

Implementation of the use of artificial neural networks for the predictive calculation of concrete resistance, Trujillo

Jhordy Bryan C6ndor-Palomino¹, Clinton Steiner Huam6n-Sandoval¹, Eduardo Manuel Noriega-Vidal, Msc.¹, Juan Carlos Martell-Ortiz, Msc.¹, Alan Yordan Valdiviezo- Velarde, Dr. ¹, 6lex Arqu6medes Herrera-Viloch6, Dr.¹, jbc6ndorc@ucvvirtual.edu.pe, cshuamanh@ucvvirtual.edu.pe, enoriegavi@ucvvirtual.edu.pe, jmartellor@ucvvirtual.edu.pe, avaldivieso@ucv.edu.pe, aherrerav@ucv.edu.pe,

¹Departamento de Ingenier6a Civil, Universidad C6sar Vallejo, Per6

Abstract– This research aimed to implement artificial neural networks for predicting concrete strength. Specific objectives included assessing the accuracy of these networks, determining the progress of their training, and evaluating the mean square error. The applied methodology employed a non-experimental descriptive cross-sectional design. The overall conclusion highlighted the successful implementation of artificial neural networks in predicting concrete strength. The network architecture was detailed, comprising input, hidden, and output layers with 10, 19, and 1 neuron, respectively, using Matlab. Specific findings indicated a high level of accuracy at 99.997%, confirming the effectiveness of concrete strength prediction. Furthermore, a training progress of 100.00% was achieved, demonstrating the neural network's ability to adjust internal parameters and learn to predict concrete strength with provided data. Regarding the neural network's mean square error, a coefficient of $MSE = 1.5949$ was obtained.

Ultimately, it was concluded that the use of artificial neural networks is a valid approach for estimating concrete compressive strength. This research opens promising perspectives for their future application in monitoring concrete quality.

Keywords– Compression strength, artificial neural networks, concrete.

Implementation of the use of artificial neural networks for the predictive calculation of concrete resistance, Trujillo

Jhordy Bryan C6ndor-Palomino¹, Clinton Steiner Huam6n-Sandoval¹, Eduardo Manuel Noriega-Vidal, Msc.¹, Juan Carlos Martell-Ortiz, Msc.¹, Alan Yordan Valdiviezo- Velarde, Dr.¹, Alex Arqu6medes Herrera-Viloché, Dr.¹, jbondorc@ucvvirtual.edu.pe, cshuamanh@ucvvirtual.edu.pe, enoriegavi@ucvvirtual.edu.pe, jmartellor@ucvvirtual.edu.pe, avaldivieso@ucv.edu.pe, aherrerav@ucv.edu.pe,

¹Departamento de Ingenier6a Civil, Universidad C6sar Vallejo, Per6

Resumen – La presente investigaci6n tuvo como objetivo general la implementaci6n de redes neuronales artificiales para predecir la resistencia del concreto. Los objetivos espec6ficos incluyeron evaluar la precisi6n de estas redes, determinar el progreso de su entrenamiento y el error medio cuadr6tico. La metodolog6a adoptada fue de tipo aplicada, con un dise1o no experimental transversal descriptivo. La conclusi6n general destac6 la exitosa implementaci6n de redes neuronales artificiales en el c6lculo predictivo de la resistencia del concreto. Se detall6 la arquitectura de la red, que consta de capas de entrada, oculta y salida, con 10, 19 y 1 neuronas respectivamente, utilizando Matlab. Las conclusiones espec6ficas indicaron un alto grado de precisi6n del 99.997%, confirmando la eficacia de la predicci6n de la resistencia del concreto. Adem6s, se logr6 un progreso de entrenamiento del 100.00%, evidenciando la capacidad de la red neuronal para ajustar sus par6metros internos y aprender a predecir la resistencia del concreto con los datos brindados. Con respecto al error medio cuadr6tico de la red neuronal se obtuvo un coeficiente de MSE = 1.5949. En 6ltima instancia, se concluy6 que el uso de redes neuronales artificiales es un enfoque v6lido para estimar la resistencia a la compresi6n del concreto. Esta investigaci6n abre perspectivas prometedoras para su aplicaci6n futura en la supervisi6n de la calidad del concreto.

Palabras claves– Resistencia a la compresi6n, redes neuronales artificiales, concreto, hormig6n.

Abstract– This research aimed to implement artificial neural networks for predicting concrete strength. Specific objectives included assessing the accuracy of these networks, determining the progress of their training, and evaluating the mean square error. The applied methodology employed a non-experimental descriptive cross-sectional design. The overall conclusion highlighted the successful implementation of artificial neural networks in predicting concrete strength. The network architecture was detailed, comprising input, hidden, and output layers with 10, 19, and 1 neuron, respectively, using Matlab. Specific findings indicated a high level of accuracy at 99.997%, confirming the effectiveness of concrete strength prediction. Furthermore, a training progress of 100.00% was achieved, demonstrating the neural network's ability to adjust internal parameters and learn to predict concrete strength with provided data. Regarding the neural network's mean square error, a coefficient of MSE = 1.5949 was obtained.

Ultimately, it was concluded that the use of artificial neural networks is a valid approach for estimating concrete compressive strength. This research opens promising perspectives for their future application in monitoring concrete quality.

