

Diseño estructural de edificios sismorresistentes de acero aplicando redes neuronales artificiales

Design of seismic-resistant steel buildings applying artificial neural networks

Jorge Alejandro Cota¹, Juan Bojórquez¹, Edén Bojórquez¹, Fernando Arias¹, Mario Llanes¹, Daniel Yee¹, Luis Guaranga².

RESUMEN

Este artículo presenta el desarrollo y validación de modelos de Redes Neuronales Artificiales (RNA) aplicados al diseño estructural de edificios de acero de 3 a 8 niveles. La investigación surge ante la necesidad de reducir los tiempos de diseño en zonas sísmicas para el noroeste de México, donde los métodos tradicionales resultan complejos y demandan múltiples iteraciones normativas. Se analizaron y diseñaron 62 edificios mediante software especializado, generando una base de datos para entrenar diez modelos de RNA, los cuales fueron validados posteriormente frente a los parámetros establecidos en la normativa vigente. Los resultados muestran que las RNA alcanzaron altos niveles de precisión en la predicción de parámetros estructurales, logrando una reducción significativa de los tiempos de diseño sin comprometer la seguridad. En particular, se observó que los modelos entrenados con una mayor cantidad de datos mostraron el mejor desempeño. Se concluye que la aplicación de RNA constituye una innovación relevante en la ingeniería estructural, ya que permite agilizar procesos, optimizar recursos y mantener la confiabilidad en el diseño de edificios de acero.

Recibido: Diciembre 2025
Aceptado: Diciembre 2025
Publicado: Diciembre 2025

Palabras Clave:

Edificios de acero, estructuras, inteligencia artificial, redes neuronales

Keywords:

Steel buildings, structures, artificial intelligence, artificial neural networks

ABSTRACT

This paper presents the development and validation of an Artificial Neural Network (ANN) models applied to the design of steel buildings with 3-8 stories. The research was conducted in response to the need to reduce design times in seismically active areas in northwest Mexico, where traditional methods are complex and require multiple iterations of normative parameters. Sixty-two buildings were analyzed and designed using specialized software, generating a database for training ten ANN models, which were later validated against the established parameters in current regulations. The results show that the ANNs achieved high levels of accuracy in predicting a significant reduction in design times without compromising safety. In particular, models trained with a larger dataset showed the best performance. It is concluded that the application of ANN constitutes a relevant innovation in structural engineering, allowing for process acceleration, resource optimization and reliability maintenance in steel building design.

1. INTRODUCCIÓN

El diseño estructural es fundamental para la industria de la construcción, puesto que con ella se busca garantizar que cualquier obra o edificación cuente con la resistencia y rigidez suficientes, ante la acción de cargas operacionales o provenientes de fenómenos naturales, para evitar el colapso. Sin embargo, en el ámbito profesional, existe una problemática en el enfoque tradicional de diseño ya que, al ser iterativo, se depende de constantes revisiones y validaciones contra normativas establecidas, por lo que, se traduce en un proceso lento, repetitivo y laborioso. Es por ello por lo que, la metodología propuesta resalta la oportu-

*Juan Bojorquez Mora, juanbm@uas.edu.mx

¹ Universidad Autónoma de Sinaloa, FIC, Culiacán Rosales, Sinaloa, México. C.P. 80040

² Universidad de Sonora, departamento de Física, Matemáticas e Ingeniería, Sonora, Mexico.

nidad de cubrir una necesidad urgente, al aplicar técnicas innovadoras que permiten agilizar los procesos, reduciendo significativamente los tiempos de análisis, diseño, y verificación de los cálculos estructurales [1].

Históricamente, el diseño de estructuras ha evolucionado partiendo de enfoques empíricos y manuales, migrando hacia métodos informáticos más avanzados que, si bien han mejorado la precisión, aun demandan un esfuerzo considerable en términos de tiempo. En este contexto, la inteligencia artificial, y particularmente las Redes Neuronales Artificiales (RNA), han emergido como herramientas prometedoras para optimizar procesos en distintas áreas de la ingeniería civil. Por ejemplo, existen publicaciones donde se aborda la aplicación de modelos de RNA como una alternativa a los métodos numéricos para predecir la respuesta sísmica de estructuras [2]. Por otro lado, la inteligencia artificial se ha implementado como herramienta de optimización de elementos tipo losa [3], de cálculo de desempeño en estructuras de acero [4], o más específicamente en la predicción de la capacidad de carga de vigas de acero [5]. En ese sentido, los métodos probabilísticos exactos, como la simulación de Montecarlo, han demostrado ser útiles para la predicción de datos, aunque aún se requiere mejorar su eficiencia y facilidad de uso. Por otro lado, se tiene las redes neuronales artificiales (RNA) que es un programa o modelo de aprendizaje automático que toma decisiones de manera similar al cerebro humano, mediante el uso de procesos que imitan la forma en que las neuronas biológicas trabajan juntas para resolver problemas y llegar a conclusiones. La aplicación de las RNA en el diseño de estructuras podría revolucionar la eficiencia del proceso, reduciendo considerablemente los tiempos de análisis y diseño [6]. Las RNA ofrecen una capacidad superior para resolver problemas complejos y no lineales, presentando una solución eficaz para las limitaciones de los métodos tradicionales. Este avance no solo ha de beneficiar a ingenieros estructurales, sino que también contribuiría a la seguridad de las construcciones, alineándose con los principios de los Programas Nacionales Estratégicos (PRONACES) de vivienda y atendiendo demandas nacionales prioritarias en la construcción [7].

