

Importancia de las redes neuronales artificiales en la ingeniería civil: Una revisión sistemática de la literatura

Importance of artificial neural networks in civil engineering: A systematic review of the literature

Frank Jesús Valderrama-Purizaca¹ ; Daniel Armando Chávez-Barturen² ; Sócrates Pedro Muñoz-Pérez³ ; Victor Tuesta-Monteza⁴ ; Heber Ivan Mejía-Cabrera⁵

¹Bach. Ingeniería Civil, Universidad Señor de Sipán, Pimentel, Perú, vpurizacafrankj@crece.uss.edu.pe,

²Bach. Ingeniería Civil, Universidad Señor de Sipán, Pimentel, Perú, cbarturendanie@crece.uss.edu.pe,

³Magíster, Universidad Señor de Sipán, Pimentel, Perú, msocrates@crece.uss.edu.pe,

⁴Magíster, Universidad Señor de Sipán, Pimentel, Perú, vtuesta@crece.uss.edu.pe,

⁵Magíster, Universidad Señor de Sipán, Pimentel, Perú, hmejia@crece.uss.edu.pe

Recibido: 5 de diciembre de 2020. Aceptado: 14 de diciembre de 2020

Resumen– Las redes neuronales artificiales (RNA) tienen un papel relevante en la actualidad, diversas áreas aplican esta técnica por las ventajas que presentan para resolver problemas complejos con muchas restricciones en comparación con los métodos tradicionales, que están quedando desfasados. Se conoce muy poco acerca de esta técnica y su aplicación en distintas ramas de la Ingeniería Civil. Por tal motivo, la presente investigación tiene por objetivo realizar una revisión sistemática de la literatura para identificar el uso de esta técnica y determinar los resultados de la aplicación de modelos de RNA en la ingeniería civil. Se incluyeron un total de 41 artículos científicos que se distribuyen de la siguiente forma: 6 en Scopus, 1 en ScienceDirect, 23 en ProQuest, 7 en Google Académico, 2 en Dialnet, 2 en SciELO. Se encontró que las RNA son utilizadas para predecir o pronosticar variables asociadas a los campos de estudio de la ingeniería civil, se hallaron 8 aplicaciones de RNA para propiedades del concreto, 11 para propiedades del suelo, 5 para análisis sísmico, 9 para hidráulica, 7 para valorización de inmuebles y 1 para diseño de puentes. Así mismo se encontró que el Perceptrón Multicapa es el modelo de RNA más utilizado, logrando en promedio un R^2 de 0.99, lo que demuestra ventajas para resolver problemas con precisión, en tiempos más cortos, con datos faltantes en los conjuntos de datos, así como la reducción del factor de error.

Palabras clave– Red neuronal; propiedades del concreto; mecánica de suelos; análisis sísmico; aprendizaje automático; modelo RNA.

Abstract– Artificial neural networks (ANN) have a relevant role nowadays; several areas apply this technique due to the advantages they have to solve complex problems with many constraints compared to traditional methods, which are becoming outdated. Very little is known about this technique and its application in different branches of Civil Engineering. For this reason, the present research aims to conduct a systematic review of the literature to identify the use of this technique and to determine the results of the application of ANN models in civil engineering. A total of 41 scientific articles were included, distributed as follows: 6 in Scopus, 1 in ScienceDirect, 23 in ProQuest, 7 in Google Scholar, 2 in DialNet, 2 in SciELO. It was found that ANNs are used to predict or forecast variables associated with the fields of study in civil engineering; 8 applications of ANN were found for concrete properties, 11 for soil properties, 5 for seismic analysis, 9 for hydraulics, 7 for real estate valuation and 1 for bridge design. Likewise, it was found that the multilayer Perceptron is the most used ANN model, achieving an average R^2 of 0.99, which shows advantages to solve problems with precision, in shorter

Citar este artículo como: Valderrama-Purizaca F.J., Chávez-Barturen D.A., Muñoz-Pérez S.P., Tuesta-Monteza V.A., Mejía-Cabrera H.I. Importancia de las redes neuronales artificiales en la ingeniería civil: Una revisión sistemática de la literatura. *ITECKNE*, 18(1), 2021 pp. 71 -83. doi: <https://doi.org/10.15332/iteckne.v18i1.2542>

times, with missing data in the data sets, as well as the reduction of the error factor.

Keywords– Neural Network; concrete properties; soil mechanics; seismic analysis; machine learning; ANN model.

1. INTRODUCCIÓN

Las RNA son una sucesión de capas que contienen un gran número de unidades interconectadas entre sí llamadas neuronas [1]. Las RNA se describen como un sistema compuesto por nodos que tratan de asemejarse a las neuronas, las que a su vez poseen conexiones que tratan de simular la sinapsis de los sistemas biológicos. Estos modelos son utilizados como un método estadístico alternativo a los métodos tradicionales [2] different models are developed to estimate the compaction parameters of sandy soil using artificial neural network (ANN. Gracias a la estructura que poseen y a su capacidad de aprendizaje, las RNA pueden ayudar a resolver distintos problemas como la predicción de valores, la detección similitudes, el reconocimiento de patrones, inclusive cuando una entrada en particular no se haya conocido antes [3].

En principio, para que una RNA aprenda debe ser entrenada con una base de datos a la cual se le denomina conjunto datos de entrenamiento. Posteriormente, se establecen las reglas y las relaciones y, finalmente, se predicen los valores [4]. Cada una de las neuronas tiene una serie de pesos que determina la importancia de la neurona y qué tanto influye en el valor final; así pues, en el desarrollo de la RNA se aumenta la precisión de los modelos modificando los pesos de asociación con cada neurona [5] que se encuentran en una banda transportadora. Para el posicionamiento de la banda transportadora se utiliza la técnica de lógica difusa. El control de posicionamiento presenta un error aceptable debido a los protocolos de comunicaciones usados. El reconocimiento de imágenes se realiza a través de técnicas de Visión Artificial y Redes Neuronales. El sistema de reconocimiento de imágenes consta de tres etapas: adquisición de imágenes digitales a color, procesamiento de imágenes y extracción de las diferentes características de las imágenes e identificación de la figura geométrica. Este sistema puede diferenciar siete formas geométricas (círculo, cuadrado, triángulo, rectángulo, elipse, rombo, estrella de cinco puntas. El proceso de aprendizaje lo realizan mediante algoritmos especiales, los cuales tratan de imitar los mecanismos de aprendizaje de un sistema biológico. Por esta razón, en los últimos años, muchas disciplinas han comenzado a incorporar el uso de modelos de RNA como una herramienta para resolver problemas complejos y se les está dando una gran aceptación, debido a que son capaces de dar resultados con errores mínimos [6].

En ingeniería civil también se han aplicado diversos modelos de RNA que ayudan a resolver problemas relacionados con la realidad, que son muy variables y difíciles de predecir. Por ejemplo, predecir la vida útil de una estructura

–que no es una tarea sencilla– puesto que ocurren muchos cambios internos y externos en la estructura que en su mayoría son aleatorias. Asimismo, existen factores que están influenciados por diversas condiciones como la ubicación geográfica y la calidad de los materiales [7].

El propósito de esta investigación es determinar la importancia de las RNA y su aplicación en la ingeniería civil, para lo cual se hizo una revisión sistemática de las investigaciones más relevantes donde se hayan aplicado modelos de RNA. De igual manera, se pretende identificar las ventajas de las RNA sobre los métodos estadísticos tradicionales, para así influenciar en la utilización de esta técnica de inteligencia artificial en la ingeniería civil.

2. METODOLOGÍA

2.1 Estrategia de búsqueda

La búsqueda bibliográfica es un tipo de investigación que se basa en materiales publicados [8] en revistas científicas, repositorios de tesis, periódicos, artículos, entre otros; así como de publicaciones periódicas disponibles en Internet. La revisión de la literatura permite al investigador obtener un panorama general del avance de la disciplina en cuanto a un tópico específico de interés que permite cubrir campo de acción amplio para establecer nuevas investigaciones [9].

La búsqueda se desarrolló usando títulos de temas y palabras claves en idioma inglés para representar los conceptos de RNA, propiedades del concreto, suelos, hidráulica, ingeniería sísmica, y valorización de inmuebles. La revisión de la literatura consideró las publicaciones desde el 2007 hasta el 19 de noviembre del 2020. Posteriormente, los resultados fueron compilados en una bitácora de búsqueda, creada en una hoja de cálculo para luego ser organizados con Mendeley.

2.2 Selección de estudios

En primer lugar, se identificó el material bibliográfico, realizando la búsqueda con palabras claves de acuerdo con el tema, obteniendo 281 registros de las bases de datos, Scopus, ScienceDirect, ProQuest, Google Académico, Dialnet, SciELO, EBSCO. Luego de aplicar criterios de calidad se seleccionaron 41 publicaciones. Los distintos artículos encontrados fueron revisados por los autores de manera independiente y cualquier desacuerdo para mantener o eliminar un material fue resuelto en mutuo acuerdo. Asimismo, se revisaron las referencias de los estudios ya seleccionados para encontrar otros artículos potenciales para la investigación.