Keywords– Compression strength, artificial neural networks, concrete.

Digital Object Identifier: (only for full papers, inserted by LACCEI).
ISSN, ISBN: (to be inserted by LACCEI).
DO NOT REMOVE

I. INTRODUCCI6N

La industria de la construcci6n no ha sido ajena a la inteligencia artificial, que ayuda a los ingenieros de la construcci6n a automatizar diversos proyectos como la construcci6n de edificios, represas, puentes, entre otros; que a menudo requieren uso de muchas horas de trabajo y mano de obra [1].

Se constat6 que la resistencia a la compresi6n del concreto experimenta cambios a lo largo del tiempo. Por ejemplo, se estima que alrededor del s6ptimo d6a se logra alcanzar aproximadamente el 70-75% de la resistencia obtenida a los 28 d6as, mientras que a los 56 y 90 d6as se obtienen resistencias que son entre un 10% y un 15% superiores a las registradas a los 28 d6as [2].

La resistencia a la compresi6n es la caracter6stica m6s significativa del concreto una vez que ha endurecido, la cual se considera crucial para garantizar la calidad del material. Con el fin de estimar la resistencia a la compresi6n del concreto, generalmente se deben realizar pruebas exhaustivas para establecer correlaciones entre los componentes del concreto y su resistencia. Sin embargo, estas pruebas son costosas, requieren mucho tiempo y una gran cantidad de materiales. Una soluci6n a este problema es utilizar modelos computacionales como las redes neuronales artificiales y la regresi6n lineal m6ltiple, los cuales se basan en bases de datos [3].

El proceso de una Red Neuronal Artificial (RNA) implica proporcionar repetidamente a la red patrones de entrada y ajustar los pesos de conexi6n coincidentes en base a los datos de salida recibidos. Existen tres categor6as de aprendizaje: supervisado, aprendizaje por refuerzo y aprendizaje no supervisado, que a su vez utilizan diferentes algoritmos dependiendo de la informaci6n del patr6n de entrada disponible [4]. Las redes neuronales artificiales presentan beneficios significativos, entre los cuales se destacan su habilidad para generalizar y responder eficientemente a nuevas entradas sin precedentes [5].

Como objetivos espec6ficos se tiene, determinar el grado de precisi6n de las redes neuronales artificiales, determinar el progreso de entrenamiento de la red neuronal artificial y determinar el error cuadr6tico de la red neuronal en el c6lculo de la resistencia del concreto.

En Ir6n se desarroll6 una investigaci6n donde se us6 algoritmos de aprendizaje autom6tico y profundo para predecir la resistencia del concreto reforzado con fibras de acero, basado en los datos recopilados de la literatura abierta.

En consecuencia, se recopilaron 176 conjuntos de datos de diferentes revistas y documentos de conferencias. Basándose en el análisis de los parámetros más influyentes, como la relación agua-cemento y el contenido de agregados finos [6].

En España se realizó la investigación “Modelos predictivos de la resistencia del hormigón mediante estadística y redes neuronales artificiales”, el objetivo es realizar un análisis y evaluación de la relevancia de los factores que impactan en la dosificación de la mezcla en relación con la resistencia a la compresión del concreto después de 28 días, se utilizaron modelos de regresión lineal y múltiple basados en estadística clásica, junto con redes neuronales artificiales, para predecir la resistencia a la compresión. [7]. en la Escuela Colombiana de Ingeniería Julio Garavito, a través de su investigación “Implementación de redes neuronales para estimar la resistencia a la compresión del concreto utilizando agregados reciclados y materiales cementales suplementarios”, tiene como objetivo crear un sistema que pueda estimar la resistencia a la compresión de concreto que contiene agregados reciclados y aditivos de cemento. Se recolectaron 45 artículos correspondientes a 536 datos para desarrollar este proyecto [8].

A nivel nacional, en la Universidad Católica de Santa María, a través de su investigación “Uso de redes neuronales artificiales para determinar una nueva alternativa de método de diseño de mezcla de concreto de resistencias convencionales en la ciudad de Arequipa - 2022”, se propuso una alternativa a los diseños de mezcla convencionales mediante el uso de inteligencia artificial y aprendizaje automático. [9]. En Cusco, en la Universidad César Vallejo, realizaron una investigación titulada “Aplicación de redes neuronales en el diseño óptimo de concreto en la reducción del Cemento Portland Cusco - 2021”. Esta tesis se enfocó en abordar el desafío de reducir el uso de cemento en la producción de concreto. Se destacó que es posible lograr una disminución en el consumo de cemento sin comprometer la resistencia del material, gracias a la aplicación de técnicas modernas disponibles para los ingenieros en la actualidad, como las redes neuronales. La hipótesis principal de la tesis sostuvo que, al emplear métodos como las redes neuronales en el diseño del concreto, es posible lograr una reducción mínima del 20% en el consumo de cemento. Para lograr los objetivos planteados, la tesis utilizó un enfoque cuantitativo de orientación positivista, con un enfoque deductivo y un diseño experimental [10]. En Lambayeque, en la Universidad Nacional Pedro Ruiz Gallo, en su investigación “Aplicación de redes neuronales artificiales en el ensayo de la resistencia a la compresión del concreto, utilizando agregados de la cantera Tres Tomas, distrito Mesones Muro - provincia Ferreñafe - región Lambayeque”, se propuso utilizar una Red Neuronal Artificial para mejorar la eficiencia del ensayo de resistencia a la compresión del concreto convencional sin comprometer la precisión de los resultados. Se trabajó con una muestra de 294 probetas, de las cuales 240 se utilizaron para entrenar y validar la red, mientras que el resto se utilizó para evaluar su capacidad de generalización [11].