El presente proyecto de investigación se embarca en esta tendencia global de innovación tecnológica, enfocándose en el diseño estructural de edificios de acero de 3 a 8 niveles mediante la aplicación de modelos de RNA. Los modelos de RNA se han desarrollado como una de las mejores herramientas de aprendiza-

je, que imitan los procesos de los sistemas nerviosos naturales. Las RNA están compuestas por una serie de componentes básicos de procesamiento de información interconectados, conocidos como neuronas, las cuales, reciben información de diferentes fuentes y generan una salida de acuerdo con una función no lineal predefinida. La arquitectura de las RNA consta de 3 capas; la capa de entrada, que contiene los posibles parámetros que pueden influir en la salida; la capa oculta, que genera parámetros de ponderación y el sesgo durante el proceso de entrenamiento; y la capa de salida, la cual consta de neuronas de salida [8]. Para el presente estudio, se aplica el método de entrenamiento supervisado más común, se utiliza el Perceptrón Multicapa (MLP), que aprende mediante un proceso denominado algoritmo de retro propagación [9], [10]. Este algoritmo emplea el error cuadrático medio (MSE) como índice de rendimiento. El error en MSE se determina como la diferencia entre las salidas de destino y de la red [11].

Por lo tanto, al implementar estas herramientas, optimizar el tiempo en el diseño de edificios de uso habitacional no solo permite brindar una respuesta ágil a la creciente demanda de vivienda, si no también, reducir costos administrativos y de gestión, otorgando una ventaja competitiva en el mercado inmobiliario. Asimismo, un proceso de diseño eficiente optimiza el uso de recursos humanos y tecnológicos, mitiga riesgos financieros asociados a retrasos como el incremento de costos por inflación o variaciones en materiales y mano de obra, asegurando la calidad y la seguridad estructural de las edificaciones, contribuyendo al desarrollo de proyectos viables, oportunos y sostenibles.

2. CONCEPTOS GENERALES

2.1. El trabajo del diseñador estructural

El diseñador estructural se encarga de distribuir y dimensionar los elementos de un proyecto constructivo de manera que puedan resistir de forma adecuada las cargas a las que estará sometido. Entre sus responsabilidades se incluyen: la definición del esquema general de la estructura, la evaluación de las distintas configuraciones estructurales, el análisis de las condiciones de carga, el análisis de esfuerzos y deformaciones, el diseño de cada componente y la elaboración de los planos de detalles correspondientes. En un sentido más preciso, el término diseño hace referencia al proceso de dimensionar los elementos estructurales una vez determinadas las fuerzas actuantes, siendo este el

enfoque principal del texto, con énfasis en el uso del acero estructural como material de construcción [12].

2.2. Marcos

Un marco puede definirse como una estructura compuesta de dos o más miembros que se unen mediante conexiones, algunas de las cuales, o todas ellas, son resistentes a momentos para formar una configuración rígida. Los miembros de los marcos pueden clasificarse como columnas y vigas. Estos miembros de las estructuras están sometidos básicamente a momentos flexionantes y a fuerzas cortantes. El uso más común de las estructuras de marcos es en la construcción de edificios de oficinas, hoteles, apartamentos, casas, almacenes o bodegas, escuelas y estructuras semejantes [13].

2.3. Diafragmas horizontales

En los edificios modernos de construcción ligera, los muros y elementos divisorios son delgados y por lo general no forman parte integral del sistema estructural, por lo tanto, el marco de acero debe proporcionar toda la resistencia a las fuerzas laterales. Cuando las fuerzas de viento actúan de forma lateral sobre el costado de un edificio de varios pisos, estas fuerzas se transmiten por el revestimiento al montaje y luego elementos horizontales de la losa. Las losas de piso, rigidizadas por los miembros horizontales de los pisos, es decir, por vigas y trabes de piso, forman diafragmas horizontales que unen las columnas en cada nivel de piso. Estos diafragmas horizontales actúan como placas rígidas en su plano y entregan los incrementos de carga de viento surgen en cada piso a una serie de elementos verticales denominados sistemas de cortante, los cuales a su vez transfieren esas cargas horizontales a la cimentación [13].

2.4. Inteligencia artificial

Las técnicas de Inteligencia Artificial (IA) están en rápido crecimiento y se han utilizado ampliamente en diversas disciplinas de ingeniería [14]. La IA puede entenderse como la disciplina científica y de ingeniería dedicada a desarrollar máquinas capaces de actuar de forma inteligente. En este contexto, una máquina se considera inteligente cuando puede tomar decisiones adecuadas en situaciones de incertidumbre. De igual manera, se le atribuye inteligencia cuando posee la capacidad de aprender y mejorar su desempeño a partir de la experiencia adquirida [15].

