

UNIVERSIDAD SAN FRANCISCO DE QUITO USFQ

Colegio de Ciencias e Ingenierías

**Predicción de la resistencia a la compresión del hormigón
mediante el uso de Redes Neuronales**

Gerson Isaac Osorio Tinoco

Ingeniería Civil

Trabajo de fin de carrera presentado como requisito
para la obtención del título de
Ingeniero Civil

Quito, 14 de mayo de 2023

UNIVERSIDAD SAN FRANCISCO DE QUITO USFQ

Colegio de Ciencias e Ingenierías

HOJA DE CALIFICACIÓN DE TRABAJO DE FIN DE CARRERA

**Predicción de la resistencia a la compresión del hormigón mediante el uso
de Redes Neuronales**

Gerson Isaac Osorio Tinoco

Nombre del profesor, Título académico

Pablo Torres Rodas, Ph.D.

Quito, 14 de mayo de 2023

© DERECHOS DE AUTOR

Por medio del presente documento certifico que he leído todas las Políticas y Manuales de la Universidad San Francisco de Quito USFQ, incluyendo la Política de Propiedad Intelectual USFQ, y estoy de acuerdo con su contenido, por lo que los derechos de propiedad intelectual del presente trabajo quedan sujetos a lo dispuesto en esas Políticas.

Asimismo, autorizo a la USFQ para que realice la digitalización y publicación de este trabajo en el repositorio virtual, de conformidad a lo dispuesto en la Ley Orgánica de Educación Superior del Ecuador.

Nombres y apellidos: Gerson Isaac Osorio Tinoco

Código: 211269

Cédula de identidad: 1719151654

Lugar y fecha: Quito, 14 de mayo de 2023

ACLARACIÓN PARA PUBLICACIÓN

Nota: El presente trabajo, en su totalidad o cualquiera de sus partes, no debe ser considerado como una publicación, incluso a pesar de estar disponible sin restricciones a través de un repositorio institucional. Esta declaración se alinea con las prácticas y recomendaciones presentadas por el Committee on Publication Ethics COPE descritas por Barbour et al. (2017) Discussion document on best practice for issues around theses publishing, disponible en <http://bit.ly/COPETHeses>.

UNPUBLISHED DOCUMENT

Note: The following capstone project is available through Universidad San Francisco de Quito USFQ institutional repository. Nonetheless, this project – in whole or in part – should not be considered a publication. This statement follows the recommendations presented by the Committee on Publication Ethics COPE described by Barbour et al. (2017) Discussion document on best practice for issues around theses publishing available on <http://bit.ly/COPETHeses>.

RESUMEN

En este proyecto se utilizó un modelo basado en redes neuronales artificiales para predecir la resistencia a la compresión del hormigón. Se obtuvieron datos de 13 tesis de la Universidad Central del Ecuador y ensayos de laboratorio realizados en la Universidad San Francisco de Quito. Con esa información se entrenó la red neuronal de 4 capas. Los resultados muestran que el modelo desarrollado puede predecir con una 97 % precisión la resistencia a la compresión de las muestras cilíndricas de hormigón. Es importante destacar que el objetivo no es reemplazar los ensayos en laboratorio sino complementarlos. Las redes neuronales permiten entender y predecir el comportamiento de materiales no uniformes como el hormigón. Por tanto, las conclusiones indican que las redes neuronales pueden ser una herramienta muy útil para el desarrollo de la tecnología del hormigón.

Palabras clave: redes neuronales artificiales, resistencia a la compresión, diseño de mezclas, hormigón, ensayos de laboratorio.

ABSTRACT

This project used an artificial neural network model to predict the compressive strength of concrete. Data from 13 theses from Central University of Ecuador and laboratory tests conducted at San Francisco University of Quito were collected. The four-layer neural network was trained using this information. The results demonstrate that the developed model can predict the compressive strength of cylindrical concrete samples with 97% accuracy. It is important to note that the objective is not to replace laboratory tests but to complement them. Neural networks enable the understanding and prediction of the behavior of non-uniform materials such as concrete. Therefore, the findings suggest that neural networks can be a valuable tool for the advancement of concrete technology.

Keywords: artificial neural networks, compressive strength, mix design, concrete, laboratory tests.

TABLA DE CONTENIDO

I. INTRODUCCIÓN.....	10
Antecedentes.....	10
II. OBJETIVOS.....	11
Objetivo General	11
Objetivos Específicos.....	11
III. DESARROLLO DEL TEMA	11
Metodología	11
Revisión de literatura	13
El hormigón.....	13
Agregados.....	14
Agregado Grueso	15
Agregado Fino	15
Cemento	15
Agua de mezclado	16
Aditivo Superplastificante.....	16
Humo de sílice	16
Datos.....	16
Obtención de datos.....	17
Resumen de Variables.....	18
Análisis de datos.....	20
Normalización de datos.....	22
División de datos.....	24
Red Neuronal Artificial (RNA).....	25
Neurona Artificial.....	25
Funciones de Activación.....	26
Arquitectura de una RNA simple.....	27
Arquitectura de la RNA utilizada para la predicción de la resistencia a la compresión	28
Compilación del modelo.....	29
Resultados.....	30
Pérdida en el proceso de entrenamiento de la Red Neuronal Artificial	30
Resultados de las variables de entrenamiento	31
Resultados de las variables de prueba	32
Resultados de las variables de validación.....	33
IV. CONCLUSIONES.....	35
V. REFERENCIAS BIBLIOGRÁFICAS.....	36

