



UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO
PROGRAMA DE MAESTRÍA Y DOCTORADO EN INGENIERÍA
INGENIERÍA CIVIL – ESTRUCTURAS

***“HERRAMIENTAS DE INTELIGENCIA ARTIFICIAL PARA LA ESTIMACIÓN DE LA
RESPUESTA SÍSMICA DE EDIFICIOS DE MEDIANA ALTURA CON
AMORTIGUADORES VISCOSOS LINEALES”***

TESIS

QUE PARA OPTAR POR EL GRADO DE:
MAESTRO EN INGENIERÍA

QUE PRESENTA:

ING. LUIS HERNÁNDEZ MARTÍNEZ

ASESORES:

**DR. JOSÉ ALBERTO ESCOBAR SÁNCHEZ
M. EN I. ERIBERTO ELÍAS BALLINAS DÍAZ**

PROGRAMA DE MAESTRÍA Y DOCTORADO EN INGENIERÍA

CIUDAD DE MÉXICO, SEPTIEMBRE, 2022



Universidad Nacional
Autónoma de México

Dirección General de Bibliotecas de la UNAM

Biblioteca Central



UNAM – Dirección General de Bibliotecas
Tesis Digitales
Restricciones de uso

DERECHOS RESERVADOS ©
PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL

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

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

JURADO ASIGNADO:

Presidente: Dr. Oscar Alberto López Bátiz

Secretario: Dr. Adrián Pozos Estrada

Vocal: Dr. José Alberto Escobar Sánchez

1^{er} suplente: Dr. Roberto Gómez Martínez

2^{do} suplente: Dr. Héctor Guerrero Bobadilla

INSTITUTO DE INGENIERÍA, UNAM

TUTOR DE TESIS:

DR. JOSÉ ALBERTO ESCOBAR SÁNCHEZ

FIRMA

AGRADECIMIENTOS

Quiero agradecer a mi mamá por siempre apoyarme y darme una infinidad de oportunidades, las que a veces, no aproveché, pero ella siempre estuvo ahí para brindarme todo su apoyo y cariño. A mi papá, por darme calma y guiarme en diversas ocasiones en el camino que he recorrido. A mis hermanos, Antonio por ser tolerante muchas veces y aprender a vivir conmigo y mi pésimo carácter, y a Iván por darme aliento y siempre buscar la manera de ayudarme. También a las familias Ojeda Martínez y Maldonado Hernández por los sabios consejos y la gran calidez que los caracteriza.

Al Dr. Escobar, por nuevamente brindarme la oportunidad de ser su asesorado y seguir aprendiendo de él. Al próximo doctor Eriberto Ballinas por orientarme y enseñarme casi todos los días, ser un gran amigo y maestro al mismo tiempo. A cada uno de los profesores que tuve en este corto período en el sistema de posgrado. A mis sinodales por haber invertido su tiempo para hacerme correcciones y comentarios de este escrito.

A mis amigos Abel Pérez, Michael Hernández, Diego Martínez, Alejandro García, Luis Orihuela, Carlos Vásquez, Catalina Hernández y Edgar Hernández por su apoyo durante estos dos últimos años, mediante pláticas y mucha distracción. A mis amigos de la maestría Noé Quintana, Eduardo Vilchis, Valentín Jiménez; Fernando Cueto y Luis Cobos, con ellos sufrí y gocé mucho este proceso. Todo el apoyo brindado durante estos años es algo que nunca les podré terminar de agradecer y jamás podré pagárselos, muchas gracias, amigos. También a Miguel Moctezuma, sin su ayuda no habría llegado a este punto de mi carrera profesional.

A Pamela por estar conmigo y entender lo importante que es mi profesión para mí, además siempre me ayudó a calmarme y alegrarme en los días complicados.

Al Consejo Nacional de la Ciencia y Tecnología (CONACYT) por el apoyo económico que me otorgaron durante mis estudios de maestría.

RESUMEN

Se desarrolló una metodología con herramientas de inteligencia artificial para la estimación de la respuesta sísmica de estructuras de acero equipadas con amortiguadores viscosos lineales, ubicados en suelo blando de la Ciudad de México. Para esto, se elaboró una base de datos que contiene la información geométrica, mecánica y de la respuesta dinámica de 135 marcos de acero estructural sometidos a movimientos sísmicos correspondientes a la amenaza sísmica de la zona. Los marcos y los dispositivos de disipación sísmica se diseñaron con para limitar la distorsión máxima de entrepiso a 0.01.

La aplicación de la metodología planteada en este estudio se desarrolló en el lenguaje de programación PYTHON y la paquetería para redes neuronales artificiales (RNA), Tensorflow. Los análisis sísmicos en los marcos se llevaron a cabo con un programa de análisis estructural comercial. Los resultados muestran que las RNA son una herramienta efectiva para el análisis de estructuras de acero equipadas con amortiguadores viscosos lineales, en las zonas estudiadas de la Ciudad de México.

ABSTRACT

A method to estimate the seismic response of steel structures equipped with linear viscous dampers, located in soft soil in Mexico City, were developed with artificial intelligence tools. For this, a database containing the geometric, mechanical, and dynamic response information of 135 structural steel frames subjected to seismic movements corresponding to the seismic hazard in the area, was developed. The frames and seismic dissipation devices were designed to limit the maximum drift to 0.01.

The application of the methodology proposed in this study was developed in the PYTHON programming language and the package for artificial neural networks (ANN), Tensorflow. Seismic analyzes on the frames were carried out with a commercial structural analysis program. The results show that ANNs are an effective tool for the analysis of steel structures equipped with linear viscous dampers, in the studied areas of Mexico City.

CONTENIDO

AGRADECIMIENTOS	iii
RESUMEN.....	iv
ABSTRACT	iv
INTRODUCCIÓN	1
PLANTEAMIENTO DEL PROBLEMA.....	1
JUSTIFICACIÓN	1
OBJETIVOS	1
Objetivos generales	1
Objetivos particulares.....	2
USO DE LA INTELIGENCIA ARTIFICIAL EN LA INGENIERÍA CIVIL	3
INTELIGENCIA ARTIFICIAL.....	5
2.1 CONCEPTO DE INTELIGENCIA ARTIFICIAL	5
2.2 APRENDIZAJE AUTOMÁTICO	5
2.3 APRENDIZAJE PROFUNDO.....	6
2.4 REDES NEURONALES.....	7
2.4.1 Neuronas artificiales.....	7
2.4.2 Redes neuronales artificiales.....	9
2.5 CLASIFICACIÓN DE LAS REDES NEURONALES	12
2.5.1 Estructura por capas	12
2.5.2 Estructura por flujo de datos	13
2.5.3 Tipo de respuesta de la red.....	14
2.5.4 Tipo de aprendizaje	15
2.5.5 Tipo de salida	15
2.6 EVALUACIÓN DE UNA RED NEURONAL.....	16
2.6.1 Función de coste.....	16
2.6.2 Gradiente descendente.....	17
2.6.3 Ajuste del modelo.....	18
2.6.4 Rendimiento del modelo	19
2.6.5 Detención temprana (EarlyStopping).....	20
3 ELABORACIÓN DE LA BASE DE DATOS.....	21
3.1 DISEÑO ESTÁTICO DE MARCOS.....	21
3.2 SISTEMA DE DISIPACIÓN DE ENERGÍA	23
3.3 ANÁLISIS DINÁMICO	26

3.3.1	Sitios de estudio	26
3.3.2	Espectros de desplazamiento.....	27
3.3.3	Análisis dinámico no lineal.....	27
3.4	BASE DE DATOS	29
ESTIMACIÓN DE LA RESPUESTA DINÁMICA CON REDES NEURONALES.....		33
4.1	PREPROCESAMIENTO DE DATOS	33
4.2	REDES NEURONALES.....	34
4.2.1	Desplazamientos en la azotea.....	34
4.2.1	Distorsión máxima de entrepiso.....	39
4.2.2	Aceleración máxima en azotea.....	44
4.3	ESTIMACIÓN DE LA RESPUESTA DINÁMICA.....	47
4.3.1	Desplazamiento máximo en azotea	48
4.3.2	Distorsión máxima de entrepiso.....	49
4.3.3	Aceleración máxima en azotea.....	51
CONCLUSIONES Y COMENTARIOS.....		53
BIBLIOGRAFÍA Y REFERENCIAS		55

INTRODUCCIÓN

PLANTEAMIENTO DEL PROBLEMA

Uno de los objetivos de la ingeniería civil es innovar en el diseño estructural de las edificaciones, garantizando la seguridad de sus usuarios y minimizando los costos de construcción. Para alcanzar este objetivo se han desarrollado diversas metodologías, como el uso de nuevos materiales, tendencias de diseño novedosas, mejoramiento de las normas de diseño, etc. Para zonas de alta sismicidad, como la Ciudad de México, adicionalmente, se pueden utilizar sistemas disipadores de energía para protección sísmica.

Los sistemas de protección sísmica (SPS) se pueden instalar en las estructuras en las que se requiere controlar los desplazamientos debidos a demandas sísmicas. “El concepto básico es que la energía se disipe a través del trabajo que desarrollen estos dispositivos y no por el comportamiento dúctil de los elementos de la estructura”, (Badillo, 2000). Adicionalmente, se debe considerar la complejidad y cantidad recursos necesarios para la realización de los análisis estructurales.

JUSTIFICACIÓN

En la actualidad, los proyectos de ingeniería civil deben elaborarse de manera eficiente, con tendencias de diseño modernas, como la denominada “por desempeño”, y también de arquitectura. Esto orilla a las futuras generaciones de ingenieros especialistas en estructuras, a utilizar tecnologías nuevas, como los sistemas de protección sísmica. Por ejemplo, los contraventeos restringidos al pandeo, aisladores de goma laminadas en la base, amortiguadores viscosos lineales, etc. Dado que el análisis de las estructuras equipadas con alguno de estos sistemas requiere muchos recursos computacionales, surge la necesidad de una herramienta de análisis eficaz, rápida y confiable.

Debido a la cantidad elevada de recursos necesarios para el análisis de estos sistemas estructurales, es indispensable el desarrollo de una metodología o una herramienta, con la que se obtengan resultados viables y rápidos para poder entender el comportamiento de las estructuras con sistemas de disipación de energía.

Según bibliografía consultada, Adeli (1989), Dechao Qu, et al. (2018), entre otros, se encontró evidencia de que la inteligencia artificial, en específico las redes neuronales artificiales (RNA), tienen la capacidad de relacionar parámetros que caracterizan un problema con un resultado final. Por lo tanto, son una herramienta confiable para estimar el comportamiento sísmico de una estructura. Además, reducen la cantidad de recursos computacionales requeridos para la obtención de resultados.

OBJETIVOS

Objetivos generales

Desarrollar una metodología con herramientas de inteligencia artificial, en específico redes neuronales artificiales, con la capacidad de estimar la respuesta sísmica de estructuras de acero equipadas con amortiguadores viscosos lineales, ubicados en suelo blando de la Ciudad de México. Para esto, se elaboró una base de datos que contiene la información geométrica, mecánica y de la respuesta dinámica de 135 marcos de acero estructural sometidos a movimientos sísmicos correspondientes a la amenaza sísmica de la zona.

Objetivos particulares

- Elaborar una base de datos que contiene la información geométrica, mecánica y de la respuesta dinámica de 135 marcos de acero estructural, sometidos a movimientos sísmicos correspondientes a la amenaza sísmica de la zona.
- Para la información de la base de datos, diseñar 135 marcos de acero estructural con las especificaciones de las Normas Técnicas del Reglamento de Construcciones para el Distrito Federal, ahora Ciudad de México. También, diseñar los amortiguadores viscosos lineales utilizando las especificaciones del ASCE 41-17.
- A partir de la información generada para la base de datos, desarrollar una red neuronal artificial (RNA), con la capacidad de estimar la respuesta sísmica de estructuras de acero equipadas con amortiguadores viscosos.
- Estimar con la RNA la respuesta dinámica de estructuras ajenas a la base de datos sometidas a diversos movimientos sísmicos.

CAPÍTULO 1 USO DE LA INTELIGENCIA ARTIFICIAL EN LA INGENIERÍA CIVIL

Durante años, la inteligencia artificial ha sido una herramienta utilizada en diferentes áreas de la ingeniería civil, por ejemplo, ingeniería estructural, hidráulica y geotécnica. A continuación, se describen algunas de las investigaciones realizadas en el área de la ingeniería estructural.

Se tiene información que, desde finales de los años 80, se han utilizado RNA para estudiar diversos problemas en la ingeniería estructural, por ejemplo, Adeli (1989), determinó el módulo de sección transversal ideal para una viga sometida a esfuerzos cortantes y momentos flexionantes.

Hajela y Berke (1991), hicieron uso de esta herramienta para mapear la relación carga-desplazamiento y determinar el desplazamiento deseado o la respuesta a la tensión en el análisis estático de armaduras de acero. Para realizarlo, se estimó el área transversal de los elementos de la armadura sin que los desplazamientos superaran los límites establecidos en reglamentación de la época o, en su defecto, los desplazamientos máximos establecidos por el diseñador. De forma paralela, se hizo una optimización, enfocada al peso de la estructura, buscando que sea lo más ligera posible.

En el estudio realizado por Yeh, Kuo y Hsu (1993), se intentó transportar el conocimiento cualitativo de un experto en cimentaciones a una RNA para determinar daños en pilotes de concreto presforzado. Otra herramienta de diseño de armaduras fue elaborada Kang y Yoon (1994), para buscar la optimización de los elementos, considerando aspectos como la sección transversal, los esfuerzos últimos bajo condiciones de carga particulares y el peso total de la estructura.

La optimización de recursos mediante el uso de RNA se presenta en el programa StructNet (Messner et al., 1994). Se consideraron 15 parámetros de un proyecto a desarrollar (área del proyecto, uso de la estructura, tipo tiempo de construcción, etc.), con lo que se determinó qué sistema estructural era óptimo, dando parámetros como tipo de vigas, columnas y losas.

Abdalla y Stavroulakis (1995), desarrollaron una RNA para la estimación de diagramas momento-curvatura de dos conexiones semirrígidas viga-columna, la primera utilizando un perfil metálico y la segunda con placas de acero, ambas conexiones fueron atornilladas. Rafiq (2001), propuso tres metodologías para el cálculo del espesor de una losa dos direcciones: previamente se determinaron aspectos del diseño como cantidad de acero, espaciado de acero y tipo de concreto, entre otros.

Bojórquez, et al. (2016), desarrollaron una RNA para predimensionar los elementos de una estructura sometida a demandas sísmicas. Como resultado, obtenían los valores de la geometría de las vigas y columnas, la cantidad de acero y la separación de estribos. Dhanya y Raghukanth (2017), obtuvieron los espectros de respuesta para toda la ciudad de Shimla, en la región del Himalaya. Abd-Elhamed, et al. (2018), desarrollaron una RNA para la estimación de la respuesta sísmica de una estructura de un grado de libertad.

Dechao Qu, et al. (2018), usaron una RNA para la estimación de la resistencia a compresión y a la flexión de concreto de alto rendimiento reforzado con fibras de acero. En los trabajos elaborados por Duan, et al. (2018) y Hadzima-Nyarko, et al. (2019), se calculó la resistencia a compresión y el módulo de elasticidad del concreto, el concreto fue diseñado con agregados diferentes a los comunes. En el primero se utilizaron agregados reciclados y en el segundo se cambió parcial o totalmente los agregados por desechos de caucho proveniente de llantas.

La inteligencia artificial también se ha utilizado para estimar la respuesta no lineal de estructuras. Por ejemplo, en el trabajo realizado por Pérez et al. (2019), se estimó el comportamiento sísmico de un

1. USO DE LA INTELIGENCIA ARTIFICIAL EN LA INGENIERÍA CIVIL

edificio residencial de 38 niveles de altura a base de marcos de acero estructural de cinco crujías. Los resultados obtenidos fueron muy cercanos a los reales. En el trabajo de Zhang et al. (2019), se compararon métodos clásicos de análisis estructural no lineal con una RNA, para la estimación del comportamiento de sísmico de una estructura. En Bas et al. (2020) se estimó el comportamiento no lineal de una varilla de acero debido a cargas cíclicas reversibles, obteniendo gráficas de histéresis similares a las de referencia.

CAPÍTULO 2 INTELIGENCIA ARTIFICIAL

2.1 CONCEPTO DE INTELIGENCIA ARTIFICIAL

Oracle (2021), explicó la inteligencia artificial de la siguiente manera. Cuando existen limitaciones computacionales como humanas; se puede utilizar la inteligencia artificial. En términos simples, inteligencia artificial (IA), se refiere a sistemas o máquinas que imitan la inteligencia humana para realizar tareas y pueden mejorar iterativamente a partir de la información que recopilan.

Por otra parte, Bourcier (2003), definió la inteligencia artificial como una rama de la informática que intenta reproducir las funciones cognitivas humanas como el razonamiento, la memoria, el juicio o la decisión y, después, confiar una parte de esas facultades, que se consideramos signos de inteligencia, a las computadoras.

Es importante comprender que los diversos programas computacionales y otras herramientas, fueron desarrollados bajo instrucciones lógicas y sistematizadas, precargadas en el código fuente. Por lo que estos programas no pueden ir más allá de las limitaciones de su funcionamiento. Si se necesita un procedimiento nuevo u otro enfoque, es necesario el uso de otro programa o analizar manualmente en busca de una solución. Dependiendo de la existencia de programas computacionales enfocados a ese problema y de su complejidad. Para este tipo de situaciones se podría desarrollar una herramienta de inteligencia artificial que puede superar las limitaciones de la lógica computacional.

Actualmente la IA tienen muchos usos, por ejemplo: el reconocimiento de patrones, filtrado de ruido en audio, imágenes y videos, la predicción de valores (climatológicos, investigación en diversas áreas, sistemas lineales y no lineales), procesamiento de señales, modelado económico y financiero, entre otros. De acuerdo con Matich (2001), las principales ventajas que ofrecen las redes neuronales sobre la programación clásica son:

- Aprendizaje adaptativo: La capacidad de aprender a realizar tareas basadas en un entrenamiento o en una experiencia inicial.
- Autoorganización: Una red neuronal puede crear su propia organización o representación de la información que recibe mediante una etapa de aprendizaje.
- Tolerancia a fallas: La destrucción parcial de una red conduce a una degradación de su estructura; sin embargo, algunas capacidades de la red se pueden retener, incluso sufriendo un gran daño.
- Operación en tiempo real: Los cálculos neuronales pueden ser realizados en paralelo; para esto se diseñan y fabrican máquinas con hardware especial para obtener esta capacidad.
- Fácil inserción dentro de la tecnología existente: Se pueden obtener chips especializados para redes neuronales que mejoran su capacidad en ciertas tareas. Ello facilita la integración modular en los sistemas existentes.

