



REVISTA INGENIO

Uso de Redes Neuronales Artificiales (RNA) para la Predicción de la Resistencia a la Compresión y Módulo de Elasticidad del Hormigón.

Use of Artificial Neural Networks (ANNs) for the Prediction of the Compressive Strength and Modulus of Elasticity of Concrete.

Enlil Santiago Ganchala Padilla [1](#) | [ID](#) Universidad Central del Ecuador

Jonathan Mauricio Piñarcaja Rivadeneira [2](#) | [ID](#) Universidad Central del Ecuador

Luis Alejandro Machado Salazar [3](#) | [ID](#) Universidad Central del Ecuador

HISTORIA DEL ARTÍCULO

Recepción: 18/09/2023

Recepción tras revisión: 18/10/2023

Aprobación: 18/11/2023

Publicación: 15/01/2024

PALABRAS CLAVE

Redes neuronales artificiales (RNA), Neural Fitting (nftool), Diseño de mezclas, Resistencia a la Compresión (f_c), Módulo de elasticidad (Ec).

RESUMEN

La presente investigación indica el diseño de un modelo de inteligencia artificial en base a redes neuronales artificiales (RNA) que permita predecir la resistencia a la compresión " f_c " y módulo de elasticidad "Ec" del hormigón. La metodología se realizó en tres etapas: La Etapa Delta donde se conformó una base de datos constituida por resultados de diseños de hormigones (caracterización de agregados, dosificaciones, resistencia a la compresión y módulo de elasticidad) elaborados con cemento tipo GU sin aditivos y agregados procedentes de las canteras del Distrito Metropolitano de Quito, obtenidos de trabajos de titulación de diversas universidades del país y de ensayos comerciales realizados por el Laboratorio de Ensayo de Materiales y Modelos de la Facultad de Ingeniería y Ciencias Aplicadas. En la siguiente Etapa Theta se realizó el diseño de la RNA utilizando el software Matlab y la herramienta Neural Fitting "nftool" para el entrenamiento, validación y testeo de la RNA a través de indicadores de desempeño como el coeficiente de correlación de Pearson "R" en la etapa de evaluación y el coeficiente de determinación " R^2 " para medir la eficiencia de la RNA; finalmente en la etapa Gamma se comprobó los resultados pronosticados de la RNA con el " f_c " y "Ec" real del hormigón obtenidos a través de ensayos realizados a 20 cilindros de hormigón, diseñados para resistencias de 21, 24 y 28 MPa utilizando agregados de la cantera de Pifo y cemento Tipo GU. Estableciendo que la RNA predice satisfactoriamente la resistencia a la compresión y módulo de elasticidad del hormigón obteniendo un valor de R^2 para el " f_c " igual a 95.12% y para el "Ec" de 92.20% entre los resultados pronosticados con los resultados reales para mezclas de 21, 24 y 28 MPa; validando su uso para la predicción de estas propiedades en el hormigón.

ARTICLE HISTORY

Received: 18/09/2023

Received after revision: 18/10/2023

Approved: 18/11/2023

Accepted: 15/1/2024

KEYWORDS

Artificial Neural Networks (RNA), Neural Fitting (nftool), Blend Design, Compression Resistance (f_c), Modulus of Elasticity (Ec).

ABSTRACT

This research work outlines the development of an artificial intelligence model based on Artificial Neural Networks (ANNs) designed to forecast the Compressive Strength " f_c " and Elastic Modulus "Ec" of concrete. The research methodology was carried out in three stages: The Delta Stage where a comprehensive database was created, comprising data from various concrete mix designs. This database included aggregate characterization, mix proportions, compressive strength, and elastic modulus. These concrete mixes were produced using GU-type cement without additives and aggregates sourced from quarries in the Metropolitan District of Quito. Data were gathered from research projects conducted at different universities across the country and from commercial tests performed at the Materials Testing and Models Laboratory of the Faculty of Engineering and Applied Sciences. The Theta Stage involved the development of the ANN using MATLAB software and the Neural Fitting "nftool" tool for training, validation, and testing. Key performance indicators, such as the Pearson correlation coefficient "R", were employed during the evaluation stage, while the coefficient of determination " R^2 " was used to gauge the ANN's efficiency. Finally, in the Gamma Stage, the ANN's predicted results were compared with the actual concrete Compressive Strength " f_c " and Elastic Modulus "Ec" values, which were obtained through tests on 20 concrete cylinders designed for strengths of 21, 24, and 28 MPa. These cylinders were produced using aggregates from the Pifo quarry and GU-type cement. The results demonstrated that the ANN successfully predicted both compressive strength and elastic modulus, achieving an R^2 value of 95.12% for " f_c " and 92.20% for "Ec" in the case of mixtures with strengths of 21, 24, and 28 MPa. This validates the ANN's applicability for predicting these concrete properties.

1. INTRODUCCIÓN

El hormigón es el material más usado por la industria de la construcción en el Ecuador, debido a sus propiedades de durabilidad y resistencia a lo largo del tiempo, y en conjunto con el acero de refuerzo ha logrado componer el 91.8% de las estructuras que se construyen en el país [1]. Su fabricación se realiza a partir de la mezcla de componentes como el agua, cemento, agregado fino y grueso; donde las proporciones de cada componente se ven afectadas directamente por el método de dosificación a utilizarse, influyendo principalmente en la resistencia a la compresión y otras propiedades mecánicas del hormigón como el módulo de elasticidad [2].

Es así como la resistencia a la compresión del hormigón evoluciona con el tiempo, y con su valor se realizan los diseños estructurales de obras civiles; mismo que se obtiene al realizar el ensayo estandarizado que se determina después de un periodo de curado en probetas cilíndricas, y se la mide cuando ha alcanzado una edad de 28 días después de realizada la mezcla [3].

Mientras que el módulo de elasticidad del hormigón, representa la rigidez de este material ante una carga impuesta sobre el mismo, y desde el punto de vista de diseño y análisis de estructuras de hormigón armado, esta propiedad y su correcta estimación nos permite alcanzar análisis estructurales más acertados en cuanto a estudios de rigidez lateral de piso y el cálculo de derivas de piso en una estructura; cuyo valor se determina la mayoría de veces a través de ecuaciones impuestas por el American Concrete Institute (ACI) [4].

Por tal razón se han realizado estudios enfocados en conocer las propiedades del hormigón, utilizando agregados provenientes de ciertos lugares de nuestro país, y estableciendo experimentalmente ecuaciones "Ecuación 1" para obtener el módulo de elasticidad, con la finalidad de tener un valor confiable y más apegado a la realidad para el dimensionamiento de estructuras de hormigón armado; puesto que las ecuaciones propuestas por el comité ACI.318.19 (NEC-15) son ajustadas a las regiones de Estados Unidos, en las cuales tanto la calidad como características de los agregados y materiales son muy diferentes a los del país [5].

Ecuación 1

Fórmula para el cálculo del módulo de elasticidad

$$E_{CNEC} = 4700 * \sqrt{f'c} (MPa)$$

Por otro lado, la incorporación de Inteligencia Artificial (IA) en la investigación para predecir eventos de cualquier índole siempre ha despertado interés en los seres humanos, es así como la aplicación de Redes Neuronales Artificiales permite adaptar paradigmas naturales y aplicarlos para la solución práctica de problemas. En Ingeniería, pueden ser adaptadas en modelos con información histórica y ser procesados por un computador para predecir el comportamiento o resultado sin tener la necesidad de descubrir estrechas

relaciones matemáticas entre variables que resultan complejas para el ser humano [6].

Es por esto que Villegas [7] afirma que las Redes Neuronales Artificiales (RNA) son un modelo de cómputo que, por su estructura, trata de imitar el comportamiento del cerebro de forma similar al de las neuronas biológicas, a través del procesamiento de datos de entrada mediante algoritmos matemáticos que generen un resultado que obedezca al aprendizaje de dicho proceso; obteniendo una red que identifica características y resultados a valores de respuesta de acuerdo al historial de datos que se registran. A nivel nacional se han realizado pocas investigaciones utilizando RNA aplicados al campo de ingeniería civil, como es la investigación de López & Ontaneda [8] titulada "Diseño de mezclas de hormigón aplicando redes neuronales artificiales para diferentes agregados del cantón Quito, provincia de Pichincha", desarrollaron una herramienta para estimar cantidades de los componentes de hormigón para diversas resistencias a través de las RNA utilizando el software Matlab y Java, para lo cual realizaron una base de datos compuesto por los diseños de hormigón convencionales con cemento tipo GU y sin aditivos, demostrando que el uso de RNA es una alternativa viable para el diseño de mezclas de hormigón, pues estimaron dosificaciones con un coeficiente de determinación del 96.57% para hormigones de resistencias entre 21 y 28 MPa.

La presente investigación tiene objetivo proponer un modelo matemático mediante el uso de redes neuronales artificiales que permita la predicción de la resistencia a la compresión y módulo de elasticidad del hormigón, pues en el laboratorio de ensayos de materiales y modelos de la Universidad Central del Ecuador y demás universidades existe gran cantidad de estudios relacionados a la obtención de las propiedades $f'c$ y E_c , mismos que han utilizado agregados de distintas canteras y cemento portland tipo GU, cuyos resultados se encuentran almacenados y sin uso. Conformando una base de datos histórica de diseños de mezclas de hormigón que se utilizaron en el desarrollo de la estructura de la RNA más apropiada para la predicción de las propiedades $f'c$ y E_c , cuyos modelos se evaluaron a través de los coeficientes de correlación Pearson "R" el cual indica la relación existente entre las variables de entrada y salida. Y finalmente se comprueba los valores pronosticados y eficiencia del modelo con ensayos de resistencias a la compresión y módulo de elasticidad de probetas cilíndricas de hormigón cuyo indicador de validaciones el coeficiente de determinación R^2 que nos indica la relación entre los valores experimentales y pronosticados del modelo.

Siendo este modelo matemático un aporte para aquellos diseñadores que utilizan fórmulas empíricas para estimar el módulo de elasticidad y aplicarlo en diseños estructurales de proyectos de hormigón armado, pues los resultados que

obtendrán serán a partir de datos reales en función de las características de los materiales que se pretende utilizar, y así obtener un comportamiento adecuado y lo más cercano a la realidad en sus modelos estructurales.

Dentro del presente proyecto de investigación uno de los aspectos más importantes y limitaciones considerados en la creación de la herramienta Informática, es el lugar de procedencia de los materiales que conforman el hormigón; puesto que el espectro de datos que se utilizó considera únicamente a ensayos de hormigones con agregados pertenecientes al distrito metropolitano de Quito cuya dosificación sea prevista para 21, 24 y 28 MPa, exenta de aditivos o cualquier otro material en su composición y únicamente que hayan utilizado cementos portland tipo GU.