ÍNDICE DE TABLAS

Tabla 1. Variables de análisis con sus respectivas unidades y normativas.....	19
---	----

ÍNDICE DE FIGURAS

Figura 1 Comparación de muestras obtenidas	18
Figura 2. Diagrama de caja y bigote de las variables obtenidas	20
Figura 3 Distribución de la resistencia a la compresión del hormigón de los datos obtenidos	21
Figura 4. Diagrama de coeficientes de correlación de las variables	22
Figura 5 Diagrama de caja y bigote de las variables normalizadas	23
Figura 6 Esquema de una Neurona Artificial	26
Figura 7 Arquitectura de una RNA Simple.....	27
Figura 8 Arquitectura del modelo de RNA utilizado para la predicción de la resistencia a la compresión del hormigón.....	29
Figura 9 Perdida del modelo durante el entrenamiento	30
Figura 10 Resultados de las variables de entrenamiento vs. los valores reales	32
Figura 11 Resultados de las variables de prueba vs. los valores reales	33
Figura 12 Resultados de las variables de validación vs. los valores reales	34

I. INTRODUCCIÓN

Antecedentes

Hoy en día, la tecnología ha favorecido a diversas industrias al simplificar los procesos que solían ser más largos, optimizando así el tiempo y la obtención de resultados. La Inteligencia Artificial es un campo de las ciencias de la computación que ayuda a resolver problemas de forma autónoma, tomando en consideración el comportamiento del cerebro humano (Morales, D., 2017). Las redes neuronales son un ejemplo de este sistema, ya que funcionan de manera similar a los procesos de pensamiento humano y están diseñadas para resolver problemas complejos.

La ingeniería civil es una de las disciplinas que se han visto beneficiadas por el uso de la inteligencia artificial (Morales, D., 2017). Uno de los desafíos frecuentes en proyectos de construcción es la verificación de la resistencia a la compresión de las muestras de mezclas de hormigón. Comúnmente, este proceso requiere de la revisión de normativas y estándares internacionales de construcción. Para llevar a cabo este procedimiento, se requiere poseer conocimientos acerca de las proporciones adecuadas de cemento, agua y agregados en la composición del hormigón (González et al., 2012). También, se usan otros sistemas computacionales para poder analizar a profundidad los resultados de estas pruebas, lo cual implica una tarea que demanda atención y precisión.

Dado que estimar la resistencia a la compresión del hormigón es un proceso complejo, la inteligencia artificial utiliza una serie de métodos en la computadora, como funciones que le permiten aprender y realizar la acción de manera similar a un humano (González et al., 2012). Esto se logra a través de la implementación de códigos o algoritmos de programación diseñados para resolver los desafíos planteados. Algunos ejemplos principales de aprendizaje automático incluyen las redes neuronales artificiales, lógica difusa y los algoritmos evolutivos.

Las redes neuronales artificiales son un modelo computacional que posee de un conjunto de elementos procesadores denominadas neuronas artificiales que se interconectan entre ellas, reciben y envían información unas a otras. (García y Varón, 2023). Es decir, procesan la información, la conectan y dan una respuesta. La información que las neuronas reciben es por medio de variables que contienen datos para poder dar como respuesta el resultado de la interrelación.

En este caso de estudio, se desarrollará un método complementario para el diseño de mezclas de hormigón usando redes neuronales para poder estimar la resistencia a la compresión del hormigón.

II. OBJETIVOS

Objetivo General

Desarrollar un método complementario al diseño de mezclas de hormigón por medio de redes neuronales para estimar la resistencia a la compresión del hormigón.

Objetivos Específicos

- Realizar una revisión bibliográfica acerca del diseño de mezclas de hormigón para entrenar la red neuronal.
- Programar una red neuronal por medio de Python.
- Analizar los datos pronosticados por la red neuronal con los datos reales provenientes de ensayos realizados por la USFQ.