2.5. Aprendizaje automático

La tecnología de aprendizaje automático puede resolver problemas que no se pueden resolver con métodos tradicionales [16]. El aprendizaje automático es una rama de la IA enfocada en el desarrollo de algoritmos que permiten automatizar la resolución de problemas complejos de aprendizaje, los cuales resultan difíciles de abordar mediante métodos convencionales de programación explícita. Estos algoritmos generan modelos matemáticos capaces de establecer relaciones entre variables de interés (características y objetivos) a partir de los datos, con el fin de realizar predicciones o tomar decisiones sin necesidad de ser programados de manera directa para cada tarea [17]. También se enfoca en crear algoritmos capaces de permitir que los sistemas aprendan y se perfeccionen de manera automática a partir de la experiencia [18].

2.6. Red neuronal artificial

Una RNA es un modelo computacional inspirado en el funcionamiento del sistema nervioso biológico [19]. Está compuesta por unidades de procesamiento simples y altamente interconectadas, denominadas neuronas, las cuales se enlazan mediante conexiones con pesos que transmiten las señales. Su funcionamiento implica la recopilación, análisis y tratamiento de datos, así como el diseño de la arquitectura de la red, la definición del número de capas y unidades ocultas, la inicialización, el entrenamiento, la simulación, el ajuste de pesos y sesgos, y finalmente la etapa de prueba. Las RNA se aplican en distintos ámbitos para manejar grandes volúmenes de información, ofreciendo análisis valiosos que facilitan la predicción y la clasificación de nuevos datos [20].

2.7. Aprendizaje supervisado

El aprendizaje supervisado se distingue porque el entrenamiento se lleva a cabo bajo la guía de un agente externo (supervisor o maestro), quien define cuál debería ser la respuesta correcta de la red ante una entrada específica. Si la salida generada no coincide con la esperada, el supervisor interviene ajustando los pesos de las conexiones, con el objetivo de que la respuesta producida se acerque lo más posible a la deseada [21].

3. METODOLOGÍA

En la Fig. 1 se muestra el diagrama de flujo que se aplicó para el desarrollo de esta investigación con la cual se obtuvieron los resultados esperados.




Fig. 1. Diagrama de flujo de la metodología

3.1. Determinación de las características de los edificios

Los edificios en estudio se encuentran destinados a uso habitacional. En este estudio, se analizó un modelo de edificio con planta cuadrada, con un diseño estructural de 3 a 8 niveles, compuesto por tres crujeías en cada eje ortogonal, con claros libres variados en 5,6,7 y 8 metros. Además, se consideró una variación en la altura de entrepiso de los edificios de 3, 3.5 y 4 metros. En las figs. 2 y 3 se muestra la vista en planta y en corte de un edificio como ejemplo.




Fig. 2. Vista en planta de los edificios con dimensiones variables.




Fig 3. Vista en corte de los edificios con alturas variables de entrepiso

3.2. Normativas y reglamentos aplicables

Se revisaron las normativas y reglamentos de construcción vigentes a nivel nacional y regional aplicables al diseño estructural de este tipo de edificaciones. En el presente estudio se empleó el Código Nacional de Diseño Estructural, complementado con el Reglamento de Construcciones para el Distrito Federal (RCDF), las Normas Técnicas Complementarias para el Diseño Estructural [22], así como el Manual de Diseño por Sismo y Viento de la Comisión Federal de Electricidad (CFE) [23], [24]. Estas disposiciones se aplicaron de manera integral en el desarrollo y verificación de cada uno de los modelos estructurales analizados.

3.3. Diseño y análisis estructural

Se analizaron y diseñaron 62 edificios de acero con marcos rígidos y planta cuadrada, teniendo en cuenta las dimensiones, características y normativas especificadas. El modelado, diseño y análisis estructural de los edificios se llevó a cabo utilizando el software ETABS, mientras que el espectro de diseño sísmico se obtuvo con el programa PRODISIS. En los diseños se revisaron los estados límites de colapso y de servicio establecido en el manual de CFE. Se consideran ubicados en el noroeste de México considerada como zona sísmica tipo b o intermedia. Los edificios se di-

señaron considerando un factor de comportamiento sísmico $Q=2$, y su uso es habitacional. No se consideraron los efectos de interacción suelo-estructura. En la Figs. 4 y 5 se muestra un ejemplo del modelado y distribución de los perfiles estructurales de los edificios en el software ETABS.




Fig. 4 Modelo 3D de un edificio de 8 niveles



Fig. 5. Distribución de perfiles en un edificio de 8 niveles.

3.4. Generación de base de datos

Se generó una base de datos organizada y clasificada que incluye todas las dimensiones, perfiles estructurales, estados límite de colapso y servicio, distorsiones de entrepiso, periodos de vibración, combinaciones de diseño, cargas vivas unitarias, entre otros aspectos relevantes de los 62 diseños de edificios. En las tablas 1, 2 y 3 se muestra la base de datos.