II. METODOLOGIA

Se consideró una investigación aplicada debido a su propósito y resultados que busca, los cuales pueden tener una aplicación directa en la sociedad tanto a corto como a mediano plazo, con el objetivo de abordar problemas existentes [12]. El diseño de investigación que se llevó a cabo en este contexto se clasifica como no experimental transversal descriptivo; implica la falta de capacidad para controlar variables o asignar sujetos o condiciones de manera aleatoria [13].

Se tuvo como variable independiente a: Las redes neuronales artificiales; que son herramientas confiables, fáciles de manejar y efectivas que se emplean para resolver problemas complejos que van más allá de los métodos o modelos estadísticos tradicionales [14]

Como dimensiones de esta variable se tuvo: Grado de precisión, progreso de entrenamiento, y error medio cuadrático. El indicador que corresponde para grado de precisión y progreso de entrenamiento es el de porcentaje, y para el error medio cuadrático el coeficiente MSE. Se hizo uso de la escala de razón.

Como variable dependiente se tuvo: Cálculo de la resistencia a la compresión del concreto, lo cual se define como el resultado de dividir la carga máxima aplicada durante el ensayo (carga de rotura por compresión) por el área transversal del elemento sometido a ensayo [15]

Como dimensiones se tuvo: Diseño $f'c$, relación agua – cemento, tamaño máximo de agregado grueso y edad de rotura. El indicador para la relación agua – cemento es el coeficiente a/c , para el tamaño de agregado es el tamaño en cm y para la edad de rotura son los días 7, 14 y 28 días de rotura, para ello se hizo uso de la escala de razón.

a. Población, muestra y muestreo

La población se refiere al grupo de casos que cumplen con ciertas especificaciones o características establecidas por el investigador y sobre el cual se busca obtener conclusiones generales o inferencias [16]. En este sentido, la población objeto de investigación estuvo conformado por probetas de concreto sometidas a ensayos de resistencia a la compresión, en laboratorios ubicados en la provincia de Trujillo, del departamento La Libertad, 2023. El criterio de inclusión fue contar con el diseño de mezcla de dichas probetas y que las fichas técnicas de los ensayos de resistencia a la compresión debieron estar debidamente firmadas y selladas por los profesionales a cargo.

Una muestra estadística es una parte o subconjunto de unidades representativas de un conjunto llamado población o universo, seleccionadas de forma aleatoria, y que se somete a observación científica con el objetivo de obtener resultados válidos para el universo total investigado [17]. En este sentido, se consideró 100 probetas de concreto sometidas a ensayos de resistencia a la compresión de realizadas en el laboratorio trujillano Ingeofaltop – Perú.

En esta investigación se utilizó un método de muestreo probabilístico estratificado, que consiste en seleccionar muestras de manera aleatoria de cada estrato o grupo (según su resistencia de concreto) y poder asegurar que cada estrato esté representado en la muestra. Garantizando así una mayor precisión en los resultados.

b. Técnicas e instrumentos de recolección de datos

Las técnicas de recolección de datos en una investigación se refieren a los enfoques y recursos empleados para obtener la información necesaria que permita responder a las interrogantes planteadas y lograr los objetivos establecidos en el estudio [18]

Para la variable independiente se utilizó la técnica de la observación, puesto que evidenciaremos los resultados de la iteración realizada a través del Software MATLAB, mediante el cual se definió la arquitectura de la red neuronal, se estableció los parámetros de entrenamiento, entre otros aspectos.

Para la variable dependiente se recopilamos los resultados de las pruebas de resistencia a la compresión de las muestras utilizando la información proporcionada por el Laboratorio – Consultoría & Construcción Ingeofaltop Perú. El instrumento utilizado fue la base de datos con los resultados brindados por la empresa mencionada.

Confiabilidad

La confiabilidad se refiere a la consistencia de los resultados obtenidos mediante una medida. Es la capacidad de un instrumento de medición para producir resultados estables y consistentes en diferentes ocasiones y bajo condiciones similares [19]

En tal sentido, el instrumento de la presente investigación tuvo confiabilidad debido a la validación de los instrumentos de recolección por parte de los expertos, asimismo los resultados descritos en las fichas técnicas fueron tomados de un laboratorio especialista y respaldado por ingenieros civiles colegiados.

Por otro lado, software MATLAB es un instrumento de uso mundial respaldado por MathWorks, una empresa líder en el campo del software técnico.

c. Procedimiento

Se buscó realizar el siguiente diseño arquitectónico en una RNA.