III. DESARROLLO DEL TEMA

Metodología

La metodología utilizada en este estudio se basó en los siguientes pasos:

1. Revisión bibliográfica: Se realizó una exhaustiva revisión de 13 tesis de la Universidad Central del Ecuador y archivos de dosificación de mezcla realizados en la Universidad San Francisco de Quito. Esta revisión permitió obtener datos relevantes para el entrenamiento de la red neuronal.
2. Extracción de datos: A partir de la revisión bibliográfica, se extrajeron los datos necesarios para el entrenamiento de la red neuronal. Estos datos incluyen variables relacionadas con la resistencia a la compresión.
3. Normalización de datos: Los datos obtenidos se sometieron a un proceso de normalización utilizando el escalador “MinMaxScaler” de la biblioteca scikit-learn. Este proceso garantizó que todas las variables estuvieran en un rango de $[0, 1]$, lo cual es óptimo para el entrenamiento de la red neuronal.
4. División de datos: Los datos normalizados se dividieron en conjuntos de entrenamiento, prueba y validación utilizando la función “train_test_split” de la biblioteca scikit-learn. Se asignó el 90% de los datos para el conjunto de entrenamiento, el 10% para el conjunto de prueba y se reservaron datos adicionales para el conjunto de validación.
5. Creación del modelo de red neuronal: Se construyó un modelo de red neuronal utilizando la biblioteca Keras. El modelo consta de tres capas densas, con funciones de activación ReLU en las dos primeras capas y una función de activación lineal en la capa de salida.
6. Compilación y entrenamiento del modelo: El modelo se compiló utilizando la función de pérdida de error cuadrático medio “mean_squared_error” y el optimizador “Adam”. A continuación, se procedió al entrenamiento del modelo utilizando los datos de entrenamiento. Se ejecutaron 100 épocas con un tamaño de lote de 32.

7. Evaluación del modelo: Se evaluó el rendimiento del modelo utilizando los datos de prueba. Se calculó la pérdida del modelo en los datos de prueba y se obtuvo el puntaje R^2 para evaluar la precisión de las predicciones del modelo.
8. Predicción y visualización de resultados: Se realizaron predicciones utilizando el modelo entrenado en los conjuntos de prueba y validación. Los resultados se invirtieron en la escala original utilizando el escalador inverso “inverse_transform”. Finalmente, se generaron gráficos de dispersión para comparar las predicciones de resistencia a la compresión pronosticadas por el modelo con los valores reales.

Esta metodología permitió utilizar la información recopilada en la revisión bibliográfica y entrenar una red neuronal para predecir la resistencia a la compresión en base a las variables seleccionadas. Los resultados obtenidos proporcionaron una evaluación cuantitativa del desempeño del modelo y su capacidad para hacer predicciones precisas.

Revisión de literatura

El hormigón

El hormigón es una mezcla de cemento, agregados finos y gruesos, agua, aditivos químicos (Flores, H., 2014). Según Tafur y Viracucha (2018), una característica principal del hormigón es su resistencia a los esfuerzos de compresión. Además, la resistencia a la compresión del hormigón puede ser influenciada por varios factores, como el tipo de cemento, la cantidad de agua, los agregados, la relación agua/cemento, el proceso de curado y la edad del hormigón, como menciona Osejo (2020). Asimismo, según los estudios de Flores, se ha demostrado que la adición de fibras de acero a la mezcla de hormigón puede aumentar significativamente su resistencia a la compresión. Por lo tanto, la incorporación de fibras de acero en la mezcla de hormigón es otro factor importante a considerar para mejorar su

resistencia a la compresión, esta se toma en cuenta ya que algunos datos extraídos constan con mezclas que usan fibras de acero.

Agregados

En general, los agregados desempeñan un papel fundamental en la composición del hormigón, representando entre el 60% y el 80% de su masa total (Romero, C., 2014). Se distinguen dos tipos de agregados: los finos y los gruesos. Es esencial que estos agregados cuenten con partículas limpias, libres de materia orgánica, sales y otros contaminantes. Además, se recomienda que los agregados tengan una forma angular o semi-angular, con una textura áspera, para lograr una óptima adherencia con el cemento (Romero, C., 2014).

La densidad de los agregados, medida en términos de su peso por unidad de volumen, es un factor relevante en la resistencia del hormigón a la compresión. Una mayor densidad se traduce en una mayor resistencia, ya que implica una mayor cantidad de material por unidad de volumen disponible para soportar las cargas aplicadas (Flores, H., 2014).

Otro aspecto importante a considerar es el contenido de humedad de los agregados. La presencia de una cantidad adecuada de agua en la mezcla es esencial para lograr la hidratación del cemento y la formación de la pasta de hormigón. Un contenido de humedad óptimo garantiza una adecuada trabajabilidad del hormigón y una mejor compactación, lo que contribuye a su resistencia final (Romero, C., 2014).

El módulo de finura es una medida que indica la distribución de tamaños de partículas en los agregados. Un módulo de finura adecuado asegura una mezcla bien graduada, con una combinación equilibrada de partículas finas y gruesas. Esto influye en la resistencia y durabilidad del hormigón, ya que una buena gradación mejora la compacidad y la capacidad de llenado de los espacios entre las partículas, lo que a su vez incrementa la resistencia a la compresión (Narváez, A., 2014).