2.2 APRENDIZAJE AUTOMÁTICO

Una de las ramas de la IA son el aprendizaje automático y el aprendizaje profundo.

El aprendizaje automático (AA) es una rama de la inteligencia artificial (IA), que se enfoca en desarrollar sistemas que aprendan, o mejoren, el rendimiento en función de los datos que consumen. Por su parte, la inteligencia artificial es un término amplio que se refiere a sistemas o máquinas que imitan la inteligencia humana. El AA y la IA, suelen nombrarse juntos, y los

términos a veces se usan indistintamente, pero no significan lo mismo. Es importante destacar que, aunque todo aprendizaje automático es IA, no toda la IA es AA (Oracle, 2022).

Los algoritmos más utilizados en AA son: regresión lineal, árboles de decisiones, vecinos cercanos y k-medias, el que agrupa objetos en k número de conjuntos, dependiendo de sus características.

El procedimiento general que sigue cualquier sistema de AA para aprender es el siguiente:

- Entrenamiento: Se compone de una base de datos a la que el sistema tiene acceso y a partir de la que se genera un modelo.
- Producción: Corroborar que el modelo tenga un rendimiento esperado referente a la estimación de datos no etiquetados o ajenos a la base de datos, los que normalmente se espera que sean superiores a un 85%.
- Aprendizaje activo: El modelo se mantendrá en un aprendizaje continuo para obtener mejores resultados en futuras estimaciones y, con éste, corregir errores que puedan presentarse en él.

Existe una diferencia entre la programación tradicional y el aprendizaje automático. Para conceptualizar sus diferencias básicas, en la figura 2.2.1, se muestran diagramas de flujo para ambos casos. En la programación tradicional se tiene un conjunto de datos de entrada y un programa con procedimientos o lógica a seguir. Los que se ingresan en una computadora para que ésta última entregue un conjunto de valores de salida o resultados. Por otro lado, el aprendizaje automático, utiliza la información de los datos de entrada y los de salida, para generar una rutina que los relacione.

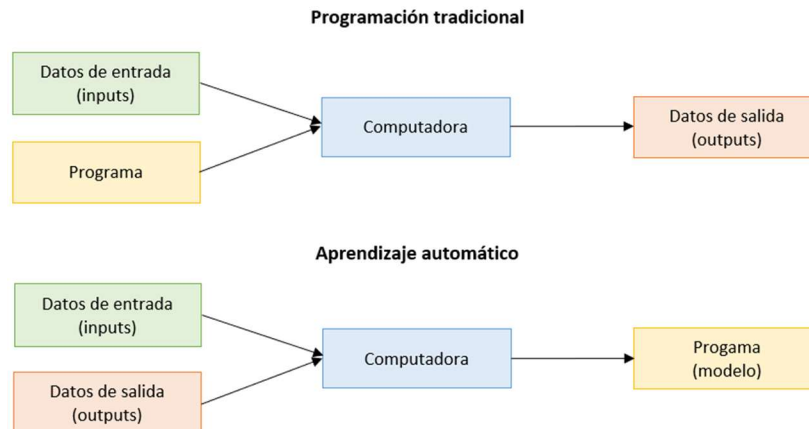


Figura 2.2.1 Procesos de análisis de datos (adaptada de Mehra, 2020)

2.3 APRENDIZAJE PROFUNDO

El aprendizaje profundo es un tipo, o subconjunto; de aprendizaje automático que usa redes neuronales artificiales (RNA), para permitir que los sistemas digitales aprendan y tomen decisiones fundamentadas en datos no estructurados y sin etiquetar. Estas redes, además de considerar las variables de entrada, considera una interrelación entre las entradas para así estimar una salida. En la figura 2.3.1, se muestra un diagrama del aprendizaje profundo como subconjunto del aprendizaje automático y este, a su vez, de la inteligencia artificial.

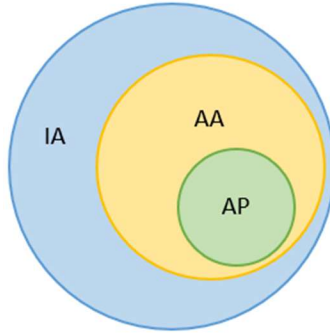


Figura 2.3.1. Esquemas de tipos de aprendizaje (adaptado de Yepes, 2022)

“En general, el aprendizaje automático entrena sistemas de inteligencia artificial para aprender de experiencias adquiridas con datos, reconocer patrones, hacer recomendaciones y adaptarse. Particularmente, con el aprendizaje profundo en lugar de simplemente responder a conjuntos de reglas; los sistemas digitales generan conocimiento a partir de ejemplos para después usarlo al reaccionar, comportarse y actuar como personas”, Microsoft (2022).

Cuando se tiene un gran volumen de datos, el uso del aprendizaje profundo tiene una gran ventaja respecto al aprendizaje automático. Por su parte, el AA tiene una asíntota respecto al rendimiento, es decir, la precisión y el desempeño no mejora en cada iteración. A diferencia del AP que mejora conforme se tengan mayor cantidad de datos, como se ejemplifica en la figura 2.3.2.

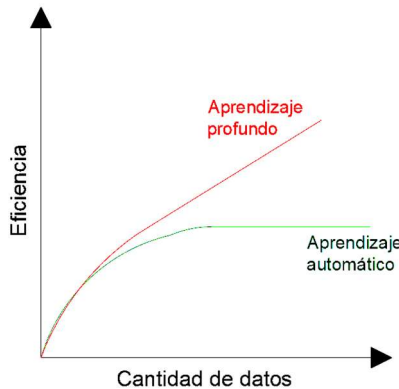


Figura 2.3.2. Eficiencia los tipos de aprendizaje

2.4 REDES NEURONALES

2.4.1 Neuronas artificiales

Una neurona artificial se comporta de manera similar a la biológica en la figura 2.4.1, se muestra un ejemplo de ésta, y en la figura 2.4.2 se muestra una neurona artificial. La neurona biológica cuenta con dendritas, donde se recibe información de otras neuronas (sinapsis), en el centro se encuentra el cuerpo celular o soma, parte en la que se procesa la información recibida. Por último, se tiene el axón, encargado de distribuir la información hacia otras neuronas procesada mediante una serie de terminales, localizadas al final de éste.




Figura 2.4.1. Neurona biológica

Mientras que en las neuronas artificiales en el inicio se observan ramas similares a las dendritas, se tienen puntos en los que se ingresa la información o datos para analizar (X_i), después se tienen las intensidades o pesos (W_i) lo que se relacionan a la sinapsis. En el núcleo se acumula la sumatoria de todas las entradas (Σ) y procesan los datos mediante una función de activación o función de umbral ($f()$), al final se tiene una salida que depende de los procesos previos a este paso; también se encarga de distribuir la información a otras neuronas, es decir, tiene la función del axón.




Figura 2.4.2 . Neurona artificial

De acuerdo con Basogain (s.f.), la neurona artificial fue diseñada para emular las características del funcionamiento básico de la neurona biológica. En esencia, se aplica un conjunto de entradas a la neurona, cada una de las que representa una salida de otra neurona.

Flórez y Fernández (2008) caracterizaron a las RNA con los siguientes elementos (figura 2.4.3):

- Valor o estado de activación (a_{t-1}), anterior a la recepción de los estímulos.
- Estímulos o entradas a la neurona (x_i), con pesos asociados (w_{ij}).
- Función de propagación, que determina la entrada total a la neurona (Net_j) o bias.
- Función de activación o transferencia (f), que combina las entradas a la neurona con el estado de activación inicial para producir un nuevo valor de activación.
- Función de salida (F), que transforma el estado final de activación en la señal de salida.
- Señal de salida que se transmite, en su caso, a otras neuronas artificiales (y_i).
- Regla de aprendizaje, que determina la forma de actualización de los pesos de la red (aprendizaje).

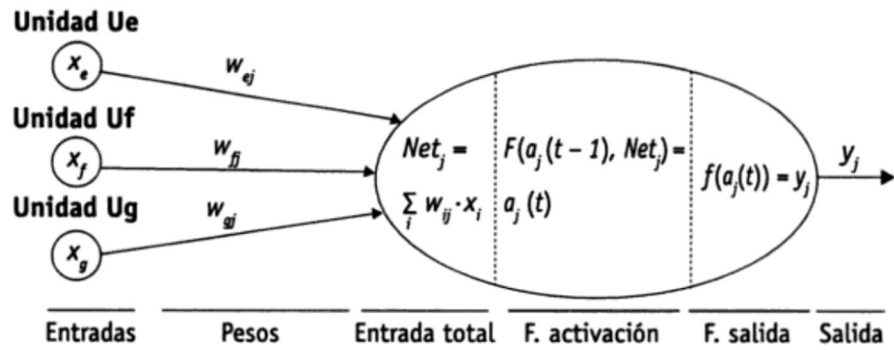


Figura 2.4.3. Modelo genérico de una neurona artificial

2.4.2 Redes neuronales artificiales

Usualmente conocida como red neuronal o red neuronal artificial (RNA), o con las iniciales en inglés, ANN (*Artificial Neural Networks*), son un conjunto de neuronas artificiales que están conectadas entre sí. De acuerdo con International Business Machines Corporation (2021), “una red neuronal es un modelo simplificado que emula el modo en que el cerebro humano procesa la información: funciona simulando un número elevado de unidades de procesamiento interconectadas que parecen versiones abstractas de neuronas”.

De acuerdo con Flórez y Fernández (2008), las redes neuronales están formadas por varias neuronas artificiales. Estas son dispositivos simples de cálculo que a partir de un vector de entrada procedente del mundo exterior o mediante estímulos recibidos por otras neuronas proporcionan una respuesta única (salida). En la figura 2.4.4 se ejemplifica una red neuronal artificial.




Figura 2.4.4. Esquema de una RNA básica

Resulta útil caracterizar 3 tipos de neuronas artificiales, unidades de entrada, de salida y ocultas, así como mencionar que las capas de una red neuronal están distribuidas de la misma manera:

- **Neuronas de entrada:** Reciben señales desde el entorno, provenientes de sensores o de otros sectores del sistema (como archivos de almacenamiento de patrones de aprendizaje).
- **Neuronas ocultas:** Reciben estímulos y emiten salidas dentro del sistema sin mantener contacto alguno con el exterior. En ellas se lleva a cabo el procesamiento básico de la información, estableciendo la representación interna de esta.
- **Neuronas de salida:** Envían su señal directamente fuera del sistema una vez finalizado el tratamiento de la información (salidas de la red).

En la figura 2.4.4, se muestra el flujo de los datos a través de una RNA, pero no el proceso que elabora en cada una de las partes. A continuación, se realiza una breve explicación de cada uno de estos procesos:

- a) **Estado de activación:** Todas las neuronas que son parte de una RNA se encuentran en un estado excitado o de reposo (continuo o discreto, limitado o ilimitado). Es necesario conocer el estado del sistema en un instante por medio un vector de números reales para representar el estado de activación respecto al tiempo de todas las neuronas. Se puede representar con la ecuación (Ec. 2.4.1)

$$A(t) = [a_1(t), a_2(t), \dots, a_i(t), \dots, a_N(t)] \quad (\text{Ec. 2.4.1})$$

- b) **Estímulos o entradas a la neurona:** Son variables procedentes del exterior que se le otorgan a las neuronas de entrada. Puede ser de dos tipos: “binarias” (0 ó 1, sexo que toman los valores “masculino” o “femenino”, etc.) o “continua” (variable que toma un valor numérico como el peso o altura de un grupo de personas), dependiendo del tipo de red y su arquitectura. Las capas superiores (siguientes a la capa de entrada), tendrá como entrada (inputs) datos de salida de la capa previa debido a la conexión entre estas (sinapsis), estos datos van acompañados de un peso indicativo de la importancia relativa. Las salidas son binarias o continuas.

Por lo anterior se puede afirmar que cada j -ésima neurona de la red, recibe un conjunto de señales que le proporcionan información del estado de activaciones de todas las neuronas previas. Así, cada conexión entre la neurona i y la neurona j está ponderada por un peso W_{ij} (Flórez y Fernández, 2008).

- c) **Función de propagación:** Indica el procedimiento que debe realizar la combinación de valores de entrada con los pesos de las conexiones que llegan a una neurona. Los pesos W_{ij} se agrupan en un vector W , en el que se indica la influencia que tiene la neurona i sobre la j . Los pesos W_{ij} pueden ser positivos, negativos o nulos. Cuando i está activa y j recibe una señal de activación se considera peso positivo. En caso de que i esté activa y j reciba una señal de desactivación, es un peso negativo. Si el peso $W_{ij} = 0$ se considera un peso nulo y no existe conexión entre las dos neuronas.

Flórez y Fernández (2008) señalan que, de esta forma, la regla de propagación permite obtener, a partir de las entradas y los pesos recibidos, el valor del potencial postsináptico Net_j de la neurona en un momento t , de acuerdo con la función σ_j , como se ejemplifica en la ecuación (Ec. 2.4.2):

$$Net_j(t) = \sigma_j(W_{ij}, X_i(t)) \quad (\text{Ec. 2.4.2})$$

La función más utilizada es la de tipo lineal, esta se basa en la suma de las entradas con los pesos sinápticos asociados a estas (ecuación (Ec. 2.4.3)).

$$Net_j(t) = \sum_i W_{ij} * X_i(t) \quad (\text{Ec. 2.4.3})$$

- d) **Función de activación o transferencia:** Combina la entrada total a la j -ésima neurona (potencial postsináptico Net_j), obtenida a partir de los estímulos y pesos recibidos, con el

estado inicial de la neurona $[a_j(t - 1)]$, para producir un nuevo estado de activación acorde con la nueva información recibida $[a_j(t)]$, como se muestra en la ecuación (Ec. 2.4.4).

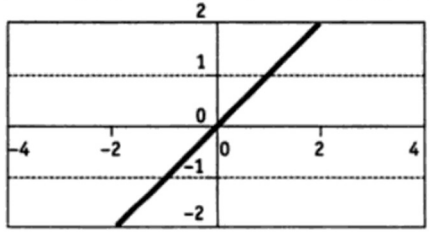
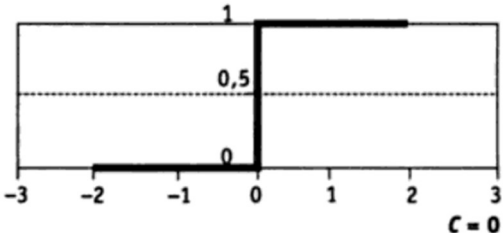
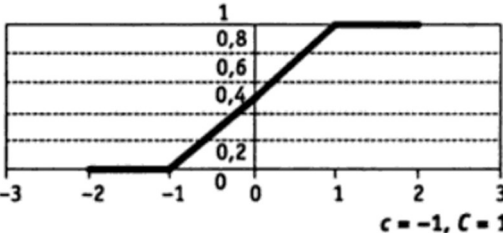
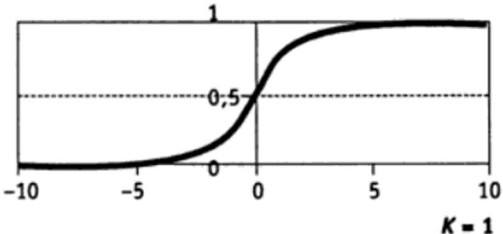
$$a_j(t) = f[a_j(t - 1), Net_j(t)] \quad (\text{Ec. 2.4.4})$$

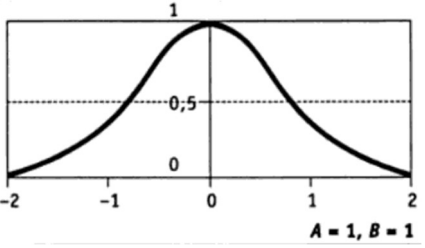
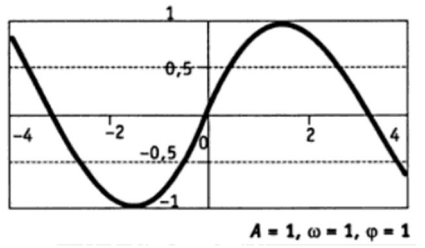
Por otro lado, en muchos modelos de redes no se considera que el estado actual de una neurona no depende de su estado previo, como se expresa en la ecuación (Ec. 2.4.5).

$$a_j(t) = f[Net_j(t)] = f\left[\sum_i W_{ij} * X_i(t)\right] \quad (\text{Ec. 2.4.5})$$

Existen muchas funciones de transferencia, las más comunes son: lineal o identidad, escalón o signo, mixta o lineal a tramos, sigmoide o logística, gaussiana y sinusoidal. En la tabla 2.4.1, se presentan las funciones y se muestra la representación gráfica de cada una.

Tabla 2.4.1. Funciones de activación comunes

Función	Representación
<p style="text-align: center;">Lineal</p> $a_j = f(Net_j(t)) = Net_j$ <p style="text-align: center;"><i>Rango</i> = $(-\infty, \infty)$</p>	
<p style="text-align: center;">Escalón</p> $a_j = f(Net_j) = \begin{cases} 1 & \text{si } Net_j \geq c \\ 0 & \text{si } Net_j < c \end{cases}$ <p style="text-align: center;"><i>Rango</i> = $\{0,1\}$</p>	
<p style="text-align: center;">Mixta</p> $a_j = f(Net_j) = \begin{cases} 1 & \text{si } Net_j \geq c \\ Net_j & \text{si } c \leq Net_j < c \\ 0 & \text{si } Net_j < c \end{cases}$ <p style="text-align: center;"><i>Rango</i> = $[0,1]$</p>	
<p style="text-align: center;">Sigmoide</p> $a_j = f(Net_j) = \frac{1}{1 + e^{-k*Net_j}}$ <p style="text-align: center;"><i>Rango</i> = $(0,1)$; $k > 0$</p>	

<p>Gaussiana</p> $a_j = f(Net_j) = Ae^{-B[Net_j]^2}$ <p>Rango = (0,1) ; A > 0 ; B > 0</p>	
<p>Sinusoidal</p> $a_j = f(Net_j) = A * \sin(\omega * Net_j + \varphi)$ <p>Rango = (-1,1)</p>	

- e) **Función de salida:** Toda neurona tiene asociada una función de salida F que transforma el estado actual de activación $a_j = f(Net_j(t))$ en una señal $y_j(t)$, ecuación (Ec. 2.4.6

$$y_j(t) = F(a_j) = F\left(f(Net_j(t))\right) \quad (\text{Ec. 2.4.6})$$

Por lo tanto, el vector que contiene las salidas de todas las funciones en un instante se representa con la ecuación (Ec. 2.4.7.

$$Y(t) = F\left(a_1(t), a_2(t), \dots, a_j(t), \dots, a_N(t)\right) = F\left(f(Net_1(t)), f(Net_2(t)), \dots, f(Net_j(t)), \dots, f(Net_N(t))\right) \quad (\text{Ec. 2.4.7})$$

- f) **Señal de salida:** En problemas de clasificación se considera un conjunto finito de salidas, y en tareas de ajuste de funciones, salidas continuas dentro de un determinado intervalo. El tipo de salida determinará la función de transferencia y salida que se implementa en las neuronas de la última capa de la red.
- g) **Regla de aprendizaje:** El conocimiento se encuentra representado en los pesos de las conexiones (W_{ij}) entre las neuronas, por lo que el proceso de aprendizaje (entrenamiento) requiere un cambio en los valores de los pesos, por lo tanto, se modifican las conexiones.