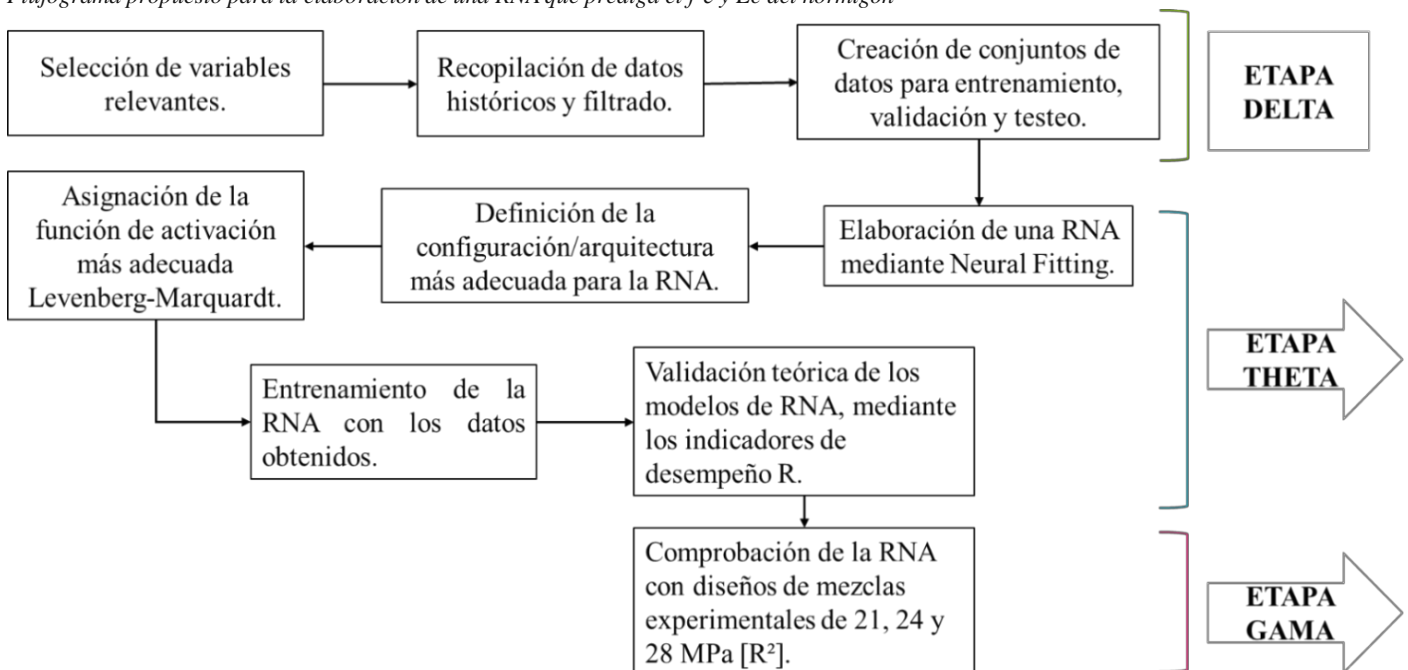
2. MÉTODO

Se detalla el proceso por el cual se llevó a cabo el desarrollo de la Red Neuronal Artificial más adecuada que permita la predicción de valores como la resistencia a la compresión y módulo de elasticidad del hormigón a la edad de 28 días con el menor error posible al momento de validarla a través de ensayos normalizados de probetas cilíndricas.

La elaboración de la RNA consiste en una serie de procesos a seguir, mismos que se explican a lo largo de esta sección y que se utilizan de manera general para la predicción de variables a través de RNA presentado gráficamente en la Figura. 1

Figura. 1

Flujograma propuesto para la elaboración de una RNA que prediga el $f'c$ y Ec del hormigón



Nota: En la imagen se indica el procedimiento realizado para la elaboración de esta investigación.

2.1 Etapa Delta

Se realiza la selección de las variables influyentes en las propiedades del hormigón como es la $f'c$ y Ec , tomando en cuenta los estudios de López & Ontaneda [8] y Santamaria, Morales & Pilaluisa [9] los cuales indican el análisis de sensibilidad de variables y los parámetros que tienen mayor incidencia en la determinación de la resistencia a la compresión y módulo de elasticidad del hormigón. Teniendo así los parámetros más relevantes

con lo que se conformó y depuró el espectro de datos en el software Microsoft Excel, y cuyos valores fueron tomados de diferentes ensayos comerciales e investigaciones cuyo objetivo ha sido la obtención del módulo de elasticidad y la resistencia a la compresión del hormigón para diferentes dosificaciones utilizando agregados de las principales canteras del distrito metropolitano de Quito, observando en la Tabla. 1 las referencias y procedencia de la información tomada para esta investigación son cuanto a la elaboración de la base de datos.

Tabla. 1

Referencias de datos utilizados en la investigación

N°	UNIVERSIDAD	TITULO	AUTOR
1	Escuela Politécnica del Ejército	Módulos de elasticidad y curvas de esfuerzo deformación. en base a la compresión del hormigón a 21. 28. 35 MPa	Sofía Elizabeth Herrería Cisneros. Fausto Marcelo Villegas Dávila
2	Universidad Católica del Ecuador	Determinación de la ecuación del módulo de elasticidad representativo para la provincia de pichincha. en muestras de cilindros de hormigón con materiales de la mina de san Antonio de pichincha.	Israel Jiménez. Alexis valladares
3	Universidad Católica del Ecuador	Determinación de la ecuación del módulo de elasticidad del hormigón en la provincia de pichincha elaborado con materiales de la mina Holcim, ubicada en la parroquia pifo y cemento Holcim	Londoño Doménica. Terán Wilson
4	Universidad Central del Ecuador	Módulo estático de elasticidad del hormigón. en base a su resistencia a la compresión: $f'_c = 21$ y 28 MPa. fabricado con materiales de la mina de Guayllabamba-pichincha y cemento Selvalegre	Morales Escobar Diego Alejandro. Ojeda Cueva Franklin Santiago. Rodríguez Narváez Diego David. Rosero Benavides Arturo Javier Asmal Iturralde Daniel. Andrés.
5	Universidad Central del Ecuador	Estudio del módulo de elasticidad estático del hormigón en base a la resistencia a la compresión ($f'_c = 21, 28$ MPa) fabricado con material de la mina de Pintag.	Ocaña Borja Jorge. Luis Perdomo Velásquez Alejandro. Antonio Pérez Casco Juan Carlos
6	Universidad Central del Ecuador	Caracterización del módulo estático de elasticidad del hormigón a partir de pruebas a compresión simple en probetas cilíndricas con diferentes agregados del cantón quito, provincia de pichincha	Paucar Paucar Mayra Alexandra. Sacasari Luzpa Grace Stephanie
7	universidad Central del Ecuador	Determinación del módulo de rotura y deflexiones en vigas de hormigón, fabricado con materiales procedentes de las canteras de pifo, San Antonio de pichincha y Guayllabamba	Morales Sandoval Edison Fernando. Morocho Jumbo José Antonio. Porras Abril Erick Alexander. Sánchez Reinoso Nelson Aníbal
8	Laboratorio de Ensayo de Materiales y Modelos	Ensayos comerciales	Universidad Central

2.1.1 Identificación de variables para la elaboración de la base de datos en el diseño de la RNA.

Para la elaboración de la base de datos se ocuparon resultados e información de ensayos comerciales e investigaciones realizados en el Laboratorio de Ensayo de Materiales y Modelos de la Universidad Central del Ecuador, así como también información de proyectos de investigación realizados en las diferentes Universidades del país relacionados al objeto de estudio.

La información obtenida presentada en la Tabla. 2, corresponden a la caracterización de los agregados, tipo de cemento, dosificación, propiedades del hormigón en estado fresco como el asentamiento y hormigón en estado endurecido como resistencia a la compresión y módulo de elasticidad.

Tabla. 2*Parámetros obtenidos de diseño de mezclas*

INDICADOR DE MEDICIÓN	SIMBOLOGÍA	UNIDAD
Cantidad de Cemento	C	
Cantidad de Agua.	W	
Cantidad de Agregado Arena	A	Kilogramos (Kg)
Cantidad de Agregado Grueso	R	
Módulo de finura arena	MFA	
Módulo de finura ripio	MFR	Adimensional
Tamaño nominal máximo ripio	TNM	Milímetros (mm)
Densidad suelta arena (DSA)	DSA	
Densidad suelta ripio (DSR)	DSR	
Densidad compactada arena (DCA)	DCA	Gramos por centímetro cúbico (g/cm ³)
Densidad compactada ripio (DCR)	DCR	
Densidad aparente arena (DAR)	DAA	
Densidad aparente ripio (DAR)	DAR	
Capacidad de absorción arena (CAA)	CAA	
Capacidad de absorción ripio (CAR)	CAR	Porcentaje (%)
Abrasión (AB)	AB	
Resistencia a la compresión f'c (28 días)	f'c	MPa
Módulo de elasticidad (28 días)	Ec	MPa

Nota. La tabla muestra los parámetros obtenidos de la recopilación de información de ensayos comerciales y proyectos de investigación relacionados a la resistencia a la compresión y módulos de elasticidad del hormigón.

Una vez realizada la recopilación de información se obtuvo el siguiente resumen del espectro de datos que se indica en la Tabla 3.

Tabla. 3*Numero de datos obtenido en la recopilación*

F'c (MPa)	Nº Datos
21	186
24	103
28	112
35	24
Total	425

Nota. En la tabla se indica el número total de datos obtenidos y recopilados de acuerdo con cada resistencia.

Con la información recopilada se realiza la depuración o filtrado del espectro de datos a través de la identificación de datos atípicos y uso de rangos aceptables a través de:

Criterio del rango máximo: La primera clasificación se realizó con la recomendación de la norma ASTM-C31 cuya adaptación a la normativa ecuatoriana es NTE-INEN-1573 [10], que nos indica los rangos de variación aceptables de acuerdo con la Figura. 2.

Figura. 2*Rango de variación de resistencia de cilindros individuales*

	Coeficiente de variación (ver nota 12)	Rango aceptable de variación de resistencia de cilindros individuales (ver nota 12)	
		2 cilindros	3 cilindros
Cilindros de 150 por 300 mm			
Condiciones de laboratorio	2,4%	6,6%	7,8%
Condiciones de campo	2,9%	8,0%	9,5%
Cilindros de 100 por 200 mm			
Condiciones de laboratorio	3,2%	9,0%	10,6%

Nota: En la imagen se puede observar el coeficiente de variación para ensayos de resistencia a la compresión en cilindros de hormigón. NTE INEN 1573 [10].

Método de Tukey: Conocido también como diagrama de caja y bigotes, [11] lo identifica como un gráfico que presenta la tendencia central, dispersión y la simetría de un conjunto de datos, además que permite identificar elementos atípicos de manera sencilla.

Finalmente, luego de realizar el proceso de depuración de datos se resume el espectro de datos a utilizarse para el f'c y Ec de la siguiente manera como se indica en la Tabla. 4.

Tabla. 4.

Datos a utilizarse luego del filtrado para $f'c$ y Ec .

F'c	Nº Datos
21	98
24	54
28	60
Total	212

Nota. La tabla muestra el número total de datos obtenidos para cada resistencia luego de realizar el proceso de filtrado a utilizarse en la RNA para la predicción de la resistencia a la compresión y módulo de elasticidad.

2.1.2 Capa de entrada (INPUT)

Para definir las variables de la capa de entrada que se utilizaron en la programación de la Red Neuronal Artificial se tomó en cuenta los parámetros y análisis de sensibilidad detallados en el apartado 2.1., como es la caracterización de los agregados y dosificación, que son parámetros que influyen en la resistencia a la compresión y módulo de elasticidad del hormigón, dándonos un total de 17 variables. Los parámetros a ocupar en la capa de entrada se presentan en la Tabla. 5.

Tabla. 5

Variables capa de entrada

N.º	Capa	Variable	Unidad
1		Resistencia a la compresión de diseño ($f'cd$)	MPa
2		Módulo de finura arena (MFA)	Adimensional
3		Módulo de finura ripio (MFR)	
4	ENTRADA	Tamaño nominal máximo ripio (TNM)	Milímetros (mm)
5		Densidad suelta arena (DSA)	Gramos por centímetro cúbico (g/cm^3)
6		Densidad suelta ripio (DSR)	
7		Densidad compactada arena (DCA)	
8		Densidad compactada ripio (DCR)	Porcentaje (%)
9		Densidad aparente arena (DAR)	
10		Densidad aparente ripio (DAR)	Kilogramo (kg)
11		Capacidad de absorción arena (CAA)	
12		Capacidad de absorción ripio (CAR)	
13		Cantidad de Cemento (C)	
14		Cantidad de Agua (W)	
15		Cantidad de Agregado Arena (A)	
16		Cantidad de Agregado Grueso (R)	
17		Tipo de cemento	Adimensional

Nota. La tabla muestra las variables de entrada que se ocuparán para realizar la programación de la RNA.