Tabla 1. Base de datos de edificios parte 1 – Geometría del edificio (en metros)

No. Edificio	Long Crujía X1	Long Crujía X2	Long Crujía X3	Long Crujía Y1	Long Crujía Y2	Long Crujía Y3	H por nivel
1	6	6	6	6	6	6	3

Tabla 2. Base de datos de edificios parte 2 – Perfiles estructurales y código numérico

No. Edificio	Grupo de secciones	Columnas	Vigas principales	Vigas secundarias
1	1	HSSX18X18X7/8 915	W14X53 110	W10X45 810
	2	HSSX18X18X5/8 910	W14X48 105	W10X45 810

Tabla 3. Base de datos de edificios parte 3 – Distorsiones de entrepiso para combinaciones de diseño y periodo fundamental de vibración

No. Edificio	Colapso (0.015) Comb 2	Colapso (0.015) Comb 6	Servicio (0.004) Comb 2	Servicio (0.004) Comb 6	Periodo de vibrar (s)
1	0.010	0.010	0.0023	0.0023	0.89

3.5. Selección de modelo de red neuronal artificial

Una vez obtenida la base de datos de diseño estructurales, el siguiente paso fue seleccionar el tipo de modelo de RNA que se utilizará. Existen diferentes tipos de modelos de RNA para ayudar a resolver diferentes problemas a continuación, se describen brevemente algunos de ellos:

- RNA con función de base radial: se pueden usar para la clasificación y agrupamiento de datos.
- Red neuronal convolucional: se utilizan para el reconocimiento de objetos, clasificación de imágenes, detección de objetos y segmentación de imágenes.
- Red neuronal gráfica: es un tipo especial de red neuronal diseñada para procesar datos representados en forma de gráfico.
- Red neuronal recurrente: son ideales para tareas que involucran datos secuenciales, como el procesamiento del lenguaje natural (traducción, generación de texto), el análisis de series temporales (predicción de precios, análisis de clima), y el reconocimiento de voz.

- RNA Perceptrón multicapa: es un tipo de red neuronal artificial que utiliza múltiples capas de neuronas para reconocer y aprender patrones complejos en los datos, así como utilizar regresión lineal [25].

Para este proyecto se optó por utilizar el modelo de RNA perceptrón multicapa, debido a que este modelo es adecuado para resolver problemas complejos, funciona eficazmente tanto con datos de entrada grandes como pequeños, y proporciona predicciones rápidas tras el proceso de entrenamiento. Además, es capaz de procesar grandes volúmenes de datos. El funcionamiento de este tipo de RNA se ilustra en la fig. 6




Fig. 6. Modelo de RNA perceptrón multicapa.

Las RNA estas basadas en el funcionamiento del cerebro humano siendo los círculos las neuronas y las líneas la comunicación que existe entre ellas.

La arquitectura de las Redes neuronales artificiales de perceptrón multicapa es la siguiente:

Capa de Entrada (círculos amarillos): Esta capa recibe los datos de entrada, cada neurona en esta capa corresponde a una característica del conjunto de datos como la cantidad de niveles del edificio, numero de crujiás en X, numero de crujiás en Y, dimensiones.

Capas Ocultas (Círculos azules): Estas son capas intermedias entre la capa de entrada y la capa de salida, puede haber múltiples capas ocultas, y su función es aprender patrones complejos en los datos para predecir resultados basados a partir de la base de datos proporcionada, cada neurona en una capa oculta está conectada a cada neurona en la capa anterior y a cada neurona en la capa siguiente.

Capa de Salida (Círculos verdes): Esta es la capa final donde se obtienen los resultados generados por la RNA en forma numérica, estos números se tendrán que interpretar como perfiles de acero estructural para nuestra propuesta de diseño estructural [8].

3.6. Entrenamiento de una red neuronal artificial

3.6.1. Preprocesamiento de datos

Para entrenar un modelo de RNA de tipo perceptrón multicapa que aprenda eficazmente de los datos es necesario tener una base de datos a la cual se le aplicará un preprocesamiento de datos, ya que la base de datos original puede contener números, textos, entre otros caracteres que deben ser transformados en números para que el modelo de RNA lo entienda [26]. Además del preprocesamiento de datos también se deben dividir los datos en forma de Inputs y Outputs.

3.6.2. Procedimiento de entrenamiento de la RNA

I. Importación de datos: Se cargaron las bases de datos previamente procesadas en formato de inputs y outputs dentro de la aplicación Neural Net Fitting de MATLAB.

II. Configuración de parámetros de entrenamiento: Se asignaron los porcentajes correspondientes a los conjuntos de entrenamiento, validación y prueba según la cantidad total de datos disponibles.

III. Se definió el número de neuronas en la capa oculta para las simulaciones.

IV. Ejecución del entrenamiento: Al iniciar el proceso (Train), MATLAB genera un resumen con los resultados, buscando minimizar el Error Cuadrático Medio (MSE).

V. Se realizaron múltiples iteraciones ajustando porcentajes y número de neuronas hasta obtener el menor MSE posible.

VI. Evaluación del desempeño: Se analizaron los gráficos de entrenamiento, desempeño y regresión para verificar la eficiencia del modelo y su capacidad predictiva.

VII. Exportación del modelo entrenado: Una vez obtenido el mejor desempeño, se exportó el modelo RNA en código de programación.

VIII. Pruebas del modelo: Se realizaron pruebas con nuevos datos de entrada para verificar la capacidad predictiva de la RNA.

IX. Los resultados numéricos obtenidos fueron reinterpretados como perfiles estructurales de columnas, vigas y vigas secundarias.

X. Interpretación final: Los valores numéricos se asociaron con perfiles estructurales específicos (por ejemplo, 131.72 $\rightarrow$ W14X82).