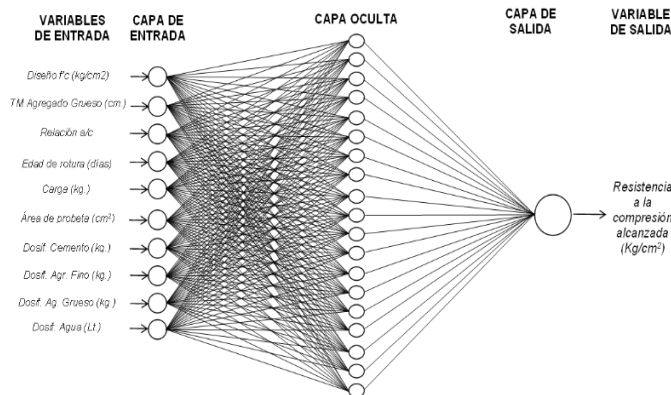


Fig. 1 Representación gráfica de la arquitectura de la Red Neuronal Artificial el cual consta de una capa de entrada de 10 neuronas, una capa oculta de 19 neuronas y una capa de salida de 1 neurona

Posterior a ello, después de recopilar esta información, se introdujo las variables a analizar en MATLAB en formato de matriz, esto se realizó con el propósito de permitir que la red neuronal aprenda a establecer conexiones entre los patrones iniciales y el patrón resultante.

Para el aprendizaje de la Red Neuronal Artificial se ingresaron datos como, ver Fig. 2:

Fila 1: Diseño de resistencia de concreto requerido (kg/cm2).

Fila 2: Tamaño máximo nominal del agregado grueso (cm).

Fila 3: Relación agua/cemento (a/c).

Fila 4: Edad de rotura de probeta (días).

Fila 5: Carga a la que fue sometida la probeta en la prueba (kg).

Fila 6: Área de la probeta en contacto con la máquina (cm2).

Fila 7: Dosificación de cemento (kg).

Fila 8: Dosificación del agregado fino por cada kilo de cemento(kg).

Fila 9: Dosificación. del agregado grueso por cada kilo de cemento (kg).

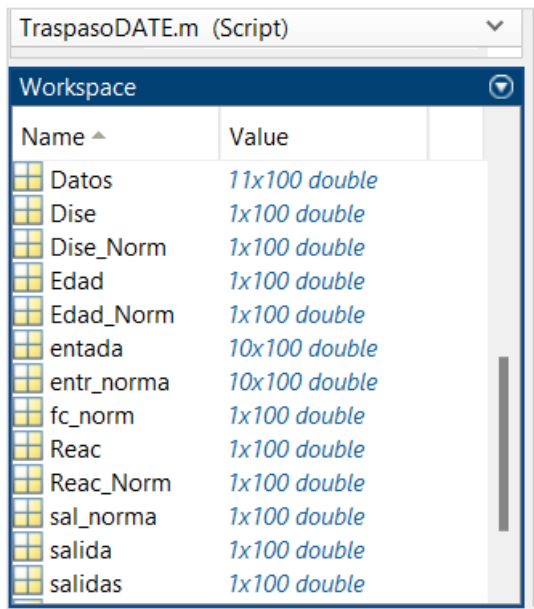
Fila 10: Dosificación del agua por cada kilo de cemento (lt).

Fila 11: Resistencia a la compresión obtenida del ensayo (kg/cm2).

	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	280	280	280	280	280	280	280	280	280	280	280	280	280	280
2	1.2700	1.2700	1.2700	1.2700	1.2700	1.2700	1.2700	1.2700	1.2700	1.2700	1.2700	1.2700	1.2700	1.2700
3	0.6250	0.6250	0.6250	0.6250	0.6250	0.6250	0.6250	0.6250	0.6250	0.6250	0.6250	0.6250	0.6250	0.6250
4	7	14	7	14	7	14	7	14	7	14	7	14	7	28
5	35250	45025	36705	46435	33980	44215	36075	45080	37405	45640	34925	43790	34195	52150
6	176.9500	176.7150	176.7150	177.1860	176.9500	177.4220	177.1860	176.7150	176.9500	176.7150	177.1860	176.9500	177.1860	176.9500
7	1	1	1	1	1	1	1	1	1	1	1	1	1	1
8	1.7270	1.7270	1.7270	1.7270	1.7270	1.7270	1.7270	1.7270	1.7270	1.7270	1.7270	1.7270	1.7270	1.7270
9	1.6850	1.6850	1.6850	1.6850	1.6850	1.6850	1.6850	1.6850	1.6850	1.6850	1.6850	1.6850	1.6850	1.6850
10	0.5000	0.5000	0.5000	0.5000	0.5000	0.5000	0.5000	0.5000	0.5000	0.5000	0.5000	0.5000	0.5000	0.5000
11	199.2100	254.7900	207.7100	262.0700	192.0300	249.2100	203.6000	255.1000	211.3900	258.2700	197.1100	247.4700	192.9900	294.7200