Agregado Grueso

Se denomina agregado grueso al material que se retiene en el tamiz #4, derivado de la desintegración de las rocas. (Abata, E., 2014). El agregado grueso es uno de los componentes de mayor importancia del hormigón. (Rodríguez, S.,2014). Este influye de manera significativa en la resistencia y propiedades estructurales (Romero, C., 2014). Es por esto por lo que es importante que el agregado sea resistente, libre de fisuras y recubrimientos, y sobre todo limpio. Abata, J., & Eugenia, M. (2014).

Agregado Fino

Se denomina agregado fino al material que pasa por el tamiz #4, derivado de la desintegración de las rocas (Abata, E., 2014). Según Rodríguez (2014), estas partículas forman gran parte de la masa total del hormigón. En los hormigones altamente resistentes, la característica principal que debe cumplir el agregado fino es que no debe ser menor de 2,3 ni mayor a 3,1 mm para poder tener un buen manejo y resistencia a la compresión (Romero, C., 2014).

Cemento

Se trata de un material inorgánico amasado con agua que forma una pasta que se endurece de acuerdo con los procesos de hidratación, una vez que se endurece mantiene la resistencia y estabilidad debajo del agua (Flores, M., 2018). Hay dos tipos de cemento el que es en base a arcilla y los puzolánicos. El cemento Portland es el que se usa comúnmente en la preparación del hormigón (Romero, C.,2014). El tipo de calidad se encuentra dentro de la norma ASTM C150 (Romero, C.,2014).

Agua de mezclado

Es la cantidad de agua que necesita el hormigón por unidad de volumen para que el cemento se hidrate (Romero, C.,2014). El agua que se recomienda para las mezclas es el agua potable, sin embargo, se pueden usar otros tipos de agua con tal de que sean libres de químicos y materia orgánica para que no afecte el proceso de fraguado de la mezcla (Narváez, A., 2014). El agua que se utilice debe cumplir con la norma INEN 2617:2012 (Flores, M., 2018).

Aditivo Superplastificante

El aditivo plastificante es un tipo de producto químico que mejora la característica del hormigón (Narváez, A., 2014). En este caso al reaccionar con el cemento, el hormigón tiende a fluir más rápido sin necesitar agua (Flores, M., 2018). La dosificación debe ser entre 1 y 2 % en peso del cemento (Narváez, A., 2014). Este químico se debe usar con medida ya que puede echar a perder la resistencia del hormigón. El aditivo debe cumplir con la normativa ASTM C-494 (Romero, C.,2014).

Humo de sílice

El humo de sílice se trata de un conjunto de partículas vítreas finas de una forma redonda y con un diámetro pequeño (Flores, M., 2018). La densidad de este está ente los 2.2 g/cm³, tiene gran contenido de carbón de micro sílice con una densidad muy pequeña (Narváez, A., 2014).

Datos

En esta etapa se hace un recuento del procedimiento que se realizó para la obtención de datos, después se escogieron las variables para el funcionamiento de la red neuronal. Se realizó un análisis exploratorio de los datos para identificar la tendencia que seguían los mismos y verificar que sean adecuados para que la red neuronal no tenga errores al momento de realizar

sinapsis entre la información recibida. A continuación, se presenta una breve descripción de los pasos que se siguió.

Obtención de datos

En esta etapa, se realizó una investigación exhaustiva de datos que servirían como información de entrada para la red neuronal. Así pues, por medio de una revisión bibliográfica se encontraron 13 tesis de la Universidad Central del Ecuador (UCE), las mismas contenían información relevante de estudios que se realizaron años atrás acerca de la dosificación de mezcla de hormigones y sus resultados de resistencia a la compresión. De igual manera, se realizó una búsqueda de información en los archivos de la Universidad San Francisco de Quito (USFQ) acerca de dosificaciones y ensayos que se realizaron en el laboratorio.

Para evaluar la efectividad de los estudios realizados por la UCE en ese momento, en comparación con los realizados por la USFQ, fue necesario considerar que los datos se obtuvieron en diferentes circunstancias y utilizando distintos materiales en diferentes periodos de tiempo.

En total se extrajo 663 datos limpios de entrada de las tesis de la UCE y 48 datos de la USFQ. Esto se puede observar con mayor calidad en la Figura 1 que se muestra a continuación, en donde se observa la diferencia mayoritaria que tienen los datos de la UCE a comparación de los de la USFQ.