2.5 CLASIFICACIÓN DE LAS REDES NEURONALES

Existen varios tipos de RNA, se clasifican de acuerdo con sus características o propiedades de su arquitectura (distribución), tipo de aprendizaje, etc. A continuación, se exponen algunas de estas clasificaciones.

2.5.1 Estructura por capas

La capacidad de cálculo y la potencia requerida por la computadora que realizará el proceso de la RNA es directamente proporcional a las conexiones entre neuronas que constituyen la red.

2.5.1.1 Redes monocapa

Como lo dice su nombre, están compuestas por una sola capa de neuronas, es la RNA más sencilla, ejemplificada en la figura 2.5.1, donde los nodos, representados con círculos; por los que se distribuyen los datos de entrada no se consideran constituyentes de una capa. Todas las entradas están conectadas a toda neurona artificial, estas conexiones conllevan su propio peso implícito.

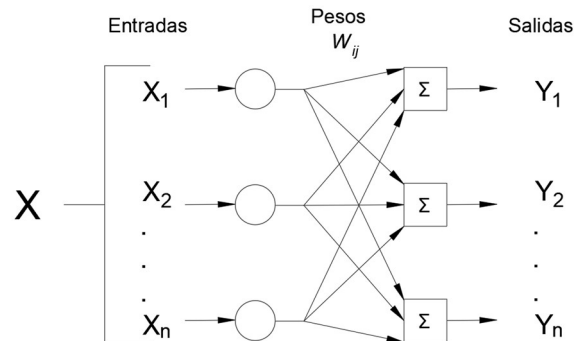


Figura 2.5.1. Ejemplo de RNA monocapa

2.5.1.2 Redes multicapa

En este tipo de red, las neuronas están organizadas en varias capas (entrada, oculta u ocultas y salida), por lo que forman un grupo de capas simples en cascada. Un ejemplo se muestra en la figura 2.5.2. Se observa que la salida de una capa es la entrada de la siguiente, este tipo de red presenta cualidades y aspectos superiores a los presentes en las redes monocapa.

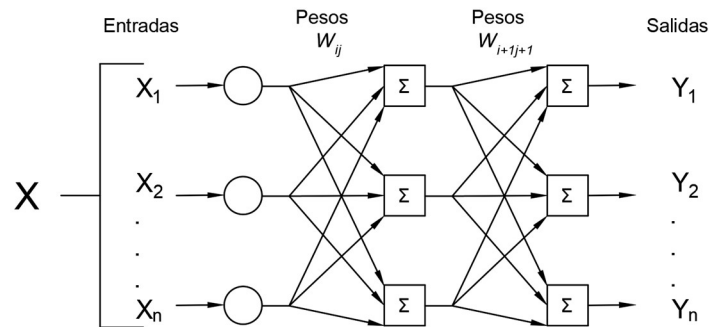


Figura 2.5.2. Ejemplo de RNA multicapa (dos capas)

2.5.2 Estructura por flujo de datos

La dirección que tienen los datos determina el flujo que siguen, se tiene dos tipos:

2.5.2.1 Redes de propagación hacia adelante (feedforward)

Ninguna de las salidas de las neuronas es entrada de una neurona de la misma capa, ni de ninguna capa precedente. La información circula sólo en un sentido, desde las capas de entrada hacia las de salida, en la figura 2.5.3 se muestra un ejemplo de éstas.


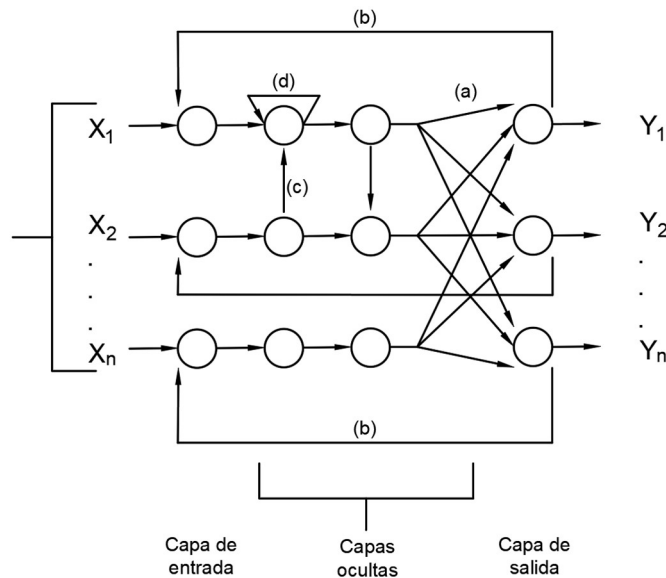


Figura 2.5.3. Flujo de datos hacia adelante

2.5.2.2 *Redes de propagación hacia atrás (feedback)*

Las salidas de las neuronas pueden ser la entrada de una neurona en el mismo nivel, llamada conexión lateral; o de niveles previos. En estas redes se presentan ciclos cerrados conocidos como sistemas recurrentes; la salida de una neurona se convierte en la entrada de esta. En la figura 2.5.4 se muestra un ejemplo de este tipo de redes.



Nota: (a) conexión hacia adelante, (b) conexión hacia atrás, (c) conexión lateral, (d) conexión recurrente

Figura 2.5.4. Tipos de RNA por flujo de datos

2.5.3 Tipo de respuesta de la red

2.5.3.1 *Redes hetero asociativas*

Este tipo de redes están entrenadas para que, si se presenta un determinado patrón o valor A; el sistema responda con un valor diferente B. Este tipo de RNA requieren mínimo 2 capas, una de entrada para captar y retener la información y otra para mantener la salida con la información asociada.

2.5.3.2 *2.6.2 Redes auto asociativas*

Entrenadas para asociar un patrón consigo mismo, reduciendo su interés ante la presentación de un patrón A afectado por ruido (A'), para que su respuesta sea el patrón original A, por lo que la red actúa como un filtro. Estas redes se pueden implementar en una capa, en la que se retiene la

información de entrada y representa la información auto asociada. Si se desea mantener la información de entrada y salida, se agregarán capas adicionales.

2.5.4 Tipo de aprendizaje

2.5.4.1 Aprendizaje supervisado

Se caracteriza por la presencia de un agente externo (supervisor) que controla el proceso de entrenamiento, estableciendo la respuesta que debería generar la red a partir de una entrada determinada. Estos algoritmos requieren el emparejamiento de cada vector de entrada con su correspondiente vector de salida.

El entrenamiento consiste en presentar el vector de entrada a la red, calcular la salida de la red y compararla con la salida deseada o real; el error o diferencia resultante se utiliza para retroalimentar en forma de iteraciones a la red y cambiar los pesos de acuerdo con un algoritmo que tienda a minimizar el error (Basogain, s.f.).

2.5.4.2 Aprendizaje no supervisado

Este tipo de aprendizaje no requiere de un vector de salidas deseadas, por lo tanto, no se compara entre las salidas reales y las salidas esperadas, el vector de entrenamiento sólo es el vector de entrada. La interpretación de las salidas depende de la estructura de estas y también del algoritmo de aprendizaje.

El algoritmo de entrenamiento modifica los pesos de la red de forma que produzca vectores de salida consistentes mediante las propiedades estadísticas de la entrada de entrenamiento y agrupa en clases a los vectores similares, esto se le conoce como asociación de características (feature mapping). Las dos metodologías más utilizadas son el aprendizaje hebbiano y el competitivo y cooperativo.

2.5.4.3 Aprendizaje reforzado

El algoritmo se reduce a indicar mediante una señal de refuerzo si la salida obtenida en la red se ajusta a la deseada (éxito = +1 o fracaso = -1). Cuando la respuesta es correcta, el aprendizaje por refuerzo es similar al aprendizaje supervisado, debido a que en ambos casos el modelo recibe información acerca de la respuesta correcta o idónea. En cambio, cuando se tiene una respuesta errónea el aprendizaje supervisado informa exactamente al modelo qué debería haber respondido, mientras que el aprendizaje por refuerzo solo le informa acerca de que el comportamiento ha sido inapropiado y cuánto error se ha cometido.

Se trata de un aprendizaje supervisado, pero más lento, con fundamento en la idea de no disponer de un ejemplo completo del comportamiento deseado, es decir; de no indicar durante el entrenamiento exactamente la salida que se desea que proporcione la red ante una determinada entrada (Matich, 2001).

En este tipo de aprendizaje, la función del supervisor se asemeja más a la de un crítico que opina de la respuesta de la red, más que a la de un maestro, que indica a la red la respuesta concreta que debe generar; como sería en el aprendizaje supervisado.

2.5.5 Tipo de salida

Los modelos de aprendizaje supervisado, con los datos de entrada se tienen datos de salida objetivo o valores reales; se podrán predecir variables de salida en función de futuras variables de entrada, las que pueden ser de clasificación o de regresión. La clasificación se enfoca en que el modelo elija

alguna clasificación preestablecida a la que pertenece la nueva predicción o salida. En la figura 2.5.5 se muestra un ejemplo que, con base en las entradas longitud y peso, se clasifica como grupo verde o azul. En la salida de regresión, el objetivo es un valor numérico, como se muestra en la figura 2.5.6, en la que se estiman puntos específicos de la función.

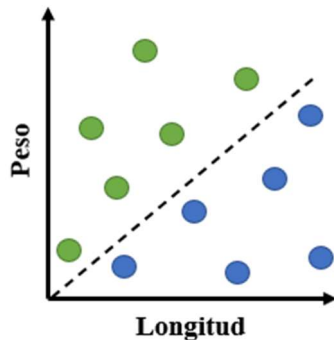


Figura 2.5.5. Ejemplo de clasificación




Figura 2.5.6. Ejemplo de regresión

Por otro lado, los modelos de aprendizaje no supervisado tienen reglas de clustering y reglas de asociación. El clustering es una tarea que tiene como finalidad principal el agrupamiento de conjuntos de objetos no etiquetados para construir subconjuntos de datos conocidos como clusters. Dependiendo de las reglas de agrupamiento se pueden clasificar de diferente manera (figura 2.5.7). Las reglas de asociación se utilizan para descubrir hechos que ocurren en común dentro de un determinado conjunto de datos, por ejemplo, cuando pides un caldo, este lleva vegetales y para ingerirse se utiliza una cuchara.




Figura 2.5.7. Ejemplo de clustering

2.6 EVALUACIÓN DE UNA RED NEURONAL

Al final del proceso, cuando se obtiene una predicción por parte de la red neuronal, se deben evaluar los resultados. La manera en que se estima es comparando los valores de la predicción con los valores correctos, aquellos con los que se elaboró la base de datos.

2.6.1 Función de coste

La función de coste es un promedio del error que proporciona un valor único con el que se evalúa la red neuronal y ayuda a monitorizar su rendimiento durante la base de entrenamiento en cada una de las iteraciones (epochs). La función de coste debe ir reduciéndose, ya que esta se encuentra ligada al

error que tiene la red neuronal, a causa de la modificación de los pesos (W_{ij}) y de la función de propagación, valores bias.

Existen diversas funciones de coste, las que están dadas para modelos de clasificación, como son: exactitud (accuracy), recuerdo (recall), precisión (precision), etc.; y para modelos de regresión: Promedio del error absoluto (mean absolute error, mae), error cuadrático medio (mean square error, mse), etc.

Cada una de éstas tiene un comportamiento diferente y se enfoca a una medición del error de manera distinta. También depende que tipo de base de datos es con la que se entrena al modelo, cantidad de datos, distribución, precisión, etc., y de esta forma, elegir el método ideal para cada modelo en específico.

2.6.2 Gradiente descendente

El método de descenso por gradiente, gradient descent, de ahora en adelante, es uno de los algoritmos de optimización más populares en aprendizaje automático, particularmente por su uso extensivo en el campo de las redes neuronales. El gradiente descendente, es un método general de minimización para cualquier función (f). A la versión original se le considera lenta pero versátil, sobre todo para casos de funciones multidimensionales.

Al algoritmo gradiente descendente se le conoce por varios nombres, sobre todo en la literatura en inglés (vanilla gradient descent, batch gradient descent), algunas veces se les da el nombre de steepest descent, pero este término es más propio para aproximación analítica de integrales. El algoritmo también tiene una versión gemela que, en lugar de buscar por un mínimo, busca el punto máximo de una función (Meza Ruíz, 2016).

El gradiente descendente trabaja de la siguiente la manera, teniendo una función cualquiera, en este caso la función de coste busca mínimo absoluto, figura 2.6.1; el punto a es un mínimo, pero el punto b es el mínimo absoluto, punto que se busca obtener con el gradiente descendente.




Figura 2.6.1. Mínimo absoluto

Como se observa en la figura 2.6.2-a, se realizaron distintas iteraciones con una diferencia pequeña (tasa de aprendizaje), ya que se deben hacer varias para llegar al mínimo. En figura 2.6.2-b, se hacen pocas iteraciones con una tasa de aprendizaje mayor y no se consigue un resultado correcto. En la figura 2.6.2-c se muestra una tasa de aprendizaje que no es constante, como en los casos anteriores, lo que se conoce como gradiente descendente adaptativo; mientras más se acerca al mínimo la tasa de aprendizaje se va reduciendo, por lo que se hacen más iteraciones y se llega al valor mínimo.

Existen diversos métodos con lo que se puede llevar a cabo este proceso de gradiente descendente adaptativo, como el método Adam, Adadelta, Nadam, entre otros.




Figura 2.6.2. Descenso de gradiente

2.6.3 Ajuste del modelo

El entrenamiento de modelos de inteligencia artificial, aprendizaje automático o aprendizaje profundo se podría considerar que entre más iteraciones realice; el aprendizaje será más exacto o en caso contrario, cuando se realizan pocas iteraciones el modelo aprenderá incorrectamente. No obstante, el aprendizaje del modelo depende de todos los aspectos mencionados previamente, ya que cuando se tiene un aprendizaje infructuoso se pueden presentar dos situaciones; el sobre ajuste (*overfitting*) o el bajo ajuste (*underfitting*).

2.6.3.1 Sobre ajuste (*overfitting*)

El sobre ajuste se presenta cuando el modelo se apega demasiado al ruido de los datos. Cuando se hacen muchas iteraciones en la fase de entrenamiento o se tienen modelos muy complejos, con una cantidad de neuronas y capas ocultas muy grande; provoca que el modelo no aprenda, sino memorice los datos y se sobre ajusta a los datos de salida. Cuando esto ocurre, se presenta en el conjunto de datos de entrenamiento un bajo error, pero en el conjunto de datos de prueba hay errores elevados.

En la figura 2.6.3 se presenta en color verde un modelo ideal, que se aproxima a todos los valores y en color rojo un modelo sobre ajustado, que tiene un comportamiento erróneo. Esto se ejemplifica con el punto negro, ya que en el modelo ideal tendría una predicción con un error casi nulo, pero con el modelo sobre ajustado hay un error elevado.

2.6.3.2 Bajo ajuste (*underfitting*)

El bajo ajuste se produce cuando el modelo no se ajusta a la tendencia de los datos, esto es por un bajo número de iteraciones o el modelo es muy simple, bajo número de capas o de neuronas. En la figura 2.6.3, de color magenta, se observa un modelo bajo ajustado, su comportamiento no va de acuerdo con los datos, por lo tanto; este no aprende de manera eficiente y sus predicciones serán incorrectas.




Figura 2.6.3. Ejemplo de sobre ajuste y bajo ajuste

2.6.4 Rendimiento del modelo

Como se ha explicado en apartados anteriores, para que un modelo sea eficiente, se debe reducir el error en la predicción de las salidas, mientras ocurre el proceso de aprendizaje. En la figura 2.6.4 se presenta de color verde un modelo idóneo que va reduciendo el error de acuerdo con el número de iteraciones que se realizan y de color rojo un modelo defectuoso, en donde el error va aumentando conforme aumenta la cantidad de iteraciones.

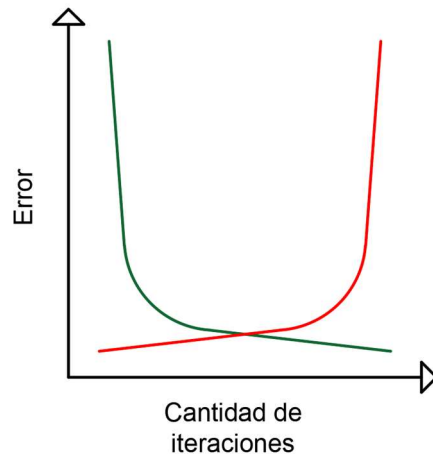


Figura 2.6.4. Rendimiento de un modelo

La figura 2.6.5 se muestran diversos rendimientos en función de la reducción del error respecto a la cantidad de iteraciones que realiza el modelo. En la línea verde se muestra el comportamiento de los datos de entrenamiento del modelo eficiente, siendo éste, su objetivo principal. Las otras 3 líneas reflejan el rendimiento que tiene el conjunto de datos de prueba: en color azul se muestra el rendimiento para estos datos, en donde se observa que tiene un comportamiento similar, por lo tanto; la red neuronal tiene un rendimiento óptimo. La línea magenta ejemplifica que el error que no se minimiza suficiente debido a que la cantidad de iteraciones es baja, por lo que existe bajo ajuste (underfitting). En rojo se muestra la situación para el sobre ajuste (overfitting), a pesar de que se tiene un rendimiento aceptable, conforme siguen aumentando la cantidad de iteraciones, el error comienza a incrementar rápidamente.