Fig. 2 Data a procesar mediante la Red Neuronal Artificial

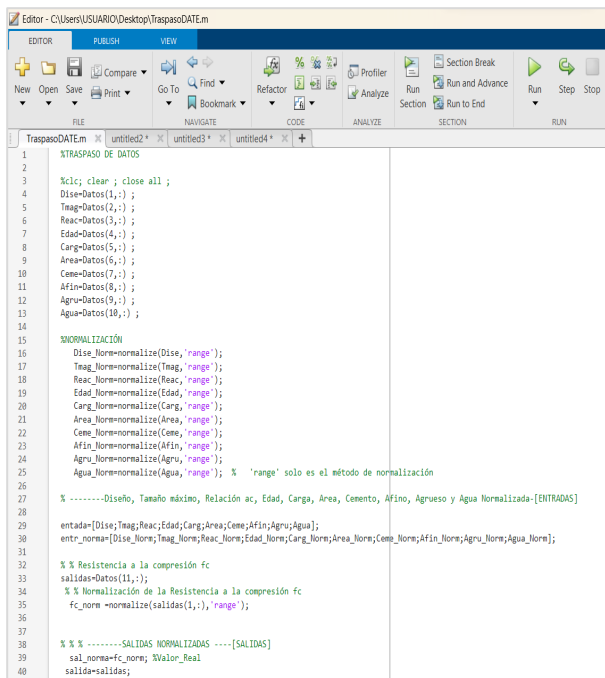
Los datos ingresados genera una matriz de 11x100, lo cual se debe a que están incluidas las 10 variables de entrada y 1 variable de salida. Por ello, la matriz “Entada” es una matriz de 10x100, con 10 variables de entrada. Por otro lado, la matriz “Salida” es una matriz de 1x100, con una matriz de salida. Todas estas matrices, elaboradas con los 100 datos de muestra, ver Fig. 3.



Name	Value
Datos	11x100 double
Dise	1x100 double
Dise_Norm	1x100 double
Edad	1x100 double
Edad_Norm	1x100 double
entrada	10x100 double
entr_norma	10x100 double
fc_norm	1x100 double
Reac	1x100 double
Reac_Norm	1x100 double
sal_norma	1x100 double
salida	1x100 double
salidas	1x100 double

Fig.3 Generación de matrices

El código de preprocesamiento inicia con el traspaso de datos, que consiste en extraer las diferentes variables de la matriz de datos, y se asignan a variables individuales dentro del código conforme al número de fila que se asignó a cada variable. La normalización implica ajustar los valores de las variables para que estén en una escala común, lo cual es beneficioso para el algoritmo de aprendizaje. Posterior a ello, se crea una matriz de entrada con las 10 variables; además de una matriz con las variables normalizadas que serán aprovechadas por el algoritmo de entrenamiento. Finalmente, se define la variable de salida, en este caso se extrae la variable de la resistencia a la compresión f_c ; lo que permite normalizar la variable para un mejor aprendizaje por parte de la red neuronal, ver Fig. 4.



```

1  XTRASPASO DE DATOS
2
3  %clc; clear; close all;
4  Dise=Datos(1,:);
5  Reag=Datos(2,:);
6  Reac=Datos(3,:);
7  Edad=Datos(4,:);
8  Carg=Datos(5,:);
9  Area=Datos(6,:);
10 Ceme=Datos(7,:);
11 AFIn=Datos(8,:);
12 Agru=Datos(9,:);
13 Agua=Datos(10,:);
14
15 %NORMALIZACIÓN
16 Dise_Norm=normalize(Dise,'range');
17 Reag_Norm=normalize(Reag,'range');
18 Reac_Norm=normalize(Reac,'range');
19 Edad_Norm=normalize(Edad,'range');
20 Carg_Norm=normalize(Carg,'range');
21 Area_Norm=normalize(Area,'range');
22 Ceme_Norm=normalize(Ceme,'range');
23 AFIn_Norm=normalize(AFIn,'range');
24 Agru_Norm=normalize(Agru,'range');
25 Agua_Norm=normalize(Agua,'range'); % 'range' solo es el método de normalización
26
27 % .....Diseño, Tamaño máximo, Relación ac, Edad, Carga, Área, Cemento, AFIno, Agruoso y Agua Normalizada-[ENTRADAS]
28
29 entrada=[Dise;Reag;Edad;Carg;Area;Ceme;AFIn;Agru;Agua];
30 entr_norma=[Dise_Norm;Reag_Norm;Reac_Norm;Edad_Norm;Carg_Norm;Area_Norm;Ceme_Norm;AFIn_Norm;Agru_Norm;Agua_Norm];
31
32 %% Resistencia a la compresión fc
33 salidas=Datos(11,:);
34 %% Normalización de la Resistencia a la compresión fc
35 fc_norm=normalize(salidas(1,:), 'range');
36
37
38 %% % .....SALIDAS NORMALIZADAS .....[SALIDAS]
39 sal_norma=fc_norm; %Valor_Real
40 salida=salidas;

```

Fig. 4 Código de preprocesamiento de datos

Se utilizó una serie de algoritmos que permitirán al software construir la Red Neuronal Artificial.

El principal algoritmo en el que se basó la presente investigación, y que el programa MATLAB utilizó para entrenar la RNA, fue el algoritmo Levenberg Marquart, esto debido a que se destaca por su excepcional rapidez de convergencia, una virtud crucial para optimizar el tiempo de entrenamiento. El Levenberg-Marquardt no solo ha demostrado un rendimiento sobresaliente en problemas de regresión, alineándose con los objetivos de la investigación, sino que también exhibe una eficiencia computacional valiosa, ver Ecuación (1)

$$w(t+1) = w(t) - [J^t(w) \cdot J(w) + \mu I]^{-1} \cdot J^t(w) \cdot e(w) \quad (1)$$

Donde:

- w : pesos sinápticos de la neurona
- t : iteraciones
- J(w) : matriz Jacobiana
- I : matriz de identidad
- μ : parámetro que aumenta o disminuye en la iteración