2.3 Criterio de elegibilidad

Cada uno de los resultados obtenidos fueron evaluados detalladamente, usando como criterios de inclusión: aplicación de redes neuronales en ramas de la ingeniería civil y como criterios de exclusión: aquellas investigaciones no relacionadas directamente con la ingeniería civil. Fueron descartados aquellas investigaciones publicadas en idiomas distintos

al inglés y español, y aquellas con más de 13 años de antigüedad. Las publicaciones que superaron el filtro de calidad de acuerdo con las bases de datos se distribuyeron de la siguiente manera: 6 de Scopus, 1 de ScienceDirect, 23 de ProQuest, 7 de Google académico, 2 de DialNet y 2 de SciELO. En la Tabla I se muestra la cantidad de artículos seleccionados por base de datos y por año de publicación. En total fueron recopilados 41 artículos, en su mayoría con una antigüedad de 5 años.

3. RESULTADOS

3.1 Características de los estudios

Fueron encontradas 8 publicaciones con aplicación de modelos de RNA para la predicción de la resistencia a la compresión, el módulo elástico, la resistividad eléctrica, la resistencia al fuego del concreto, y el diseño de estructuras de concreto armado. Así mismo, fue hallado un estudio de aplicación de RNA al diseño de puentes de concreto armado. En mecánica de suelos se encontraron 13 estudios. En análisis sísmico 5 estudios. En hidráulica 9 estudios donde utilizan RNA para calcular la socavación, el coeficiente de descarga, precipitaciones, encausamiento de inundaciones, demanda de agua, filtración y estabilización de presas. Del mismo modo fueron encontrados 7 estudios enfocados a la valorización de inmuebles.

3.2 Redes neuronales artificiales para predecir las propiedades del concreto

3.2.1 Resistencia a la compresión del concreto

En [10] se analizaron estudios previos donde sustituyen los agregados por desechos de caucho para mejorar las propiedades del concreto armado. Se recolectaron un total de 457 mezclas, estas fueron utilizadas para desarrollar un modelo que permita predecir la resistencia a la compresión del concreto con caucho de neumáticos. El 70% de los datos se usó durante la etapa de entrenamiento, el 15% se usó para la etapa de validación y el 15% para la etapa de prueba. El conjunto de datos estuvo formado por 6 variables que incorporaba la cantidad de cemento, la relación agua-cemento, el porcentaje de agregado fino, el porcentaje de agregado grueso, el porcentaje de caucho fino y grueso. La predicción generada por la red alcanzó un co-

eficiente de determinación (R^2) de 0,96 y 0,98 para las etapas de entrenamiento y prueba, respectivamente. La raíz del error cuadrático medio (RMSE) fue de 4,8 y 3,78 para las etapas de entrenamiento y prueba. Finalmente, los autores señalan que la aplicación de una RNA de retropropagación multicapa en el campo de la predicción de la resistencia a la compresión del hormigón con caucho de neumáticos es apropiada y puede considerarse como un enfoque alternativo y adecuado.

En el trabajo desarrollado por [11] se utilizó Perceptrón Multicapa para predecir la resistencia a la compresión y la resistencia a la flexión de concretos de alto rendimiento, reforzados con fibra de acero, llegando a recopilar hasta 162 ejemplos etiquetados de resistencia a la compresión y 102 ejemplos etiquetados de resistencia a la flexión para desarrollar los modelos. En este estudio el 80% de los datos fueron usados para el entrenamiento y el 20% para la validación. En la RNA usada para estimar la resistencia a la flexión, se usaron como variables de entrada el diámetro, la longitud, la relación de aspecto y el volumen de las fibras de acero y la resistencia a la flexión del concreto sin fibras de acero. Para estimar la resistencia a la compresión, las variables de entrada fueron el diámetro, la longitud, la relación de aspecto y el volumen de las fibras de acero, y la resistencia a la compresión sin fibras. Se realizaron una serie de pruebas para determinar la arquitectura de la red, estableciéndose en 5 neuronas para la capa de entrada, 15 neuronas en la capa oculta, una neurona en la capa de salida para el modelo de resistencia a la flexión. Así mismo se establecieron 6 neuronas en la capa de entrada, 20 neuronas en la capa oculta y una neurona en la capa de salida para el modelo de resistencia a la compresión. El primer modelo de RNA predijo el esfuerzo a la flexión con un ECM de 0,1492 y 0,0376 en la etapa de entrenamiento y prueba, respectivamente; y un R^2 de 0,9777 y 0,9986 en el entrenamiento y la prueba. El segundo modelo predijo la resistencia a la compresión con un ECM de 0,0876 y 0,0980 en el entrenamiento y la prueba, respectivamente; un R^2 de 0,9923 y 0,9901 en la etapa de entrenamiento y prueba, respectivamente. Estos resultados indican que los modelos de redes neuronales artificiales pueden utilizarse para predecir la resistencia a la flexión y la resistencia a la compresión del concreto de alto rendimiento, determinar la fracción de volumen de las fibras de acero y optimizar las mezclas para los concretos de alto rendimiento reforzados con fibras de acero.

TABLA I.
DISTRIBUCIÓN DE LOS ARTÍCULOS USADOS COMO REFERENCIA SEGÚN BASE DE DATOS Y AÑO DE PUBLICACIÓN

Bases de datos	Año de publicación										Total
	2007	2009	2011	2012	2015	2016	2017	2018	2019	2020	
Scopus	-	-	-	-	1	-	-	-	1	4	6
Science Direct	-	-	-	-	-	-	-	1	-	-	1
ProQuest	-	-	-	-	-	2	4	9	5	3	23
Google académico	-	-	1	1	1	1	1	-	1	1	7
Dialnet	-	1	-	-	-	-	1	-	-	-	2
SciELO	1	-	-	-	-	1	-	-	-	-	2
Total	1	1	1	1	2	4	6	10	7	8	41

Fuente: Los autores

En [12] se propuso un Perceptrón Multicapa para predecir la propiedad del concreto. En esta investigación el modelo fue entrenado con 3215 ensayos de resistencia a la compresión del concreto, de donde se estableció las siguientes variables, cantidad de cemento, cantidad de agua, módulo de figura de la piedra, módulo de figura de la arena, tamaño máximo nominal de la piedra, peso específico de la arena, peso específico de la piedra, tipo de cemento, periodo de curado. El conjunto de datos incorporó ensayos de resistencia a la compresión de 210, 250, 280 y 300 kg/cm². Los resultados muestran un error de 3,29%. En [13] se utilizó un Perceptrón Multicapa para predecir la resistencia a la compresión del concreto, analizando los factores más importantes que intervienen en su estimación como la relación agua-cemento, las condiciones de humedad, el tamaño máximo de los agregados y la edad del concreto, considerando 785 muestras para el entrenamiento y validación, logrando un coeficiente de correlación (R) de 0,9176.

3.2.2 Resistencia a la compresión y módulo elástico del concreto

Se ha encontrado un estudio que aplicó un Perceptrón Multicapa para predecir la resistencia a la compresión y el módulo elástico de concretos hechos con agregados reciclados [14]. En este estudio se analiza la importancia de las características de los agregados reciclados para ver cuáles influyen más en la resistencia a la compresión y el módulo elástico del concreto. La base de datos utilizada estuvo compuesta por 46 mezclas de concreto con varios tipos de agregados reciclados, a los cuales se le efectuaron los ensayos correspondientes. En este estudio se usaron en total 14 variables de entradas, de las cuales 8 variables fueron respecto a las características de los agregados, se usaron 5 para las proporciones de mezcla, y 1 variable fue el tiempo de curado. Se desarrollaron dos de Perceptrón Multicapa, para el primero se utilizaron las 8 variables con respecto a los agregados. En la etapa de entrenamiento, este modelo tuvo un R² para los valores de resistencia a la compresión y el módulo elástico de 0,9984 y 0,9999, respectivamente. Para la fase de validación y prueba el R² estuvo alrededor de 0,994. En el segundo modelo se utilizaron las 14 variables de entrada. Para la fase de entrenamiento, los valores de resistencia a la compresión y el módulo elástico fueron estimados con un R² de 0,997 y 0,9941, respectivamente; para la fase de validación y prueba los valores estuvieron en el rango de 0,987 a 0,9931. Finalmente, los resultados obtenidos muestran que la absorción de agua es una característica muy influyente en los valores de resistencia a la compresión de concretos con agregados reciclados. Mientras que, para el módulo elástico, las características más influyentes son la absorción del agua y la gravedad específica [14].