Estos perfiles se aplicaron en el diseño estructural, y posteriormente se verificaron en ETABS para comprobar su cumplimiento normativo.

Durante las iteraciones de entrenamiento, se prestó especial atención a evitar el fenómeno de sobreajuste (overlearning), el cual ocurre cuando la red memoriza los datos de entrenamiento perdiendo su capacidad para predecir correctamente nuevos casos. Para mitigar esto, se monitoreó el error en el subconjunto de validación; mediante la técnica de parada temprana (early stopping), el entrenamiento se detenía automáticamente si el error de validación comenzaba a divergir respecto al error de entrenamiento, garantizando así que el modelo conservara una adecuada capacidad de generalización [27, 28].

3.7. Validación de las redes neuronales artificiales

Una vez que el modelo de RNA ha sido entrenado, es necesario validarlo. Esto se realiza comparando los resultados de diseño estructural proporcionados por los modelos de RNA contra los resultados obtenidos mediante la metodología convencional para un mismo edificio. Para esto se generaron ejercicios de diseño estructural de prueba, uno para cada edificio.

4. ANÁLISIS DE RESULTADOS

Para este proyecto se desarrolló un total de 10 modelos de RNA: cinco de ellos enfocados en edificios de 3 y 4 niveles, y los otros cinco enfocados a edificios de acero con alturas entre 5 y 8 niveles. Cada modelo tiene una retroalimentación con diferente número de muestras con datos de diseños estructurales verificados, así como también datos experimentales los cuales son propuestas de diseño estructural basadas en la experiencia de los resultados obtenidos a partir de los diseños estructurales verificados. En la tabla 4 se presenta un resumen con las características de retroalimentación utilizadas en cada modelo de RNA.

En la tabla 5 se muestran las arquitecturas que tuvieron mejor desempeño de cada modelo de RNA empleado, por ejemplo: 8x14x3 donde el primer número “8” indica las entradas seguido del número de neuronas en la capa oculta “14” y por ultimo las salidas “3” donde se reflejan los resultados del modelo. Así como el error cuadrático medio (MSE) obtenido.

A continuación, se presenta una serie de tablas (6-11) que muestran las comparativas entre los resultados obtenidos por medio de los modelos RNA y los obtenidos mediante la metodología tradicional. Para la correcta interpretación de estos datos, se aclara que los valores numéricos reportados corresponden a las etiquetas identificadoras de los perfiles estructurales (según la codificación de la Tabla 2) y no a magnitudes físicas o dimensiones.

Cada comparativa se realizó sobre un mismo diseño de edificio de 3 a 8 niveles para validar las pruebas de aprobación. En este sentido, la columna ‘Cumple’ indica ‘Sí’ cuando el perfil predicho por la RNA satisface los requerimientos normativos de los estados límite de servicio y colapso, validación que fue verificada mediante el software ETABS.

La Tabla 12 muestra la precisión de cada modelo de RNA, obtenida a través de un proceso de validación que consistió en evaluar un conjunto de muestras seleccionadas aleatoriamente para diferentes niveles de edificio, según lo descrito en el apartado de Metodología. El porcentaje reflejado indica el grado de precisión del modelo RNA para predecir resultados dentro del rango de etiquetas establecido, en comparación con los resultados obtenidos en los diseños estructurales propuestos.

La Tabla 13 presenta una comparación de los tiempos requeridos para llevar a cabo el diseño estructural de cada edificio con distintos niveles, utilizando tanto la metodología tradicional como los modelos de RNA.

Tabla 4. Resumen de retroalimentación que se aplicó a cada modelo de RNA

No. Modelo RNA	Nombre del Modelo	Para edificios con niveles de:	Retroalimentación		Total de Muestras
			No. de datos Verificados	No. de datos Experimentales	
1	RNA	3 y 4	30	0	30
2	RNA100d	3 y 4	30	70	100
3	RNA200d	3 y 4	30	170	200
4	RNA400d	3 y 4	30	370	400
5	RNiA	3 y 4	30	770	800
6	RNA2	5-8	32	0	32
7	RNA197d	5-8	32	165	197
8	RNA393d	5-8	32	361	393
9	RNA785d	5-8	32	753	785
10	RNiA2	5-8	32	1,538	1,570

Tabla 5. Resumen de las arquitecturas de los modelos de RNA

Arquitecturas propuestas					
3 y 4 Niveles			5-8 Niveles		
Modelo RNA	Arquitectura	MSE	Modelo RNA	Arquitectura	MSE
RNA	8x14x3	0.27	RNA2	8x20x5	4.43E-26
RNiA	8x22x3	13.17	RNiA2	8x30x5	17.88
RNA400d	8x24x3	11.28	RNA785d	8x26x5	16.05
RNA200d	8x18x3	13.20	RNA393d	8x22x5	10.13
RNA100d	8x18x3	1.22	RNA197d	8x24x5	2.47

Tabla 6. Comparativa de resultados para edificios de 3 niveles, Manual vs RNA

Elemento Est.	Modelo RNA	RNA	Etabs	Cumple
Columna	RNA	125	130	Sí
	RNiA	145	130	Sí
	RNA400d	140	130	Sí
	RNA200d	150	130	Sí
	RNA100d	145	130	Sí
Viga	RNA	525	525	Sí
	RNiA	525	525	Sí
	RNA400d	525	525	Sí
	RNA200d	530	525	Sí
	RNA100d	535	525	Sí