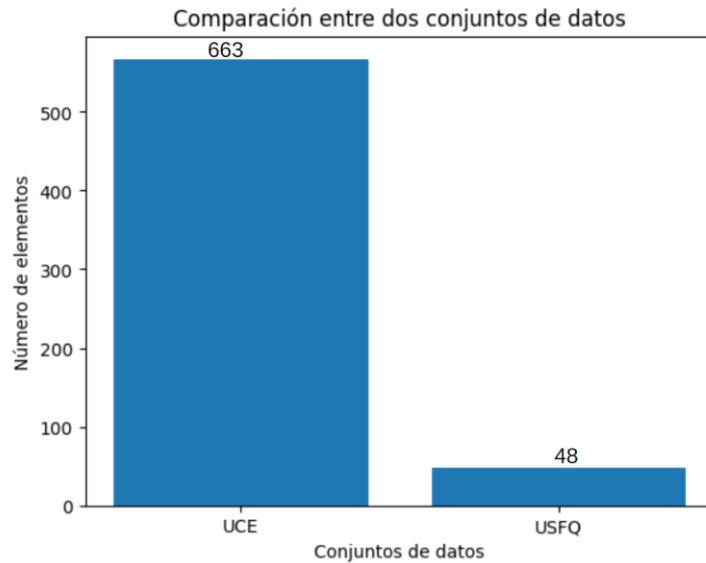


Figura 1 Comparación de muestras obtenidas

Resumen de Variables

Al analizar los datos en el diseño de mezclas tanto en la UCE como en la USFQ, se tomaron en consideración la mayoría de los resultados de los ensayos necesarios para garantizar la calidad del hormigón, siguiendo las normativas correspondientes. Aunque estos resultados estaban relacionados individualmente con la resistencia a la compresión, se buscó utilizarlos con un propósito adicional: predecir la resistencia a la compresión. La variable de respuesta en este caso fue el valor de la resistencia a la compresión en [MPa]. En la Tabla 1, se presenta un resumen de las 21 variables de análisis, incluyendo sus unidades y normativas respectivas, que fueron consideradas para el funcionamiento de la red neuronal en el contexto de este estudio.

Tabla 1. Variables de análisis con sus respectivas unidades y normativas

	#	Variables	Unidad	Normativa
Agregado Grueso	1	Cantidad en mezcla	kg	-
	2	Densidad S.S.S.	g/cm ³	NTE INEN 857 - ASTM C-127
	3	Contenido de humedad	%	NTE INEN 862- ASTM C-566
	4	Módulo de Finura	-	NTE INEN 696 – ASTM C-136
	5	Absorción	%	NTE INEN 857 - ASTM C-70
Agregado Fino	6	Cantidad en mezcla	kg	-
	7	Densidad S.S.S.	g/cm ³	NTE INEN 856 - ASTM C-128
	8	Contenido de humedad	%	NTE INEN 862- ASTM C-566
	9	Módulo de Finura	-	NTE INEN 696 – ASTM C-136
	10	Absorción	%	NTE INEN 856 - ASTM C-70
Cemento	11	Cantidad en mezcla	kg	-
	12	Densidad	g/cm ³	NTE INEN 156 - ASTM C-188
Humo de sílice	13	Cantidad en mezcla	kg	-
	14	Densidad	g/cm ³	NTE INEN 156 - ASTM C-188
Aditivo plastificante	15	Cantidad en mezcla	kg	-
	16	Densidad	g/cm ³	ASTM C-494
Agua	17	Cantidad en mezcla	kg	-
Relación	18	w/c (Diseño)	-	-
Agua/Cemento	19	w/c (Mezcla Total)	-	-
Fibras de Acero	20	Cantidad en mezcla	kg	-
Hormigón	21	Edad	días	NTE INEN 1576 - ASTM C-31
	-	Resistencia a la compresión	MPa	NTE INEN 1573 - ASTM C-139