3.2.3 Resistencia a la compresión y resistividad eléctrica del concreto

En [15] se propone un Perceptrón Multicapa para predecir la resistencia a la compresión y la resistividad eléctrica del concreto. Para ello, se realizaron ensayos de compresión

a 41 mezclas de concreto. El contenido de cemento en la mezcla fue de 250, 200 y 350 kg/cm³. Las relaciones de agua-cemento usadas fueron de 0,45, 0,55 y 0,67. Asimismo, se usó agregado grueso con tamaños máximos de 1", ¾" y ½". El 77% y el 23% de los datos fueron usados para entrenar y validar el modelo de redes neuronales para predecir la resistencia a la compresión. Este modelo utilizó como variables de entrada la velocidad de pulso y el peso unitario, teniendo una arquitectura de 2 neuronas en la capa de entrada, 15 neuronas en la primera capa oculta, 10 neuronas en la segunda capa oculta, y una neurona a la salida. El Perceptrón Multicapa utilizado para predecir la resistividad eléctrica consideró una arquitectura de 3 neuronas en la capa de entrada, 8 neuronas en la primera capa oculta, 12 neuronas en la segunda capa oculta y 1 neurona en la capa de salida, estableciendo como variables de entrada la resistencia a la compresión, la velocidad de pulso y el peso unitario. Asimismo, la red neuronal predijo la resistencia a la compresión del concreto con un R² de 0,7027 y un error promedio fue de 9,3%; también, los datos de la resistividad eléctrica del concreto simulados tuvieron un R² de 0,4281 y un error promedio de 30,7%.

3.2.4 Resistencia al fuego

En [16] se propuso el modelo de RNA Adaptive Neuro-Fuzzy Interface System (ANFIS) para pronosticar la resistencia al fuego de las columnas de concreto, para ello construyeron una base de datos a partir de los resultados obtenidos del análisis numérico a los elementos estructurales de los diseños de las edificaciones. En total, fueron analizados 398 series de datos que conformaron el conjunto de datos de las cuales 318 (80%) fueron utilizados para el entrenamiento y 80 (20%) para validación. Se establecieron 6 variables de entrada como el ancho y el peralte de la columna de concreto armado, el espesor del recubrimiento, el porcentaje de acero, el coeficiente de carga axial y un coeficiente de momento de flexión, toda esta estructura permitió tener una variable de salida que fue la resistencia al fuego de la columna de concreto armado. Los resultados muestran un error medio durante la prueba de 0,319 para los datos de entrenamiento, 0,511 para los datos de prueba y 0,245 para los datos de validación. Los resultados de esta investigación son la prueba del éxito de la aplicación de redes neuronales artificiales para resolver problemas complejos reales en el campo de la construcción. Así pues, estos modelos permitieron predecir la resistencia al fuego de las columnas de concreto armado, superando a los métodos tradicionales y métodos de modelación matemática, que ponen en relieve la eficacia y la viabilidad de la aplicación de esta técnica innovadora para la toma de decisiones y la evaluación de los problemas que se plantean durante la planificación y ejecución de proyectos de construcción.

3.2.5 Concreto armado

En [17] se propusieron dos modelos de Perceptrón Multicapa para predecir los esfuerzos en la superficie del concreto (SC) y en el acero (SR), para ello, se construyó un

pórtico a escala real y se fue cargando gradualmente hasta llegar a su capacidad máxima, luego se instaló un extensómetro SC1 en la parte superior izquierda de la viga para medir las rotaciones, otro extensómetro SC2 en la parte inferior a la mitad de la luz, y un tercer extensómetro SC3 a 1/3 de la luz; estos dos últimos para medir los desplazamientos verticales. Los valores obtenidos durante el ensayo permitieron construir una base de datos con 110 ejemplos, de las cuales el 70% se utilizó para el entrenamiento y el 30% para la validación y prueba. La red neuronal artificial estuvo construida con una capa de entrada con 4 neuronas, una capa oculta de 20 neuronas, y una capa de salida con 3 neuronas. Se utilizaron como variables de entrada los desplazamientos verticales y las rotaciones. La RNA predijo los esfuerzos de tensión en la superficie del concreto SC1, SC2 y SC3 con un error máximo de 11,1%, 12,7% y 27,5% y un R^2 de 0,9994, 0,9993 y 0,9692, respectivamente. Los esfuerzos en el acero SR1, SR2 y SR3 tuvieron un error máximo de 12,1%, 28,7% y 12,4% con un R^2 de 0,9994, 0,9636 y 0,9992, respectivamente. Con estos resultados se puede observar que la RNA predijo los esfuerzos de tensión, tanto del acero como el concreto con precisión.

3.3 Redes neuronales aplicadas al diseño de puentes de concreto armado

Se encontró un estudio sobre la aplicación de Perceptrón Multicapa para el diseño de puentes [18] donde se propone optimizar el diseño de puentes postensados de tipo Box Girder, considerando el costo, la seguridad y el tiempo de iniciación de la corrosión del acero, dicho puente estaba compuesto de tres vanos, el vano principal tiene una longitud de 44 metros y los vanos externos 35,2 metros, a partir del cual se generaron 34 variables definidas por la geometría longitudinal (2), geometría de la sección transversal (9), concreto (3), el acero de refuerzo (11), y el acero postensado del puente (9). Para la construcción del conjunto de datos fueron utilizados 4500 ejemplos, de las cuales el 70% se usaron para el entrenamiento, el 15% para la validación y el 15% para la prueba. Para el entrenamiento se utilizó el algoritmo de backpropagation de Levenberg-Marquardt con el que se obtuvieron buenos resultados, lográndose un R^2 entre 0,912 y 0,999 y el ECM toma valores entre 0,0001 y 0,088. Estos resultados indican que la RNA es una buena herramienta para predecir la respuesta de las estructuras, reducir el tiempo en el que se obtienen los resultados, tener soluciones menos costosas, sin descuidar los niveles de seguridad y la durabilidad considerados para un proyecto de construcción.

3.4 Redes neuronales artificiales para predecir las propiedades del suelo

3.4.1 Parámetros de compactación y CBR del suelo

Se han encontrado 11 estudios sobre la aplicación de las redes neuronales en la mecánica de suelos, en su mayoría para predecir las propiedades mecánicas de los suelos a partir de sus propiedades físicas. En [19] se aplicó un Per-

ceptrón Multicapa para la predicción de la Relación de Soporte de California (CBR) de Subbase del pavimento usando datos de las propiedades físicas del suelo. En esta investigación se examina la capacidad de las RNA para desarrollar una correlación entre el CBR de la subbase y los datos primarios del suelo, lo que podría ayudar a estimar el CBR con fines de predicción y para identificar la importancia de cada propiedad física con respecto a la resistencia de la subbase. El ECM fue muy aceptable, alcanzando aproximadamente un 4,3% y la media del error porcentual fue inferior al 5%. Según los resultados se determinó que las propiedades que más influyen en los valores de CBR son las sales solubles, ocupando el primer lugar, con una importancia relativa del 39,46%, mientras que el índice de yeso ocupa el segundo lugar, con un 9,83%, y la máxima densidad seca (MDD) ocupa el tercer lugar, con un 6,68%.

Otro tipo de modelos de redes neuronales es el Grupo de Manejo de Datos (GMDH), usado para estimar los parámetros de compactación como la máxima densidad seca (γ_d máx), el óptimo contenido de humedad ($w_{\text{ópt}}$) de los suelos de forma indirecta a partir de las propiedades físicas determinadas de forma más sencilla como el límite líquido (LL), el límite plástico (LP) y el contenido de grano fino (FC), así como el contenido de arena (SC). Se utilizó una base de datos que contenía 212 ejemplos para el entrenamiento de la RNA. Luego de varios experimentos se determinó la mejor arquitectura con 4 neuronas en la capa de entrada, 2 neuronas en la capa oculta y una neurona en la capa de salida. Se compararon los parámetros de compactación medidos experimentalmente con las predicciones para evaluar el rendimiento de GMDH. Los resultados muestran que las redes neuronales de tipo GMDH generalizado tiene una gran capacidad para la predicción de la máxima densidad seca y el óptimo contenido de humedad. Se realizó un análisis de sensibilidad del modelo obtenido para estudiar la influencia de los parámetros de entrada en los resultados del modelo, y se muestra que LL y LP son las variables más influyentes en los parámetros de compactación. Asimismo, se demostró que los modelos propuestos son más precisos en comparación con todas las demás correlaciones empíricas [20].