Una solución para evitar el sobre ajuste es evitar que se supere el número de iteraciones donde se encuentra el punto rojo, para ello se vuelve a entrenar al modelo o, en su defecto, utilizar alguna

función que ayude a evitar el sobre ajuste y detenga el entrenamiento cuando deje de existir la mejora en el rendimiento.

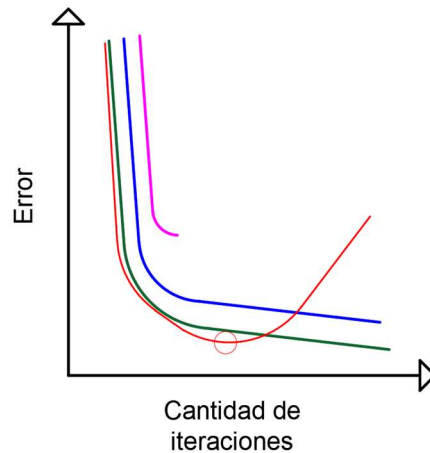


Figura 2.6.5. Diversos rendimientos

2.6.5 Detención temprana (EarlyStopping)

Para evitar problemas con el rendimiento y que los modelos tengan sobre ajuste o bajo ajuste se utilizó la función callback *EarlyStopping*, que sirve para detener el entrenamiento del modelo antes de la cantidad especificada de iteraciones bajo ciertas condiciones.

Los parámetros de la función son: “monitor”, aplicado al monitoreo del parámetro de salida perteneciente al conjunto de datos de pruebas “val_loss”, reducción del error en el conjunto de prueba. El segundo parámetro es el “mode”, el valor que va a buscar en el conjunto val_loss, en este caso será mínimo “min”, el tercero es el detallado, “verbose”, el que toma dos valores 0 o 1, el primero para que se haga de manera pasiva o silenciosa y el segundo para que se haga de manera activa, en este caso será 1. Por último, se tiene el valor de rango “patience”, es la cantidad en el que va a detener el aprendizaje si no mejora el rendimiento. A continuación, se muestra la línea del código que se utilizó:

```
early_stop = EarlyStopping (monitor='val_loss', mode='min', verbose = 1, patience = 10)
```

De acuerdo con los parámetros establecidos, el callback *EarlyStopping* va a detener el entrenamiento del modelo cuando el rendimiento de los datos de salida del conjunto de prueba no mejore después de 10 iteraciones; por lo tanto, se puede asegurar que no se presentará un sobre ajuste, ni el bajo ajuste del modelo, respecto a la distribución de los datos. Esta función se utilizó en todos los modelos de redes neuronales artificiales desarrollados durante este trabajo.

CAPÍTULO 3

3 ELABORACIÓN DE LA BASE DE DATOS

3.1 DISEÑO ESTÁTICO DE MARCOS

Se diseñaron 27 marcos planos de seis, nueve y doce niveles de altura. Las características geométricas, número y longitud de crujías, variaron como se muestra en la tabla 3.1.1. La altura de entrepiso es de 4 m para planta baja y 3.5 m para los subsecuentes. Para los marcos se utilizó acero estructural grado 50 de esfuerzo a la fluencia $f_y = 3515 \text{ kg/cm}^2$. Para el diseño y análisis, se consideraron a los marcos con uso de oficinas.

Tabla 3.1.1. Variación de propiedades geométricas de marcos

Niveles (#)	Número de crujías (#)	Longitud de crujías (m)
6	3	8
9	5	9
12	4	10

Los diseños se realizaron siguiendo las recomendaciones de las Normas Técnicas Complementarias para el Diseño y Construcción de Estructuras de Acero del 2020 (NTCEA-20), del Reglamento de Construcciones para el Distrito Federal, RCDF, (Gaceta Oficial de la Ciudad de México, 2020). Los marcos se le añadieron las cargas unitarias estipuladas en las Normas Técnicas Complementarias sobre Criterios y Acciones para el Diseño Estructural de las Edificaciones 2020 (NTCCA-20), RCDF (Gaceta Oficial de la Ciudad de México, 2020) en la sección 15.9.2.2. En las tablas 3.1.2 y 3.1.3, se muestran las cargas consideradas para los marcos según su área tributaria.

Tabla 3.1.2. Carga muerta

Descripción	Entrepiso		Azotea	
	kN/m ²	kg/m ²	kN/m ²	kg/m ²
Sobre carga muerta NTC	0.4	40	0.4	40
Muros divisorios	1.5	150	-	-
Acabado inferior (piso)	0.4	40	-	-
Acabado superior	0.4	40	0.4	40
Instalaciones	0.6	60	-	-
Impermeabilizante y enladrillado	-	-	1	100
Total	3.3	330	1.8	180

Tabla 3.1.3. Carga para marcos

L (m)	Ubicación	CMA (kN/m)	CVI (kN/m)	CV (kN/m)	PP (kN/m)
10	Entrepisos	33.00	18.00	25.00	24.00
	Azotea	18.00	2.00	4.00	24.00
9	Entrepisos	33.00	14.58	20.25	19.44
	Azotea	18.00	1.62	3.24	19.44
8	Entrepisos	33.00	11.52	16.00	15.36
	Azotea	18	1.28	2.56	15.36

*Nota: (CMA) Carga muerta adicional, (CVI) Carga viva instantánea, (CV) Carga viva, (PP) Peso propio

3. ELABORACIÓN DE LA BASE DE DATOS

En la tabla 3.1.4, se muestran los perfiles estructurales utilizados para los elementos de cada uno de los marcos. Por simplicidad se utilizaron los mismos perfiles en todos los niveles. También se anotan las propiedades geométricas de cada marco, y el nombre del modelo matemático. El nombre de cada modelo se definió por la cantidad de niveles (N), el número de crujiás (C) y la longitud de crujiás (L).

Tabla 3.1.4. Propiedades de los marcos

Modelo	Niveles #	Crujiás #	Longitud (m)	Vigas	Columnas (cm)
N6-C3-L8			8	W 21*68	HSS 30*30*2.86
N6-C3-L9		3	9	W 24*84	HSS 40*40*2.54
N6-C3-L10			10	W 27*102	HSS 50*50*2.54
N6-C4-L8			8	W 21*68	HSS 30*30*2.86
N6-C4-L9	6	4	9	W 24*84	HSS 40*40*2.54
N6-C4-L10			10	W 27*102	HSS 50*50*2.54
N6-C5-L8			8	W 21*68	HSS 30*30*2.86
N6-C5-L9		5	9	W 24*84	HSS 40*40*2.54
N6-C5-L10			10	W 27*102	HSS 50*50*2.54
N9-C3-L8			8	W 21*68	HSS 45*45*2.54
N9-C3-L9		3	9	W 24*84	HSS 50*50*3.18
N9-C3-L10			10	W 27*102	HSS 60*60*3.18
N9-C4-L8			8	W 21*68	HSS 45*45*2.54
N9-C4-L9	9	4	9	W 24*84	HSS 50*50*3.18
N9-C4-L10			10	W 27*102	HSS 60*60*3.18
N9-C5-L8			8	W 21*68	HSS 45*45*2.54
N9-C5-L9		5	9	W 24*84	HSS 50*50*3.18
N9-C5-L10			10	W 27*102	HSS 60*60*3.18
N12-C3-L8			8	W 21*68	HSS 60*60*2.54
N12-C3-L9		3	9	W 24*84	HSS 70*70*3.18
N12-C3-L10			10	W 27*102	HSS 70*70*3.81
N12-C4-L8			8	W 21*68	HSS 60*60*2.54
N12-C4-L9	12	4	9	W 24*84	HSS 70*70*3.18
N12-C4-L10			10	W 27*102	HSS 70*70*3.81
N12-C5-L8			8	W 21*68	HSS 60*60*2.54
N12-C5-L9		5	9	W 24*84	HSS 70*70*3.18
N12-C5-L10			10	W 27*102	HSS 70*70*3.81

La base de datos se amplió con variantes de los marcos principales, cambiando la altura de entrespiso y de la planta baja; se incrementó y redujo en 0.25 y 0.5 m, respectivamente. En la tabla 3.1.5, se muestra la variante de los marcos con un número de identificación. Cabe mencionar que para estos se utilizaron los mismos perfiles para las variantes que en los originales.

Tabla 3.1.5. Alturas de modelos

Cambio	h entrespiso	h PB	Modelos	ID
Original	3.5	4	27	1-27
+0.25	3.75	4.25	27	28-54
+0.50	4	4.5	27	55-81
-0.25	3.25	3.75	27	82-108

-0.50	3	3.5	27	109-135
-------	---	-----	----	---------

En la tabla 3.2.1, se muestra el valor del primer período de vibración de los 135 modelos. Se complementa con el modelo y un ID que se le asigna para facilitar la identificación de la altura de entrespacio y planta baja.

3.2 SISTEMA DE DISIPACIÓN DE ENERGÍA

La ecuación (Ec. 3.2.1), establece el equilibrio dinámico de una estructura con movimiento en la base, donde las fuerzas de inercia (masa por aceleración relativa), las fuerzas de amortiguamiento (viscosidad por velocidad relativa) y fuerzas de la estructura (rigidez por desplazamiento relativo), son iguales a la masa por la aceleración del suelo (base).

$$m\ddot{u} + c\dot{u} + ku(t) = -m\ddot{u}_g \quad (\text{Ec. 3.2.1})$$

Las vibraciones producidas por una acción sísmica o eólica en las estructuras pueden ser controladas con sistemas de disipación de energía con el fin de reducir las demandas de fuerzas en los elementos estructurales.

De acuerdo con Gómez et al. (2008), existen cuatro formas de control: pasivo, activo, semi activo e híbrido.

- **Control pasivo:** Un sistema de control pasivo no requiere una fuente externa de potencia. Los dispositivos de control pasivo producen fuerzas en respuesta al movimiento de la estructura. La energía total en un sistema estructural controlado de esta forma, incluyendo los dispositivos mencionados, no aumenta.
- **Control activo:** Un sistema de control activo requiere de una fuente externa de potencia para alimentar los actuadores que aplican fuerzas a la estructura, las cuales pueden ser usadas tanto para suministrar, como para disipar energía, en la misma. En un sistema de control activo con retroalimentación, las señales enviadas a los actuadores de control son consecuencia de las respuestas, normalmente movimientos; de la estructura, medidas con sensores físicos.
- **Control semiactivo:** Los sistemas de control semiactivo son una clase de sistemas de control activo para los que la energía externa requerida es de menor orden de magnitud, comparada con la que necesitan los sistemas convencionales. Normalmente los dispositivos de control semiactivo no suministran energía mecánica al sistema estructural (incluyendo estructura y actuadores) y, por lo tanto, se garantiza la estabilidad tipo entrada-acotada salida acotada (BIBO). Estos dispositivos frecuentemente son considerados como dispositivos pasivos controlables.
- **Control híbrido:** Los sistemas de control híbrido son aquellos que emplean una combinación de sistemas pasivos y activos. Por ejemplo, una estructura acondicionada con amortiguadores viscoelásticos y un amortiguador activo de masa en la parte superior del edificio; o una estructura aislada en la base con actuadores controlados activamente para mejorar su comportamiento.

Tabla 3.2.1. Períodos de vibración de las estructuras

ID	Modelo	Período (s)	ID	Modelo	Período (s)	ID	Modelo	Período (s)	ID	Modelo	Período (s)	ID	Modelo	Período (s)
1	N6-C3-L8	1.76	28	N6-C3-L8+0.25	1.91	55	N6-C3-L8+0.5	2.07	82	N6-C3-L8-0.25	1.62	109	N6-C3-L8-0.5	1.47
2	N6-C3-L9	1.51	29	N6-C3-L9+0.25	1.63	56	N6-C3-L9+0.5	1.76	83	N6-C3-L9-0.25	1.39	110	N6-C3-L9-0.5	1.27
3	N6-C3-L10	1.35	30	N6-C3-L10+0.25	1.45	57	N6-C3-L10+0.5	1.56	84	N6-C3-L10-0.25	1.24	111	N6-C3-L10-0.5	1.14
4	N6-C4-L8	1.78	31	N6-C4-L8+0.25	1.94	58	N6-C4-L8+0.5	2.09	85	N6-C4-L8-0.25	1.64	112	N6-C4-L8-0.5	1.49
5	N6-C4-L9	1.52	32	N6-C4-L9+0.25	1.65	59	N6-C4-L9+0.5	1.78	86	N6-C4-L9-0.25	1.4	113	N6-C4-L9-0.5	1.28
6	N6-C4-L10	1.36	33	N6-C4-L10+0.25	1.47	60	N6-C4-L10+0.5	1.58	87	N6-C4-L10-0.25	1.25	114	N6-C4-L10-0.5	1.15
7	N6-C5-L8	1.8	34	N6-C5-L8+0.25	1.95	61	N6-C5-L8+0.5	2.11	88	N6-C5-L8-0.25	1.65	115	N6-C5-L8-0.5	1.5
8	N6-C5-L9	1.53	35	N6-C5-L9+0.25	1.66	62	N6-C5-L9+0.5	1.79	89	N6-C5-L9-0.25	1.41	116	N6-C5-L9-0.5	1.29
9	N6-C5-L10	1.37	36	N6-C5-L10+0.25	1.48	63	N6-C5-L10+0.5	1.59	90	N6-C5-L10-0.25	1.26	117	N6-C5-L10-0.5	1.15
10	N9-C3-L8	2.21	37	N9-C3-L8+0.25	2.38	64	N9-C3-L8+0.5	2.56	91	N9-C3-L8-0.25	2.03	118	N9-C3-L8-0.5	1.87
11	N9-C3-L9	2.04	38	N9-C3-L9+0.25	2.2	65	N9-C3-L9+0.5	2.37	92	N9-C3-L9-0.25	1.88	119	N9-C3-L9-0.5	1.73
12	N9-C3-L10	1.89	39	N9-C3-L10+0.25	2.04	66	N9-C3-L10+0.5	2.19	93	N9-C3-L10-0.25	1.74	120	N9-C3-L10-0.5	1.6
13	N9-C4-L8	2.22	40	N9-C4-L8+0.25	2.4	67	N9-C4-L8+0.5	2.58	94	N9-C4-L8-0.25	2.04	121	N9-C4-L8-0.5	1.88
14	N9-C4-L9	2.05	41	N9-C4-L9+0.25	2.21	68	N9-C4-L9+0.5	2.38	95	N9-C4-L9-0.25	1.89	122	N9-C4-L9-0.5	1.73
15	N9-C4-L10	1.9	42	N9-C4-L10+0.25	2.05	69	N9-C4-L10+0.5	2.2	96	N9-C4-L10-0.25	1.75	123	N9-C4-L10-0.5	1.61
16	N9-C5-L8	2.23	43	N9-C5-L8+0.25	2.4	70	N9-C5-L8+0.5	2.58	97	N9-C5-L8-0.25	2.05	124	N9-C5-L8-0.5	1.88
17	N9-C5-L9	2.06	44	N9-C5-L9+0.25	2.22	71	N9-C5-L9+0.5	2.39	98	N9-C5-L9-0.25	1.9	125	N9-C5-L9-0.5	1.74
18	N9-C5-L10	1.91	45	N9-C5-L10+0.25	2.06	72	N9-C5-L10+0.5	2.21	99	N9-C5-L10-0.25	1.76	126	N9-C5-L10-0.5	1.61
19	N12-C3-L8	2.76	46	N12-C3-L8+0.25	2.98	73	N12-C3-L8+0.5	3.2	100	N12-C3-L8-0.25	2.55	127	N12-C3-L8-0.5	2.33
20	N12-C3-L9	2.53	47	N12-C3-L9+0.25	2.73	74	N12-C3-L9+0.5	2.93	101	N12-C3-L9-0.25	2.33	128	N12-C3-L9-0.5	2.14
21	N12-C3-L10	2.44	48	N12-C3-L10+0.25	2.64	75	N12-C3-L10+0.5	2.83	102	N12-C3-L10-0.25	2.25	129	N12-C3-L10-0.5	2.07
22	N12-C4-L8	2.77	49	N12-C4-L8+0.25	2.98	76	N12-C4-L8+0.5	3.2	103	N12-C4-L8-0.25	2.55	130	N12-C4-L8-0.5	2.34
23	N12-C4-L9	2.54	50	N12-C4-L9+0.25	2.73	77	N12-C4-L9+0.5	2.94	104	N12-C4-L9-0.25	2.34	131	N12-C4-L9-0.5	2.14
24	N12-C4-L10	2.45	51	N12-C4-L10+0.25	2.64	78	N12-C4-L10+0.5	2.84	105	N12-C4-L10-0.25	2.26	132	N12-C4-L10-0.5	2.07
25	N12-C5-L8	2.78	52	N12-C5-L8+0.25	2.99	79	N12-C5-L8+0.5	3.21	106	N12-C5-L8-0.25	2.56	133	N12-C5-L8-0.5	2.35
26	N12-C5-L9	2.54	53	N12-C5-L9+0.25	2.74	80	N12-C5-L9+0.5	2.94	107	N12-C5-L9-0.25	2.34	134	N12-C5-L9-0.5	2.15
27	N12-C5-L10	2.46	54	N12-C5-L10+0.25	2.65	81	N12-C5-L10+0.5	2.84	108	N12-C5-L10-0.25	2.27	135	N12-C5-L10-0.5	2.08

Los amortiguadores viscosos lineales son un sistema de disipación de energía pasivo, con una relación lineal entre la fuerza de amortiguamiento y la velocidad. En la ecuación (Ec. 3.2.2, se añade un término al amortiguamiento, valor dado por el sistema disipador, este añade al sistema una fuerza a la estructura para disipar la energía. Con la adición de más amortiguamiento, los valores de masa por aceleración y rigidez por desplazamiento se reducen, dado que la aceleración en la base mantiene el mismo valor.

$$m\ddot{u}(t) + [c\dot{u}(t) + f(\dot{u})] + ku(t) = -m\ddot{u}_g \quad (\text{Ec. 3.2.2})$$

En la figura 3.2.1, se muestra el esquema de un amortiguador viscoso lineal. Este funciona con un fluido viscoso que, al presentarse una demanda, la cabeza del pistón se mueve de un lado a otro; en su interior el fluido pasa de una cámara a otra a través de orificios en la cabeza del pistón. Se debe considerar que en el proceso de disipación de energía se da por la fricción entre el fluido y la cabeza del pistón por lo que, los amortiguadores se calientan (Brown et al., 2015).