Análisis de datos

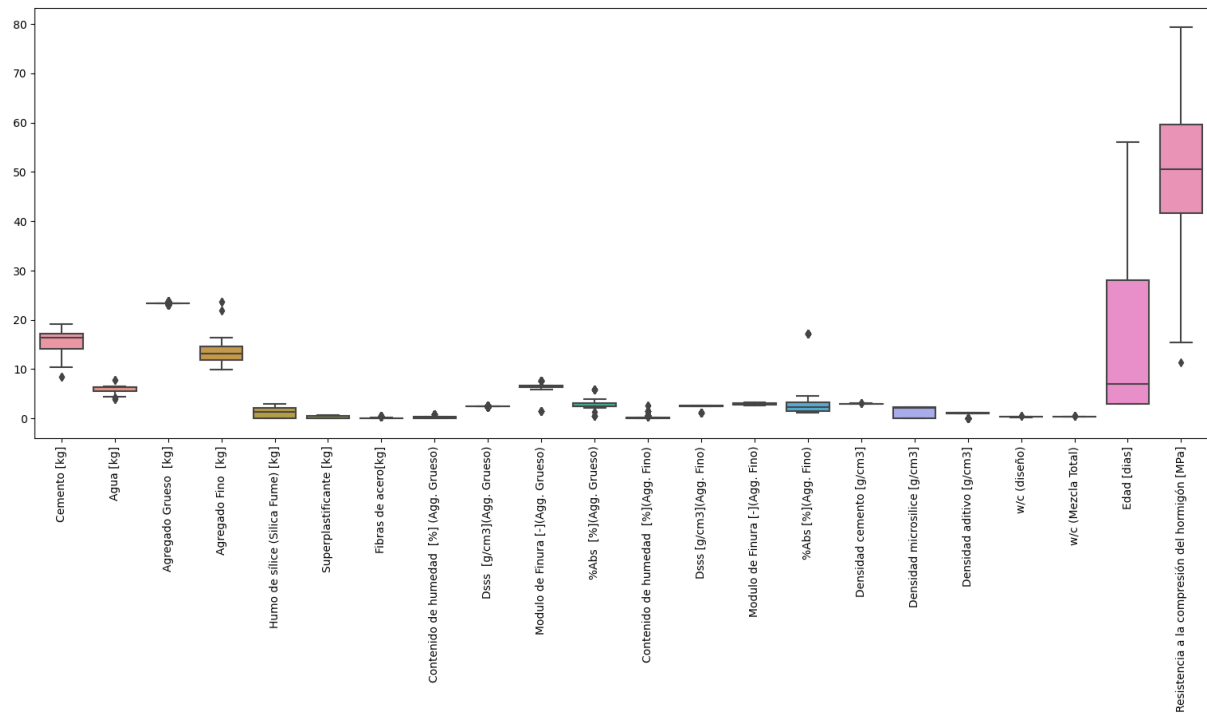


Figura 2. Diagrama de caja y bigote de las variables obtenidas

En la Figura 2 se puede observar que las 21 variables predictoras consideradas tienen diferentes tamaños de muestra, y se aprecia una notable asimetría en la distribución de los datos, lo que indica que no siguen una distribución normal. Por esta razón, es necesario realizar una normalización de los datos para evitar posibles sesgos en la variable de respuesta.

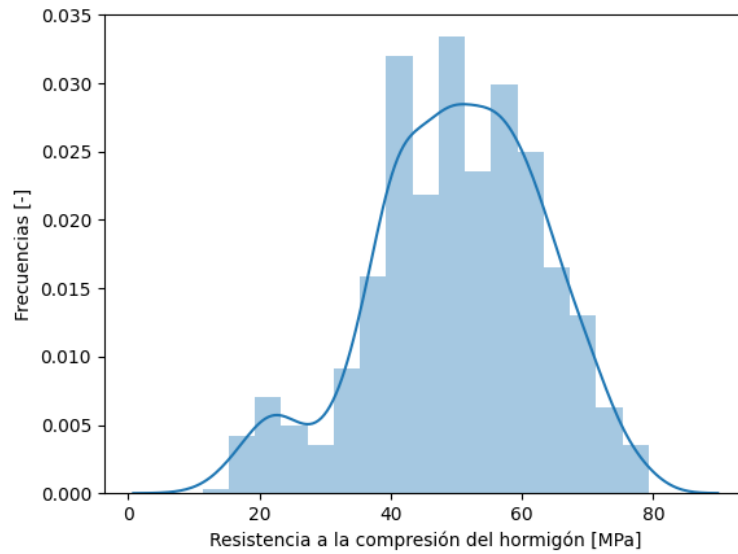


Figura 3 Distribución de la resistencia a la compresión del hormigón de los datos obtenidos

En la Figura 3 se presenta la distribución de las respuestas acerca de la compresión del hormigón en donde se puede observar que aparentemente sigue una distribución normal de los datos por su curva pronunciada en forma de campana, pero también se identifica que existe un sesgo presente de manera que una asimetría negativa hacia la derecha corroborando así que las medias de las variables son distintas y por ende las respuestas van a tener una tendencia de respuestas a la compresión bajas y altas.




Figura 4. Diagrama de coeficientes de correlación de las variables

En la Figura 4 se puede observar que las variables presentan una correlación débil entre sí, lo que indica que son independientes y tendrán un impacto significativo en la variable de respuesta si alguna de ellas presenta un valor distinto.

Después de haber realizado este análisis exploratorio de los datos, se procedió a realizar los respectivos ajustes para evitar que el modelo de red neuronal no genere errores en los resultados de las predicciones a la resistencia del hormigón.

Normalización de datos

El escalador “MinMaxScaler” de la biblioteca scikit-learn, permite realizar una normalización de los en un rango de [0,1] (Géron, 2019). Para cada variable en el conjunto de datos, el escalador realiza la siguiente transformación:

Siendo (x_i) la variable original, el valor normalizado ($x_{i_{normalizado}}$) se calcula de la siguiente manera:

$$x_{i_{normalizado}} = \frac{x_i - x_{i_{min}}}{x_{i_{max}} - x_{i_{min}}}$$

Ecuación 1 Ecuación de normalización de variables de “MinMaxScaler”

Donde ($x_{i_{max}}$) y ($x_{i_{min}}$) son los valores máximos y mínimos de la variable.

Este proceso garantiza que los valores mínimos de las variables se transformen en 0 y los valores máximos se transformen en 1. Los demás valores se ajustan proporcionalmente dentro de este rango (Géron, 2019).




Figura 5 Diagrama de caja y bigote de las variables normalizadas

En la Figura 5 se observa que después del proceso de normalización de datos, todas tienen un mismo tamaño de muestra y las medias de las 21 variables se encuentran dentro del mismo rango. Lo que ahora generaría una mayor robustez en los resultados sin sesgos presentes. Por otro lado, también se identifica la presencia de datos atípicos que pueden generar

mínimos errores dentro de los resultados, pero hay que tomar en cuenta que, al ser variables independientes, realmente no afectarían al valor de predicción de la resistencia a la compresión.