En [21] se utilizó Perceptrón Multicapa para predecir la relación de las características de compactación, permeabilidad y resistencia al corte del suelo con las propiedades físicas del suelo. En este estudio, la base de datos de 580 ejemplos fue construida a partir de otras investigaciones disponibles, con resultados de ensayos como la granulometría, límites de Atterberg, compactación, permeabilidad medida a diferentes niveles de grado de compactación (90-100%) y pruebas de compresión triaxial con drenaje consolidado. Para evaluar el efecto de cada parámetro geotécnico sobre los resultados, se hizo un análisis de sensibilidad. Según este análisis los límites de Atterberg y el contenido de finos del suelo (limo y arcilla) son las variables más importantes para predecir la máxima densidad seca y el óptimo contenido de humedad. Otro aspecto que es coherente con el análisis de sensibilidad es el coeficiente de permeabilidad, el cual influye en el grado de compactación de los suelos. Asimismo, se observó que el

ángulo de fricción depende en gran medida de la densidad del suelo. Para evaluar el rendimiento de los modelos de predicción, se utilizaron tres enfoques estadísticos como el R^2 , la RMSE, y el coeficiente de masa residual. La comparación de los resultados demuestra que la RNA proporciona predicciones muy precisas y se pueden mejorar con el aumento de ejemplos en la base de datos. Los datos indican que las predicciones están dentro de un intervalo de confianza del 95%, siendo una de las principales fortalezas de la red neuronal su capacidad de mejorar a medida que más datos se hagan disponibles sin repetir los procedimientos de desarrollo desde el principio.

De otra parte, se halló un estudio que compara el Perceptrón Multicapa y red neuronal con enjambre de partículas [22], para medir las propiedades geotécnicas de la turba mezclada con diferentes proporciones de cemento. Los resultados indican que la resistencia a la compresión no confinada y el CBR de las muestras tratadas con cemento de 300 kg/m³ aumentaron solamente en un factor de 8,54 y 13,66, en comparación con la turba sin tratar. En las pruebas de compactación se observó que la máxima densidad seca aumentó significativamente, por ello los resultados indicaron que el Perceptrón Multicapa logró mejores resultados que la red neuronal con enjambre de partículas. Así mismo los resultados del análisis de sensibilidad mostraron que el relleno y el tiempo de curado fueron los factores más influyentes en la estimación de la resistencia a la compresión no confinada.

Existen otros estudios similares que permiten predecir la máxima densidad seca, el óptimo contenido de humedad y el CBR de los suelos, para ello fueron comparados Perceptrón Multicapa, ANFIS, SVM, ANN-BBO, esta última muestra mejores resultados de 0,965 de R^2 [24], [25] y [26]. En [23] se utiliza la regresión lineal para predecir la máxima densidad seca y el óptimo contenido de humedad, logrando un coeficiente de determinación de 0,841, lo que demuestra que la técnica no es eficiente. En [27] se propusieron cuatro modelos de Perceptrón Multicapa para predecir el CBR bajo diferentes condiciones, se encontró que la RNA es muy sensible en las capas de entrada, vinculadas a las variables de la cal y la microsilíce. Asimismo, en [24] y [26] se estima los valores de CBR utilizando simplemente datos obtenidos de ensayos básicos de suelos, estos estudios han llegado a la conclusión de que los valores de CBR estimados fueron muy similares a los reales. En el caso de los estudios enfocados a estimar los parámetros de compactación, también se han obtenido resultados fiables con la RNA de tipo GMDH, que predice mejor los parámetros de compactación en comparación con las correlaciones empíricas [28].

3.4.2 Porosidad

Fue utilizado un Perceptrón Multicapa para identificar los parámetros medios de la porosidad [29] los resultados revelan que no existe linealidad entre la dependencia de la distribución en el sistema de ecuaciones a macro escala de la porosidad, por lo que la RNA es la única capaz de resolver este problema. Esta investigación proporciona una base para aplicar RNA al crecimiento multi escala y reordenamiento de

las características microestructurales debido a la respuesta mecánica e hidráulica de los suelos a macro escala.

3.4.3 Estabilidad de taludes

La predicción del factor de seguridad de la estabilidad de taludes sísmicos se realizó mediante la comparación de modelos de enjambres de partículas y redes neuronales del tipo Perceptrón Multicapa con 6 neuronas en la capa de entrada, 10 neuronas en la capa oculta, y una neurona en la capa salida. Para ello, se usaron 669 ejemplos obtenidos de un programa de geo estudio basado en el método de equilibrio límite. El conjunto de datos consideró como variables a la altura de pendiente, el gradiente, la cohesión, el ángulo de fricción y la aceleración máxima del suelo. Después del entrenamiento y la prueba, la RNA obtuvo un R^2 de 0,915, mientras que el enjambre de partículas logró 0,986 [30].

3.4.4 Consolidación

Para estimar la presión previa a la consolidación del suelo, fueron comparadas la metodología tradicional de Casa Grande (CG) y un Perceptrón Multicapa implementado en "Neural Network Toolbox de MATLAB". La RNA fue desarrollada con 05 neuronas en la capa de entrada, 03 capas ocultas de 03 neuronas cada una, y una neurona en la capa de salida. Los resultados del estudio muestran que el error de la RNA es 0,032%, mientras que la CG de 9,658%, por lo que se evidencia que la RNA predice con mejor precisión la relación de vacíos correspondiente a la tensión previa a la consolidación, por lo que no requiere dibujo y menos intervención manual [31].

3.5 Redes neuronales artificiales aplicadas al análisis sísmico

Las RNA también fueron aplicadas en el diseño sísmico de edificaciones de concreto armado. En [32] fueron comparados dos modelos de Perceptrón Multicapa. El primer modelo (PM1) conformado por 05 neuronas en la capa de entrada, 21 neuronas en la capa oculta y 26 neuronas en la capa de salida, mientras que el segundo modelo (PM2) estuvo conformado por 5 neuronas en la capa de entrada, 25 neuronas en la capa oculta y 24 neuronas en la capa de salida, con las cuales se trató de predecir la geometría de vigas y columnas, la cantidad de acero de refuerzo longitudinal, y la separación de los estribos. La PM1 fue entrañada con base en las características de 50 diseños de edificios de 8 a 12 niveles. La PM2 fue entrañada con base en las características de 40 diseños de edificios de 4 a 7 niveles. El conjunto de datos incorporó variables como el número de grillas en la dirección X, número de grillas en la dirección Y, el número de niveles, el espaciamiento entre grillas en ambas direcciones. Las RNA lograron un error máximo de 15%, ofreciendo ventajas en cuanto a rapidez para la predicción del diseño estructural en comparación con métodos clásicos que utilizan mucho más tiempo.

En el trabajo [33] logical analysis of data (LAD se compara la técnica de aprendizaje de Análisis lógico de datos y una red neuronal profunda de 13 neuronas en la capa de

entrada, 8 neuronas en la primera capa oculta, 4 neuronas en la segunda capa oculta, 7 neuronas en la tercera capa oculta y 7 neuronas en la capa de salida, para la predicción de la respuesta sísmica de las estructuras de edificios. Para la construcción del conjunto de datos se utilizaron como atributos la aceleración máxima del suelo, el tipo de suelo, el período característico, magnitud, distancia entre el lugar y la fuente, y el período natural. La RNA profunda demostró ser más efectiva logrando una correlación de 0,84, con lo cual demostró ser una técnica muy eficiente para aprender, simular y predecir el comportamiento sísmico de las estructuras.

En [34] se usaron un total de 13.552 registros de movimiento del suelo a partir de 288 terremotos publicados por el Centro de Investigación de Ingeniería del Pacífico (PEER). El conjunto de datos consideró atributos como la magnitud del momento, mecanismo de falla, la distancia más cercana al plano de falla y la velocidad de onda de corte. Con base en el conjunto de datos se utilizó un Perceptrón Multicapa para estimar los parámetros de una ecuación de predicción del movimiento del suelo. Los parámetros estimados fueron la aceleración máxima del suelo, la velocidad máxima del suelo, la aceleración espectral para un 5% de amortiguación para 26 periodos entre 0,01 y 4 segundos. La RNA fue construida con 5 neuronas en la capa de entrada, 5 neuronas en la capa oculta y 28 neuronas en la capa de salida, lográndose buenos resultados.

En [35] se desarrolló una red neuronal profunda con 8 neuronas en la capa de entrada, 06 capas ocultas con 30, 35, 30, 12, 8, 4 neuronas, respectivamente y una neurona en la capa de salida, para predecir la aceleración espectral del suelo, superando al modelo clásico CB-2008 del proyecto Next Generation Attenuation (NGA) del PEER. Los resultados de esta investigación indicaron que la RNA profunda predice la aceleración espectral con una precisión del 96,26%, superando al modelo CB-2008 que alcanzó una precisión del 91,93%.

En [36] se investigó el potencial de una red convolucional estándar de 24 capas y una red convolucional autoencoder para ayudar a la simulación sísmica. Durante el desarrollo se evidenció que ambas redes son de 20 a 500 veces más rápidas que el modelado por diferencia finitas (FD) y simulan de ondas sísmicas en medios acústicos 2-D con fallas y capas horizontales, demostrando que estas redes se pueden utilizar para realizar inversiones sísmicas rápidas de un mismo medio.