Para la entrada de una neurona de la capa de entrada hacia la capa oculta, el programa utiliza la siguiente expresión matemática, ver Ecuación (2)

$$E = \sum_{i=1}^N w_{ji} x_{pi} + \theta_j \quad (2)$$

Donde:

- w_{ji} : pesos sinápticos de la neurona i
- x_{pi} : información representada por un vector de entrada
- θ_j : umbral de excitación llamado sesgo o bias

Luego, para ingresar hacia la capa oculta, la expresión matemática fue la siguiente para la entrada neta en la neurona "k" de la capa de salida, ver Ecuación (3)

$$net_{pk} = \sum_{j=1}^L v_{kj} b_{pj} + \theta_k \quad (3)$$

Finalmente, la neurona "k" obtiene un valor de la salida, mediante la siguiente expresión matemática, ver Ecuación (4)

$$y_{pk} = f(net_{pk}) \quad (4)$$

En cuanto al Error medio cuadrático, se utilizó la siguiente expresión matemática, ver Ecuación (5)

$$E = \frac{\sum_{p=1}^P \sum_{k=1}^M (d_{pk} - y_{pk})^2}{P \cdot M} \quad (5)$$

Al concluir el proceso de entrenamiento, será posible realizar una comparación entre los resultados de la resistencia

a la compresión obtenidos a través de la predicción de la red neuronal artificial y los datos obtenidos mediante el ensayo de resistencia a la compresión. Este análisis permitirá evaluar la capacidad de la red neuronal para prever con precisión los niveles de resistencia a partir de los datos de entrada, estableciendo la eficacia y confiabilidad del modelo en relación con los resultados experimentales (Ver Fig. 5).

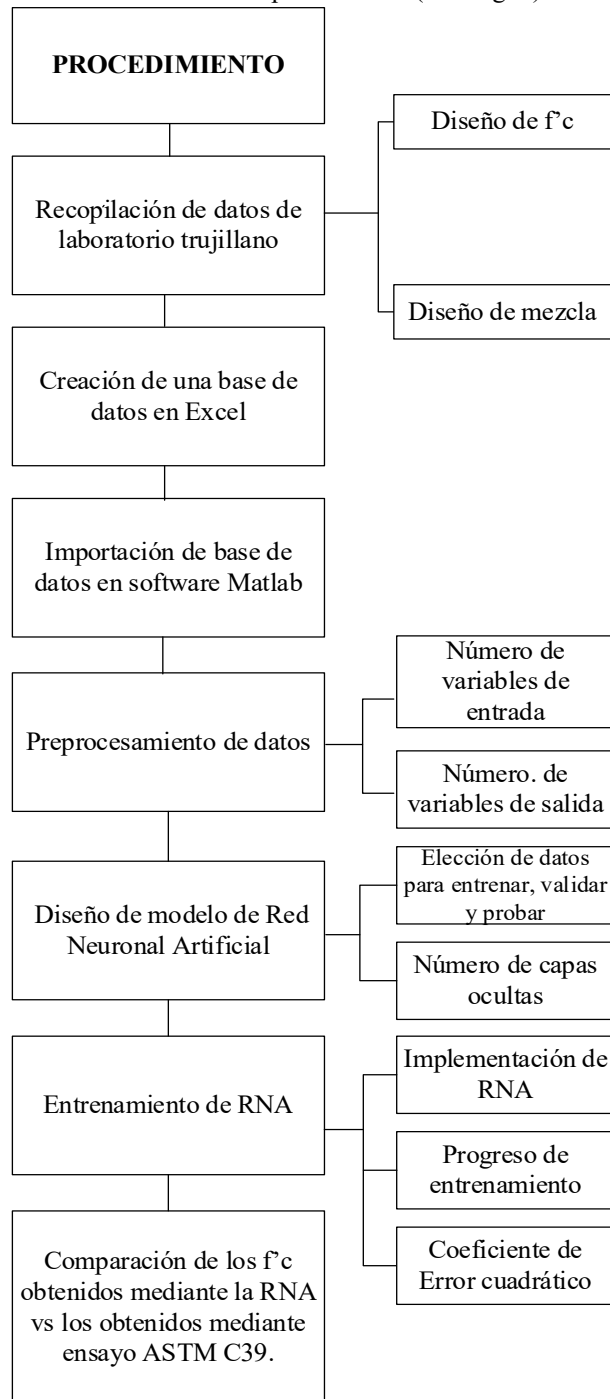


Fig. 5 Procedimiento de obtención de $f'c$ mediante RNA

d. Método de análisis de datos

El presente proyecto de investigación realizó el método de análisis estadístico, puesto que los resultados se representaron a través de gráficos y cuadros estadísticos.

e. Aspectos éticos

El propósito de la información presentada fue proporcionar datos precisos y verídicos, siguiendo las directrices establecidas por la universidad. El contenido es fiable, ya que se basa en datos obtenidos a través de ensayos respaldados por profesionales del Laboratorio – Consultoría & Construcción Ingeofaltop Perú, quienes llevaron a cabo los ensayos cumpliendo con los estándares exigidos por la normativa peruana actual.