Figura 3.2.1. Esquema de amortiguador viscoso lineal

A los marcos de la sección anterior se les agregó un sistema de disipación de energía pasivo, que consistió en amortiguadores viscosos lineales, diseñados bajo las especificaciones estipuladas en el ASCE 41-17 (American Society of Civil Engineers, 2017). Las distorsiones máximas de entrepiso se limitaron a 0.01 (1%), debido a que, en Guerrero et al., (2018), se considera que, para estructuras a base de marcos, los elementos comienzan a fluir con una distorsión de 0.01. Por otro lado, en las Normas Técnicas Complementarios para Diseño por Sismo, del RCDF (Gaceta Oficial de la Ciudad de México, 2020), se estipula que, para marcos de acero, la distorsión máxima de entrepiso con conexiones semirrígidas no debe superar el 0.015 (1.5%). Por último, el Federal Emergency Management Agency, FEMA (2018), estipula que, para marcos con conexiones a momento, la fluencia de los elementos se presenta con distorsiones en un intervalo entre 0.8 y 1.3%.

Los amortiguadores se diseñaron de acuerdo con el diagrama de cortante de cada marco y se utilizaron dos amortiguadores por nivel. En la figura 3.2.2, se muestran dos ejemplos de marcos con amortiguadores.




Figura 3.2.2. Marcos con amortiguadores

3.3 ANÁLISIS DINÁMICO

3.3.1 Sitios de estudio

Para el análisis de los marcos se utilizaron acelerogramas de 12 sitios en la ubicados en la Ciudad de México en suelo tipo II para estructura clase B, de acuerdo con las Normas Técnicas Complementarias para Diseño y Construcción de Cimentaciones (NTCDCC-20), del RCDF vigente. La información de los sitios se muestra en la figura 3.3.1 y en la tabla 3.3.1. Para tener un mejor conjunto de datos en los diversos períodos de vibración existentes, los sitios de estudio tienen períodos dominantes del suelo que varían de 0.5 a 1.2 s.

En la figura 3.3.1, se muestra el mapa geográfico de la Ciudad de México, en el que se señala con puntos en color rojo, la ubicación de los registros sísmicos utilizados. Estos se obtuvieron de la página de SASID, siguiendo las especificaciones de las NTCDS-20. Por otro lado, en la tabla 3.3.1, se muestra la información de los sitios como: coordenadas, dirección, punto de referencia y período dominante del suelo.




Figura 3.3.1. Sitios de estudio

Tabla 3.3.1. Información de puntos

Punto	Coordenadas		Dirección	Descripción	Ts (s)
	Latitud	Longitud			
A	19.4636385	-99.1605377	Av. jardín 245, San Francisco Xocotitla, Azcapotzalco, 02860 Ciudad de México, CDMX	Sam's club	1
B	19.4976237	-99.1751289	Av. de las Granjas 800, Santa Barbara, Azcapotzalco, 02230 Ciudad de México, CDMX, México	Arena CDMX	0.7
C	19.5290133	-99.1701937	Av. Tlalnepantla-Tenayuca, San José de la Escalera, Gustavo A. Madero, 07620 Ciudad de México, CDMX México	Metrobús Tenayuca	0.5
D	19.3423057	-99.1390479	Campestre Churubusco, Coyoacán, 04200 Ciudad de México, CDMX, México	Central Camionera taxqueña	1
E	19.3583200	-99.1720819	Av. Universidad 1338, Del Carmen, Coyoacán, 04100 Ciudad de México, CDMX, México	Salud digna	0.6

3. ELABORACIÓN DE LA BASE DE DATOS

F	19.3060098	-99.0649009	Av. Tláhuac 5501, San Lorenzo Tezonco, Iztapalapa 09930 Ciudad de México, CDMX, México	Torino Motors Tezonco	0.6
G	19.4875503	-99.2141819	Eje 3 Nte S/N, San Pedro Xalpa, Azcapotzalco, 02710 Ciudad de México, CDMX, México	Panteón San Isidro	0.5
H	19.2871651	-99.1367626	Prol. Canal de Miramontes 3855, Coapa, Ex de San Juan de Dios, Tlalpan, 14387 Ciudad de México, CDMX, México	Dirección UAM	0.7
I	19.4206207	-99.1769314	Chapultepec, Colonia Condesa, Cuauhtémoc, 11850 Ciudad de México, CDMX	Metro Chapultepec	0.9
J	19.3077109	-99.1344237	Calz. del Hueso 729, Coapa, Equipamiento Preparatoria N.º 5, Tlalpan 14310 Ciudad de México, CDMX, México	E.N.P #5 (U.N.A.M.)	0.8
K	19.3293474	-99.1282654	Av. Ejido San Fco. Culhuacán No. 192. Esq. Av. Sta. Ana Col Presidentes Ejidales Ira Secc, Coyoacán, C.P, 04470 Ciudad de México, CDMX, México	Pizza Plaza Santa Ana	1.2
L	19.3230704	-99.1200900	Calle Rosa María Sequeira 60. Andador S/N, Culhuacán, Coyoacán, 04480 Ciudad de México, CDMX, México	Colegio de bachilleres 4	1.1

3.3.2 Espectros de desplazamiento

Se determinó que los marcos tienen un amortiguamiento del 2.5%, límite superior, estipulado en las NTCDS-20. Para los análisis, se utilizó el acelerograma en el que se obtuvo mayor desplazamiento en el espectro de respuesta, dado el periodo de vibrar de las estructuras.

A partir del trabajo realizado por Ruíz (2018), se utilizó un amortiguamiento total del 30%. En la figura 3.3.2, se muestran los espectros de desplazamiento de los registros utilizando valores de amortiguamiento de 2.5% en verde y 30% en rojo. La parte sombreada representa el intervalo en que se encuentran los periodos de vibración de los 135 marcos estudiados. Se observa la reducción de los valores de desplazamiento al aumentar el valor del amortiguamiento.




Figura 3.3.2. Espectros de respuesta

3.3.3 Análisis dinámico no lineal

Para el análisis dinámico no lineal, se consideraron las propiedades dinámicas de los marcos mencionadas previamente, esto es, distorsión máxima de entrepiso de 0.01 (1%) y amortiguamiento total del 30%. Se utilizó la metodología propuesta por Terán y Virto (2009), donde indica que la capacidad de cada dispositivo se relaciona con la respuesta de desplazamientos para sistema de

3. ELABORACIÓN DE LA BASE DE DATOS

múltiples grados de libertad. Para lo anterior, se excitó a todos los marcos con un movimiento sísmico. En la figura 3.3.3, se muestra el acelerograma de dicho movimiento sísmico.

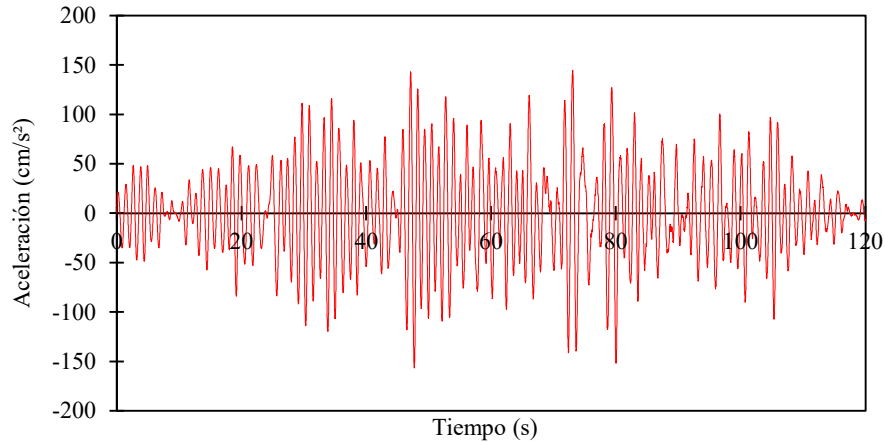


Figura 3.3.3. Acelerograma para análisis dinámico no lineal

Se comparó la respuesta de los marcos con la de un oscilador equivalente, la que se obtuvo con el método de superposición de desplazamientos modales clásico o análisis modal (Chopra, 2014). Se obtuvo la respuesta de un oscilador de múltiples grados de libertad, del producto de la respuesta oscilador de un grado de libertad equivalente y el factor de participación modal efectivo (producto del factor de participación y la forma modal en azotea).

En la figura 3.3.4, se presenta la historia de desplazamientos del marco N12-C5-L10, y la respuesta de un oscilador equivalente con 30% de amortiguamiento.

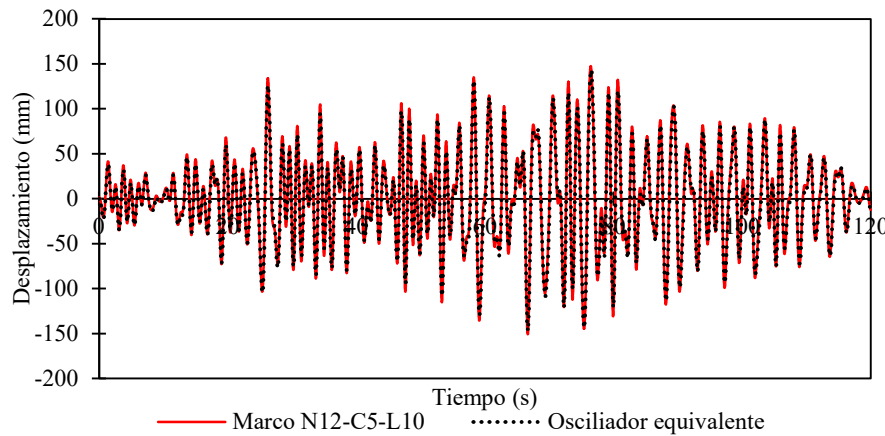


Figura 3.3.4. Historia de desplazamientos

Adicionalmente, se obtuvieron las distorsiones de entrepiso para corroborar que estas no excedieran el límite establecido anteriormente, figura 3.3.5. En este caso se aprecia que ninguna de las distorsiones supera al límite, por lo que las estructuras se encuentran en el intervalo de comportamiento elástico.




Figura 3.3.5. Distorsiones de entrepiso del marco N12-C5-L10

Lo descrito anteriormente se realizó para los 135 marcos. Todos tuvieron un comportamiento similar entre la historia de desplazamientos y la respuesta del oscilador de múltiples grados de libertad. Las distorsiones en algunos marcos superaron el límite de 1%. Pese a que superaron el límite, ninguna de las distorsiones fue mayor al 1.3 %, por lo que se considera que los elementos estructurales permanecen en el intervalo de comportamiento elástico.

3.4 BASE DE DATOS

La base de datos consta de la respuesta sísmica de los 135 marcos de acero, cada uno analizado con los 14 registros sísmicos descritos en la tabla 3.4.1. En total se cuenta con 1,890 resultados de los análisis sísmicos con sus respectivos parámetros que los caracterizan. Con esta información, se desarrollaron las RNA, con el objetivo de estimar la respuesta sísmica de las estructuras. Los datos de entrada para la base de datos son: período fundamental de vibración de la estructura, número de crujías, altura total, número de niveles, longitud de crujías, aceleración del espectro de respuesta, aceleración máxima del suelo, período dominante del suelo.

Tabla 3.4.1. Resumen de sismos de estudio

Punto	Sismo	Ts (s)	Ace. máx. (cm/s ²)	Punto	Sismo	Ts (s)	Ace. máx. (cm/s ²)
A	as2-2	1	150	H	hs2-2	0.7	99.3
B	bs3-2	0.7	106	I	is3-1	0.9	105
C	cs3-2	0.5	64.7		is4-1	0.9	154
D	ds2-1	1	192	J	js2-2	0.8	121
E	es4-2	0.6	79.5	K	ks1-1	1.2	175
F	fs4-2	0.6	88.1		ks3-1	1.2	154
G	gs4-2	0.5	69.7	L	ls2-2	1.1	209

En la tabla 3.4.2, se muestran la distribución de los 1,890 modelos con respecto a los 14 movimientos sísmicos definidos en la tabla 3.4.1.

Tabla 3.4.2. Relación de sismos con los marcos

Punto	Etiqueta	Punto	Etiqueta	Punto	Etiqueta	Punto	Etiqueta
A	1-135	E	541-675	I-1	1081-1215	L	1621-1755
B	136-270	F	676-810	I-2	1216-1350	K-2	1756-1890
C	271-405	G	811-945	J	1351-1485		

En las figuras 3.4.1 a la 3.4.3, se muestra la respuesta de los modelos en términos de desplazamientos de azotea, distorsiones y aceleraciones máximas, respectivamente. En la figura 3.4.1, se puede observar una distribución de desplazamientos en grupos. Esta depende únicamente del tipo de registro de aceleraciones y se pueden observar 14 grupos, correspondientes a los sismos de estudio.




Figura 3.4.1. Base de datos de desplazamientos

Por otro lado, en la figura 3.4.2, no se alcanza a observar una distribución en grupo de la respuesta de distorsiones como en las de los desplazamientos. En este caso, se alcanza a ver que los mayores valores de distorsión corresponden a las estructuras de 6 niveles. Esto es debido a que los valores de su periodo fundamental de vibración son similares a los de los períodos dominantes del suelo. Cabe mencionar que, en algunos de los análisis, el valor de la distorsión máxima de entrepiso fue superior a 0.01, lo cual, desde el punto de vista de la base de datos es conveniente, ya que así se tiene un intervalo más amplio de valores para el entrenamiento de la RNA.




Figura 3.4.2. Base de datos de distorsiones

Por último, en la figura 3.4.3, correspondiente a la respuesta de aceleraciones máximas, se observa un comportamiento similar al de distorsiones.

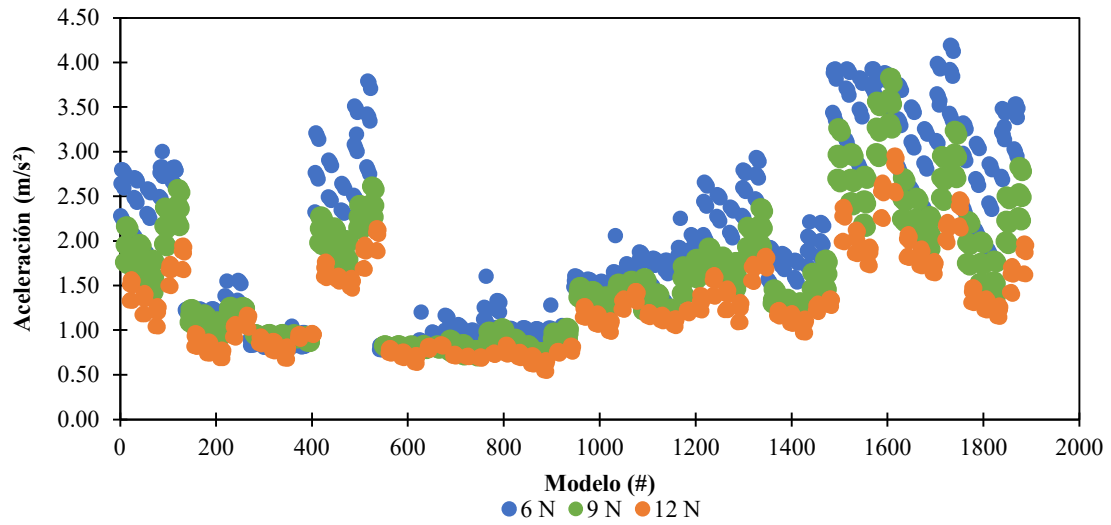


Figura 3.4.3. Base de datos de aceleraciones

CAPÍTULO 4

ESTIMACIÓN DE LA RESPUESTA DINÁMICA CON REDES NEURONALES

En total, para estudiar la capacidad de predicción en términos de desplazamientos de azotea, distorsiones de entrepiso y aceleraciones máximas, se realizaron más de 60 modelos de RNA variando su arquitectura y parámetros,. Para la elaboración de las redes neuronales y el manejo de datos, se utilizó el lenguaje de programación Python, con distintas bibliotecas enfocadas a la inteligencia artificial, como tensorflow y keras (Chollet,2015).

4.1 PREPROCESAMIENTO DE DATOS

Como primer intento, para caracterizar al grupo de estructuras estudiadas, se plantearon distintos parámetros. Sin embargo, los resultados no fueron los esperados, ya que se obtuvieron errores superiores al 40% entre los valores de referencia y las predicciones (figura 4.1.1). En color rojo se muestran los valores de referencia, las otras líneas son las predicciones realizadas por los modelos. Se observa que, a pesar de tener algunos puntos similares entre ellos, la mayoría presentan errores por arriba de lo aceptable. Por lo tanto, los parámetros fueron modificados según los valores de correlación observados en el primero modelo de RNA desarrollado.




Figura 4.1.1. Primeros modelos de RNA

Dentro del desarrollo de las RNA, se aplicaron diferentes metodologías de optimización para cada red. Por ejemplo, para la red con el objetivo de predecir los desplazamientos de azotea, los valores de entrada se normalizaron con respecto al valor mayor y se escalaron a la unidad. Para las demás redes, no se normalizó debido a que se general errores como el mostrado en la figura 4.1.1.

A partir de lo anterior, se construyeron los siguientes modelos de RNA. En tabla 4.1.1, se muestra la correlación que tiene cada uno de los parámetros seleccionados con su respectivo valor de salida para los tres objetivos planteados. En la primera columna, se muestran los valores de correlación para los desplazamientos en la azotea, en la segunda para las distorsiones máximas de entrepiso. Por último, en la tercera columna, para la aceleración máxima en azotea.

Tabla 4.1.1. Correlación de datos

Propiedades	Desplazamiento	Distorsión	Aceleración
Período	0.0127	0.2040	0.4234
Crujías	0.0124	-	0.0070

4. ESTIMACIÓN DE LA RESPUESTA DINÁMICA CON REDES NEURONALES

Altura total	0.0096	0.2710	0.3974
Niveles	0.0001	0.2716	0.3527
Longitud de crujías	0.0037	-	0.1260
Aceleración del espectro de respuesta	0.6317	0.8584	0.9783
Aceleración máxima de piso (PGA)	0.7127	0.7592	0.7938
Período del suelo	0.7775	0.8199	0.7973

Cabe mencionar que los valores de correlación representan la relación del parámetro con la salida, donde la unidad representa una correlación total y el valor de cero una correlación nula. Es importante mencionar que, el número de parámetros se varió a partir de los observado en cada prueba de RNA con respecto a los valores de correlación.

4.2 REDES NEURONALES

Se realizaron pruebas para la predicción de la respuesta dinámica de las estructuras (desplazamientos en la azotea, distorsión máxima de entrepiso y aceleración en azotea). Para cada uno de los objetivos se realizaron diversas RNA en las que se cambiaron valores de entrenamiento y de prueba, cantidad de iteraciones, cantidad de muestra por iteración, tamaño del conjunto de datos en el que se divide la base de datos para cada iteración o lote, cantidad de capas ocultas, cantidad de neuronas en la capa o capas ocultas.