3.6 Redes neuronales artificiales aplicadas en hidráulica

3.6.1 Cálculo de la profundidad de socavación

La predicción precisa de la profundidad de socavación desempeña un papel muy importante en el óptimo diseño de las estructuras, siguiendo este lineamiento, en [37] usaron datos experimentales recopilados de diferentes estudios para desarrollar un modelo que permita predecir la profundidad de socavación debajo de un vertedero

con salto de esquí. Este trabajo desarrolló un Perceptrón Multicapa, algoritmos de optimización de Harry Hawkins, enjambre de partículas, algoritmo genético para luego ser comparado con el método tradicional empírico WU. Los resultados muestran que los algoritmos de optimización de Harry Hawkins obtuvieron valores más precisos.

En [38] se implementó en MATLAB Perceptrón Multicapa (PM) con los algoritmos de minimización del error de Levenberg-Marquardt (PM-LM), Firefly algorithm (PM-FA) y particle swarm optimization (PM-PSO) para predecir la profundidad de socavación alrededor de los pilares de un puente. Los resultados muestran un R para PM-LM de 0,930, PM-FA de 0,958, PM-PSO de 0,987, demostrándose que las estimaciones de la RNA de las profundidades máximas de socavación se asemejan a los valores reales. Asimismo, se recomienda que los modelos tradicionales deben ser reemplazados por los modelos de RNA, los cuales ya han sido ampliamente adoptados para fines de predicción en otras áreas.

3.6.2 Cálculo del coeficiente de descarga

Una segunda aplicación de las redes neuronales es la predicción del coeficiente de descarga en vertederos trapezoidales, en [39] se comparó el desempeño del Perceptrón Multicapa (PM), red neuronal de base radial (RBR) y máquinas de soporte vectorial (SVM), para lo cual utilizaron 454 ejemplos obtenidos de laboratorio. Las predicciones hechas por el Perceptrón Multicapa fueron las más precisas, puesto que los valores se asemejan muy bien a los datos obtenidos de manera experimental. La PM obtuvo un RMSE de 0,019, con un R^2 de 0,985, frente a 0,934 de la RBR y 0,978 de la SVM.

En [40] se compararon 3 modelos de red neuronal, RNA ANFIS estándar con RNA ANFIS híbridas como Namely Differential Evaluation (ANFIS-DE), Genetic Algorithm (ANFIS-GA), Particle Swarm Optimization (ANFIS-PSO) para predecir el coeficiente de descarga en un vertedero lateral. Los resultados muestran que el método ANFIS estándar tiene un mayor rendimiento cuando se utilizan variables de entrada más simples, sin embargo, ANFIS-DE obtuvo un RMSE de 0,077, demostrando mayor rendimiento que ANFIS-GA y ANFIS-PSO, que obtuvieron un RMSE de 0,079 y 0,096, respectivamente.

3.6.3 Precipitaciones

En [41] se utilizaron datos de 14 estaciones de medición de caudal, ubicados en la península de España, para estimar la precipitación máxima instantánea mediante la aplicación de Perceptrón Multicapa (PM), método empírico basado en la ecuación de Fuller (MEF) y una RNA ANFIS. Los resultados muestran que el R^2 del PM es de 0,88; de ANFIS es de 0,98 y de MEF es de 0,95; sin embargo, el número de estaciones no son suficientes por lo que se recomendó la implementación de más estaciones en la península española, de esta manera se puede mejorar aún más la precisión del modelo.

3.6.4 Encausamiento de inundaciones

Las redes neuronales también se han aplicado en la predicción de encausamiento de inundaciones, en [42] se utilizaron 8 diagramas de inundaciones, de las cuales 6 fueron utilizadas para la etapa de entrenamiento y 2 en la etapa de prueba. Se desarrollaron dos modelos, una red neuronal Perceptrón Multicapa y una RNA ANFIS. La PM obtuvo un RMSE de 3,01 frente al RMSE de la ANFIS de 0,3; demostrándose claramente la superioridad de la ANFIS. El hidrograma de inundación utilizado como base para el análisis abarcó un periodo de devolución de 10.000 años.

3.6.5 Cálculo de la filtración y estabilidad de presas

En [43] se mejoró la predicción de filtración de presas utilizando una combinación de RNA Perceptrón Multicapa con algoritmo genético. Para ello, se tomaron dos puntos en la presa, las cuales permitieron observar las líneas de filtración. Los resultados demuestran que el modelo propuesto logró una MSE de 0,0202 frente a los métodos estadísticos tradicionales que obtuvieron un MSE de 0,0392, demostrando que el método propuesto es bueno para predecir la tendencia de los cambios que hay en los datos.

En [44] se planteó predecir la estabilidad de presas heterogéneas utilizando un Perceptrón Multicapa con 6 neuronas en la capa de entrada, 10 neuronas en la capa oculta y una neurona en la capa de salida. El conjunto de datos poseía 739 ejemplos, a partir del cual se utilizó el 60% para el entrenamiento y el 40% para la validación. Así mismo se encontró que todos los atributos del conjunto de datos tuvieron una influencia de 20% aproximadamente durante el entrenamiento. Según los resultados la RNA alcanzó una correlación de predicción de 0,955.

3.6.6 Cálculo de la demanda de agua

En [45] se utilizó un Perceptrón Multicapa para pronosticar la demanda de agua potable en la ciudad de Lambayeque, Perú. La RNA estuvo conformada por 12 neuronas en la capa de entrada, 9 neuronas en la capa oculta, y una neurona en la capa de salida. El conjunto de datos estuvo conformado por 252 ejemplos con 12 atributos cada uno. Los resultados muestran un R de 0,98643 por lo que se puede concluir que es viable el uso de RNA para predecir demanda de agua en una ciudad.

3.7 Redes neuronales artificiales aplicadas a la valorización de inmuebles

Para la valorización de inmuebles se encontraron 7 investigaciones donde se aplicaron modelos de RNA. En [46] utilizaron datos de valorizaciones recopilados de diversas investigaciones para desarrollar un modelo de RNA del tipo Perceptrón Multicapa. Estos modelos permitieron realizar los procesos de valorización de manera automática. Además, se encontró que existía una gran desconexión entre

las leyes estándares de tasación y la comunidad financiera para la valorización de inmuebles, por lo que se debe utilizar varios criterios de consenso para comprender mejor y potencialmente seleccionar las RNA.

En el trabajo [47] se hace una revisión de la literatura sobre el uso de las redes neuronales artificiales en especial el Perceptrón Multicapa en la predicción de la valorización de inmuebles y abarca desde el año 1991 hasta el 2015, periodo en el que se publicaron 30 artículos científicos que demuestran buenos resultados de la RNA frente a los métodos tradicionales.

Para la estimación del precio de las viviendas aplicando redes neuronales artificiales también han sido objeto de estudio, en [48] se busca sustituir los modelos tradicionales como el análisis de regresión múltiple por RNA de tipo Perceptrón Multicapa de 6 neuronas en la capa de entrada, 6 neuronas en la capa oculta y una neurona en la capa de salida, logrando un error global de 0,2. Del mismo modo en la investigación [49] desarrollaron un Perceptrón Multicapa de 6 neuronas en la capa de entrada, 4 neuronas en la capa oculta y una neurona en la capa de salida para estimar los precios de diversos inmuebles en Portugal, los resultados indicaron que el error relativo es de 0,1141 y la precisión de los resultados dados por la red neuronal artificial fue de un 12% superior en comparación con los métodos tradicionales.

La comparativa entre modelos de regresión multivariable y las RNA Perceptrón Multicapa es muy común. En [50] se compararon la efectividad de la RNA de 13 neuronas en la capa de entrada, 16 en la capa oculta y una neurona en la capa de salida, para predecir la valorización de inmuebles urbanos. Los resultados indicaron que la RNA tuvo un R^2 de 0,98 y R^2 0,97, superando así a los modelos de regresión lineal múltiple en un 3% de R, y un 7% de R^2 . Los autores llegaron a la conclusión de que los modelos de RNA superan a los modelos de regresión por que estiman con más precisión las valorizaciones de los inmuebles.

En [51] se utilizó aprendizaje supervisado con un Perceptrón Multicapa con 7 neuronas en la capa de entrada, 15 en la capa oculta y una neurona en la capa de salida para predecir el precio de los inmuebles en la ciudad de Morelia, México. Los resultados muestran un R^2 de 0,93 y errores absolutos medios muy bajos, se concluye que las RNA predicen de forma más precisa los precios de los inmuebles en comparación con los métodos tradicionales. Así mismo, en [52] se busca obtener un modelo basado en Perceptrón Multicapa de 5 neuronas en la capa de entrada, 6 neuronas en la capa oculta y una neurona en la capa de salida, para predecir el precio mensual de alquiler de manera automatizada en la ciudad de Córdoba, España. Los resultados muestran un R de 0,9352, con lo que se concluyó que las RNA predicen el precio del inmueble de acuerdo con la realidad del mercado.