Tabla 7. Comparativa de resultados para edificios de 4 niveles, Manual vs RNA

Elemento Est.	Modelo RNA	RNA	Etabs	Cumple
Columna	RNA	145	135	Sí
	RNiA	140	135	Sí
	RNA400d	145	135	Sí
	RNA200d	145	135	Sí
	RNA100d	150	135	Sí
Viga	RNA	520	520	Sí
	RNiA	540	520	Sí
	RNA400d	540	520	Sí
	RNA200d	535	520	Sí
	RNA100d	540	520	Sí

Tabla 8. Comparativa de resultados para edificios de 5 niveles, Manual vs RNA

Elemento Est.	Modelo RNA	RNA	Etabs	Cumple
Columnas	RNA2	145	130	Sí
		135	125	Sí
	RNiA2	130	130	Sí
		125	125	Sí
	RNA785d	135	130	Sí
		130	125	Sí
	RNA393d	130	130	Sí
		125	125	Sí
	RNA197d	135	130	Sí
		130	125	Sí
Elemento Est.	Modelo RNA	RNA	Etabs	Cumple
Vigas	RNA2	460	520	No
		450	515	No
	RNiA2	515	520	Sí
		510	515	Sí
	RNA785d	525	520	Sí
		520	515	Sí
	RNA393d	520	520	Sí
		515	515	Sí
	RNA197d	530	520	Sí
		525	515	Sí

Tabla 9. Comparativa de resultados para edificios de 6 niveles, Manual vs RNA

Elemento Est.	Modelo RNA	RNA	Etabs	Cumple
Columnas	RNA2	920	915	Sí
		920	915	Sí
	RNiA2	910	915	Sí
		910	915	Sí
	RNA785d	910	915	Sí
		910	915	Sí
	RNA393d	910	915	Sí
		910	915	Sí
	RNA197d	910	915	Sí
		910	915	Sí
Vigas	RNA2	540	520	Sí
		530	515	Sí
	RNiA2	530	520	Sí
		525	515	Sí
	RNA785d	535	520	Sí
		530	515	Sí
	RNA393d	525	520	Sí
		520	515	Sí
	RNA197d	515	520	Sí
		510	515	Sí

Tabla 10. Comparativa de resultados para edificios de 7 niveles, Manual vs RNA

Elemento Est.	Modelo RNA	RNA	Etabs	Cumple
Columnas	RNA2	910	910	Sí
		910	910	Sí
	RNiA2	915	910	Sí
		910	910	Sí
	RNA785d	915	910	Sí
		910	910	Sí
	RNA393d	915	910	Sí
		910	910	Sí
	RNA197d	910	910	Sí
		905	910	Sí
Vigas	RNA2	110	110	Sí
		105	105	Sí
	RNiA2	115	110	Sí
		110	105	Sí
	RNA785d	115	110	Sí
		110	105	Sí
	RNA393d	115	110	Sí
		110	105	Sí
	RNA197d	110	110	Sí
		105	105	Sí

Tabla 11. Comparativa de resultados para edificios de 8 niveles, Manual vs RNA

Elemento Est.	Modelo RNA	RNA	Etabs	Cumple
Columnas	RNA2	910	915	Sí
		905	910	Sí
	RNiA2	915	915	Sí
		910	910	Sí
	RNA785d	915	915	Sí
		910	910	Sí
	RNA393d	915	915	Sí
		910	910	Sí
	RNA197d	915	915	Sí
		910	910	Sí
Vigas	RNA2	195	160	Sí
		190	155	Sí
	RNiA2	170	160	Sí
		165	155	Sí
	RNA785d	170	160	Sí
		165	155	Sí
	RNA393d	160	160	Sí
		155	155	Sí
	RNA197d	165	160	Sí
		160	155	Sí

Tabla 12. Precisión de los resultados de los modelos de RNA

Nombre del Modelo	Precisión %
RNA	50%
RNA100d	30-40%
RNA200d	75%
RNA400d	90%
RNiA	90%
RNA2	20-30%
RNA197d	50%
RNA393d	70%
RNA785d	90%
RNiA2	90%

Tabla 13. Comparativa de los tiempos de diseño estructural aplicando el método tradicional y modelos RNA

Niveles del edificio	Tiempos de diseño estructural	
	Tradicional	RNA
3	120-180 min	10 - 15 min
4	120-180 min	10 - 15 min
5	180-240 min	15 - 20 min
6	180-240 min	15 - 20 min
7	240-300 min	20 - 25 min
8	240-300 min	20 - 25 min

5. CONCLUSIONES

El presente proyecto de investigación logró demostrar la viabilidad de aplicar modelos de redes neuronales artificiales (RNA) en el diseño estructural de edificios de acero con alturas entre 3 y 8 niveles. A través del desarrollo, entrenamiento y validación de diez modelos de RNA tipo perceptrón multicapa, se comprobó que estas herramientas pueden predecir de forma rápida y eficiente los perfiles estructurales necesarios para columnas y vigas de una propuesta de diseño estructural para edificios de acero, reduciendo significativamente los tiempos requeridos en comparación con el método tradicional basado en software de análisis estructural (como ETABS).