División de datos

Se utilizó la función “train_test_split” de la biblioteca scikit-learn, la cual permitió realizar la división del conjunto de datos en conjuntos de entrenamiento, prueba y validación.

$$datos_{normalizados} = \left[\begin{array}{c|c} X_{entrenamiento} & Y_{entrenamiento} \\ \hline X_{prueba} & Y_{prueba} \\ \hline X_{validación} & Y_{validación} \end{array} \right]$$

Ecuación 2 Partición de los datos normalizados para la creación de la RNA

El primer par de datos se tomó $(X_{entrenamiento}; Y_{entrenamiento})$ donde representan el 90% de los primeros 663 datos obtenidos en la Universidad Central del Ecuador. Este conjunto representa todos los datos con los que se va a entrenar la red.

El segundo par de datos se tomó $(X_{prueba}; Y_{prueba})$ donde representan el 10% de los primeros 663 datos obtenidos en la Universidad Central del Ecuador. Este conjunto representa todos los datos con los que se va a probar la red.

El tercer par de datos se tomó $(X_{validación}; Y_{validación})$ donde representan los primeros 48 datos obtenidos en la Universidad San Francisco de Quito. Este conjunto representa todos los datos con los que se va a validar la red.

Red Neuronal Artificial (RNA)

Una Red Neuronal Artificial (RNA) es un modelo computacional inspirado en el funcionamiento de las redes neuronales biológicas del cerebro humano (Nielsen, 2015). Está compuesta por un conjunto interconectado de unidades de procesamiento llamadas neuronas artificiales o nodos. Estas neuronas artificiales están organizadas en capas, y cada una de ellas busca realizar operaciones matemáticas en los datos de entrada para producir una salida.

Neurona Artificial

Una neurona artificial es la unidad básica de procesamiento en una RNA. Su función principal implica combinar linealmente las entradas ponderadas por los pesos sinápticos (w_i). Cada entrada (x_i) se multiplica por su peso sináptico correspondiente, reflejando así su importancia relativa en el cálculo. Estos productos ponderados se suman dentro de la neurona.

$$z = \sum_{i=1}^n x_i \cdot w_i + b$$

Ecuación 3 Combinación lineal ponderada

Además de la combinación lineal ponderada (Z), se incluye un término adicional llamado sesgo (b) en la operación de la neurona. El sesgo es un parámetro que ajusta la salida de la neurona. Se representa como un peso sináptico adicional asociado a una entrada ficticia constante de 1 (Nielsen, 2015).




Figura 6 Esquema de una Neurona Artificial

Después de realizar la suma de las entradas ponderadas y el sesgo, el resultado se pasa a través de una función de activación ($f(z)$). Esta función introduce no linealidades en el modelo y determina si la neurona se activa o no, según el resultado de la combinación lineal.

Funciones de Activación

En una RNA, las funciones de activación se aplican a la salida de cada neurona para introducir no linealidades en el modelo y permitir la representación de relaciones y patrones complejos en los datos.

ReLU (Rectified Linear Unit): Es una función no lineal que mapea los valores negativos a cero y los valores positivos se mantienen sin cambios. La función ReLU es ampliamente utilizada en capas ocultas debido a su eficiencia computacional. (Géron, 2019)

$$f(z) = \text{ReLU}(z) = \begin{cases} 0 & \text{si } z \leq 0 \\ x & \text{si } z > 0 \end{cases}$$

Ecuación 4 Función de activación ReLU

Linear: Es una función de activación lineal que conserva el valor de entrada sin modificarlo. Esta función se utiliza comúnmente en la capa de salida cuando se trata de un problema de regresión, ya que produce una salida continua. (Géron, 2019)

$$f(z) = \text{Linear}(z) = z$$

Ecuación 5 Función de activación lineal

Arquitectura de una RNA simple

La arquitectura de una RNA puede ser simplificada a una estructura compuesta por tres capas: la capa de entrada, la capa oculta y la capa de salida.

Capa de entrada: En esta capa, se reciben los valores de entrada del problema. Cada valor de entrada se representa como una neurona en esta capa. Estos valores son transmitidos a la siguiente capa para su procesamiento.

Capa oculta: Esta capa se encuentra entre la capa de entrada y la capa de salida. En cada neurona de la capa oculta, se realiza una combinación lineal de los valores recibidos de la capa anterior. Posteriormente, se aplica una función de activación a esta combinación lineal para introducir no linealidades en el modelo. La capa oculta es responsable de extraer características y representaciones de los datos de entrada. (Nielsen, 2015).

Capa de salida: En esta capa, se genera la salida final del modelo. Cada neurona en esta capa procesa la información recibida de la capa oculta y produce una salida que representa el resultado o la predicción del modelo.