De acuerdo con la revisión presentada, se observa un uso intensivo de las RNA en el campo de la ingeniería civil, en diversas áreas de aplicación como propiedades del con-

creto, propiedades del suelo como se muestra en la Tabla II. También son aplicadas en análisis sísmico, hidráulica, valo-

rización de inmuebles y diseño de puentes como se muestra en la Tabla III.

TABLA II.
MODELOS DE RNA UTILIZADOS EN PROPIEDADES DEL CONCRETO Y DEL SUELO EN LA LITERATURA CIENTÍFICA

Ámbito de aplicación	Modelo de RNA	Arquitectura	Objetivo de la aplicación	Función de activación	Resultado	Autor
Propiedades del concreto	Perceptrón Multicapa	6-9-3-2-1	Predcir la resistencia a la compresión del concreto con caucho	Log-Sigmoid	MSE = 4,80 (E) MSE = 3,78 (P)	[10]
		6-20-1 6-15-1	Predcir la resistencia a la compresión y flexión del concreto con fibras de acero	Log-Sigmoid	MSE = 0,0876 (E) MSE = 0,0980 (P) MSE = 0,1492 (E) MSE = 0,0376 (P)	[11]
		11-10-4-1	Predcir la resistencia a la compresión del concreto	Tangente hiperbólica sigmoidea	Error = 3,29%	[12]
		5-10-14-12-6-1-1	Predcir la resistencia a la compresión del concreto	Tangente hiperbólica	R = 0,9176	[13]
		4-40-1	Predcir la resistencia a la compresión y módulo elástico del concreto	Sigmoide	R ² = 0,9984 (E) R ² = 0,9940 (P) R ² = 0,9999 (E) R ² = 0,9940 (P)	[14]
		2-15-10-1 3-8-12-1	Predcir la resistencia a la compresión y la resistividad eléctrica del concreto	No detalla	R ² = 0,7027 R ² = 0,4281	[15]
		4-20-1	Predcir los esfuerzos del concreto y acero	Tangente hiperbólica	R ² = 0,9994 R ² = 0,9993 R ² = 0,9692 R ² = 0,9994 R ² = 0,9636 R ² = 0,9992	[17]
	ANFIS	6-1	Predcir la resistencia al fuego del concreto	Pertenencia gaussiana	Error = 0,319 (E) Error = 0,511 (V) Error = 0,245 (P)	[16]
Propiedades del suelo	Perceptrón Multicapa	15-11-1	Predcir el CBR del suelo	Tangente hiperbólica	MSE = 4,3%	[19]
	GMDH	4-2-1	Predcir los parámetros de compactación del suelo	No detalla	No detalla	[20]
	Perceptrón Multicapa	6-9-10-1-1	Predcir los parámetros de compactación del suelo	No detalla	No detalla	[21]
	Perceptrón Multicapa Enjambre de partículas	5-12-1	Predcir la resistencia a la compresión inconfiada del suelo	Log-Sigmoid	No detalla	[22]
	Perceptrón Multicapa ANFIS, SVM, ANN-BBO	13-7-1	Predcir el coeficiente de consolidación del suelo	No detalla	R ² = 0,965	[24]
	Perceptrón Multicapa	8-10-10-10-2	Predcir los parámetros de compactación y CBR del suelo	Log-Sigmoid	No detalla	[25]
	Perceptrón Multicapa	5-5-8-1(UCS) 4-2-3-1(CBR10) 4-2-3-1(CBR30) 4-5-1(CBR65)	Predcir la resistencia a la compresión inconfiada y el CBR del suelo	Tangente sigmoidea	No detalla	[27]
	GMDH	7-10(6)-1	Predcir el CBR del suelo	Tangente sigmoidea	No detalla	[28]
	Perceptrón Multicapa	200(3)- 1	Predcir la porosidad	Relu	No detalla	[29]
	Perceptrón Multicapa, Enjambre de partículas	6-10-1	Predcir la estabilidad de taludes	No detalla	R ² = 0,915 R ² = 0,986	[30]
	Perceptrón Multicapa	5-3-3-3-1	Predcir la relación de vacíos correspondiente a la tensión previa a la consolidación	No detalla	Error = 0,032%	[31]

Fuente: Los autores

TABLA III.

MODELOS DE RNA UTILIZADOS EN ANÁLISIS SÍSMICO, HIDRÁULICA, VALORIZACIÓN DE INMUEBLES Y DISEÑO DE PUENTES EN LA LITERATURA CIENTÍFICA

Ámbito de aplicación	Modelo de RNA	Arquitectura	Objetivo de la aplicación	Función de activación	Resultado	Autor
Análisis sísmico	Perceptrón Multicapa	5-21-26 5-25-24	Predcir las dimensiones de los elementos estructurales	Sigmoide	Error máx = 15%	[32]
	DNN	13-8-4-7-7	Predcir la respuesta sísmica de las estructuras	No detalla	R = 0,84	[33]
	Perceptrón Multicapa	5-5-28	Predcir el movimiento del suelo	Sigmoide	No detalla	[34]
	DNN	8-30-35-30-12-8-4-1	Predcir la aceleración espectral	ReLU, Softmax y Sigmoide	Precisión = 96,26%	[35]
	CNN	24 capas conv.	Hacer simulaciones sísmicas	Relu	No detalla	[36]
Hidráulica	Perceptrón Multicapa		Predcir la profundidad de socavación	No detalla	MAE = 0,176	[37]
	Perceptrón Multicapa		Predcir la profundidad de socavación	No detalla	R = 0,930	[38]
	Perceptrón Multicapa		Predcir el coeficiente de descarga	No detalla	R = 0,985 RMSE = 0,019	[39]
	ANFIS	8-6-6-1	Predcir el coeficiente de descarga de un vertedero lateral	No detalla	R ² = 0,8488 RMSE = 0,096	[40]
	Perceptrón Multicapa ANFIS		Predcir la precipitación máxima	No detalla	R ² máx. = 0,88 R ² máx. = 0,98	[41]
	Perceptrón Multicapa	4-5-1	Predicción de encausamiento de inundaciones	TanhAxon	RMSE = 3,01 RMSE = 0,30	[42]
	Perceptrón Multicapa		Predicción de filtración de presas		MSE = 0,0202 ~ 0,0339	[43]
	Perceptrón Multicapa	6-10-1	Predicción de la estabilidad de presas	Tangente hiperbólica	Predicción = 95,5%	[44]
	Perceptrón Multicapa	12-9-1	Predcir la demanda de agua potable	Sigmoide	R = 0,98643	[45]
Valorización de inmuebles	Perceptrón Multicapa		Predcir la valorización de un inmueble	No detalla	No detalla	[46]
	Perceptrón Multicapa		Modelar el mercado residencial nigeriano	No detalla	No detalla	[47]
	Perceptrón Multicapa	6-6-1	Predicción del precio de las viviendas	Sigmoide	Error = 20%	[48]
	Perceptrón Multicapa	6-4-1	Predicción del precio de los inmuebles de Portugal	Tangente hiperbólica	Error relativo = 0,1141	[49]
	Perceptrón Multicapa	13-16-1	Predcir la valorización de inmuebles en México	Sigmoide	R = 0,98	[50]
	Perceptrón Multicapa	7-15-1	Predcir el precio de los inmuebles	Tangente hiperbólica	R ² = 0,93	[51]
	Perceptrón Multicapa	5-6-1	Predcir el precio mensual de alquiler de manera automatizada	Logística	R = 0,9352	[52]
Diseño de puentes de concreto armado	Perceptrón Multicapa	34-10-1	Optimizar el diseño de puentes postensados	Sigmoide	MSE = 0,0001 ~ 0,088	[18]

Fuente: Los autores

4. DISCUSIÓN Y CONCLUSIONES

Las RNA son aplicadas en seis campos específicos de la ingeniería civil, desde el año 2007 hasta el 2020 se publicaron 8 aplicaciones de RNA para propiedades del concreto,

11 para propiedades del suelo, 5 para análisis sísmico, 9 para hidráulica, 7 para valorización de inmuebles y 1 para diseño de puentes, lo que implica que la técnica es muy interesante para los investigadores del área, esto se debe a la facilidad en su implementación y los tiempos de res-

puesta cortos a diferencia de los métodos tradicionales, así mismo la facilidad de utilizar registros con datos faltantes o con ruido para lograr una baja tasa de error influye en la elección como una buena opción para ser utilizado en predicción. En este trabajo se evidencia la importancia de las RNA en la ingeniería civil por su efectividad debido a que son capaces de aprender en entornos complejos. Un factor resaltante de las RNA es que el conjunto de datos no necesita tener una rigurosa organización previa, pues las RNA representan dicha organización durante el entrenamiento. Según los resultados de esta investigación se observa que las RNA superan en efectividad y rapidez a los métodos tradicionales, por su capacidad de adaptación y la tolerancia al fallo. Un factor importante para obtener buenos resultados con las RNA es la selección de los atributos del conjunto de datos, estos deberán representar el dominio de aplicación de modo que los valores correspondan a las variables de estudio directas. También se observa que las RNA de arquitectura sencilla generan buenos resultados, como es el Perceptrón Multicapa, al ser económicas en términos de costo computacional, es por ello que la mayoría de las aplicaciones utilizan este modelo de RNA con algunas mejoras que se logran combinando o seleccionando algoritmos de minimización de error.