2.1.3 Capa de salida (OUTPUT)

De acuerdo al objeto de estudio se definió las 2 variables de la capa de salida que se presentan en la Tabla. 6 correspondientes a las propiedades del hormigón en estado endurecido como son la resistencia a la compresión y módulo de elasticidad del hormigón a la edad de 28 días. (Anexo Tabla 6)

2.2 Etapa Theta

Se presenta lo realizado en cuanto a la programación y creación de la Red Neuronal Artificial en el software Matlab y su herramienta Neural Fitting "nftool", en la que se implementó las variables de entrada y salida, estructura, tipo, funciones de activación, entrenamiento, simulación y prueba con un correcto desempeño para diferentes RNA, verificando el coeficiente de Correlación "R" que indica el error en los resultados.

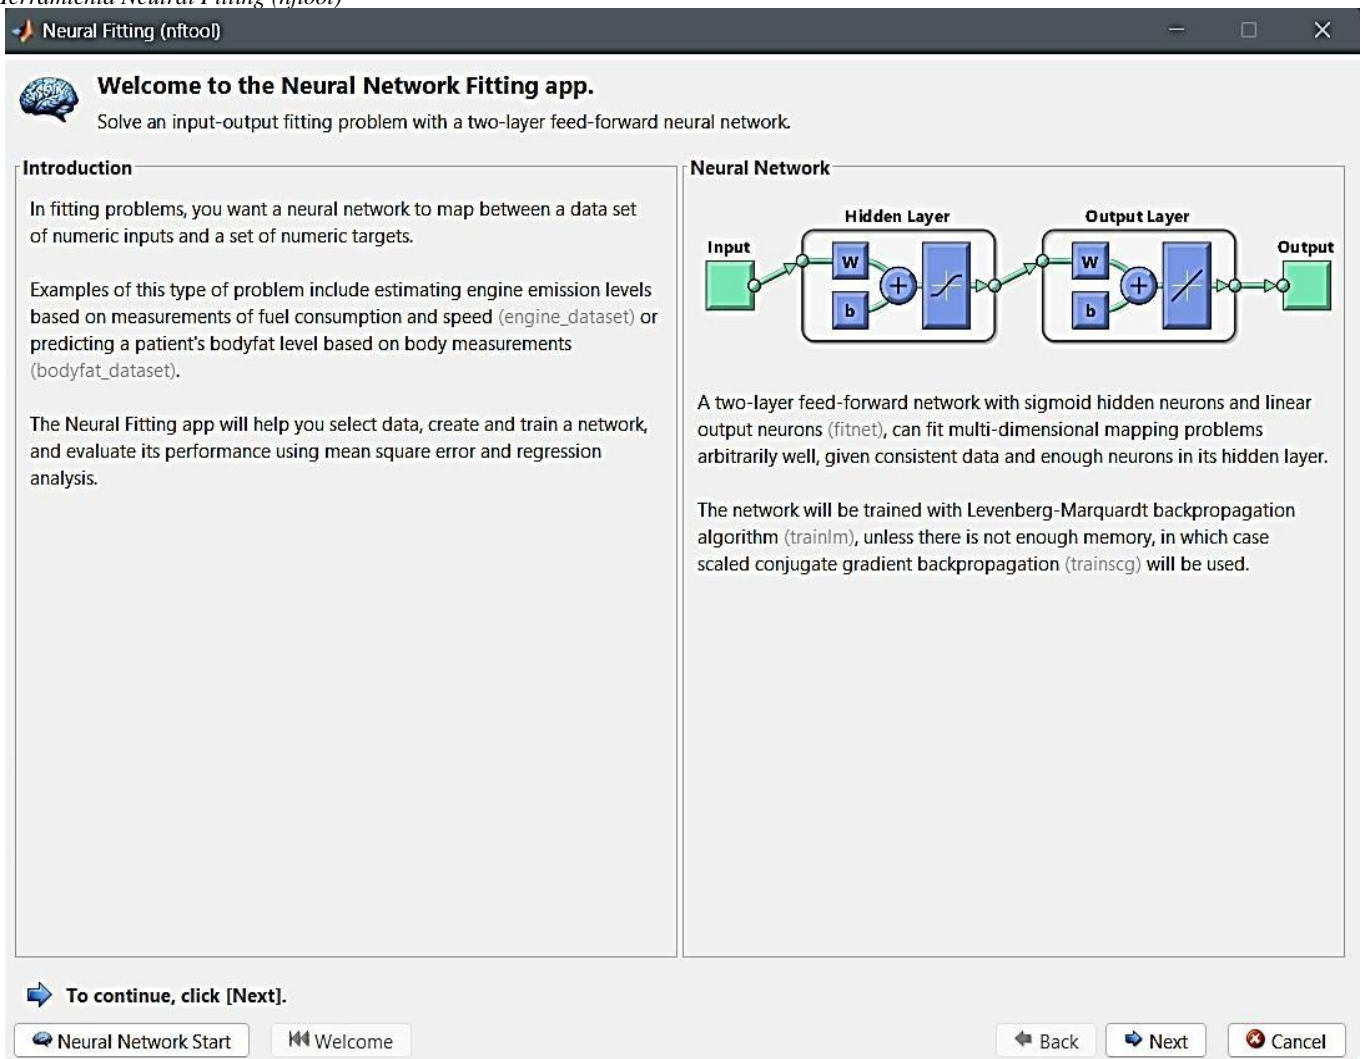
2.3 Construcción, entrenamiento y validación de la RNA

Se realizó la construcción de la red neuronal artificial (RNA) a través de MATLAB, con la herramienta Neural Fitting "nftool" de toolbox como se indica en la Figura. 3. Esta herramienta es una red neuronal multicapa estándar predeterminada que considera la interrelación de los parámetros y el error de estimación (Multilayer perceptron feed-forward backpropagation MLPFFB) de dos capas (entrada y salida) tipo feed-forward usada como función de aproximación para predicción de datos a partir de información real, con una capa oculta que utiliza la función sigmoideal de activación y una función lineal para la capa de salida teniendo los siguientes parámetros de la RNA:

Feed-forward: Implica que las conexiones van en sentido hacia adelante y es unidireccional.

- **Perceptrón Multicapa:** Posee en su arquitectura neuronas agrupadas en varios niveles o capas intermedias entre las neuronas de entrada y salida.
- **Backpropagation:** Es un tipo de aprendizaje por corrección de error supervisado, que es el recomendado para redes multicapa, ya que se proporciona una reactualización de los pesos sinápticos usados por las neuronas para emitir un resultado en función de la diferencia de valores deseados (experimentales) y los obtenidos en la salida (pronosticados).

Figura. 3
Herramienta Neural Fitting (nftool)

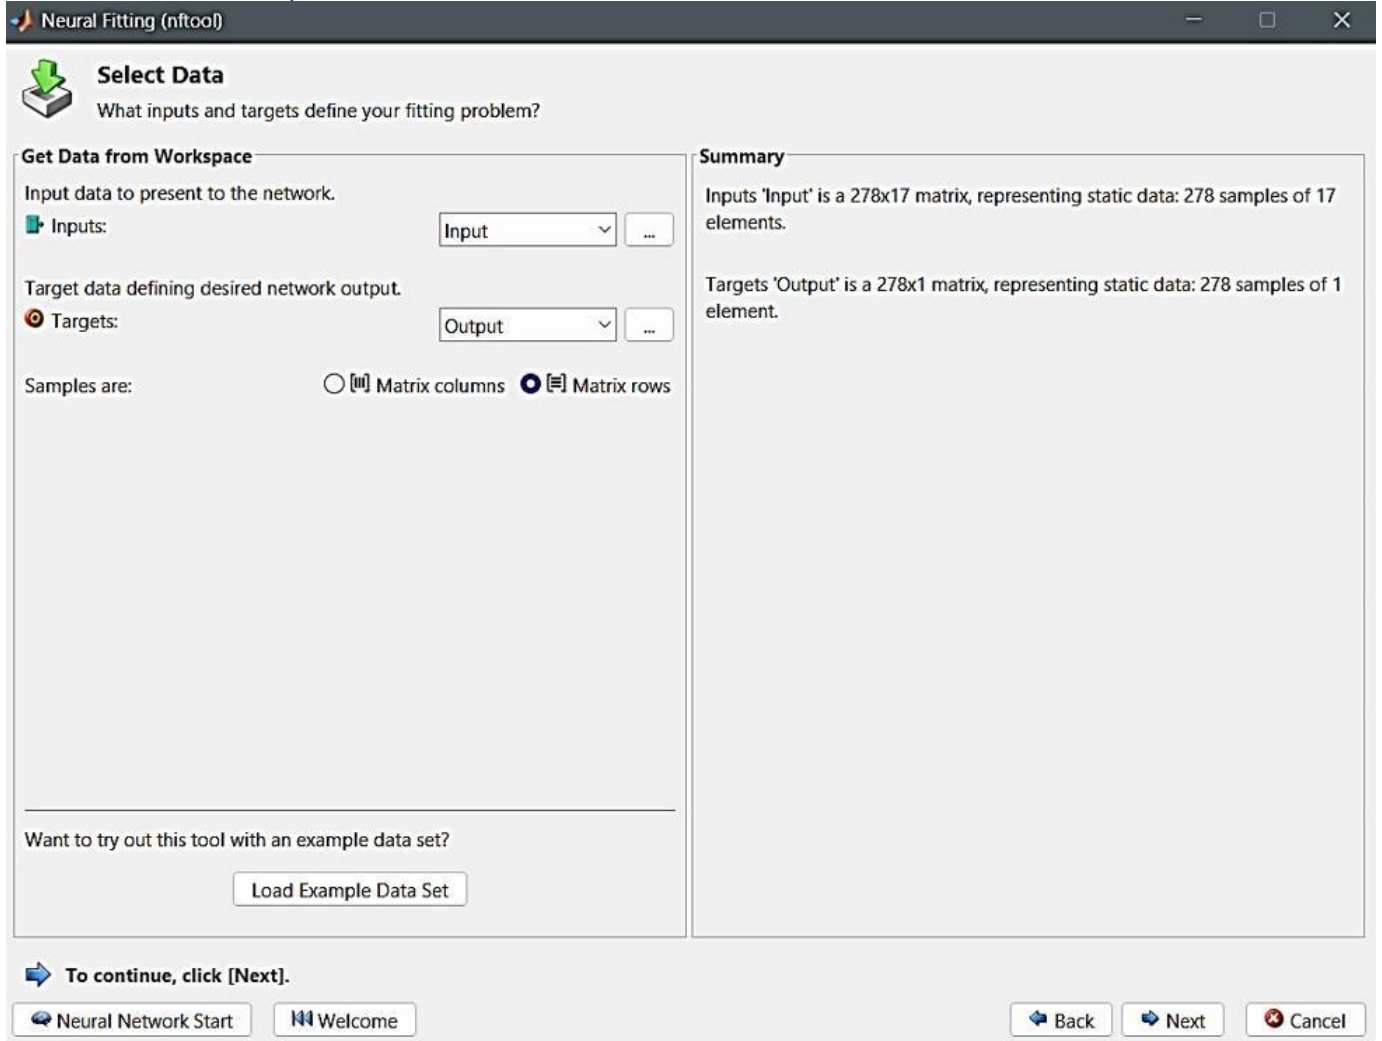


Nota: En la imagen se observa la arquitectura de la red neuronal y el tipo de red que se utilizara. Matlab [12].

Definida la arquitectura de la red neuronal a utilizarse, se obtiene la siguiente interfaz como se muestra en la Figura. 4, donde se selecciona la matriz de entrada o inputs y la matriz de salida o targets. Tomando en

consideración las variables como se describió en los apartados anteriores donde se determinó los parámetros de entrada establecidos en la Tabla. 5 y los parámetros de salida establecidos en la Tabla.