Dado que el problema a desarrollar es con salidas de regresión, se evaluó el rendimiento de modelo con la métrica del error cuadrático medio. Este corrige de manera más eficiente que su similar, el promedio del error absoluto. Como el error se eleva al cuadrado, el sistema advierte que es muy elevado, por lo tanto, ajustará los pesos y desviaciones de forma drástica para encontrar la solución en menor tiempo. Para la corrección del error, se utilizó el gradiente descendente adaptativo, por el método Adam (Kingma y Lei Ba, 2014). Para el entrenamiento de los modelos se plantearon 300 iteraciones iniciales, las que variaron dependiendo del rendimiento del modelo, debido a la función detención temprana. A continuación, se muestran los modelos de RNA con las que se obtuvieron mejores resultados.

4.2.1 Desplazamientos en la azotea

Para este caso de estudio, se tienen 4 modelos diferentes. Las RNA tienen una capa oculta y se varió la función de activación para cada capa. Para el desarrollo de las redes neuronales se dividió la base de datos en 80% para entrenamiento con 1512 datos y 20% para pruebas, con 378 datos. En la tabla 4.2.1, se muestran las características de cada uno de los modelos desarrollados.

Tabla 4.2.1. Características de RNA para desplazamientos

Modelo	Lote	Funciones de activación en capa		
		Entrada	Oculto	Salida
1-1	16	Relu	Relu	Relu
1-2	8	Relu	Relu	Sigmoide
1-3	8	Leaky Relu	Leaky Relu	Leaky Relu
1-4	12	Leaky Relu	Leaky Relu	Sigmoide

4.2.1.1 *Modelo 1-1*

En este modelo se tiene la función de activación “unidad lineal rectificada” en las 3 capas. Esta función se caracteriza por ser la que tiene mejor rendimiento en problemas de regresión. El lote es de 16, la base de datos para entrenamiento se dividió en segmentos de 16 elementos, cada iteración realizaba 95 pruebas y se detuvo el entrenamiento en la iteración 128.

En la figura 4.2.1, se muestra la reducción del error de la función de coste, de la etapa de entrenamiento y en el conjunto de pruebas, cabe mencionar que el valor del error de cada modelo depende de los valores de las salidas. En la figura 4.2.2, se muestra una ampliación de la figura 4.2.1, se observa que no se genera un sobre ajuste, ya que el valor del error no se incrementa y, por lo tanto, los valores de los errores tienden a minimizarse.




Figura 4.2.1. Minimización de los errores del modelo 1-1




Figura 4.2.2. Ampliación de la figura 4.2.1

Se obtuvo un valor de covarianza de 0.9846. En la figura 4.2.3, se muestran las predicciones realizadas por el modelo y los valores reales. De acuerdo con los valores de la covarianza obtenidos del modelo, ambos conjuntos son similares entre sí. Por otra parte, se tiene un valor de error medio de 4.32 mm y un error cuadrático medio de 5.44 mm. Los valores de los errores promedio respecto a los valores de la media y mediana son 2.67% y 2.76%, respectivamente.

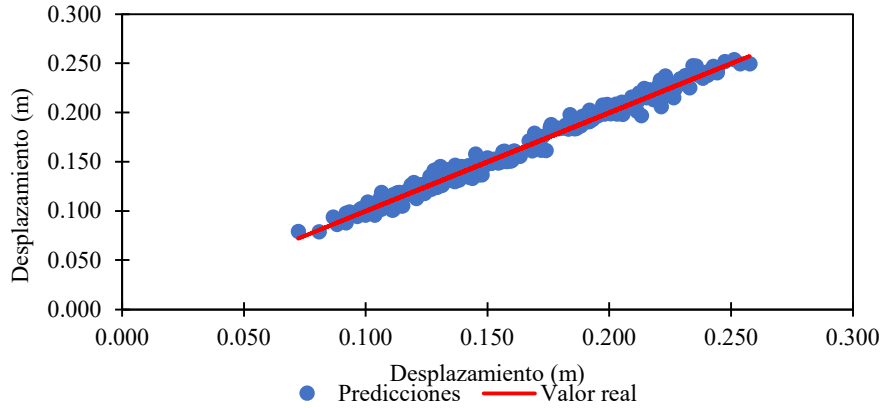


Figura 4.2.3. Predicción de desplazamientos por el modelo 1-1

4.2.1.2 Modelo 1-2

El segundo modelo cuenta con funciones de activación “relu” en las dos primeras capas y en la última tiene la función “sigmoide”, esta se enfoca principalmente en problemas de probabilidad, valores entre 0 y 1. El aprendizaje se detuvo en la iteración 168. En la figura 4.2.4, se muestra la reducción del valor del error en la etapa de entrenamiento y de pruebas del modelo. La figura 4.2.5, es una ampliación de la figura 4.2.4, donde se observa que no se genera un sobre ajuste en el modelo.




Figura 4.2.4. Minimización de los errores del modelo 1-2




Figura 4.2.5. Ampliación de la figura 4.2.4

4. ESTIMACIÓN DE LA RESPUESTA DINÁMICA CON REDES NEURONALES

En este modelo, el valor de la covarianza fue de 0.984 (figura 4.2.6), los valores del error medio y del error cuadrático medio son 4.38 y 5.84 mm respectivamente, y los errores promedio pertenecientes a los valores de la media y mediana son 2.71% y 2.80%.




Figura 4.2.6. Predicción de desplazamientos por el modelo 1-2

4.2.1.3 Modelo 1-3

Este modelo, en las 3 capas tiene la función de activación “unidad lineal rectificada leaky”, que se caracteriza por considerar valores negativos o muy pequeños para realizar el proceso de activación. Realizó 97 iteraciones para detener el aprendizaje. En la figura 4.2.7, se muestra la reducción del error, que, desde el inicio; es inferior al de los modelos anteriores, aunque la reducción presentó mayor variación para el error del conjunto de pruebas.




Figura 4.2.7. Minimización de los errores del modelo 1-3

En este modelo se tuvo una covarianza de 0.972 (figura 4.2.8), los valores del error medio y del error cuadrático medio fueron, 6.27 y 7.89 mm respectivamente; y los errores promedio respecto a los valores de la media y mediana 3.88% y 4.0%.




Figura 4.2.8. Predicción de desplazamientos por el modelo 1-3

4.2.1.4 Modelo 1-4

Se utilizó la función de activación Leaky Relu en las capas de entrada y la oculta. Para la capa de salida se utilizó la función activación sigmoide. Tuvo un lote de 12 y se realizaron 197 iteraciones. En este caso, la reducción del error de la función de costo y de las pruebas tienen una gran similitud entre sí. En la figura 4.2.9, se presenta la minimización de los errores, y en la figura 4.2.10, una ampliación de la figura 4.2.9. Los errores se reducen y el comportamiento permanece idéntico en valores muy pequeños del error.




Figura 4.2.9. Minimización de los errores del modelo 1-4




Figura 4.2.10. Ampliación de la figura 4.2.9

El modelo tuvo una covarianza de 0.98 (figura 4.2.11), el error medio y el error cuadrático medio fueron, 6.05 y 7.49 mm respectivamente. Los errores promedio respecto a los valores de la media y mediana 3.74% y 3.86%.




Figura 4.2.11. Predicción de desplazamientos por el modelo 1-4

En la tabla 4.2.2, se muestra un resumen de los 4 modelos que se utilizaron para la estimación del desplazamiento máximo en la azotea.

Tabla 4.2.2. Resumen rendimiento de modelos para estimación de desplazamientos

Modelo	Información		Covarianza (%)	Errores				Errores respecto a			
	Lote	Iteraciones		Medio (m)	Cuadrático (mm)	Medio (m)	Cuadrático (mm)	Media (%)	Mediana (%)		
1-1	16	128	0.9846 98.5%	0.0043	4.32	0.0054	5.45	0.0267	2.67%	0.0276	2.76%
1-2	8	168	0.9840 98.4%	0.0044	4.38	0.0058	5.85	0.0271	2.71%	0.0280	2.80%
1-3	8	97	0.9720 97.2%	0.0063	6.27	0.0079	7.89	0.0388	3.88%	0.0400	4.00%
1-4	12	197	0.9800 98.0%	0.0060	6.05	0.0075	7.49	0.0374	3.74%	0.0386	3.86%

4.2.2 Distorsión máxima de entrepiso

A continuación, se muestra la información de los modelos desarrollados para estimar la distorsión máxima de entrepiso. Éstos tienen la capa de entrada, dos capas ocultas y una capa de salida. Se varió la cantidad de datos para entrenamiento y para pruebas en dos conjuntos: el primero es 80% entrenamiento y 20% de pruebas, y el segundo es 75% para entrenamiento y 25% para pruebas. En la tabla 4.2.3 se muestran las características de las RNA.

Tabla 4.2.3. Características de RNA para distorsiones

Modelo	Lote	Funciones de activación en capas			Neuronas por capa			Cantidad de datos (%)	
		Entrada	Ocultas	Salida	Entrada	Ocultas	Salida	Entrenamiento	Pruebas
2-1	8	Relu	Relu	Sigmoide	6	35	1	75	25
2-2	8	Relu	Relu	Sigmoide	6	35	1	80	20
2-3	8	Leaky Relu	Leaky Relu	Sigmoide	6	40	1	75	25
2-4	8	Leaky Relu	Leaky Relu	Sigmoide	6	35	1	80	20

4.2.2.1 Modelo 2-1

El modelo 2-1 realizó 151 iteraciones previo a detener el aprendizaje. En la figura 4.2.12, se presenta la minimización del error en la función de coste y en las predicciones del modelo respecto a las salidas de prueba. La figura 4.2.13, es una ampliación de la figura 4.2.12. Entre la iteración 40 y la 80 se

4. ESTIMACIÓN DE LA RESPUESTA DINÁMICA CON REDES NEURONALES

puede observar una mejoría destacable en el aprendizaje, ya que el valor del error se reduce drásticamente.




Figura 4.2.12. Minimización de los errores del modelo 2-1




Figura 4.2.13. Ampliación de la figura 4.2.12

En este modelo se tuvo una covarianza de 0.8966 (figura 4.2.14). En valores de distorsión, el valor del error medio y del error cuadrático medio fueron 0.00059 (0.059%) y 0.0007 (0.073%) respectivamente, y los errores promedio respecto a los valores de la media y mediana 11.33% y 12.41%.




Figura 4.2.14. Predicción de distorsiones por el modelo 2-1

4.2.2.2 *Modelo 2-2*

Este modelo es similar al modelo 2-1, se detuvo el aprendizaje en la iteración 167. En la figura 4.2.15, se muestra la minimización del error de la función de coste y del conjunto de pruebas. En la Figura 4.2.16, se muestra una ampliación de la figura 4.2.15, aproximadamente en la iteración 60 se observa una mejora del aprendizaje, ya que existe a una reducción del error.




Figura 4.2.15. Minimización de los errores del modelo 2-2

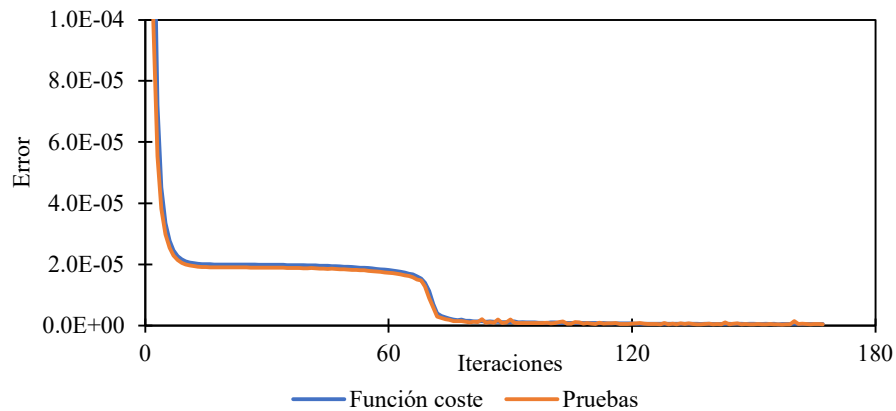


Figura 4.2.16. Ampliación de la figura 4.2.15

El modelo tuvo una covarianza de 0.9136 (figura 4.2.17), en valores de distorsión el error medio y el error cuadrático medio fueron 0.0005 (0.050%) y 0.0006 (0.063%), respectivamente, y los errores promedio respecto a los valores de la media y mediana 9.67% y 10.59%.

4. ESTIMACIÓN DE LA RESPUESTA DINÁMICA CON REDES NEURONALES




Figura 4.2.17. Predicción de distorsiones por el modelo 2-2

4.2.2.3 Modelo 2-3

El modelo se detuvo el aprendizaje en 94 iteraciones. En la figura 4.2.18, se observa cómo se minimizó el error, así como la mejoría del aprendizaje aproximadamente en la iteración 20.




Figura 4.2.18. Minimización de los errores del modelo 2-3

El modelo se tuvo una covarianza de 0.8812 (figura 4.2.19), en valores de distorsión el error medio y el error cuadrático medio fueron 0.0006 (0.064%) y 0.0008 (0.081%) respectivamente, y los errores promedio, respecto a los valores de la media y mediana 12.39% y 13.57%.




Figura 4.2.19. Predicción de distorsiones por el modelo 2-3

4.2.2.4 Modelo 2-4

Para este modelo se detuvo el aprendizaje en la iteración 102. En la figura 4.2.20, se muestra la minimización del error y en la figura 4.2.21 se muestra una ampliación de la figura 4.2.20. Se observa que existe una mejora en el aprendizaje cercana a la iteración 50. También, el valor del error en el conjunto de prueba es muy pequeño en comparación con el del conjunto de entrenamiento.




Figura 4.2.20. Minimización de los errores del modelo 2-4




Figura 4.2.21. Ampliación de la figura 4.2.20

El modelo tuvo una covarianza de 0.8877 (figura 4.2.22), en valores de distorsión, el error medio y el error cuadrático medio son 0.0006 (0.055%) y 0.0007 (0.068%) respectivamente; y los errores promedio respecto a los valores de la media y mediana son 10.61% y 11.62%.




Figura 4.2.22. Predicción de distorsiones por el modelo 2-4

En la tabla 4.2.4 se muestra un resumen de los modelos previamente explicados, cada uno se utilizó para la estimación de la distorsión máxima de entrepiso.

Tabla 4.2.4. Resumen de rendimiento modelos para estimación de distorsiones

Modelo	Información		Covarianza (%)	Errores				Errores respecto a			
	Batch	Iteraciones		Media (%)	Cuadrático (%)	Media (%)	Mediana (%)				
2-1	8	151	0.8966 89.7%	0.0006	0.059%	0.0007	0.073%	0.1133	11.33%	0.1241	12.41%
2-2	8	167	0.9136 91.4%	0.0005	0.050%	0.0006	0.063%	0.0967	9.67%	0.1059	10.59%
2-3	8	94	0.8812 88.1%	0.0006	0.064%	0.0008	0.081%	0.1239	12.39%	0.1357	13.57%
2-4	8	102	0.8877 88.8%	0.0006	0.055%	0.0007	0.068%	0.1061	10.61%	0.1162	11.62%

4.2.3 Aceleración máxima en azotea

En modelos desarrollados para estimar la aceleración máxima en azotea se utilizó la misma función de activación en todas las capas, se varió la cantidad de capas ocultas. Los datos de entrada se distribuyeron en 80% para entrenamiento y 20% para pruebas. En la tabla 4.2.5 se muestra la información de los modelos.

Tabla 4.2.5. Características de RNA para aceleraciones

Modelo	Lote	Función de activación	Número de capas			Neuronas por capas		
			Entrada	Ocultas	Salida	Entrada	Ocultas	Salida
3-1	8	Relu	1	1	1	8	45	1
3-2	8	Relu	1	2	1	8	45	1
3-3	16	Leaky Relu	1	1	1	8	45	1
3-4	16	Leaky Relu	1	2	1	8	40	1

4.2.3.1 Modelo 3-1

Este modelo se detuvo en la iteración 147. En la figura 4.2.23 se muestra la reducción de los errores, se observa que después de la iteración 40 no se reduce de manera significativa.

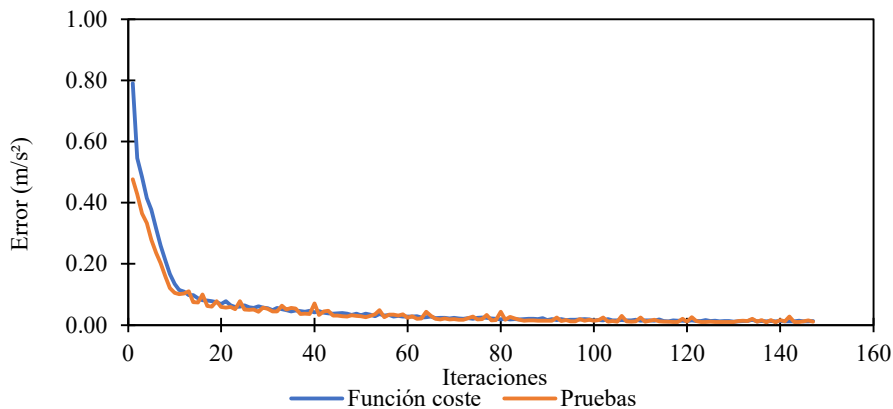


Figura 4.2.23. Minimización de los errores del modelo 3-1

En este modelo se tuvo una covarianza de 0.9848 (figura 4.2.24), en valores de aceleración se obtuvo el error medio y el error cuadrático medio fueron 0.0762 m/s^2 (76.20 mm/s^2) y 0.1006 m/s^2 (100.65 mm/s^2), respectivamente, los errores promedio respecto a los valores de la media y mediana son 4.71% y 5.39%.




Figura 4.2.24. Predicción de aceleraciones por el modelo 3-1

4.2.3.2 Modelo 3-2

Este modelo es similar al 3-1, se detuvo el aprendizaje en la iteración 93. En la figura 4.2.25 se muestra la minimización de los errores de la función de coste y del conjunto de pruebas, el error se estabilizó cercano a la iteración 10, después de esta el error ya no se reduce de manera significativa.




Figura 4.2.25. Minimización de los errores del modelo 3-2

El modelo tuvo una covarianza de 0.9737 (figura 4.2.26), los errores medio y cuadrático medio fueron 0.1026 m/s^2 (102.55 mm/s^2) y 0.1317 m/s^2 (131.69 mm/s^2), respectivamente, los errores promedio respecto a los valores de la media y mediana son 6.34% y 7.26%.