En definitiva, las RNA son de vital importancia en la ingeniería civil debido a todas las ventajas ya expuestas en comparación con los métodos tradicionales, los investigadores, ingenieros y empresas deberán invertir tiempo y recursos para aprovechar estas ventajas, pues a pesar de que no es una técnica nueva, no se aprovecha al máximo en aplicaciones críticas de la ingeniería civil. Es importante destacar la enorme necesidad de seguir investigando y aplicando en diversos problemas de predicción y clasificación donde la ingeniería civil requiere de técnicas avanzadas.

5. REFERENCIAS

- [1] I. Taleb-Bahmed, K. Harichane, M. Ghrici, B. Boukhatem, R. Rebouh, y H. Gadouri, «Prediction of geotechnical properties of clayey soils stabilised with lime using artificial neural networks (ANNs)», *Int. J. Geotech. Eng.*, 2017, DOI: 10.1080/19386362.2017.1329966
- [2] S. Khuntia, H. Mujtaba, C. Patra, K. Farooq, N. Sivakugan, y B. M. Das, «Prediction of compaction parameters of coarse grained soil using multivariate adaptive regression splines (MARS) [Predicción de los parámetros de compactación del suelo de grano grueso utilizando líneas de regresión adaptativa multivariable (MARS)]», *Int. J. Geotech. Eng.*, vol. 9, n.o 1, 2015, DOI: 10.1179/1939787914Y.0000000061
- [3] Y. Erzín y D. Turkoz, «Use of neural networks for the prediction of the CBR value of some Aegean sands [Uso de redes neuronales para la predicción del valor de CBR de algunas arenas del Egeo]», *Neural Comput. Appl.*, vol. 27, n.o 5, pp. 1415-1426, 2016, DOI: 10.1007/s00521-015-1943-7
- [4] A. Ghorbani y H. Hasanzadehshooili, «Prediction of UCS and CBR of microsilica-lime stabilized sulfate silty sand using ANN and EPR models; application to the deep soil mixing», *Soils Found.*, vol. 58, n.o 1, pp. 34-49, 2018, DOI: 10.1016/j.sandf.2017.11.002
- [5] D. C. Ramírez-González, G. Pulido-Sarmiento, B. Gerardino-Arévalo, J. M. Cruz-Romero, E. Estupiñán-Escalante, y S. Cancino-Suárez, «Adquisición y reconocimiento de imágenes por medio de técnicas de visión e inteligencia artificial», *Iteckne*, vol. 6, n.o 1, pp. 5-13, 2009, DOI: 10.15332/iteckne.v6i1.290
- [6] F. Isik y G. Ozden, «Estimating compaction parameters of fine- and coarse-grained soils by means of artificial neural networks», *Environ. Earth Sci.*, vol. 69, n.o 7, pp. 2287-2297, 2013, DOI: 10.1007/s12665-012-2057-5
- [7] D. Alemán-Morales, «Técnicas de inteligencia artificial aplicadas a problemas de ingeniería civil», *UNICA*, vol. 6, n.o 9, pp. 164-175, 2017.
- [8] J. B. Medeiros, *Escritura científica: la práctica de la fichamentos, resúmenes, comentarios*, 5ta ed. Sao Paulo: Atlas, 2003.
- [9] A. C. Gil, *Cómo elaborar proyectos de investigación*, 5ta ed. Sao Paulo: Atlas, 2010.
- [10] M. Hadzima-Nyarko, E. K. Nyarko, N. Ademović, I. Miličević, y T. K. Šipoš, «Modelling the influence of waste rubber on compressive strength of concrete by artificial neural networks», *Materials (Basel)*, vol. 12, n.o 2, 2019, DOI: 10.3390/ma12040561
- [11] D. Qu, X. Cai, y W. Chang, «Evaluating the effects of steel fibers on mechanical properties of ultra-high performance concrete using artificial neural networks», *Appl. Sci.*, vol. 8, n.o 7, 2018, DOI: 10.3390/app8071120
- [12] M. H. Díaz-Tello, «Uso de las redes neuronales artificiales en el modelado del ensayo de resistencia a compresión de concreto de construcción según la norma ASTM C39/C 39M (Tesis de grado)», Universidad Nacional de Cajamarca, 2017.
- [13] M. A. Villegas-Effio, «Aplicación de redes neuronales para la predicción de la resistencia a la compresión del concreto según el ensayo de esclerometría (Tesis de grado)», Universidad Peruana de Ciencias Aplicadas, 2020.
- [14] Z. Duan, S. Hou, C. S. Poon, J. Xiao, y Y. Liu, «Using neural networks to determine the significance of aggregate characteristics affecting the mechanical properties of recycled aggregate concrete», *Appl. Sci.*, vol. 8, n.o 11, 2018, DOI: 10.3390/app8112171
- [15] M. J. Marriaga-Lizarazo y G. J. Cortés-Gómez, «Desarrollo de un modelo de redes neuronales artificiales para predecir la resistencia a la compresión y la resistividad eléctrica del concreto», *Rev. Ing. E Investig.*, vol. 27, n.o 1, pp. 11-18, 2007.
- [16] M. Lazarevska, A. T. Gavriloska, M. Laban, M. Knezevic, y M. Cvetkovska, «Determination of fire resistance of eccentrically loaded reinforced concrete columns using fuzzy neural networks», *Complexity*, vol. 2018, 2018, DOI: 10.1155/2018/8204568
- [17] M. Vafaei, S. C. Alih, H. Shad, A. Falah, y N. H. F. A. Halim, «Prediction of strain values in reinforcements and concrete of a RC frame using neural networks», *Int. J. Adv. Struct. Eng.*, vol. 10, n.o 1, 2018, DOI: 10.1007/s40091-018-0178-0
- [18] T. García-Segura, V. Yepes, y D. M. Frangopol, «Multi-objective design of post-tensioned concrete road bridges using artificial neural networks», *Struct. Multidiscip. Optim.*, vol. 56, n.o 1, 2017, DOI: 10.1007/s00158-017-1653-0
- [19] S. Al-Busultan, G. K. Aswed, R. R. A. Almuhanha, y S. E. Rasheed, «Application of Artificial Neural Networks in Predicting Subbase CBR Values Using Soil Indices Data [Aplicación de redes neuronales artificiales en la predicción de valores de CBR de Subbase usando datos Índices de Suelo]», en *IOP*