Figura. 4
Selección de datos de entrada y salida



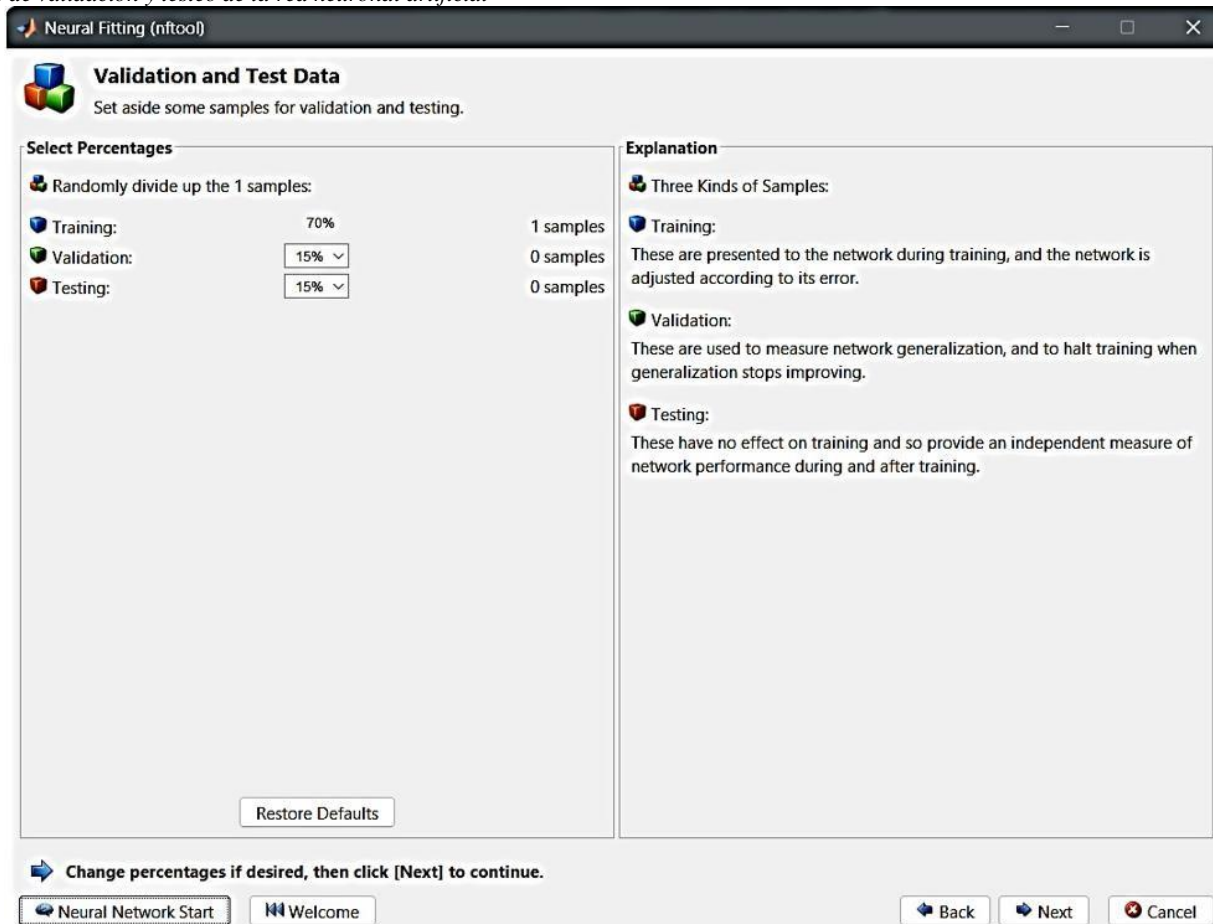
Nota. Input Data. Se seleccionan los datos que se requieren como entrada para llevar a cabo el entrenamiento. Target Data: Se seleccionan los datos con los que se quiere llevar a cabo el entrenamiento. Matlab [12].

2.3.1 Entrenamiento Red Neuronal Artificial (RNA)

Siguiendo con la creación de la red neuronal se tiene la ventana de validación y test. Donde el porcentaje para el entrenamiento es del 70% del número total de datos ingresados (Inputs – Targets), el porcentaje elegido para

la validación es del 15% de la muestra y el 15% restante se utilizará para el testeo. Ayudándonos a medir la generalización de la red y parar el entrenamiento cuando la generalización deja de mejorar antes de que se genere el sobre entrenamiento, como se indica en la Figura. 5.

Figura. 5.
Porcentaje de validación y testeo de la red neuronal artificial



Nota: Se observa la interfaz y porcentajes elegidos para la validación y testeo de la Red neuronal. Matlab [12].

Posteriormente se tiene la arquitectura de la red neuronal artificial, donde se selecciona el número idóneo de capas ocultas y el número de neuronas. Por default, el número de neuronas en la capa oculta es de 10 el cual puede ser modificado para mejorar el desempeño en la predicción de la red.

Los elementos que conforman la red neuronal para el caso de estudio son 17 capas de entrada como variables predictoras procesadas con una capa oculta de 10 neuronas propuestas para experimentación y 1 capa de salida correspondiente al valor estimado de resistencia a la compresión y módulo de elasticidad del hormigón según sea el caso, como se puede visualizar en la Figura. 6. (Anexo Fig.6)

Una vez definida la arquitectura de la red neuronal se procede a seleccionar el algoritmo de entrenamiento dentro la herramienta Neural Fitting (nftool) donde se tiene las siguientes opciones; Levenberg-Marquardt, Bayesian Regularization y Scaled Conjugate Gradient. Donde se utilizó el algoritmo de Levenberg-Marquardt backpropagation (Trainlm).

Tomando en cuenta; según Arias [13], este algoritmo es el proceso por el cual se basa una RNA con aprendizaje backpropagation que consiste en la obtención de

resultados a través del ajuste de curvas con el método de mínimos cuadrados no lineales, de manera que el software utiliza este principio para obtener la solución más adecuada a través de este método iterativo, teniendo las siguientes ventajas:

- Posee una mejor confiabilidad y desempeño en cuando al tiempo de entrenamiento y predicción de los resultados
- Este modelo permite manejar múltiples parámetros libres que no se conoce con precisión su relación
- A pesar de que ocupa más memoria del ordenador, es la que emite resultados en menor tiempo

Además, dentro de los parámetros de la red se tiene la Función de transferencia en la capa oculta Hyperbolic tangent sigmoid (tansig) y en la Función de transferencia para la capa de salida Función lineal (purelin):

- **Tansig:** Se utiliza debido a que los pesos sinápticos pueden obtener valores positivos y negativos, de manera que se puede con esta implementar la incidencia de las variables con respecto a las capas ocultas.

- **Purelin:** Se utiliza luego de que pase la capa oculta para que a medida que se disminuya la participación entre estas neuronas, se mantenga la sensibilidad lineal pues todas estas propiedades son de importancia para el modelo.

El desempeño en la predicción de la red neuronal artificial se realizó utilizando los parámetros de coeficiente de correlación R_{yel} promedio de los errores al cuadrado MSE. Lo expuesto anteriormente dentro de Matlab y su codificación se puede identificar en la Figura 7. (Anexo Fig.7)

2.3.2 Validación Red Neuronal Artificial (RNA)

Para la validación de la red neuronal artificial y verificación de la exactitud del modelo de predicción de la resistencia a la compresión y módulo de elasticidad del hormigón se utilizará los indicadores de desempeño generados en la herramienta Neural Fitting (nftool) denominado Error Cuadrático Medio (MSE) y el coeficiente de correlación de Pearson R.

- **El coeficiente R** mide la correlación entre los datos obtenidos por el modelo (Outputs) y los datos reales (Targets) donde un valor de $R=1$ representa una predicción exacta donde los resultados obtenidos del modelo Outputs son iguales a los datos reales Targets, caso contrario valores de R cercanos a 0 nos indica que el modelo no es adecuado para la predicción requerida.

- **Error Cuadrático Medio (MSE)** donde el error es la diferencia en los datos obtenidos del modelo outputs y los datos reales targets. Bajos valores en el MSE indican que el modelo tiene una aproximación adecuada

Una vez entrenada la red neuronal aparecerá la siguiente interfaz de entrenamiento como se muestra en la Figura 8. (Anexo Fig.8)

Gracias a la ventana de entrenamiento se observa los resultados y graficas que se describen a continuación:

- **Performance:** Muestra el error cuadrático medio (MSE) en función del número de iteraciones como se muestra en la Figura. 9 (Anexo Fig.9) donde si el valor del MSE es cercano a 0 nos indica un correcto modelo de red neuronal.

- **Regression:** En la Figura. 10 (Anexo Fig.10) se puede observar la recta de regresión lineal para cada conjunto de entrenamiento, validación, testeo y otro para el conjunto de datos total. Si el valor de R se aproxima a uno, la correlación tendrá mayor dependencia entre salida y la salida deseada.

Como se pudo observar la RNA presenta un coeficiente de Pearson igual a 0.94967 que garantiza la validez del modelo ya que estadísticamente se aproxima a 1, esto posteriormente se comparará con los resultados.

2.4 Etapa Gamma

Se validó la RNA más adecuada cuya distribución de resultados implicó el menor % error o coeficiente R y R^2 para la predicción de las propiedades en cuestión, a través del diseño de hormigón para 21, 24 y 28 MPa, con agregados del cantera de Holcim-Pifo y cemento Holcim tipo GU; de modo que se obtuvieron sus propiedades de resistencia a la compresión y módulo de elasticidad real, comparándolos con los valores pronosticados por la red neuronal artificial, evidenciando la eficiencia del modelo. La selección y motivo de utilizar estos agregados de la cantera antes mencionada, se debe a que son materiales comúnmente utilizados en la construcción dentro del distrito Metropolitano de Quito y también a que la RNA está elaborada con una base de datos con las propiedades de los agregados de las anteras ubicadas dentro del mismo distrito.

Y el motivo de emplear este tipo de cemento se debe a que es utilizado en diferentes tipos de obra de construcción, además de que la base de datos de la RNA está elaborada únicamente con el tipo de cemento GU.

2.4.1 Ensayos de los agregados

Los ensayos que se realizan en los agregados fino y grueso son de suma importancia ya que permite experimentales de resistencia a la compresión y módulo de elasticidad del hormigón realizado en el laboratorio de Ensayos de Materiales de la Universidad Central del Ecuador.

Determinar las propiedades físicas y mecánicas de los materiales, y con los resultados obtenidos realizar el diseño de mezclas de hormigón, que sirven para la elaboración de probetas cilíndricas que luego de ser ensayadas se utilizan para la validación de la RNA con la finalidad de cumplir con los objetivos planteados.

Los ensayos se realizan de acuerdo con la normativa NTE INEN y ASTM; donde se efectuarán únicamente aquellos cuyos resultados tengan mayor incidencia en la determinación de la resistencia a la compresión y módulo de elasticidad del hormigón los cuales se definieron en la etapa Delta.

Realizando los siguientes ensayos de acuerdo a la normativa vigente:

- Ensayo de Granulometría - (NTE INEN 696).
- Ensayo de Abrasión - (NTE INEN 860).
- Densidad aparente suelta y compactada - (NTE INEN 858).

- Densidad Real (SSS) - (NTE INEN 856) y (NTE INEN 857).
- Capacidad de Absorción - (NTE INEN 856) y (NTE INEN 857).
- Contenido de humedad - (INEN 862).

Se presenta en la Tabla. 7 el resumen de las propiedades de los ensayos realizados en los agregados fino, grueso y cemento procedentes de la cantera Holcim – Pifo. (Anexo Tabla 7).

2.4.2 Diseño de mezclas

Se realiza el diseño de mezclas mediante el método de densidad máxima ya que en el medio existen agregados gruesos y finos que no cumplen con los requisitos para ser utilizados en el diseño de hormigones por el A.C.I., en los que su granulometría, no están dentro de los límites especificados por la curva granulométrica [14]. La principal característica del método de Densidad Máxima es el de utilizar la mínima cantidad de pasta para obtener un hormigón de buena calidad, para lo cual se debe realizar una correcta combinación de agregados que deje el menor porcentaje de vacíos posibles. Para obtener una correcta combinación de los agregados se lo realiza mediante un ensayo de Densidad Óptima de los Agregados.

La elaboración del hormigón en esta investigación se la realiza bajo la norma NTE INEN 1855-2 [15] y la toma de muestras bajo la norma NTE INEN 1763 [16], Para lo cual se elaboró 10 probetas cilíndricas de 150x300mm para determinar el módulo de elasticidad y 10 probetas de 100x200mm para determinar la resistencia a la compresión; esto por cada resistencia especificada de 21, 24 y 28 MPa dándonos un total de 60 probetas, las cuales se ensayaron a la edad de 28 días para obtener el $f'c$ y E_c experimental o real con la finalidad de comparar con los $f'c$ y E_c pronosticados por la red neuronal artificial.