III. RESULTADOS

1. Red neuronal artificial implementada

En la tabla I, se observan resultados excepcionales en la implementación de la red neuronal artificial [3]. En relación al parámetro "Epoch" (época), se requirieron 49 iteraciones para alcanzar su nivel óptimo de entrenamiento. El indicador de "Performance" (rendimiento) se basa en el MSE (Error Cuadrático Medio), registrando un valor de 0.00056 durante la fase de entrenamiento, lo cual es extremadamente cercano a cero. La gradiente, con un valor de 0.78, señala que la red neuronal artificial está ajustando los pesos en la dirección correcta para minimizar las pérdidas. El indicador Mu es de 0.001, indicando un factor muy bajo, y se espera una mejora sustancial al introducir más variables de entrada para aumentar la precisión. En último término, se llevaron a cabo un total de 6 validaciones, la cantidad máxima necesaria para esta red neuronal artificial en particular.

TABLA I
IMPLEMENTACIÓN DE RED NEURONAL ARTIFICIAL

Unit	Initial Value	Stopped Value	Target Value
Epoch	0	49	1000
Elapsed Time	-	00:00:00	-
Performance	4.64E+04	0.00056	0
Gradient	1.29E+05	0.78	1.00E-07
Mu	0.001	0.001	1.00E+10
Validation Checks	0	0	0

2. Entrenamiento de RNA

En las Fig. 6, Fig. 7, Fig. 8 y Fig. 9 el eje de las abscisas representa la resistencia a la compresión mediante el ensayo ASTM C39 y el eje de las ordenadas representa la resistencia a la compresión obtenida por la RNA. Después de configurar y aplicar adecuadamente la Red Neuronal Artificial utilizando los datos recopilados de los diseños de mezcla y las probetas, se logró una precisión del 99.997% [7], como se observa en la Fig. 6. En la Fig. 7, el progreso de entrenamiento alcanzó el 100.00% [8], mientras que la validación de la predicción fue del 99.938% [20], como se visualiza en la Fig. 8. Además, se obtuvo una aprobación del funcionamiento de la red neuronal del 99.981% [3], como se observa en la Fig. 9. Estos resultados destacan la eficacia y confiabilidad del modelo implementado.




Fig. 6 Progreso de entrenamiento de RNA




Fig. 7 Etapa de validación de la RNA




Fig. 8 Etapa de prueba de la RNA




Fig. 9 Etapa final de precisión de RNA

3. Error medio cuadrático

Como se observa la Tabla II, se obtuvo el error medio cuadrático del total de datos (100) [7], el cual es $MSE=1.5949$, con un grado de correlación $R=0.99977$. En la etapa de entrenamiento con los 70 datos, se tuvo un coeficiente $MSE=0.00056$ con un grado de correlación de $R=1$. En la etapa de validación, con 15 datos, se determinó un error medio cuadrático de $MSE=7.6341$ con un coeficiente de correlación $R=0.99938$. Finalmente, con 15 datos en la etapa de prueba, tenemos un $MSE=2.9959$, con un coeficiente $R=0.99981$.

TABLA I
ERROR MEDIO CUADRÁTICO DE CADA ETAPA

	Observation	MSE	R
Training	70	0.0006	1.0000
Validation	15	7.6341	0.9994
Test	15	2.9959	0.9998
Final Training	100	1.5949	0.9998

4. Comparación de $f'c$ con RNA y norma ASTM C39

Al observar en la Fig. 10, podemos hacer la comparación entre los datos reales obtenidos en las pruebas de resistencia a la compresión y los datos obtenidos mediante la red neuronal artificial [3], los resultados presentaron una fuerte correlación. Esto, debido a la alta precisión de la red neuronal artificial que se obtuvo en su implementación a la resistencia del concreto. La diferencia más grande entre resultados se da en las probetas N° 99 y N° 100, esto podría deberse a que existen sólo 2 datos ingresados con este tipo de diseño de mezcla.

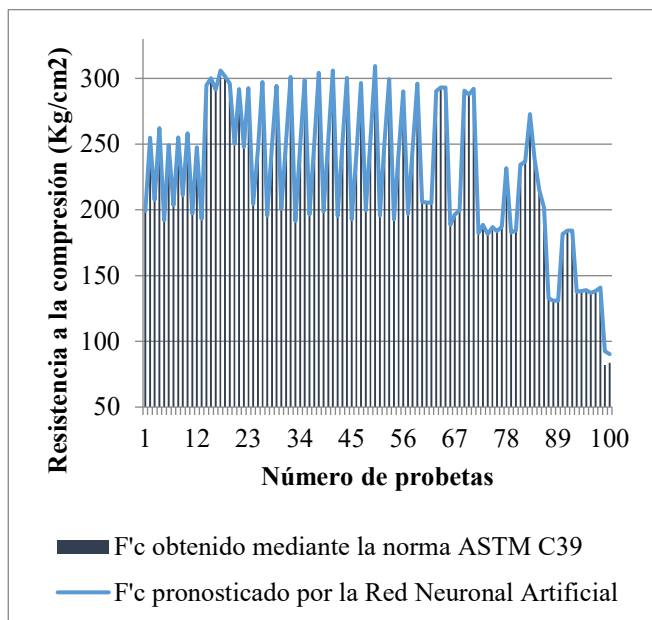


Fig. 10 Comparativa de f_c con RNA y con norma ASTM C39

IV. CONCLUSIONES

La investigación sobre la implementación de redes neuronales artificiales para el cálculo predictivo de la resistencia del concreto en Trujillo - 2023 ha arrojado resultados significativos y prometedores. En términos generales, la aplicación de estas redes en este contexto ha demostrado ser exitosa, marcando un avance importante en la predicción de la resistencia del concreto.

