43	272.05	1.46	2.01689
2.5	1	0.8	2.89	276.19	1.01	1.99341
2.4	1	0.8	3.72	268.81	0.98	1.96954
2.6	1	0.8	4.92	196.33	0.69	2.19875
2.8	1	1.6	3.93	354.19	8.16	7.87371
3.2	1	1.6	2.27	8.5	6.03	6.03341
1.9	1.6	1.6	2.12	38.17	3.99	2.46089
2.4	1	1.6	2.27	8.5	2.98	1.99482
1.8	1	1.6	3.36	2.15	2.07	2.42874
2.8	1	1.6	2.27	8.5	1.77	1.6293
2.3	4	1.6	4.04	312.34	1.73	1.33656
2.3	1	1.6	2.47	335.41	0.91	1.00594
2	2	1.6	3.5	329.77	0.9	0.428487
2.3	1	1.6	3.51	52.47	0.64	1.83117
2.1	3	1.6	2.81	298.32	0.63	0.490589

2	1	1.5	1.77	73.94	0.75	2.57736
---	---	-----	------	-------	------	---------

Tabla 3B Conjunto de prueba para la componente V.

M	h [km]	T	D [km]	Az [°]	Acel Real [m/s <sup>2</sup> ]	Acel Estim [m/s <sup>2</sup> ]
2.4	1.5	0.7	1.84	240.24	6.76	6.80543
2.6	1	0.7	3.57	221.62	1.7	2.25148
2.4	1	0.5	3.25	236.85	10.86	3.88313
3	1	0.5	3.25	110.35	11.97	15.2815
3.8	1	0.5	8.64	237.82	8.33	12.3738
1.9	1.6	0.5	2.62	212.71	2.39	3.76563
2.2	1	0.5	3.5	262.43	2.12	2.30541
1.8	1	0.5	3.46	253.32	0.9	2.1062
3.4	2	1.5	1.78	142.09	22.97	13.9606
3.2	1	1.5	2.76	96	11.64	14.8084
2	1	1.5	0.81	53.05	1.29	2.49814
3.2	1	0.5	3.71	220.15	15.27	14.019
3	1	0.5	3.97	217.05	9.87	10.7869
2.4	1.5	0.5	1.63	203.09	3.83	8.51602
2.8	1	0.8	4.06	229.58	6.11	7.90371
3	1	0.8	5.2	206.98	4.64	7.94666
2.6	2	0.8	13.59	345.48	3.29	2.02755
2.4	0.5	0.8	4.31	255.52	1.36	1.96274
3.4	2	1.6	1.74	310.63	8.47	7.94661
2.2	1	1.6	3.29	305.57	2.09	1.15382
3	1	1.6	2.27	8.5	3.05	4.2549
2.6	1	1.6	2.25	35.72	7.04	1.78292
1.5	2	1.6	3.47	62.97	1.26	2.57839

Tabla 3C. Pesos sinápticos

<b>Nodo</b>	<b>Pesos iniciales-&gt; 1ra Capa oculta</b>					
1	2.724586	-10.864439	1.241134	0.648023	-0.717899	-2.220594
2	-1.126982	7.284168	-0.865699	1.898558	2.989706	-0.197113
3	-0.874599	-1.501097	1.754725	-3.63403	1.071605	2.38615
4	-1.146088	4.566508	-0.732918	1.674906	1.391349	-1.344478
5	-3.482278	-0.289664	-0.831044	-3.792187	-3.134888	2.187979
6	-0.535694	7.272195	-0.510043	2.115021	3.405161	-1.254355
7	-1.228756	6.776514	0.289145	2.415219	-0.336899	-0.721344
8	-0.423481	-4.752622	-0.547599	-2.666368	0.634235	4.126453
9	-0.478908	3.876085	2.401883	0.387245	-0.915136	-2.181485
10	1.411118	-1.377876	-0.927262	2.484587	-3.664345	-5.454577
11	-0.185047	-3.387886	0.13061	-0.504138	0.141674	-2.315809
12	-0.198551	0.921816	-1.763909	0.604151	-2.199409	-4.973846
13	-0.739679	-7.180911	1.198687	-1.234087	-3.047643	-1.238804
14	1.841139	-9.029907	-0.128318	2.874744	1.990813	6.021005
15	1.239916	-6.390007	1.11896	-1.370052	0.287491	-0.315068
16	-2.507503	-1.284153	-1.079041	-1.788877	-4.999577	-3.437676
17	0.177111	-0.817532	0.200695	2.181185	-2.279464	-3.113156
18	-0.290248	-0.564158	3.766552	0.107765	-1.279512	-0.054443
19	-5.956884	8.975652	-1.769917	-4.305095	-2.212326	9.224723
20	-1.486263	-1.007427	1.187701	-0.834854	0.04589	-1.114343