2.4.3 Ensayos de resistencia a la compresión y módulo de elasticidad del hormigón

La obtención experimental del módulo de elasticidad del hormigón se lo realiza en base a la norma A.S.T.M. C. 469-94 “Método Estándar de Ensayo para determinar el módulo estático de elasticidad y relación de Poisson del hormigón en compresión” y para la obtención de la resistencia a la compresión del hormigón se realiza bajo la norma NTE INEN 1573 [10] - ASTM C-39.

Debido a la composición heterogénea de los materiales que conforman el hormigón, esta presenta una variación de resultados en la resistencia a la compresión y módulo de elasticidad del hormigón, es decir las muestras tomadas de una misma mezcla difícilmente se obtendrán resultados iguales.

Por tal motivo para obtener un valor representativo de los ensayos realizados a las probetas, generalmente se determina mediante la media aritmética; resistencia a la compresión media (f'_{cm}) y módulo de elasticidad medio (E_{cm}) de los n valores de rotura la cual no toma en cuenta la dispersión de los valores de resistencia y módulo obtenidos, y esto no refleja la verdadera calidad del hormigón a ser estudiado. Por tal razón se adoptó el concepto de resistencia y módulo de elasticidad característico del hormigón, que es una medida estadística que toma en cuenta el valor de la media aritmética (f'_{cm} y E_{cm}) de las roturas de las diversas probetas y también la desviación estándar de la serie de valores como se puede observar en la Tabla. 8. (Anexo Tabla 8).

3. RESULTADO Y DISCUSIÓN

Se realizó varios modelos de redes neuronales artificiales para cada caso de estudio con la finalidad de obtener diferentes arquitecturas y escoger un modelo que nos genere los mejores resultados en cuanto a la predicción de resistencia a la compresión y módulo de elasticidad del hormigón.

A continuación, se indica la arquitectura de los 5 modelos de redes neuronales artificiales diseñados cuya aproximación fue la más satisfactoria en los resultados pronosticados; así también se muestra el número de neuronas en la capa de entrada, en la capa oculta, capa de salida, las funciones de activación que se han seleccionado y los coeficientes de regresión R de cada uno de los subconjuntos que la red neuronal crea por defecto para su correcto desempeño.

3.1 Resultados de modelos de RNA para Resistencia a la compresión $f'c$

De la Tabla. 9 se puede identificar que el coeficiente de determinación R^2 en las 5 RNA elaboradas, tienen un valor cercano a 1 indicando que existe una gran relación entre los valores pronosticados y los obtenidos experimentalmente, indicando que las RNA nos permite tener una gran precisión en la predicción de la resistencia a la compresión. Sin embargo, realizando un análisis detallado se establece que la red RNA_3 genera mejores resultados, seleccionándola como el modelo final de predicción para la resistencia a la compresión " $f'c$ " de la presente investigación. Además, se puede identificar que no necesariamente al tener el coeficiente de Pearson R más cercano a 1, nos emite mejores resultados la RNA. Anexo Tabla 9.

La Figura. 11 (Anexo Fig.11) indica en sus gráficas las correlaciones lineales y su tendencia en cada uno de los procesos de la RNA, indicando el coeficiente de Pearson tanto para el entrenamiento, validación y testeado de la red; los cuales se generalizan con un valor de 0.96617, confirmando que la dispersión de datos posee una relación lineal alta, siendo este un indicador que la red se desempeña de manera correcta.

La RNA_3 posee en su arquitectura 20 capas, mismas que toman para el entrenamiento un porcentaje del 70% de los datos filtrados, 15% de ellos para la validación y el 15% restante para el testeo utilizando el algoritmo de Levenberg-Marquardt backpropagation.

3.2 Resultados de modelos de RNA para Módulo de elasticidad Ec

La Tabla. 10 muestra los diferentes tipos de arquitectura de los 5 modelos de redes neuronales diseñados y los resultados obtenidos de cada una. (Anexo Tabla 10).

La red neuronal cuyo coeficiente de determinación R^2 tiene el valor más cercano a 1, es la RNA_E5 con un valor de 0.9220 que garantiza la validez del modelo escogido; por lo tanto, este modelo será utilizado para predecir el módulo de elasticidad del hormigón de los tres diseños de mezclas elaboradas para la etapa de comprobación de la RNA.

A continuación, se muestra los resultados obtenidos de la RNA_5 en la Figura. 12 (Anexo Fig.12).

La Figura. 12 indica las correlaciones lineales entre los módulos de elasticidad del hormigón obtenidas de la red neuronal artificial mediante los tres subconjuntos (entrenamiento, validación y test) con los datos del conjunto TARGET respectivamente. El cuarto gráfico es una correlación lineal general de los resultados obtenidos del conjunto INPUT mediante la red neuronal y los datos del conjunto TARGET.

En el proceso de entrenamiento, se empleó el 70% de los datos y se puede observar una distribución próxima a la lineal con un coeficiente de correlación R igual 0.98047, en la validación se emplea el 15% de los registros disponibles, y se puede observar una distribución próxima a la lineal con un coeficiente de correlación R igual 0.96755. El 15% de los datos restantes se utilizan para el proceso de prueba o test; se puede observar que los datos se ajustan al modelo planteado con un coeficiente de correlación R igual 0.97429 lo cual indica que el modelo de red neuronal tiene un comportamiento aceptable.

También se observa el comportamiento general de la red neuronal, tomando todos los resultados obtenidos de los procesos de entrenamiento, validación y prueba, dado a conocer una correcta distribución por parte de los datos con un coeficiente de correlación R igual a 0.97726.

3.3 Comparación de $f'c$ mediante RNA y $f'c$ experimental

La Tabla. 11 muestra los resultados obtenidos de resistencia a la compresión pronosticados por la RNA y resistencia a la compresión experimental o real. (Anexo Tabla 11).

A continuación, se presenta el cálculo típico para determinar el porcentaje de error para la resistencia de 21 MPa, el cual es similar para las otras resistencias de 24 y 28 MPa.

$$\begin{aligned} \text{Error} (\%) &= \frac{F'c \text{ Experimental} - Fc \text{ Pronosticado}}{F'c \text{ Experimental}} \\ &\quad * 100 \\ \text{Error}(\%) &= \frac{24.50 - 21.25}{24.50} * 100 \\ \text{Error}(21MPa) &= 13.27\% \end{aligned}$$

Respecto a los porcentajes de error obtenidos, es importante señalar que estos deben ser lo más bajo posible, ya que cuanto menor sea el margen de error se tendrá mayor confiabilidad en los resultados, como es el caso de la predicción de la resistencia a la compresión donde se tiene un error promedio del 5.71% con un nivel de confiabilidad mayor al 94.29%.

A continuación, se presenta la Figura. 13 (Anexo Fig.13) donde se compara la Resistencia a la compresión experimental y la resistencia pronosticada por la RNA_3.

Se verifica que, con una correlación lineal entre la resistencia a la compresión obtenida en la RNA y la resistencia a la compresión experimental o real, en el eje de las abscisas se tiene la resistencia a la compresión experimental obtenida mediante la normativa A.S.T.M. C 39, y en el eje de las ordenadas la resistencia a la compresión pronosticada por la RNA. En la Figura. 14 se observa el comportamiento del modelo de red neuronal diseñada, donde se tiene un coeficiente de correlación R igual a 0.9512, lo que indica que la RNA realiza una predicción aceptable de la resistencia a la compresión de los diseños de mezclas de 21, 24 y 28 MPa ensayados con agregados de la cantera Holcim- Pifo y cemento Holcim tipo GU.

Con lo antes mencionado se puede concluir que el modelo es adecuado y confiable para realizar las predicciones de resistencia a la Compresión.

3.4 Comparación de E_c mediante RNA y E_c experimental

La Tabla. 12 (Anexo Fig.12) muestra los resultados obtenidos de módulo de elasticidad pronosticado por la RNA y módulo de elasticidad experimental o real. Anexo Tabla 12.

A continuación, se presenta el cálculo típico para determinar el porcentaje de error en la predicción del módulo de elasticidad de una resistencia de diseño de 21 MPa, el cual es similar para las otras resistencias de 24 y 28 MPa.

$$Error (\%) = \frac{F'c_{Experimental} - F'c_{Pronosticados}}{F'c_{Experimental}} * 100$$

$$Error(\%) = \frac{19887,98 - 20803}{19887,98} * 100$$

$$Error(21MPa) = 4.60\%$$

Respecto a los porcentajes de error obtenidos, es importante señalar que estos deben ser lo más bajo posible, ya que cuanto menor sea el margen de error se tendrá mayor confiabilidad en los resultados, como es el caso de la predicción de la resistencia a la compresión donde se tiene un error promedio del 4.60% con un nivel de confiabilidad mayor al 93.24%.

A continuación, se presenta la Figura. 15 donde se compara el módulo de elasticidad experimental como indica la norma ASTM 469 y el módulo de elasticidad pronosticado por la RNA_E5. De acuerdo a los resultados obtenidos se puede concluir que estos cumplen las expectativas propuestas, obteniendo un porcentaje de error bajo para cada resistencia especificada de 21, 24 y 28 MPa lo que valida la utilización de redes neuronales artificiales para la obtención de la propiedad del hormigón como es el módulo de elasticidad.

La correlación lineal entre los módulos de elasticidad obtenidos por la red neuronal RNA_E5 y el módulo de elasticidad experimental o real, en el eje de las abscisas se tiene los módulos de elasticidad experimentales obtenidos mediante la normativa A.S.T.M. C 469-94, y en el eje de las ordenadas los módulos de elasticidad pronosticados por la RNA. En la Figura. 16 se observa el comportamiento del modelo de red neuronal diseñada, donde se tiene un coeficiente de correlación R igual a 0.922, lo que indica que la RNA realiza una predicción aceptable del módulo de elasticidad de los diseños de mezclas de 21, 24 y 28 MPa realizados con agregados de la cantera Holcim-Pifo y cemento Holcim tipo GU.

Con lo antes mencionado se puede concluir que el modelo es adecuado y confiable para realizar las predicciones de módulo de elasticidad.

3.5 Comparación de E_c RNA y E_c NEC.15 – ACL.318.19

Con estos resultados pronosticados se evaluó su semejanza con respecto a los valores que recomienda la normativa ecuatoriana de la construcción, en cuanto al factor de relación con el cual se calcula el valor del módulo de elasticidad estimado. Anexo Tabla 13. (Anexo Tabla 14).

$$E_{cNEC} = 4700 * \sqrt{f'c} (MPa) \text{ vs } E_{cRNA} = 4112 * \sqrt{f'c} (MPa)$$

Como se observa existe una diferencia promedio de 12.505% con respecto a la NEC-15 y ACL.318.19, lo que indica un factor de relación en la ecuación de 4112 para la obtención de este parámetro estimado por la RNA. Coincidiendo con varios autores en la importancia de disminuir el valor estimado puesto que las propiedades de los agregados de nuestro país son diferentes a los tomados en cuenta por la normativa extranjera en sus fórmulas empíricas.

4 CONCLUSIONES

La recopilación de información y elaboración de la base de datos para la creación de la Red Neuronal Artificial tiene gran incidencia en el entrenamiento, validación y testeado de la Red Neuronal diseñada ya que esta sirve como entradas (Input) y salidas (Output) para la codificación de la RNA, puesto que no solamente importa la cantidad de datos, sino la calidad de estos, que para la investigación se midieron en base a su coherencia, relevancia y confiabilidad; a través del filtrado de datos realizado, eliminando valores atípicos para que los resultados obtenidos sean satisfactorios.