La arquitectura de la red neuronal, compuesta por capas de entrada, oculta y salida, con 10, 19 y 1 neuronas respectivamente, ha sido fundamental para lograr un alto grado de precisión del 99.977%. Este nivel de exactitud valida la idoneidad de las redes neuronales artificiales como herramienta eficaz para predecir la resistencia del concreto, ofreciendo resultados confiables y ajustados a las necesidades prácticas.

El progreso de entrenamiento alcanzado, evaluado en un 100.00%, subraya la capacidad de la red neuronal para adaptarse y aprender de manera efectiva a partir de los datos proporcionados. Este progreso se ha logrado mediante el ajuste continuo de pesos y sesgos a través del proceso del algoritmo Levenberg-Marquardt, destacando su importancia en la optimización del rendimiento de la red.

Además, es crucial abordar el error medio cuadrático, el cual es de $MSE=1.5949$. Este aspecto ofrece una visión crítica del rendimiento de la red, identificando áreas para posibles mejoras y refinamientos en futuras investigaciones.

En última instancia, estas conclusiones respaldan la afirmación de que las redes neuronales artificiales representan un enfoque válido y prometedor para estimar la resistencia a la compresión del concreto. Esto abre la perspectiva de su aplicación futura en la supervisión de la calidad del concreto, donde la precisión y la eficacia de las redes neuronales pueden contribuir significativamente al campo de la ingeniería civil.

REFERENCIAS

- [1] J. Mendoza, M. Quispe y S. Muñoz, «Una revisión sobre el rol de la inteligencia artificial en la industria de la construcción,» *Ingeniería y competitividad*, vol. 24, n° 2-2022, pp. 02-23, 2022.
- [2] S. Kosmatka, B. Kerkhoff y J. Tanesi, «Diseño y control de mezclas de concreto,» *Boletín de ingeniería EB201*, pp. 01-392, 2003.
- [3] Chingay, «Diseño de un modelo dinámico con redes neuronales artificiales para predecir la resistencia a la compresión del concreto,» pp. 21-125, 2020.
- [4] W. Campos y Y. Trujillo, «Redes Neuronales Artificiales en la estimación del esfuerzo,» *Revista Cubana de Ciencias Informáticas*, vol. 15, n° 02, pp. 183-198, 2021.
- [5] W. Rivas y B. Mazón, «Redes neuronales artificiales aplicadas al reconocimiento de patrones,» *Redes 2017*, pp. 12-199, 2018.
- [6] S. Pakzad, N. Roshan y MansourGhalehnov, «Comparison of various machine learning algorithms used for compressive strength prediction of steel fiber-reinforced concrete,» *Scientific reports*, pp. 01-12, 2023.
- [7] A. Yancha, «Modelos predictivos de la resistencia del hormigón mediante estadística y redes neuronales artificiales,» pp. 01-132, 2023.
- [8] A. Pineda, «Implementación de redes neuronales para estimar la resistencia a la compresión del concreto utilizando agregados reciclados y materiales cementales suplementarios,» pp. 01-35, 2020.
- [9] F. Loayza y R. Alvaro, «Uso de redes neuronales artificiales para determinar una nueva alternativa de método de diseño de mezcla de concreto de resistencias convencionales en la ciudad de Arequipa - 2022,» pp. 07-201, 2023.
- [10] D. Cunza y J. Mollinedo, «Aplicación de redes neuronales en el diseño Óptimo de concreto,» pp. 01- 44, 2021.
- [11] A. Sandoval, «Aplicación de redes neuronales artificiales en el ensayo de la resistencia a la compresión del concreto, utilizando agregados de la cantera Tres Tomas, distrito Mesones Muro - provincia Ferreñafe - región,» pp. 14-257, 2021.
- [12] J. Salinas, «La investigación ante los desafíos de los escenarios de aprendizaje futuros,» *Revista de Educación a Distancia*, pp. 01-24, 2016.
- [13] F. Kerlinger, «Investigación del comportamiento,» pp. 01-820, 1998.
- [14] Lazarevska, «Redes neuronales artificiales,» 2014.
- [15] Villa, «Redes neuronales,» 2023.
- [16] Hernández, «Redes neuronales,» *Marco metodológico*, p. 215, 2014.
- [17] P. Lopez, «Metodología de la investigación social cuantitativa,» *Dipòsit Digital de Documents*, p. 64, 2017.
- [18] Sekaran, «Enfoques y estructuras de trabajos de investigación,» p. 655, 2016.

- [19] D. Vellis, «Problemas de validez y fiabilidad en los cuestionarios ROSE: revisión sistemática de la producción española,» *Radu Bogdan Toma* , p. 16, 2017.
- [20] R. Enrique, «Naturaleza y Materiales del Concreto. Lima, Perú,» *Instituto de la Construcción y Gerencia*, 2004.
- [21] E. Pasquel, «Capitulo de ingeniería civil,» de *Tópicos de tecnología del concreto en el Perú*, Lima, 1998, p. 399.