Nodo	1ra Capa -> 2da Capa					
1	-2.086198	0.103651	-0.344303	0.120784	0.117048	0.401906
	0.245294	-1.506666	-0.601435	0.1044	-1.1306174	-1.81366
	0.257477	-0.094556	0.566309	-1.189864	-0.592574	1.892808
	-0.773462	-1.442393	-1.135231			
2	-0.545382	-0.955887	-0.696168	2.749823	-0.845769	-0.615321
	-1.424757	-1.050317	3.285524	1.57294	-2.317116	-0.640476
	-2.048279	-1.151621	-0.878999	1.234942	-1.913701	-2.005451
	1.086465	1.282499	1.294963			
3	-0.536886	-6.961505	4.416517	-0.725135	3.607643	0.219678
	3.665594	4.511692	-3.411692	2.281391	-2.133416	-1.7662
	-1.209645	-4.70182	-3.941422	-4.569532	0.216573	1.334321
	-0.360678	9.33318	-0.776495			
4	2.514827	-3.186951	3.169144	-2.208558	2.320602	-2.702916
	3.637039	4.920278	-3.414764	2.675446	0.13236	-1.603785
	0.747899	-1.948735	-0.965866	-2.847844	-1.837504	1.324429
	0.224785	2.508682	-0.883147			
5	-0.667576	1.031027	-1.407933	-0.476457	-0.172137	0.933302
	-1.655529	0.419685	-1.82128	-0.206262	-1.789608	0.810573
	-0.290874	-0.132058	-2.442357	0.009323	-0.224869	-0.716841
	-0.339443	0.328069	0.596201			
6	0.24976	-0.183558	0.974627	3.479977	-0.187898	0.699029
	-1.888446	-2.118842	3.755783	-3.414609	-4.033097	-2.180961
	-4.121603	-2.522049	5.606543	0.606339	-4.377359	-3.347276
	-1.082347	2.308734	-2.053548			
7	-1.244644	6.468551	-1.077485	-0.612375	-0.224609	-3.805136
	-0.755338	-0.653089	-1.561299	0.218688	-0.209354	2.048261
	-1.30159	0.946724	2.784991	1.974725	-0.547168	1.610258
	1.820535	-5.97766	0.117074			
8	0.451009	0.60143	-0.972538	0.280316	-1.420027	-1.692241
	-2.846124	-1.31756	-0.660472	-1.93063	-3.046817	1.202774
	0.580757	-1.274989	0.430598	1.321635	-0.100772	0.733404
	-0.650025	1.048814	-0.183798			
9	-2.182601	5.070823	-4.955484	0.829584	-2.215939	1.831387
	-6.186485	-2.733486	1.83509	-2.107638	0.601391	-0.674468
	-3.197589	2.972483	6.000896	2.041487	1.374889	0.409607
	0.664062	-4.76183	-1.249629			
10	-2.303673	0.234921	-1.229075	-1.389518	-1.026726	0.003372
	-0.350683	0.108368	-0.495352	0.633211	-0.110319	0.287947
	-0.313015	-0.852265	-0.615003	0.234885	-0.015553	0.135325

	1.64007	0.393538	0.114462
--	---------	----------	----------

Nodo	2da capa -> 3ra Capa					
1	0.930844	-0.83387	-2.07573	-9.151442	0.667659	0.81326
	-2.328598	1.5684	0.209424	0.723908	0.866563	
2	2.765645	0.646751	0.166021	3.713224	1.848172	-0.175335
	-2.854389	-1.230717	1.208099	-1.719293	-1.082893	
3	-1.895622	0.234419	-2.762151	0.037465	-2.003823	0.086921
	-1.343757	2.065929	0.480499	0.215891	-0.405663	
4	1.176136	0.267777	-1.796475	-3.68595	-7.492708	0.977023
	-4.530971	0.788694	-2.315706	8.218462	0.134925	
5	0.614284	-0.775413	-1.901177	0.423812	0.839468	-0.543527
	-2.554553	-4.875917	0.446681	2.011956	-0.43393	
6	-0.867389	-0.309019	-1.751488	5.377075	5.678197	0.294721
	-0.9094	1.863267	-1.140263	-10.229955	1.84649	
7	0.24411	0.846642	1.459881	1.306168	-1.327908	-1.684387
	-1.97852	-3.941809	-0.561535	1.663899	2.194655	
8	-3.162544	-0.670963	-2.493874	-1.442213	-2.6826	0.291463
	-1.827272	-3.3519	0.385494	4.592257	1.422829	
9	-1.088442	1.084032	-0.248853	-1.438503	-1.648413	0.863908
	3.445294	-0.697446	-1.323751	-1.035219	0.837479	
10	0.890998	-0.134001	0.306898	-12.911872	0.183802	0.606811
	1.515397	0.897995	-0.641204	3.732222	-1.022331	

3ra Capa -> Nodo de salida					
-3.136647	8.446416	-0.905177	-1.314542	8.753824	3.883715
7.211664	3.424127	4.736780	-1.910164	-11.864737	