Los resultados muestran que, en modelos con una mayor cantidad de datos de entrenamiento (entre 400 y 1,570 muestras), en particular los modelos RNA400d y RNA785d mostraron el mejor desempeño alcanzando niveles de precisión de hasta el 90%, lo cual valida su aplicabilidad práctica. Asimismo, al analizar los resultados obtenidos por los modelos RNA en comparación con los criterios establecidos por las normativas vigentes, se comprobó que estos cumplen adecuadamente con los parámetros requeridos, lo que refuerza su confiabilidad. Este avance representa una innovación importante para el campo de la ingeniería estructural, particularmente en contextos donde la agilidad en la toma de decisiones es crucial.

Los resultados obtenidos permiten afirmar que el uso de RNA representa una herramienta eficaz para

reducir de manera significativa los tiempos requeridos en el diseño estructural, sin comprometer la calidad ni el cumplimiento normativo. La comparación de las propuestas generadas por los modelos de RNA con los resultados obtenidos mediante el método tradicional de análisis estructural evidenció una concordancia satisfactoria con los parámetros normativos exigidos, lo cual valida la aplicabilidad práctica de esta tecnología en contextos reales.

Además, se concluye que la creación de una base de datos estructural detallada, basada en el análisis de casos reales y con datos normativamente contextualizados, es un componente clave para el desarrollo exitoso de modelos inteligentes. Esta base de datos no solo fortaleció la calidad del entrenamiento de las RNA, sino que también constituye un recurso valioso para futuras investigaciones o aplicaciones profesionales orientadas al diseño estructural automatizado.

En síntesis, la integración de inteligencia artificial, en forma de redes neuronales artificiales, en el ámbito del diseño estructural representa una innovación relevante que permite optimizar tiempos, facilitar la toma de decisiones técnicas, y mejorar la eficiencia general de los procesos de diseño.

4.1. Recomendaciones

A pesar de los avances logrados, esta investigación presenta ciertas limitaciones que deben ser consideradas:

- La base de datos generada, aunque robusta, se limita a modelos con geometrías de planta cuadrada y a edificios de entre 3 y 8 niveles, lo cual restringe la generalización de los modelos a otras tipologías estructurales o configuraciones geométricas diferentes.
- El estudio se enfocó exclusivamente en estructuras con marcos rígidos de acero, por lo que sus conclusiones no pueden extrapolarse directamente a sistemas estructurales mixtos o de otros materiales como concreto reforzado o madera.
- Los modelos de RNA utilizados fueron de tipo perceptrón multicapa; aunque eficaces, existen otras arquitecturas más avanzadas (como redes convolucionales o redes recurrentes) que no fueron exploradas en este trabajo.
- La calidad del modelo depende directamente de la calidad y variedad de los datos de entrada; en este sentido, se reconoce que una mayor cantidad de datos provenientes de distintas condiciones y configuraciones podría mejorar la capacidad de generalización del sistema.

AGRADECIMIENTOS

El presente trabajo fue posible gracias al respaldo económico de la Secretaría de Ciencia, Humanidades, Tecnología e Innovación (SECIHTI), bajo el proyecto Ciencia de Frontera CF-2023-G-1636. De igual manera, se reconoce el apoyo de dicha institución al primer autor durante su formación de posgrado.

REFERENCIAS

- [1] J. B. Mora, D. Tolentino, S. E. Ruiz, y Y. E. Bojórquez, "DISEÑO SÍSMICO PRELIMINAR DE EDIFICIOS DE CONCRETO REFORZADO USANDO REDES NEURONALES ARTIFICIALES", 2016.
- [2] E. Bojórquez, J. Bojórquez, S. E. Ruiz, y A. Reyes-Salazar, "Prediction of inelastic response spectra using artificial neural networks", *Math Probl Eng*, vol. 2012, 2012, doi: 10.1155/2012/937480.
- [3] J. Ferreiro-Cabello, E. Fraile-Garcia, E. Martinez de Pison Ascacibar, y F. J. Martinez de Pison Ascacibar, "Metamodel-based design optimization of structural one-way slabs based on deep learning neural networks to reduce environmental impact", *Eng Struct*, vol. 155, pp. 91–101, ene. 2018, doi: 10.1016/j.engstruct.2017.11.005.
- [4] Z. Bahmani, M. R. Ghasemi, S. S. Mousavi-amjad, y S. Gharehbaghi, "Prediction of Performance Point of Semi-Rigid Steel Frames Using Artificial Neural Networks", *International Journal of Intelligent Systems and Applications*, vol. 11, núm. 10, pp. 42–53, oct. 2019, doi: 10.5815/ijisa.2019.10.05.
- [5] F. Noori y H. Varaei, "Nonlinear Seismic Response Approximation of Steel Moment Frames Using Artificial Neural Networks", 2022.
- [6] S. Talatahari, F. Chen, y A. H. Gandomi, "Developing a robust machine learning framework for predicting the behavior of large-scale structure", *Journal of Building Engineering*, vol. 105, jul. 2025, doi: 10.1016/j.jobe.2025.112204.
- [7] M. Jahjouh, "An experience based artificial neural network in the design optimization of steel frames", *Engineering Research Express*, vol. 4, núm. 4, dic. 2022, doi: 10.1088/2631-8695/aca6ce.