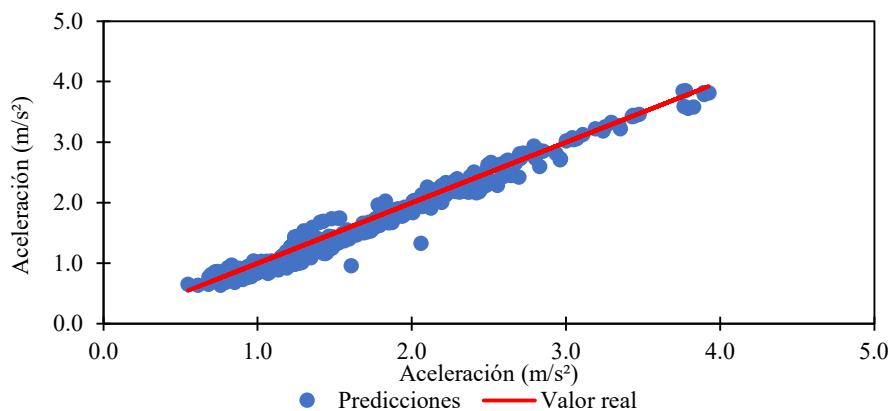


Figura 4.2.26. Predicción de aceleraciones por el modelo 3-2

4.2.3.3 *Modelo 3-3*

El modelo realizó 128 iteraciones para detener el aprendizaje. En la figura 4.2.27 se muestra la minimización del error de la función de coste y del conjunto de pruebas, estos errores tienen un comportamiento similar a los del modelo anterior, después de la iteración 10 no existe una mejora significativa.




Figura 4.2.27. Minimización de los errores del modelo 3-3

El modelo tuvo una covarianza de 0.9825 (figura 4.2.28), en valores de aceleración el error medio y el error cuadrático medio de 0.0865 m/s² (86.49 mm/s²) y 0.1114 m/s² (111.37 mm/s²), respectivamente, los errores promedio respecto a los valores de la media y mediana 5.35% y 6.12%.




Figura 4.2.28. Predicción de aceleraciones por el modelo 3-3

4.2.3.4 *Modelo 3-4*

Para este modelo se detuvo el aprendizaje en la iteración 55. En la figura 4.2.29 se muestra la minimización de los errores respecto a la cantidad de iteraciones, similar que los últimos dos modelos, se observa que a partir de la iteración 10 no existe una mejora considerable en aprendizaje..

4. ESTIMACIÓN DE LA RESPUESTA DINÁMICA CON REDES NEURONALES




Figura 4.2.29. Minimización de los errores del modelo 3-4

Este modelo es el que tuvo la menor covarianza, 0.9632 (figura 4.2.30), en valores de aceleración el error medio y el error cuadrático medio de 0.1312 m/s^2 (131.17 mm/s^2) y 0.1680 m/s^2 (168.0 mm/s^2), respectivamente, los errores promedio respecto a los valores de la media y mediana 8.11% y 9.28%.




Figura 4.2.30. Predicción de aceleraciones por el modelo 3-4

En la tabla 4.2.6 se muestra un resumen de todos los modelos previamente expuestos, los que se utilizaron para la estimación de la aceleración máxima en azotea.

Tabla 4.2.6. Resumen de rendimiento de modelos para la estimación de aceleraciones

Modelo	Información		Covarianza	Errores				Errores respecto a			
	batch	epochs		Media	Cuadrático	Media	Mediana				
			(%)	m/s ²	mm/s ²	m/s ²	mm/s ²	(%)		(%)	
3-1	8	147	0.9848 98.5%	0.0762	76.20	0.1006	100.65	0.0471	4.71%	0.0539	5.39%
3-2	8	93	0.9737 97.4%	0.1026	102.55	0.1317	131.69	0.0634	6.34%	0.0726	7.26%
3-3	16	128	0.9825 98.2%	0.0865	86.49	0.1114	111.37	0.0535	5.35%	0.0612	6.12%
3-4	16	55	0.9632 96.3%	0.1312	131.17	0.1680	168.00	0.0811	8.11%	0.0928	9.28%

4.3 ESTIMACIÓN DE LA RESPUESTA DINÁMICA

Para calcular la respuesta dinámica de los marcos estudiados, se utilizaron dos de éstos ajenos a las bases de datos con las que se entrenaron los modelos. Dichos marcos, son de acero estructural grado 50 y fueron diseñados bajo los parámetros estipulados en las normas técnicas complementarias correspondientes. Para tener un amortiguamiento total del 30%, se les colocaron amortiguadores

viscosos lineales. En general, se diseñaron bajo los mismos conceptos que los marcos con los que se elaboró la base de datos. Las propiedades geométricas de los marcos se muestran en la tabla 4.3.1.

Tabla 4.3.1. Marcos para pruebas

ID	Modelo	Niveles	Crujías	Longitud	Vigas	Columnas	Período (s)	Altura	
		#	#	m		(cm)		PB	EP
P1	N10-C3-L9	10	3	9	W24*84	55*55*3.18	2.21	4	3.5
P2	N8-C4-L8.5	8	4	8.5	W24*68	45*45*2*86	1.94	4	3.5

Los marcos fueron excitados con los 14 sismos que se utilizaron para la base de datos. Además, se incluyeron dos sismos, uno de subducción (PS) y otro intraplaca (PI), para tener un total de 16 movimientos de los que se obtuvieron resultados con el programa Etabs 19 (CSI, 2020). Posteriormente, estos resultados se compararon con los obtenidos de los modelos de inteligencia artificial.

Para conseguir los resultados con los modelos de inteligencia artificial, se requirió proveer al modelo con los mismos datos de entrada que se tienen en la base de datos con la que se entrenó, además de tener el mismo orden, para que no se generen errores en la estimación. De la figura 4.3.1 a la 4.3.3, se muestran las estimaciones de todos los modelos, de color negro el modelo con mejor desempeño y de color rojo, el valor de referencia obtenido de Etabs 19 (CSI, 2020).

4.3.1 Desplazamiento máximo en azotea

En la tabla 4.3.2, se muestran las predicciones realizadas por los modelos de IA de los desplazamientos máximos en la azotea, en ella también se muestra el promedio general y la desviación estándar de las estimaciones. Todos los modelos tienen un promedio de error inferior al 11%, la desviación estándar sólo en un modelo 1-3 fue mayor del 10%. Los valores están dados en metros y se muestran en la figura 4.3.1.

El modelo que generó mejores resultados fue el 1-2. Este modelo tuvo un error máximo de 23.79% y mínimo de 0.03%. El error promedio fue 8.17% y la desviación estándar 6.91%. En las predicciones realizadas en los marcos para los sismos ajenos a la base de datos se tuvieron mejores resultados en la estimación del sismo de subducción que en el intraplaca.

Tabla 4.3.2. Predicción de desplazamiento máximos en azotea

ID	Caso	Etabs	Modelo 1-1		Modelo 1-2		Modelo 1-3		Modelo 1-4	
			Valor	Dif. Abs. (%)	Valor	Dif. Abs. (%)	Valor	Dif. Abs. (%)	Valor	Dif. Abs. (%)
1	P1-A	0.1545	0.1533	0.76%	0.1225	20.71%	0.1866	20.80%	0.1535	0.61%
2	P1-B	0.1588	0.1602	0.90%	0.1691	6.53%	0.1500	5.56%	0.1527	3.83%
3	P1-C	0.1273	0.1414	11.12%	0.1268	0.34%	0.1253	1.55%	0.1447	13.68%
4	P1-D	0.1904	0.2058	8.09%	0.1707	10.33%	0.2632	38.25%	0.2419	27.08%
5	P1-E	0.1066	0.0975	8.53%	0.1150	7.93%	0.1117	4.80%	0.1052	1.26%
6	P1-F	0.1278	0.1224	4.24%	0.1493	16.82%	0.1322	3.39%	0.1303	1.91%
7	P1-G	0.1138	0.1150	1.10%	0.1171	2.87%	0.1248	9.67%	0.1304	14.62%
8	P1-H	0.1445	0.1260	12.80%	0.1442	0.22%	0.1456	0.76%	0.1379	4.60%
9	P1-I-1	0.2397	0.2334	2.65%	0.1955	18.46%	0.2527	5.42%	0.2837	18.32%
10	P1-I-2	0.1923	0.1994	3.69%	0.1875	2.51%	0.2005	4.27%	0.1813	5.72%
11	P1-J	0.1283	0.1386	8.06%	0.1163	9.33%	0.1361	6.07%	0.1276	0.55%
12	P1-K-1	0.2179	0.2629	20.67%	0.2031	6.80%	0.3210	47.31%	0.2834	30.07%

4. ESTIMACIÓN DE LA RESPUESTA DINÁMICA CON REDES NEURONALES

13	P1-K-2	0.1866	0.1913	2.49%	0.1637	12.27%	0.1783	4.46%	0.2167	16.09%
14	P1-L	0.2148	0.2276	5.98%	0.1900	11.53%	0.2853	32.81%	0.2635	22.66%
15	P1-PI	0.1626	0.1888	16.11%	0.1590	2.23%	0.1660	2.08%	0.2138	31.47%
16	P1-PS	0.2559	0.2367	7.49%	0.1950	23.79%	0.2939	14.85%	0.2470	3.46%
17	P2-A	0.1546	0.1705	10.25%	0.1487	3.84%	0.1561	0.95%	0.1466	5.20%
18	P2-B	0.1569	0.1303	16.93%	0.1586	1.10%	0.1389	11.46%	0.1696	8.09%
19	P2-C	0.1195	0.0987	17.44%	0.1049	12.18%	0.1010	15.47%	0.0999	16.41%
20	P2-D	0.2003	0.2251	12.41%	0.2187	9.17%	0.1953	2.51%	0.2025	1.12%
21	P2-E	0.1017	0.1194	17.42%	0.0973	4.31%	0.0922	9.31%	0.0923	9.22%
22	P2-F	0.1268	0.1442	13.77%	0.1286	1.47%	0.1095	13.65%	0.1319	4.04%
23	P2-G	0.1075	0.0881	18.06%	0.0910	15.39%	0.0938	12.74%	0.1024	4.77%
24	P2-H	0.1437	0.1077	25.05%	0.1316	8.41%	0.1380	3.97%	0.1360	5.39%
25	P2-I-1	0.2294	0.2397	4.47%	0.2295	0.03%	0.2121	7.53%	0.2002	12.75%
26	P2-I-2	0.1917	0.2000	4.34%	0.1987	3.67%	0.1808	5.66%	0.1835	4.27%
27	P2-J	0.1303	0.1187	8.92%	0.1391	6.70%	0.1301	0.18%	0.1276	2.07%
28	P2-K-1	0.2349	0.2990	27.32%	0.2581	9.91%	0.2392	1.83%	0.2494	6.18%
29	P2-K-2	0.1878	0.2184	16.31%	0.1873	0.26%	0.2037	8.46%	0.1634	12.99%
30	P2-L	0.2193	0.2465	12.39%	0.2221	1.28%	0.2279	3.90%	0.2092	4.60%
31	P2-PI	0.2357	0.2089	11.40%	0.1801	23.61%	0.2342	0.66%	0.1525	35.32%
32	P2-PS	0.2504	0.2716	8.46%	0.2321	7.33%	0.2247	10.25%	0.1983	20.81%
Promedio				10.61%		8.17%		9.71%		10.91%
Desviación estándar				6.94%		6.91%		11.07%		9.88%




Figura 4.3.1. Desplazamientos máximos en azotea

4.3.2 Distorsión máxima de entrepiso

En la tabla 4.3.3, se muestran las predicciones realizadas para la distorsión máxima de entrepiso por los 4 modelos de inteligencia artificial, también se muestra el promedio general y la desviación estándar. En todos los casos, el promedio fue inferior al 15% y la desviación estándar menor al 10%. Los resultados dados en distorsiones se muestran en la figura 4.3.2.

4. ESTIMACIÓN DE LA RESPUESTA DINÁMICA CON REDES NEURONALES

El modelo 2-4 fue el que presentó mejores resultados con un promedio de 11.51%, y una desviación estándar de 7.72%, tiene una diferencia máxima de 35.48% y una mínima de 1.61%. En los sismos de prueba para el marco P1 se obtuvieron mejores predicciones para el sismo de intraplaca, que para el de subducción. En el marco P2 fue lo contrario.

Tabla 4.3.3. Predicción de distorsión máxima de entrepiso

ID	Caso	Etabs	Modelo 2-1		Modelo 2-2		Modelo 2-3		Modelo 2-4	
			Valor	Dif. Abs. (%)	Valor	Dif. Abs. (%)	Valor	Dif. Abs. (%)	Valor	Dif. Abs. (%)
1	P1-A	0.0054	0.0051	4.67%	0.0056	3.79%	0.0049	8.45%	0.0054	1.61%
2	P1-B	0.0044	0.0036	19.09%	0.0039	11.64%	0.0035	20.61%	0.0038	14.99%
3	P1-C	0.0033	0.0030	10.36%	0.0033	1.00%	0.0030	9.72%	0.0031	5.27%
4	P1-D	0.0051	0.0054	6.81%	0.0059	16.99%	0.0054	6.65%	0.0059	16.44%
5	P1-E	0.0031	0.0032	3.35%	0.0035	14.08%	0.0032	3.24%	0.0034	8.26%
6	P1-F	0.0037	0.0032	14.00%	0.0035	5.65%	0.0032	14.35%	0.0033	9.98%
7	P1-G	0.0034	0.0029	14.54%	0.0032	5.16%	0.0029	13.65%	0.0030	10.46%
8	P1-H	0.0045	0.0037	16.49%	0.0042	6.30%	0.0036	19.08%	0.0040	10.81%
9	P1-I-1	0.0051	0.0044	12.18%	0.0049	3.69%	0.0043	14.45%	0.0047	7.62%
10	P1-I-2	0.0038	0.0047	25.46%	0.0052	38.65%	0.0044	17.44%	0.0051	35.48%
11	P1-J	0.0051	0.0041	19.31%	0.0045	10.97%	0.0039	22.71%	0.0044	14.11%
12	P1-K-1	0.0087	0.0071	18.23%	0.0082	6.45%	0.0071	18.37%	0.0079	9.05%
13	P1-K-2	0.0076	0.0061	18.90%	0.0066	13.20%	0.0062	17.55%	0.0065	14.54%
14	P1-L	0.0058	0.0062	7.04%	0.0068	17.87%	0.0064	10.43%	0.0068	17.44%
15	P1-PI	0.0064	0.0060	6.66%	0.0063	1.14%	0.0061	4.59%	0.0063	2.40%
16	P1-PS	0.0094	0.0069	26.25%	0.0078	16.90%	0.0069	26.32%	0.0076	18.95%
17	P2-A	0.0067	0.0061	8.24%	0.0065	3.06%	0.0059	11.02%	0.0063	5.83%
18	P2-B	0.0046	0.0041	9.61%	0.0042	7.90%	0.0038	16.22%	0.0041	9.62%
19	P2-C	0.0032	0.0032	1.81%	0.0035	8.56%	0.0031	4.29%	0.0034	4.25%
20	P2-D	0.0058	0.0064	10.62%	0.0069	19.35%	0.0064	11.23%	0.0067	16.10%
21	P2-E	0.0033	0.0036	9.11%	0.0037	13.37%	0.0034	3.06%	0.0036	10.05%
22	P2-F	0.0037	0.0035	5.41%	0.0036	2.90%	0.0033	10.24%	0.0035	5.10%
23	P2-G	0.0035	0.0030	12.84%	0.0033	4.57%	0.0030	13.63%	0.0032	7.70%
24	P2-H	0.0056	0.0043	22.21%	0.0045	18.69%	0.0040	28.79%	0.0044	21.02%
25	P2-I-1	0.0052	0.0051	2.68%	0.0052	1.08%	0.0048	9.16%	0.0051	3.04%
26	P2-I-2	0.0055	0.0055	0.91%	0.0058	5.05%	0.0053	3.80%	0.0057	3.97%
27	P2-J	0.0058	0.0048	18.10%	0.0049	15.98%	0.0044	24.83%	0.0048	17.25%
28	P2-K-1	0.0102	0.0088	13.63%	0.0101	0.86%	0.0087	14.29%	0.0095	6.97%
29	P2-K-2	0.0082	0.0074	9.74%	0.0080	2.37%	0.0076	7.66%	0.0075	8.12%
30	P2-L	0.0072	0.0073	1.75%	0.0081	13.14%	0.0074	3.25%	0.0077	7.14%
31	P2-PI	0.0054	0.0071	31.47%	0.0074	38.54%	0.0073	36.37%	0.0071	31.61%
32	P2-PS	0.0101	0.0083	17.82%	0.0094	6.78%	0.0083	17.36%	0.0088	13.01%
			Promedio	12.48%		10.49%		13.84%		11.51%
			Desviación estándar	7.76%		9.39%		8.11%		7.72%




Figura 4.3.2. Distorsiones máximas de entropeso

4.3.3 Aceleración máxima en azotea

En la tabla 4.3.4, se muestran las estimaciones obtenidas de los cuatro modelos de IA para la aceleración máxima en azotea, estos valores están en unidades de m/s^2 . En todos los casos, para el promedio se tienen valores inferiores al 10% de diferencia entre los valores, teniendo un valor mínimo para el modelo 3-2 con 0.93%. Lo mismo pasa con la desviación estándar, se tienen valores inferiores al 10% y en el modelo 3-3 se obtuvo el valor menor de 3.97%. Los resultados obtenidos para estos modelos se muestran en la figura 4.3.3.

En este caso el modelo 3-3 fue el que presentó mejores resultados. El modelo tuvo un error promedio de 5.81% y una desviación estándar 3.97%. La diferencia máxima fue de 14.07% y la mínima de 0.09%. Para los sismos de prueba, en el caso del marco P1 se obtuvieron mejores resultados en el sismo de intraplaca que en el de subducción, aunque la diferencia entre los errores es inferior al 1%. Por otro lado, para el marco P2 se obtuvieron mejores resultados para el sismo de subducción que para el intraplaca.