El uso de métodos estadísticos para la clasificación de datos es de suma importancia al implementar Redes Neuronales Artificiales independientemente del objetivo para el cual se las crea; el método de Tukey o diagramas de caja y bigotes es una excelente alternativa para identificar datos atípicos que puedan interrumpir con el desempeño de las RNA, puesto que al entrenarlas con datos que sean muy dispersos o con poca relación en sus variables y datos semejantes, resultará en la emisión de predicciones erróneas.

Mediante la utilización del software matemático Matlab se diseñó diversas redes neuronales artificiales para la predicción de resistencia a la compresión " $f'c$ " y módulo de elasticidad " E_c " del hormigón de tipo feed forward backpropagation utilizando la herramienta Neural Fitting (nftool) del toolbox con la implementación del algoritmo de Levenberg-Marquardt (Trainlm) para establecer relaciones

entre los conjuntos de datos de entrada con los de salida. Estos modelos fueron evaluados, utilizando indicadores de desempeño como el coeficiente de correlación R en la etapa de evaluación y el cuadrado del coeficiente de determinación R² en la etapa de comprobación.

En el estudio de predicción de propiedades del material, se evaluaron diferentes diseños de redes neuronales para predecir la resistencia a la compresión "f'c" y el módulo de elasticidad "Ec". El diseño óptimo para la predicción de f'c consta de 17 neuronas en la capa de entrada, 20 en la capa oculta y 1 en la capa de salida. Los resultados, obtenidos después de 9 iteraciones en las etapas de entrenamiento, validación y prueba, revelaron un coeficiente de correlación R de 0.96617 (Tabla.9) indicando la efectividad del modelo. En cuanto a la predicción de Ec, el diseño seleccionado incluye 17 neuronas en la capa de entrada, 13 en la capa oculta y 1 en la capa de salida. Los resultados de la red, obtenidos después de 8 iteraciones en las fases de entrenamiento, validación y prueba, mostraron un coeficiente de correlación R de 0.97726 (Tabla.10), lo que sugiere la viabilidad del modelo para predecir esta propiedad del material.

En la creación de modelos predictivos a través de Redes Neuronales Artificiales al utilizar una base de datos amplia y cuya calidad haya sido comprobada a través de un filtrado con métodos estadísticos; independientemente de la arquitectura que se utilice, los resultados que se obtendrán serán cercanos a los experimentales y sus coeficientes de correlación tenderán a la unidad, pero es responsabilidad del programador escoger el modelo que mejor se acople a su necesidad, tomando en cuenta la exactitud a la cual se requieren en el estudio.

En el proceso de comprobación de los valores pronosticados respecto a los valores experimentales o reales para la resistencia a la compresión "f'c" de las resistencias de diseño de 21, 24 y 28 MPa se obtuvieron errores del 13.27%, 2.27% y 1.58% respectivamente (Tabla. 11), y un coeficiente de determinación R² igual a 0.9512 (Figura. 14) lo que nos indica que la estructura de Red Neuronal Artificial diseñada tiene un error menor al 15% al realizar la predicción de la resistencia a la compresión del hormigón.

En el proceso de comprobación de los valores pronosticados respecto a los valores experimentales para el módulo de elasticidad "Ec" de las resistencias de diseño de 21, 24 y 28 MPa se obtuvieron errores del 4.60%, 5.71% y 9.98% respectivamente (Tabla. 12), y un coeficiente de determinación R² igual a 0.922 (Figura. 16) lo que nos indica que la estructura de Red Neuronal Artificial diseñada tiene un error menor al 10% al realizar la predicción del módulo de elasticidad del hormigón. (Anexo Fig.16).

La importancia de obtener coeficientes de determinación altos indica un buen desempeño de los modelos predictivos, puesto que estos disminuyen el error en sus resultados, confirmando la proximidad y confiabilidad de estos.

De acuerdo con el objeto de estudio de la presente investigación sobre la aplicación de redes neuronales artificiales en la predicción de la resistencia a la compresión y módulo de elasticidad del hormigón, se concluye que en base a los resultados se acepta la hipótesis planteada puesto que se obtuvieron resultados de predicción con un nivel de confiabilidad mayor al 94.29% (Tabla. 11) en la resistencia a la compresión "f'c" y mayor al 93.24% (Tabla. 12) en módulo de elasticidad "Ec".

Las redes establecidas poseen un aplicación práctica, pues su base de datos obtenida de tesis y ensayos de laboratorio fue considerada solamente con aquellas dosificaciones en las cuales no se ha modificado la granulometría de los agregados y tampoco se ha realizado la adición de otros componentes diferentes a los convencionales; evidenciando esto en la parte experimental donde al tener un agregado fino cuya tendencia tenía una gran cantidad de gruesos, se logró obtener datos muy precisos entre los pronosticados y los reales.

El módulo de elasticidad del hormigón es una característica muy importante para el diseño y desempeño de las estructuras, pero se obvia su obtención en los ensayos comerciales puesto que la normativa únicamente acepta su uso con la resistencia a la compresión, y su valor se calcula a través de fórmulas preestablecidas para agregados de alta calidad, los cuales no siempre se utilizan en la construcción de las obras en nuestro país, siendo la RNA que se realizó una herramienta a disposición de calculistas para la implementación de Ec más reales en sus diseños que se pretenda utilizar hormigón con agregados del cantón Quito.

Finalmente, se concluye que la utilización de redes neuronales artificiales es un método válido y de utilidad práctica que se puede utilizar en el ámbito profesional en el control de calidad del hormigón, para la estimación o predicción de la resistencia a la compresión y Módulo de elasticidad del hormigón luego del sustento teórico, implementación de la Red Neuronal Artificial, pruebas de laboratorio, análisis de resultados y comprobación. Así también su implementación en la obtención de otras propiedades que permitan o faciliten datos en base a información real a diseñadores que utilizan este material en sus diseños.

REFERENCIAS

- [1] El Universo, «El hormigón es el más usado para construir viviendas en Ecuador», El Universo, Quito, p. 1, Sep. 14, 2018.
- [2] C. Martínez y A. Hernández, «Predicción de resistencia a compresión del hormigón mediante redes neuronales haciendo uso del agregado de la cantera de Antonio Maceo», Revista de Arquitectura e Ingeniería, vol. 14, n. o 1, pp. 1-17, Feb. 2020, Cuba.
- [3] L. González, A. Guerrero, S. Delvasto y A. Ernesto, «Redes neuronales artificiales para estimar propiedades en estado fresco y endurecido, para hormigones reforzados con fibras metálicas», Cuaderno Activa, n. o 2016, pp. 95- 107, 2017.
- [4] E. Chele, «Determinación del módulo de elasticidad en hormigones estructurales de 21 y 28 MPa utilizando agregados de la cantera Agres», Universidad Estatal del Sur de Manabí, 2019. [Online]. Disponible en: <http://repositorio.unesum.edu.ec/handle/53000/2011>.
- [5] J. Calderón, Determinación del módulo de elasticidad del hormigón hidráulico de (f_c 21 y 24) MPa, con árido de la cantera Agre s.a. del cantón Portoviejo», tesis de Ingeniería Civil, Universidad Estatal del Sur de Manabí, 2021.
- [6] S. Siami-Namini and A. S. Namin, «Forecasting economics and financial time series: arima vs. lstm», Mar. 2018. Accessed: May 07, 2023. [Online]. Available: <http://arxiv.org/abs/1803.06386>
- [6] E. Fiesler and R. Beale, Handbook of Neural Computation, 1st ed. New York, Routledge, 1997.
- [7] M. A. Villegas, Aplicación de redes neuronales para la predicción de la resistencia a la compresión del concreto según el ensayo de esclerometría, tesis de pregrado, Universidad Peruana de Ciencias Aplicadas, Lima, 2019.
- [8] M. López Domínguez and J. Ontaneda Culqui, Diseño de mezclas de hormigón aplicando redes neuronales artificiales para diferentes agregados del cantón Quito, provincia de Pichincha, tesis de pregrado, Universidad Central del Ecuador, 2021. [online]. Disponible en: <http://www.dspace.uce.edu.ec/bitstream/25000/24621/1/UCE-FING-CIC-LÓPEZ MARCO-ONTANEDA JAIRO.pdf>
- [9] J. Santamaría, L. Morales y J. Pilaluisa, «Modelo para dosificación de mezclas de hormigón utilizando lógica difusa» figempa: Investigación y Desarrollo, vol. 1, n. o 1, pp. 54-61, 2018. doi: 10.29166/revfig.v1i1.815.
- [10] nte inen 1573, «Hormigón de cemento hidráulico. determinación de la resistencia a la compresión de especímenes cilíndricos de hormigón de cemento hidráulico». Norma técnica ecuatoriana, 2010, p. 5. [Online]. Disponible en: <http://normaspdf.inen.gob.ec/pdf/nte/1573.pdf>
- [11] I. Amón Uribe, Guía metodológica para la selección de técnicas de depuración de datos, tesis de maestría, Universidad Nacional de Colombia, Facultad de Minas, Escuela de Sistemas, 2010.
- [12] MathWorks, «Matlab». The MathWorks Inc, 2019.
- [13] J. C. Arias Molina, Propuesta de un analizador virtual (soft-sensor) para la predicción del punto final de ebullición del jet y t95 del acpm de la unidad de procesamiento de crudo u150 de la gerencia. Refinería de Barrancabermeja, Ecopetrol S.A., Universidad Industrial de Santander Facultad de Ingenierías Físicoquímicas, Escuela de Ingeniería Química, Bucaramanga, 2016. [Online]. Disponible en: <http://tangara.uis.edu.co/biblioweb/tesis/2016/164920.pdf>
- [14] D. Asmal, J. Ocaña, A. Perdomo y J. Pérez, Estudio del módulo de elasticidad estático del hormigón en base a la resistencia a la compresión ($f'_c = 21, 28$ MPa) fabricado con material de la mina de Píntag, Universidad Central del Ecuador, 2012.
- [15] nte inen 1855-2, «Hormigones. Hormigón preparado en obra. Requisitos». Norma Técnica Ecuatoriana, p. 3, 2015. 41 Ganchala E., et al.
- [16] nte inen 1763, «Hormigón de cemento hidráulico. Muestreo». Norma Técnica Ecuatoriana, pp. 1-12, 2010, [Online]. Disponible en: <https://www.normalizacion.gob.ec/buzon/normas/1338-3.pdf>

Anexos

Tabla 6

Variables capa de salda

N.º	Capa	Variable
1	SALIDA	Resistencia a la compresión del hormigón (f_c)
2	SALIDA	Módulo de elasticidad del hormigón (E_c)

Nota. Esta tabla muestra las variables de salida o resultados que se obtendrá producto de la RNA.

Tabla 7

Propiedades de los agregados y cemento

Descripción	Arena	Ripio	Unidad
D _s s	2,64	2,52	g/cm ³
% Absorción	2,52	3,31	%
% Humedad	0,43	0,78	%
D _{ap} Compactada	1,68	1,47	g/cm ³
D _{ap} Suelta	1,53	1,37	g/cm ³
Módulo Finura	3,07	5,82	ad
% óptimo de mezcla	41	59	%

Descripción	Valor	Unidad
Densidad óptima de la mezcla	1.78	g/cm ³
Densidad máxima de la mezcla	1.80	g/cm ³
Densidad del cemento	2.81	g/cm ³

Tabla 8

Valores de resistencia a la compresión y módulo de elasticidad característicos.