- Conference Series: Materials Science and Engineering*, 2020, vol. 671, n.o 1, DOI: 10.1088/1757-899X/671/1/012106
- [20] A. Ardakani y A. Kordnaei, «Soil compaction parameters prediction using GMDH-type neural network and genetic algorithm [Predicción de parámetros de compactación del suelo utilizando red neuronal y algoritmo genético tipo GMDH]», *Eur. J. Environ. Civ. Eng.*, vol. 23, n.o 4, 2019, DOI: 10.1080/19648189.2017.1304269
- [21] P. Tizpa, R. Jamshidi Chenari, M. Karimpour Fard, y S. Lemos Machado, «ANN prediction of some geotechnical properties of soil from their index parameters [RNA para predecir algunas propiedades geotécnicas del suelo a partir de sus parámetros índices]», *Arab. J. Geosci.*, vol. 8, n.o 5, 2015, DOI: 10.1007/s12517-014-1304-3
- [22] A. Dehghanbanadaki, M. A. Sotoudeh, I. Golpazir, A. Keshkarbanaeemoghadam, y M. Ilbeigi, «Prediction of geotechnical properties of treated fibrous peat by artificial neural networks», *Bull. Eng. Geol. Environ.*, vol. 78, n.o 3, 2019, DOI: 10.1007/s10064-017-1213-2
- [23] V. Y. Katte, S. M. Mfoyet, B. Manefouet, A. S. L. Wouatong, y L. A. Bezeng, «Correlation of California Bearing Ratio (CBR) Value with Soil Properties of Road Subgrade Soil [Correlación del valor del Coeficiente de Soporte de California (CBR) con las propiedades del suelo de la subrasante de la carretera]», *Geotech. Geol. Eng.*, vol. 37, n.o 1, 2019, DOI: 10.1007/s10706-018-0604-x
- [24] M. D. Nguyen et al., «Soft-computing techniques for prediction of soils consolidation coefficient [Técnicas de soft-computing para la predicción del coeficiente de consolidación de los suelos]», *Catena*, vol. 195, 2020, DOI: 10.1016/j.catena.2020.104802
- [25] S. K. Alam, A. Mondal, y A. Shiuly, «Prediction of CBR Value of Fine Grained Soils of Bengal Basin by Genetic Expression Programming, Artificial Neural Network and Kriging Method [Predicción del valor de CBR de los suelos de grano fino de la cuenca de Bengala por medio de la programación de», *J. Geol. Soc. India*, vol. 95, n.o 2, 2020, DOI: 10.1007/s12594-020-1409-0
- [26] G. O. Bogado, N. A. Pintos, H. O. Reinert, y D. A. Bressan, «Correlación entre parámetros de compactación y propiedades geotécnicas en suelos tropicales misioneros», *Rev. Geol. Apl. a la Ing. y al Ambient.*, vol. 39, n.o 19, p. 26, 2017.
- [27] A. Ghorbani y H. Hasanzadehshooili, «Prediction of UCS and CBR of microsilica-lime stabilized sulfate silty sand using ANN and EPR models; application to the deep soil mixing [Predicción de UCS y CBR de arena limosa de sulfato estabilizado con microsilíce y cal utilizando modelos ANN y EPR]», *Soils Found.*, vol. 58, n.o 1, 2018, DOI: 10.1016/j.sandf.2017.11.002
- [28] T. Fikret Kurnaz y Y. Kaya, «Prediction of the California bearing ratio (CBR) of compacted soils by using GMDH-type neural network [Predicción del coeficiente de rodamiento de California (CBR) de los suelos compactados mediante el uso de la red neural tipo GMDH]», *Eur. Phys. J. Plus*, vol. 134, n.o 7, 2019, DOI: 10.1140/epjp/i2019-12692-0
- [29] H. Dehghani y A. Zilian, «Poroelectric model parameter identification using artificial neural networks: on the effects of heterogeneous porosity and solid matrix Poisson ratio», *Comput. Mech.*, vol. 66, n.o 3, 2020, DOI: 10.1007/s00466-020-01868-4
- [30] B. Gordan, D. Jahed Armaghani, M. Hajihassani, y M. Monjezi, «Prediction of seismic slope stability through combination of particle swarm optimization and neural network», *Eng. Comput.*, vol. 32, n.o 1, 2016, DOI: 10.1007/s00366-015-0400-7
- [31] M. R. Motahari, «Estimation of the Pre-Consolidation Pressure in Soils Using ANN method», *Curr. World Environ.*, vol. 11, n.o Special Issue 1(2016), 2016, DOI: 10.12944/cwe.11.special-issue1.10
- [32] J. Bojórquez Mora, D. Tolentino, S. Ruiz, y E. Bojórquez, «Diseño sísmico preliminar de edificios de concreto reforzado usando redes neuronales artificiales», *Concreto y Cem. Investig. y Desarro.*, vol. 7, n.o 2, pp. 60-78, 2016.
- [33] A. Abd-Elhamed, Y. Shaban, y S. Mahmoud, «Predicting dynamic response of structures under earthquake loads using logical analysis of data», *Buildings*, vol. 8, n.o 4, 2018, DOI: 10.3390/buildings8040061
- [34] J. Dhanya y S. T. G. Raghukanth, «Ground Motion Prediction Model Using Artificial Neural Network», *Pure Appl. Geophys.*, vol. 175, n.o 3, 2018, DOI: 10.1007/s00024-017-1751-3
- [35] A. Tahmassebi, A. H. Gandomi, S. Fong, A. Meyer-Baese, y S. Y. Foo, «Multi-stage optimization of a deep model: A case study on ground motion modeling», *PLoS One*, vol. 13, n.o 9, 2018, DOI: 10.1371/journal.pone.0203829
- [36] B. Moseley, T. Nissen-Meyer, y A. Markham, «Deep learning for fast simulation of seismic waves in complex media», *Solid Earth Discuss.*, 2019, DOI: 10.5194/se-2019-157
- [37] S. S. Sammen et al., «Enhanced artificial neural network with Harris hawks optimization for predicting scour depth downstream of ski-jump spillway», *Appl. Sci.*, vol. 10, n.o 15, 2020, DOI: 10.3390/app10155160
- [38] N. M. Dang, D. Tran Anh, y T. D. Dang, «ANN optimized by PSO and Firefly algorithms for predicting scour depths around bridge piers», *Eng. Comput.*, 2019, DOI: 10.1007/s00366-019-00824-y
- [39] R. Norouzi, R. Daneshfaraz, y A. Ghaderi, «Investigation of discharge coefficient of trapezoidal labyrinth weirs using artificial neural networks and support vector machines», *Appl. Water Sci.*, vol. 9, n.o 7, 2019, DOI: 10.1007/s13201-019-1026-5
- [40] H. Bonakdari y A. H. Zaji, «New type side weir discharge coefficient simulation using three novel hybrid adaptive neuro-fuzzy inference systems», *Appl. Water Sci.*, vol. 8, n.o 1, 2018, DOI: 10.1007/s13201-018-0669-y
- [41] P. Jimeno-Sáez, J. Senent-Aparicio, J. Pérez-Sánchez, D. Pulido-Velázquez, y J. María Cecilia, «Estimation of instantaneous peak flow using machine-learning models and empirical formula in Peninsular Spain», *Water (Switzerland)*, vol. 9, n.o 5, 2017, DOI: 10.3390/w9050347
- [42] M. R. Hassanvand, H. Karami, y S. F. Mousavi, «Investigation of neural network and fuzzy inference neural network and their optimization using meta-algorithms in river flood routing», *Nat. Hazards*, vol. 94, n.o 3, 2018, DOI: 10.1007/s11069-018-3456-z
- [43] X. Zhang, X. Chen, y J. Li, «Improving Dam Seepage Prediction Using Back-Propagation Neural Network and Genetic Algorithm», *Math. Probl. Eng.*, vol. 2020, 2020, DOI: 10.1155/2020/1404295
- [44] C. Costa Costa, «Predicción de la estabilidad de presas heterogéneas mediante redes neuronales artificiales (Tesis de maestría)», Escuela Técnica Superior de Ingeniería de Caminos, Canales y Puertos, 2016.
- [45] Y. A. Vidaurre Siadén, «Aplicación de las redes neuronales artificiales para el pronóstico de la demanda de agua potable

- en la empresa Epsel S.A. de la ciudad de Lambayque (Tesis de grado)», Universidad Católica Santo Toribio de Mogrovejo, 2012.
- [46] D. Epley, «The need to reference automatic valuation models to the valuation process», *J. Real Estate Lit.*, vol. 25, n.o 1, 2017.
- [47] R. B. Abidoye y A. P. C. Chan, «Artificial neural network in property valuation: application framework and research trend», *Property Management*, vol. 35, n.o 5. 2017, DOI: 10.1108/PM-06-2016-0027
- [48] J. M. Núñez-Tabales, J. M. Caridad y Ocerin, N. Ceular Villamondos, y A. M. Fuentes-Jiménez, «Estimación del precio de la vivienda mediante redes neuronales artificiales (RNA) en diferentes marcos temporales», *Metodol. Encuestas*, vol. 11, n.o 1, pp. 79-101, 2009, [En línea]. Disponible en: <http://casus.usal.es/pkp/index.php/MdE/article/view/994>.
- [49] M. C. Canavarró Teixeira, «Modelos econométricos para el precio de los inmuebles: Un caso de estudio en Portugal (Tesis doctoral)», Universidad de Córdoba, 2011.
- [50] J. C. Preciado Carrillo, «Valoración De Inmuebles Urbanos : Comparativa modelo regresión multivariable versus redes neuronales artificiales para la ciudad de Morelia, Michoacán, México (Tesis doctoral)», Universidad Politécnica de Valencia, 2015.
- [51] J. C. Preciado Carrillo, «Redes neuronales artificiales, una aplicación al mercado inmobiliario habitacional de segmento medio de la ciudad de Morelia Michoacán, México», vol. XIV, n.o 1, pp. 49-68, 2019.
- [52] J. M. Núñez-Tabales, F. J. Rey-Carmona, y J. M. Caridad y Ocerin, «Redes neuronales (RN) aplicadas a la valoración de locales comerciales», *Inf. la Constr.*, vol. 69, n.o 545, 2017, DOI: 10.3989/ic.15.053