Tabla 4.3.4. Predicción de aceleración máxima en azotea

ID	Caso	Modelo 3-1		Modelo 3-2		Modelo 3-3		Modelo 3-4		
		Etabs	Valor	Dif. Abs. (%)	Valor	Dif. Abs. (%)	Valor	Dif. Abs. (%)	Valor	Dif. Abs. (%)
1	P1-A	1.7632	1.7589	0.24%	1.6659	0.96%	1.6104	8.67%	1.6289	7.62%
2	P1-B	1.0858	1.0934	0.70%	1.0327	5.72%	1.0226	5.82%	0.9861	9.18%
3	P1-C	0.9548	0.9022	5.51%	0.8187	9.95%	0.8375	12.29%	0.7652	19.86%
4	P1-D	1.9808	2.0861	5.31%	1.9901	5.08%	1.9420	1.96%	1.8937	4.40%
5	P1-E	0.8267	0.9225	11.59%	0.8733	16.60%	0.8754	5.89%	0.8468	2.44%
6	P1-F	0.767	0.9179	19.68%	0.8823	28.28%	0.8744	14.00%	0.8579	11.86%
7	P1-G	0.7529	0.8046	6.87%	0.8018	11.60%	0.7658	1.72%	0.7500	0.38%
8	P1-H	1.3665	1.2822	6.17%	1.1046	12.57%	1.1743	14.07%	1.0339	24.34%
9	P1-I-1	1.2238	1.3632	11.39%	1.2811	12.68%	1.2761	4.28%	1.2574	2.75%
10	P1-I-2	1.7463	1.8007	3.11%	1.6145	3.24%	1.6205	7.20%	1.5676	10.24%
11	P1-J	1.3006	1.4036	7.92%	1.2599	4.70%	1.2871	1.04%	1.2376	4.85%
12	P1-K-1	2.6907	2.6840	0.25%	2.4666	6.57%	2.5247	6.17%	2.2815	15.21%

4. ESTIMACIÓN DE LA RESPUESTA DINÁMICA CON REDES NEURONALES

13	P1-K-2	1.7488	1.8842	7.74%	1.9284	16.02%	1.7864	2.15%	1.8629	6.53%
14	P1-L	2.2447	2.3869	6.33%	2.3273	7.40%	2.2619	0.77%	2.2133	1.40%
15	P1-PI	1.8225	1.7680	2.99%	1.8584	7.92%	1.6831	7.65%	1.8231	0.03%
16	P1-PS	2.3992	2.5064	4.47%	2.3368	0.06%	2.3564	1.78%	2.1660	9.72%
17	P2-A	2.0636	2.0706	0.34%	1.9590	0.45%	1.9768	4.21%	1.8593	9.90%
18	P2-B	1.202	1.2475	3.78%	1.1377	1.98%	1.1254	6.38%	1.1164	7.12%
19	P2-C	0.9397	0.9387	0.11%	0.8337	7.31%	0.8416	10.44%	0.7944	15.46%
20	P2-D	2.202	2.3586	7.11%	2.2809	8.80%	2.2758	3.35%	2.2188	0.76%
21	P2-E	0.8205	0.9683	18.02%	0.9002	19.21%	0.8802	7.28%	0.8774	6.93%
22	P2-F	0.8572	0.9220	7.56%	0.8967	14.79%	0.8477	1.11%	0.8789	2.53%
23	P2-G	0.8613	0.8144	5.44%	0.8113	2.14%	0.7499	12.93%	0.7732	10.23%
24	P2-H	1.4535	1.4379	1.07%	1.2230	11.69%	1.3206	9.14%	1.1615	20.09%
25	P2-I-1	1.5036	1.4972	0.42%	1.4098	0.16%	1.3995	6.92%	1.3695	8.92%
26	P2-I-2	1.8169	1.9696	8.41%	1.8170	5.16%	1.8642	2.60%	1.7085	5.97%
27	P2-J	1.3623	1.5563	14.24%	1.4019	9.61%	1.4398	5.69%	1.3602	0.15%
28	P2-K-1	3.1388	3.1461	0.23%	2.9449	3.59%	3.0238	3.66%	2.7257	13.16%
29	P2-K-2	2.1156	2.2417	5.96%	2.2730	12.87%	2.1868	3.37%	2.2142	4.66%
30	P2-L	2.5905	2.6602	2.69%	2.6468	7.57%	2.5928	0.09%	2.5740	0.64%
31	P2-PI	1.8009	1.9913	10.57%	2.1256	25.24%	1.9657	9.15%	2.0994	16.58%
32	P2-PS	2.8455	2.8223	0.82%	2.6982	1.99%	2.7237	4.28%	2.5454	10.55%
Promedio				5.85%		0.93%		5.81%		8.26%
Desviación estándar				5.11%		8.57%		3.97%		6.38%




Figura 4.3.3. Aceleraciones máximas en azotea

CONCLUSIONES Y COMENTARIOS

Se desarrolló una metodología con herramientas de inteligencia artificial, específicamente RNA, para estimar la respuesta sísmica de estructuras de acero estructural equipadas con amortiguadores viscosos lineales, ubicadas en suelo blando de la Ciudad de México. A partir de los resultados obtenidos de los modelos estudiados, se llegó a las siguientes conclusiones:

Se analizaron 12 modelos de RNA con la capacidad de estimar los desplazamientos, distorsiones de entrepiso y aceleraciones. En el modelo 1-2, correspondiente a los valores de desplazamientos en azotea, se obtuvieron las mejores estimaciones con un error promedio de 8.17% y una desviación estándar de 6.91%. Para las distorsiones de entrepiso el modelo que estimó de mejor manera fue el 2-4 error promedio de 11.51%, y una desviación estándar de 7.72%. Y para las aceleraciones máximas en azotea el modelo 3-3, tuvo un error promedio de 5.81% y una desviación estándar 3.97%.

Las RNA tienen la capacidad de estimar el comportamiento lineal de las estructuras desplantadas en suelo blando de la Ciudad de México. Como se observó en el caso de distorsiones, ninguno de los marcos ajenos a la base de datos, incurrió en el intervalo de comportamiento inelástico.

La capacidad de aprendizaje de las RNA es importante, porque en los resultados obtenidos, se observó la similitud que tienen las predicciones respecto a los valores de referencia obtenidos con el programa de análisis estructural Etabs 19 (CSI, 2020). Los valores de los errores obtenidos se encuentran en parámetros inferiores al 15%.

Para las RNA se observó que entre más pequeño era el valor de salida a predecir, era más complicado que se estimara correctamente. Esto fue debido a que los modelos más precisos son los de aceleraciones, seguidos por los de desplazamientos y por último los de distorsiones, aunque no existe una gran diferencia entre el rendimiento de estos últimos.

El tiempo de cómputo para la obtención de resultados es inferior con una RNA, que con un programa de análisis estructural comercial. En modelos de RNA se obtuvieron los todos resultados en menos de un minuto, mientras que Etabs 19, requería aproximadamente 15 minutos para cada marco.

En este trabajo se presentó una metodología con inteligencia artificial, la que se pueden reducir los recursos de cómputo necesarios para la obtención de resultados. Bajo las condiciones planteadas en este trabajo se obtuvieron resultados con un bajo margen de error.

Es importante hacer énfasis en que, para cada caso, el modelo debe entrenarse con una base de datos correcta y el modelo estar bien desarrollado con las funciones de activación, cantidad de capas y neuronas necesarias para la resolución del problema que se le presenta. También es mejor tener parámetros cuantitativos que cualitativos, porque la IA, trabaja con funciones matemáticas simples, las que se vuelven más complejas de acuerdo con la complejidad de la arquitectura del modelo.

RECOMENDACIÓN

Se recomienda ampliar la base de datos para el entrenamiento de las redes neuronales. Con esto, existiría un mejor aprendizaje y se obtendrían estimaciones más precisas. A su vez, considerando exportar el trabajo a modelos más complejos, se requieren más datos, lo que implica más capas ocultas y neuronas, es decir; un modelo más complejo.

BIBLIOGRAFÍA Y REFERENCIAS

Abdalla, K., y Stavroulakis, G. (1995). A Backpropagation Neural Network Model for Semi-rigid Steel Connections. *Computer-Aided Civil and Infrastructure Engineering*, 10(2), 77-87. <https://doi.org/10.1111/j.1467-8667.1995.tb00271.x>

Abd-Elhamed, A., Shaban, Y., y Mahmoud, S. (2018). Predicting Dynamic Response of Structures under Earthquake Loads Using Logical Analysis of Data. *Buildings*, 8(4), 61. <https://doi.org/10.3390/buildings8040061>

Adeli, H. (2001). Neural Networks in Civil Engineering: 1989–2000. *Computer-Aided Civil and Infrastructure Engineering*, 16(2), 126-142. <https://doi.org/10.1111/0885-9507.00219>

Adeli, H., y Yeh, C. (1989). Perceptron Learning in Engineering Design. *Computer-Aided Civil and Infrastructure Engineering*, 4(4), 247-256. <https://doi.org/10.1111/j.1467-8667.1989.tb00026.x>

American Society of Civil Engineers. (2017). ASCE/SEI 41-17. Seismic Evaluation and Retrofit of Existing Buildings. <https://doi.org/10.1061/9780784414859>

Andrade, E. (2013). Estudios de los principales tipos de redes neuronales y las herramientas para su aplicación [Tesis de licenciatura, Universidad Politécnica Salesiana]. Repositorio Institucional–I - Universidad Politécnica Salesiana.

Arnal, L., y Betancourt, M. (2020). Reglamento de Construcciones para el Distrito Federal, ilustrado y comentado. Trillas.

Badillo, H. (2000). Criterio de diseño sísmico por desempeño para reforzar edificios con disipadores de energía. [Tesis de maestría, Universidad Nacional Autónoma de México]. Repositorio institucional – Universidad Nacional Autónoma de México. México

Bas, E., Aslangil, D., y Moustafa, M. (2020). *Predicting Nonlinear Seismic Response of Structural Braces Using Machine Learning*. arXiv.org. Recuperado el 6 de junio 2022, from <https://arxiv.org/abs/2007.13662>.

Basogain, X. (s.f.) Redes neuronales artificiales y sus aplicaciones. Escuela Superior de Ingeniería de Bilbao, España.

Bojórquez, J, Tolentino, D., Ruiz, S., y Bojórquez, E. (2016). Diseño sísmico preliminar de edificios de concreto reforzado usando redes neuronales artificiales. *Concreto y Cemento. Investigación y Desarrollo*, 7(2), 60-78. Recuperado el 16 de octubre de 2021, de http://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S2007-30112016000100060&lng=es&tlng=es.

Brown, A., Uno, M., Stratford, J., y Thompson, J. (2015). Steel moment frame with supplemental fluid viscous dampers – 12 moor house avenue a case study. *Steel Innovations Conference 2015*. Retrieved 16 June 2022, from <https://www.scnz.org/wp-content/uploads/2020/11/P44-STEEL-MOMENT-FRAME-WITH-SUPPLEMENTAL-FLUID-VISCOUS-DAMPERS-12-MOOREHOUSE-AVENUE-A-CASE-STUDY-Brown-min.pdf>.

Chollet, F., y otros. (2015). Keras. GitHub. Retrieved from <https://github.com/fchollet/keras>

Chopra, A. (2014). Dinámica de estructuras (4ª edición). Pearson educación.

- Dhanya, J., y Raghukanth, S. (2017). Ground Motion Prediction Model Using Artificial Neural Network. *Pure and Applied Geophysics*, 175(3), 1035-1064. <https://doi.org/10.1007/s00024-017-1751-3>
- Duan, Z., Hou, S., Poon, C., Xiao, J., y Liu, Y. (2018). Using Neural Networks to Determine the Significance of Aggregate Characteristics Affecting the Mechanical Properties of Recycled Aggregate Concrete. *Applied Sciences*, 8(11), 2171. <https://doi.org/10.3390/app8112171>
- Etabs v.19, Computer and Structures, Inc. (2020).
- Federal Emergency Management Agency (1997). *Nehrp Guidelines for the Seismic Rehabilitation of Buildings*. Washington, D.C.
- Federal Emergency Management Agency (2018). *Seismic Performance Assessment of Buildings P-58-5*. Washington, D.C.
- Flórez, R., y Fernández, J. (2008). Las redes neuronales artificiales. *Netbiblo*.
- Gaceta Oficial de la Ciudad de México. (2020). *Reglamento de Construcciones para el Distrito Federal, México*.
- García-Segura, T., Yepes, V., y Frangopol, D. (2017). Multi-objective design of post-tensioned concrete road bridges using artificial neural networks. *Structural and Multidisciplinary Optimization*, 56(1), 139-150. <https://doi.org/10.1007/s00158-017-1653-0>
- Gómez Pizano, D. Marulanda Casas, J. y Thomson Roach, P. (2008) Sistemas de control para la protección de estructuras civiles sometidas a cargas dinámicas. *Dyna*; Vol. 75, núm. 155 (2008); 77-89 *DYNA*; Vol. 75, núm. 155 (2008); 77-89 2346-2183 0012-7353.
- Guerrero, H., Ji, T., Escobar, J., y Terán-Gilmore, A. (2018). Effects of buckling-restrained braces on reinforced concrete precast models subjected to shaking table excitation. *Engineering Structures*, 163, 294-310. <https://doi.org/10.1016/j.engstruct.2018.02.055>
- Hadzima-Nyarko, M., Nyarko, E., Ademović, N., Miličević, I., y Šipoš, T. (2019). Modelling the Influence of Waste Rubber on Compressive Strength of Concrete by Artificial Neural Networks. *Materials*, 12(4), 561. <https://doi.org/10.3390/ma12040561>
- Hajela, P., y Berke, L. (1991). Neurobiological computational models in structural analysis and design. *Computers and Structures*, 41(4), 657-667. [https://doi.org/10.1016/0045-7949\(91\)90178-o](https://doi.org/10.1016/0045-7949(91)90178-o)
- International Business Machines Corporation. (15 de octubre de 2021). *Redes neuronales*. <https://www.ibm.com/docs/es/spss-modeler/SaaS?topic=nodes-neural-networks>.
- Kang, H., y Yoon, C. (1994). Neural Network Approaches to Aid Simple Truss Design Problems. *Computer-Aided Civil and Infrastructure Engineering*, 9(3), 211-218. <https://doi.org/10.1111/j.1467-8667.1994.tb00374.x>
- Kingma, D., y Lei Ba, J. (2014). Adam: A Method for Stochastic Optimization. *Rd International Conference For Learning Representations, San Diego, 2015*. <https://doi.org/https://doi.org/10.48550/arXiv.1412.6980>
- Matich, D. J. (2001). *Redes neuronales: Conceptos básicos y aplicaciones*. [Apuntes de informática aplicada a la ingeniería de procesos – orientación I] – Universidad Tecnológica Nacional, Facultad Regional Rosario. Departamento de Ingeniería Química. Argentina.

- Mehra, S (2020). Detection of offensive language in social media post. [Tesis de maestría, Cork Institute of Technology]. Repositorio Institucional - Cork Institute of Technology. Irlanda
- Messner, J., Sanvido, V., y Kumara, S. (1994). StructNet: A Neural Network for Structural System Selection. *Computer-Aided Civil And Infrastructure Engineering*, 9(2), 109-118. <https://doi.org/10.1111/j.1467-8667.1994.tb00366.x>
- Meza Ruíz, I. (2016). Descenso por gradiente (Gradient descent). [Turing.iimas.unam.mx](https://turing.iimas.unam.mx). Retrieved 27 March 2022, from https://turing.iimas.unam.mx/~ivanvladimir/posts/gradient_descent/.
- Microsoft. (15 de abril 2022). ¿Qué es el aprendizaje profundo?. <https://azure.microsoft.com/es-es/overview/what-is-deep-learning/>
- Oracle. (12 de marzo de 2022). ¿Qué es el aprendizaje automático?. <https://www.oracle.com/mx/data-science/machine-learning/what-is-machine-learning/>
- Oracle. (20 de octubre de 2021). ¿Qué es la inteligencia artificial-IA?. <https://www.oracle.com/mx/artificial-intelligence/what-is-ai/>
- Pérez Ramírez, C., Amézquita Sánchez, J., Valtierra Rodríguez, M., Adeli, H., Domínguez González, A., y Romero Troncoso, R. (2019). Recurrent neural network model with Bayesian training and mutual information for response prediction of large buildings. *Engineering Structures*, 178, 603-615. <https://doi.org/10.1016/j.engstruct.2018.10.065>
- Qu, D., Cai, X., y Chang, W. (2018). Evaluating the Effects of Steel Fibers on Mechanical Properties of Ultra-High Performance Concrete Using Artificial Neural Networks. *Applied Sciences*, 8(7), 1120. <https://doi.org/10.3390/app8071120>
- Rafiq, M., Bugmann, G., y Easterbrook, D. (2001). Neural network design for engineering applications. *Computers and Structures*, 79(17), 1541-1552. [https://doi.org/10.1016/s0045-7949\(01\)00039-6](https://doi.org/10.1016/s0045-7949(01)00039-6)
- Ruiz, G. S. (2018). Comentarios al apéndice B (Edificios con Disipadores de Energía Sísmica de las NTCS-2017). Serie Investigación y Desarrollo, SID706, Instituto de Ingeniería, UNAM.
- Russell, S., Norvig, P., Corchado Rodríguez, J., y Joyanes Aguilar, L. (2004). *Inteligencia artificial*. Pearson Educación.
- Sánchez Badillo, A., y Terán Gilmore, A. (2008). Diseño por desempeño de estructuras dúctiles de concreto reforzado ubicadas en la zona del lago del Distrito Federal: ejemplo de aplicación. *Revista de Ingeniería Sísmica*, (78), 47. <https://doi.org/10.18867/ris.78.23>
- Terán Gilmore, A., y Virto Cambray, N. (2009). Preliminary Design of Low-Rise Buildings Stiffened with Buckling-Restrained Braces by a Displacement-Based Approach. *Earthquake Spectra*, 25(1), 185-211. <https://doi.org/10.1193/1.3054638>
- Vafaei, M., Alih, S., Shad, H., Falah, A., y Halim, N. (2018). Prediction of strain values in reinforcements and concrete of a RC frame using neural networks. *International Journal of Advanced Structural Engineering*, 10(1), 29-35. <https://doi.org/10.1007/s40091-018-0178-0>
- Yeh, Y., Kuo, Y., y Hsu, D. (1993). Building KBES for Diagnosing PC Pile with Artificial Neural Network. *Journal of Computing in Civil Engineering*, 7(1), 71-93.

Yepes Piqueras, V. (2022). Aprendizaje profundo. Victoryepes.blogs.upv.es. Recuperado el 5 de mayo de 2022, <https://victoryepes.blogs.upv.es/tag/aprendizaje-profundo/>.

Zhang, R., Chen, Z., Chen, S., Zheng, J., Büyüköztürk, O., y Sun, H. (2019). Deep long short-term memory networks for nonlinear structural seismic response prediction. *Computers & Structures*, 220, 55-68. <https://doi.org/10.1016/j.compstruc.2019.05.006>