CILINDRO	21 MPa		24 MPa		28 MPa	
	RESISTENCIA	MÓDULO DE ELASTICIDAD ASTM 469	RESISTENCIA	MÓDULO DE ELASTICIDAD ASTM 469	RESISTENCIA	MÓDULO DE ELASTICIDAD ASTM 469
N °	MPa	MPa	MPa	MPa	MPa	MPa
1	21,31	21213,12	21,31	21213,12	29,18	20266,68
2	25,42	19656,75	25,42	19656,75	29,8	21452,28
3	24,39	19770,74	24,39	19770,74	32,85	22481,77
4	23,57	19830,51	23,57	19830,51	30,19	22190,26
5	21,72	20514,92	21,72	20514,92	29,87	22423,41
6	22,66	19298,13	22,66	19298,13	31,83	20704,44
7	24,9	19797,32	24,9	19797,32	29,22	21275,48
8	22,97	17754,96	22,97	17754,96	30,38	21667,08
9	20,74	20904,67	20,74	20904,67	28,22	22173,91
10	25,35	20296,46	25,35	20296,46	28,18	22468,29
PROMEDIO	23,3	19903,76	23,3	19903,76	29,97	21710,36
DESVIACIÓN ESTÁNDAR	1,7	961,68	1,7	961,68	1,47	780,09
COEFICIENTE VARIACIÓN	0,07	0,05	0,07	0,05	0,05	0,04
VALOR CARACTERÍSTICO	23,27	19887,99	23,27	19887,99	29,95	21697,57

Tabla 9Resumen de los modelos de redes neuronales artificiales para f_c

RED NEURONAL ARTIFICIAL	ARQUITECTURA			COEFICIENTE DE REGRESIÓN				R ²
	Capa Entrada	Capa Oculta	Capa de Salida	Training	Validation	Test	All	
RNA_1	17	10	1	0.95232	0.92355	0.9666	0.94967	0.945
RNA_2	17	15	1	0.98405	0.95574	0.90756	0.9671	0.9232
RNA_3	17	20	1	0.98289	0.91103	0.95316	0.96617	0.9512
RNA_4	17	25	1	0.98022	0.95441	0.93279	0.96677	0.9623
RNA_5	17	50	1	0.9791	0.91071	0.88776	0.95458	0.9422

Tabla 10Resumen de los modelos de redes neuronales artificiales para E_c

RED NEURONAL ARTIFICIAL	ARQUITECTURA			COEFICIENTE DE REGRESIÓN				R ²
	Capa Entrada	Capa Oculta	Capa de Salida	Training	Validation	Test	All	
RNA_E1	17	10	1	0.98477	0.9704	0.95224	0.97717	0.5693
RNA_E2	17	15	1	0.97815	0.9729	0.9762	0.97715	0.8169
RNA_E3	17	25	1	0.98115	0.97162	0.96443	0.97673	0.7530
RNA_E4	17	17	1	0.97506	0.98313	0.98097	0.97725	0.816
RNA_E5	17	13	1	0.98047	0.96755	0.97429	0.97726	0.9220

Tabla 11

Comparación de resultados $f'c$ experimental y $f'c$ pronosticado por RNA

f'c Diseño (MPa)	Edad (Días)	F'c Experimental (MPa)	F'c Pronosticado (MPa)	Error (MPa)	Error %	Promedio %
21	28	24.50	21.25	3.250435	13.27	
24	28	26.20	25.61	0.5942735	2.27	5.71
28	28	31.80	31.30	0.503524	1.58	

Tabla 12

Comparación de resultados E_c experimental y E_c pronosticado por RNA

f'c Diseño (MPa)	Edad (Días)	Ec Experimental (MPa)	Ec Pronosticado RNA_5 (MPa)	Error (MPa)	Error %	Promedio %
21	28	19887,98	20803	915,02	4,60	
24	28	21333,12	20114	1219,12	5,71	6.76
28	28	21697,57	19533	2164,56	9,98	

Tabla 13

Valores del módulo de elasticidad mediante la RNA y NEC - 15

f'c Diseño (MPa)	Ec Pronosticado RNA (MPa)	Ec NEC (MPa)	Diferencia (MPa)	Diferencia %	Promedio %
21	20803	21538.11	735.11	3413%	
24	20114	23025.2	2.911.204	12644%	12505%
28	19533	24870.06	5.337.062	21460%	

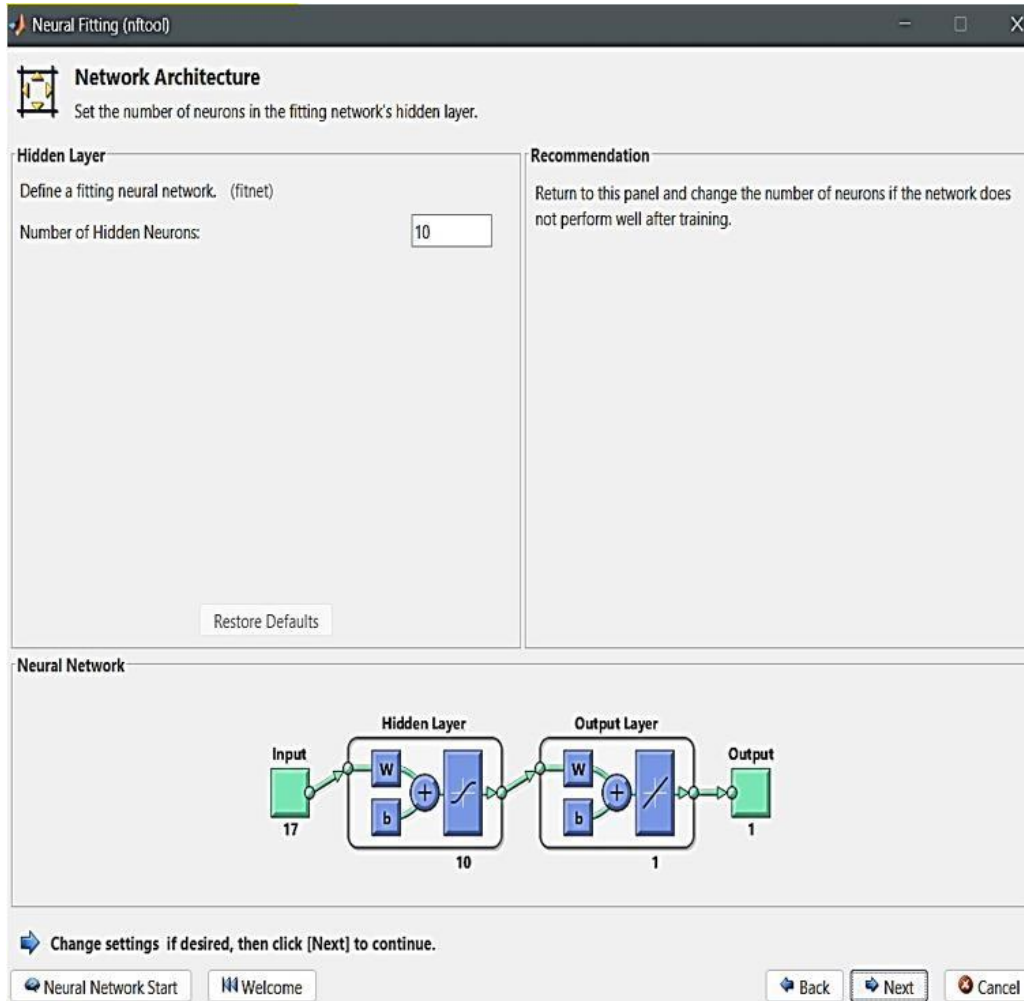
Tabla 14

Factor obtenido de RNA

f'c Diseño (MPa)	Ec Pronosticado RNA (MPa)	Factor	Factor promedio
21	19533	4.539.587	
24	20114	4.105.753	4112
28	20803	3691.39	

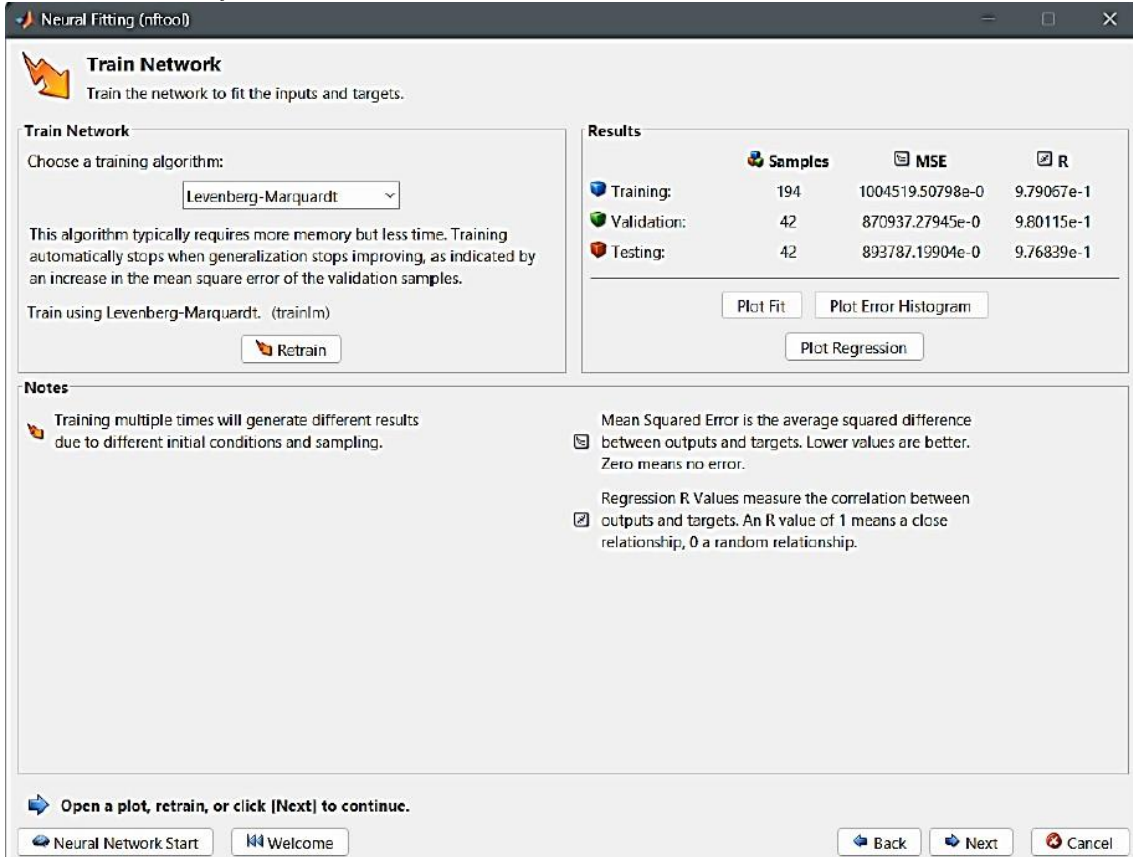
Anexo

Figura. 6

Arquitectura de la Red Neuronal Artificial

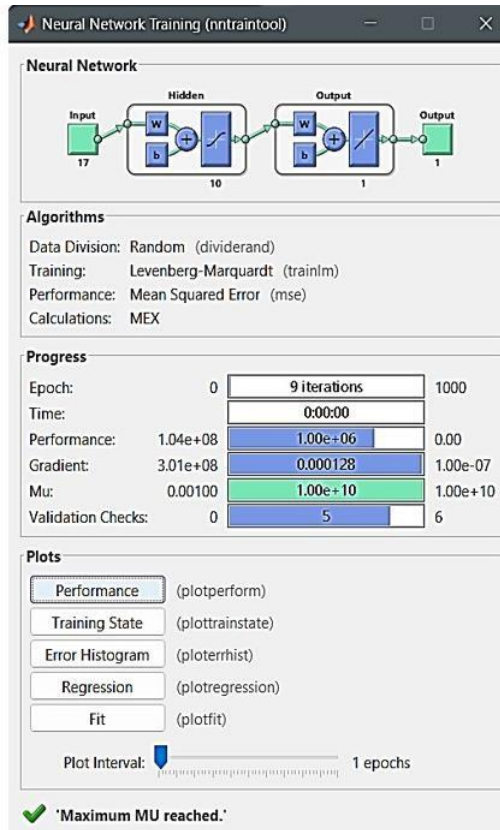
Nota: Se observa la interfaz y la arquitectura de la red neuronal como son la capa de entrada, número de neuronas y capa de salida. Matlab [12].