[8] S. A. Banimahd, A. I. Giouvanidis, S. Karimzadeh, y P. B. Lourenço, “A multi-level approach to predict the seismic response of rigid rocking structures using artificial neural networks”, *Earthquake Engineering and Structural Dynamics*, vol. 53, núm. 6, pp. 2185–2208, may 2024, doi: 10.1002/eqe.4110.

[9] S. S. Afshari, C. Zhao, X. Zhuang, y X. Liang, “Deep learning-based methods in structural reliability analysis: a review”, el 1 de julio de 2023, *Institute of Physics*. doi: 10.1088/1361-6501/acc602.

[10] B. Tekwani y A. B. Gupta, “Predicting Compressive Strength of Pervious Concrete Using Artificial Neural Network and Regression”, en *IOP Conference Series: Earth and Environmental Science*, Institute of Physics, 2024. doi: 10.1088/1755-1315/1326/1/012150.

[11] S. J. S. Hakim et al., “Application and development of Artificial Neural Networks to predict structural damage subjected to earthquake-A review”, en *IOP Conference Series: Earth and Environmental Science*, Institute of Physics, 2023. doi: 10.1088/1755-1315/1205/1/012037.

[12] J. C. . McCormac, *Diseño de estructuras de acero*, Quinta edición. México: Alfaomega Grupo Editor, 2013.

[13] Sriramulu Vinnakota, “Estructuras de acero: Comportamiento LRFD”, Mc Graw Hill/Interamericana, núm. Primer edición, p. 926, 2006.

[14] S. Bhatta y J. Dang, “Seismic damage prediction of RC buildings using machine learning”, *Earthq Eng Struct Dyn*, vol. 52, núm. 11, pp. 3504–3527, sep. 2023, doi: 10.1002/eqe.3907.

[15] J. Humberto. Sossa Azuela y Fernando. Reyes Cortés, *Inteligencia artificial aplicada a robótica y automatización*, Primer edición. México: Alfaomega Grupo Editor, 2021.

[16] R. Hou y Q. Hou, “Prediction of the shear capacity of ultrahigh-performance concrete beams using neural network and genetic algorithm”, *Sci Rep*, vol. 13, núm. 1, dic. 2023, doi: 10.1038/s41598-023-29342-0.

[17] M. A. Kraus y M. Drass, “Artificial intelligence for structural glass engineering applications — overview, case studies and future potentials”, *Glass Structures and*

Engineering, vol. 5, núm. 3, pp. 247–285, nov. 2020, doi: 10.1007/s40940-020-00132-8.

[18] F. Kazemi, N. Asgarkhani, T. Shafighfard, R. Jankowski, y D. Y. Yoo, “Machine-Learning Methods for Estimating Performance of Structural Concrete Members Reinforced with Fiber-Reinforced Polymers”, el 1 de enero de 2025, Springer Science and Business Media B.V. doi: 10.1007/s11831-024-10143-1.

[19] T. A. Nguyen, H. B. Ly, H. V. T. Mai, y V. Q. Tran, “Using ANN to Estimate the Critical Buckling Load of y Shaped Cross-Section Steel Columns”, *Sci Program*, vol. 2021, 2021, doi: 10.1155/2021/5530702.

[20] A. El-Shahat, “Introductory Chapter: Artificial Neural Networks”, en *Advanced Applications for Artificial Neural Networks*, InTech, 2018. doi: 10.5772/intechopen.73530.

[21] X. B. Olabe, “REDES NEURONALES ARTIFICIALES Y SUS APLICACIONES”, Bilbao.

[22] ADMINISTRACIÓN PÚBLICA DE LA CIUDAD DE MÉXICO, “NORMA TÉCNICA COMPLEMENTARIA SOBRE CRITERIOS Y ACCIONES PARA EL REGLAMENTO DE CONSTRUCCIONES DE CDMX”, *Gaceta Oficial de la Ciudad de México.*, 2020.

[23] CFE, “Manual de Diseño de Obras Civiles: Diseño por Viento”, p. 515, 2020.

[24] CFE, “Manual de diseño de obras civiles: Diseño por sismo.”, 2015.

[25] S. C. Jayasinghe et al., “A review on the applications of artificial neural network techniques for accelerating finite element analysis in the civil engineering domain”, el 1 de abril de 2025, Elsevier Ltd. doi: 10.1016/j.compstruc.2025.107698.

[26] H. Bartsch, J. Voelkel, y M. Feldmann, “Developing artificial neural networks to estimate the fatigue strength of structural steel details using the new European database”, *Steel Construction*, feb. 2024, doi: 10.1002/stco.202400029.

[27] T. A. Gharah Tapeh y M. Z. Naser, “Artificial intelligence, machine learning, and deep learning in structural engineering: a scientometrics review of trends and

best practices”, Archives of Computational Methods in Engineering, vol. 30, pp. 115–159, 2023, doi: 10.1007/s11831-022-09793-w.

[28] C. Burton, T. J. Massam, y C. McCrum, “Machine learning in structural design: an opinionated review”, Front. Built Environ., vol. 8, p. 815717, 2022, doi: 10.3389/fbuil.2022.815717.