Figura. 7
Arquitectura de la Red Neuronal Artific



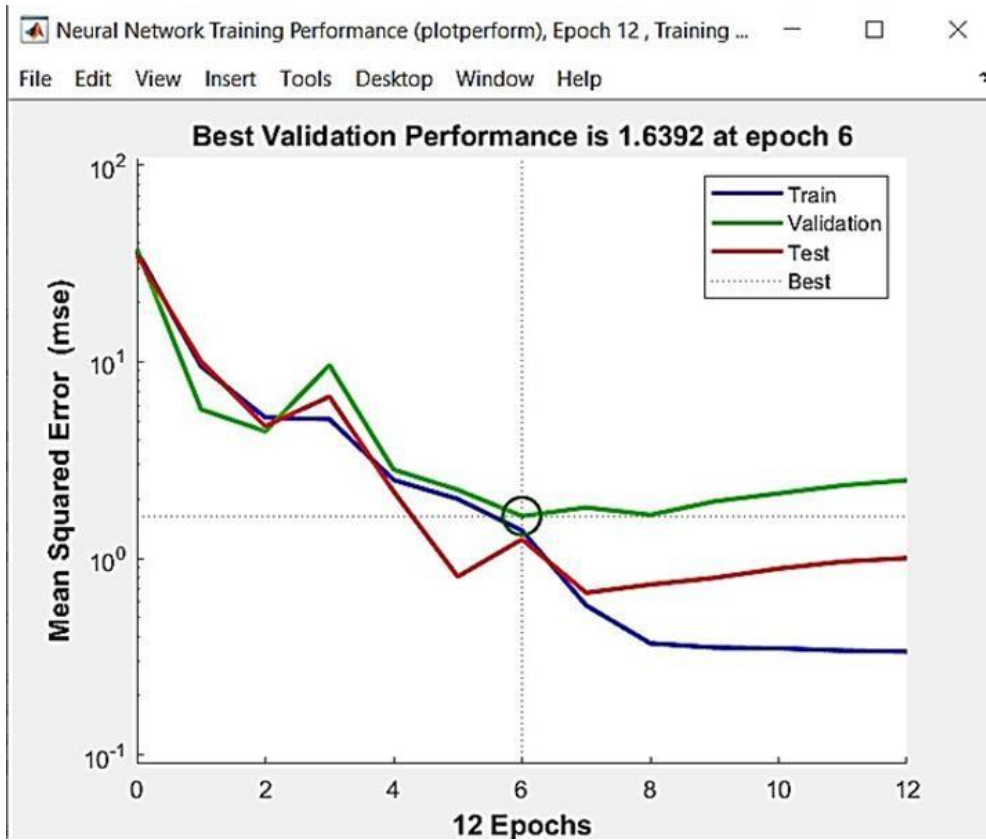
Nota: Se observa la interfaz de entrenamiento de la red neuronal artificial. Matlab [12]

Figura. 8
Resultados entrenamiento de la red neuronal



Nota: Se observa los resultados del entrenamiento de la RNA, así como también los gráficos o plots. Matlab [12].

Figura. 9
Error cuadrático medio (MSE)



Nota: La gráfica representa el error cuadrático medio vs número de iteraciones. Matlab [12].

Figura. 10
Regresión Lineal

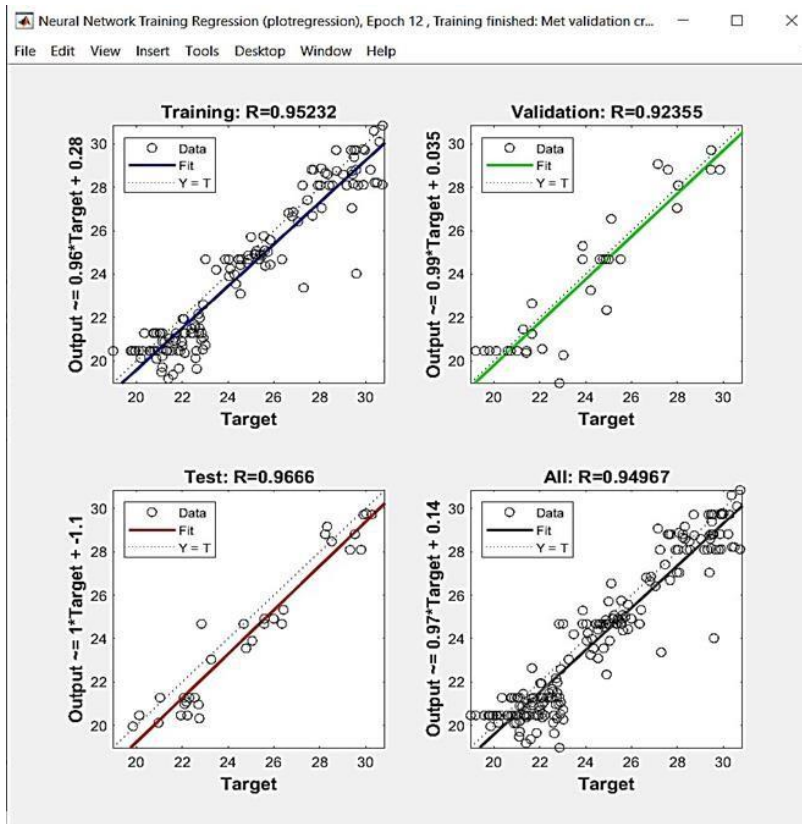


Figura. 11

Regresión para los datos de entrenamiento, validación, test y total de datos la RNA_3

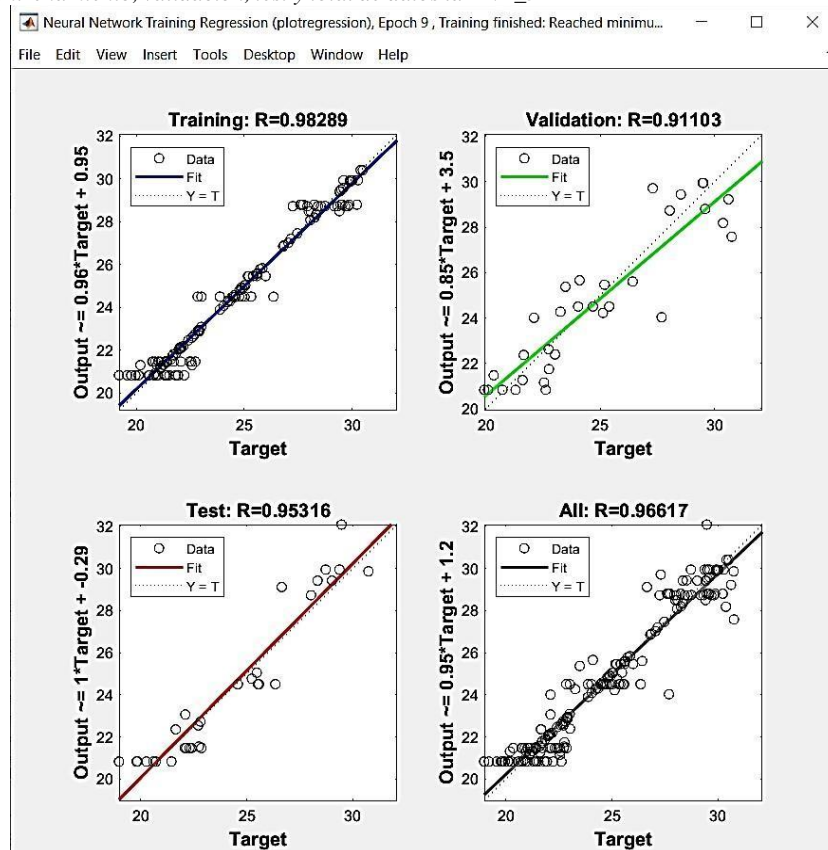


Figura. 12

Regresión para los datos de entrenamiento, validación, test y total de datos la RNA_5

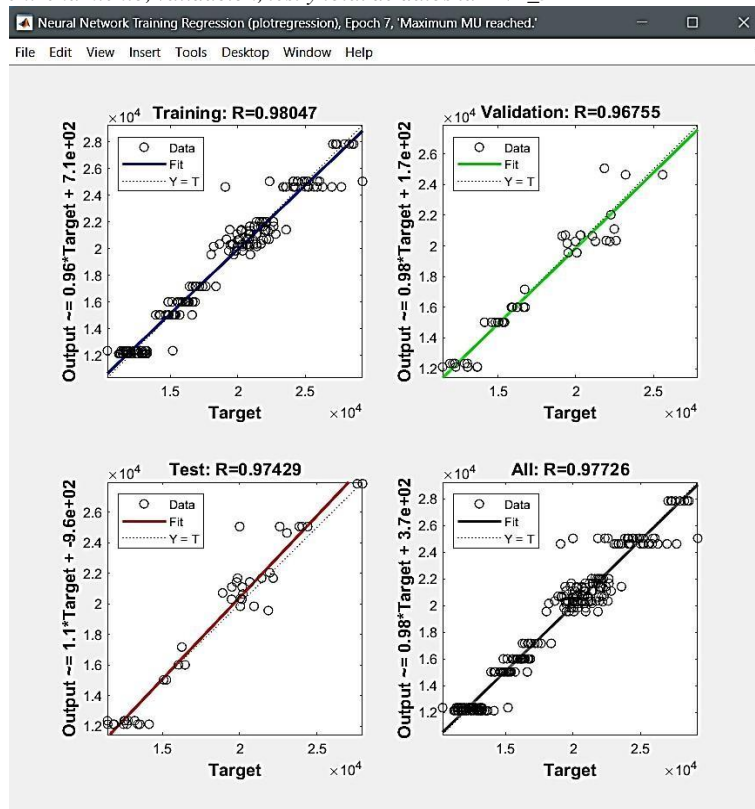


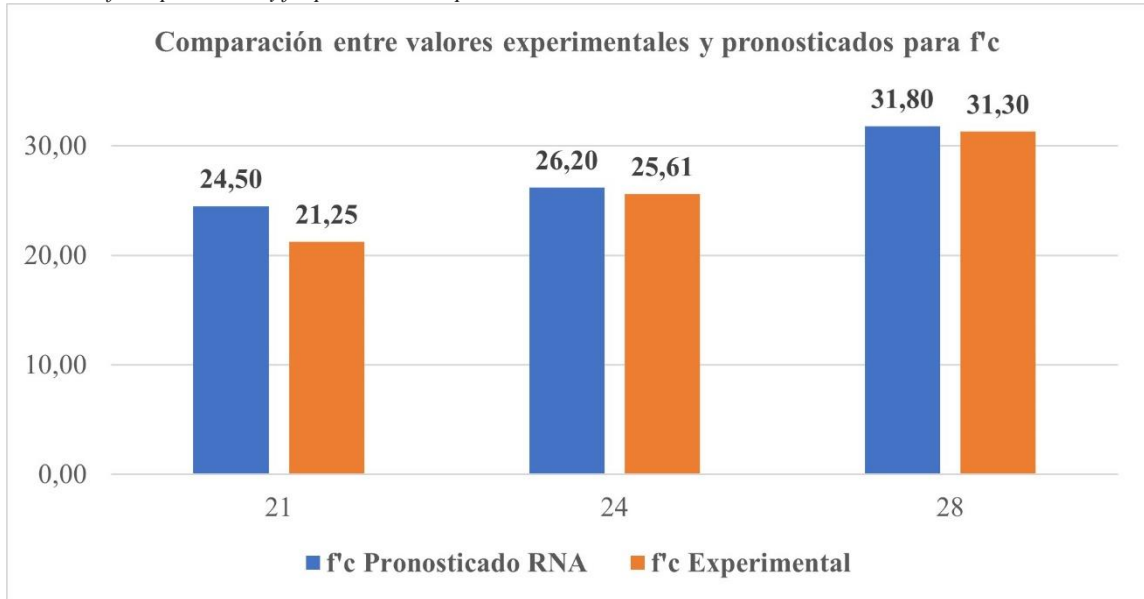

Figura. 13*Comparación de resultados $f'c$ experimental y $f'c$ pronosticados por RNA***Figura. 14***Comparación de resultados $f'c$ experimental y $f'c$ pronosticados por RNA*

Figura. 15

Comparación de resultados E_c experimental y E_c Pronosticado por RNA




Figura. 16

Comparación de resultados E_c experimental y E_c Pronosticado por RNA