Figura 7 Arquitectura de una RNA Simple

Arquitectura de la RNA utilizada para la predicción de la resistencia a la compresión

La RNA tiene una arquitectura de cuatro capas: una capa de entrada, dos capas ocultas y una capa de salida.

Capa de entrada:

La capa de entrada consta de 21 neuronas que representan los 21 datos de entrada del modelo. Estos datos son características o atributos utilizados para predecir la variable objetivo. Cada neurona en esta capa recibe un dato de entrada y lo procesa.

Capa oculta 1:

La primera capa oculta está compuesta por 64 neuronas. Cada neurona en esta capa toma como entrada las salidas de las neuronas de la capa anterior y realiza una combinación lineal de esas entradas, seguida de una función de activación ReLU. Estas operaciones permiten a cada neurona en la capa oculta aprender y extraer características relevantes de los datos de entrada.

Capa oculta 2:

La segunda capa oculta consta de 32 neuronas. Al igual que la primera capa oculta, cada neurona en esta capa procesa las salidas de las neuronas de la capa anterior y aplica una combinación lineal y una función de activación no lineal a esas entradas. La presencia de múltiples capas ocultas en la arquitectura de la red neuronal aumenta su capacidad para capturar relaciones complejas en los datos.

Capa de salida:

La capa de salida está compuesta por una sola neurona que produce la predicción o estimación final. Esta neurona recibe las salidas de las neuronas de la última capa oculta y realiza una combinación lineal de esas entradas, seguida de una función de activación lineal.

La función de activación lineal permite que la salida sea proporcional a la suma ponderada de las entradas, sin aplicar una transformación no lineal adicional.

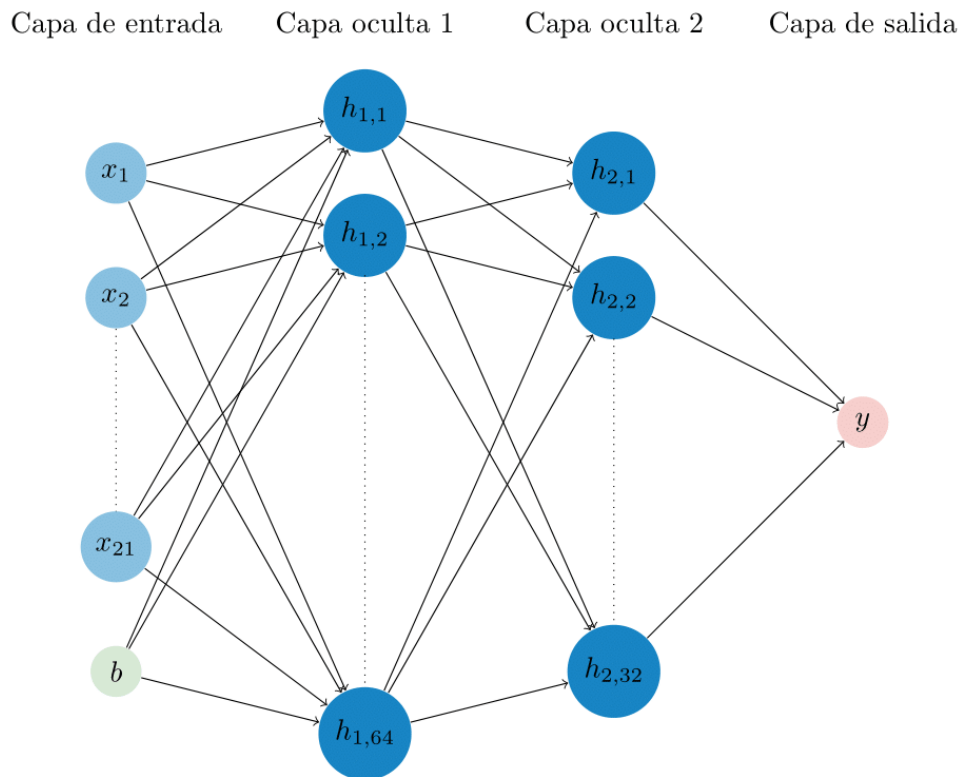


Figura 8 Arquitectura del modelo de RNA utilizado para la predicción de la resistencia a la compresión del hormigón.

Compilación del modelo

Se utilizó “mean_squared_error” de la biblioteca keras, para la compilación del modelo. La compilación implica configurar los elementos necesarios para que el modelo pueda aprender de los datos. Esta función mide la diferencia cuadrática promedio entre las salidas predichas por el modelo y las salidas reales del conjunto de datos de entrenamiento. El objetivo es minimizar esta pérdida durante el entrenamiento. Además, se utilizó el optimizador "Adam" de la biblioteca keras, que es un algoritmo popular para ajustar los pesos del modelo y actualizarlos en función de la magnitud del gradiente y la tasa de aprendizaje.

También se dispuso que, durante el entrenamiento, el modelo se expuso repetidamente a los datos de entrenamiento y ajustó sus pesos para mejorar su rendimiento. En este caso, se

ejecutaron 100 épocas, lo que significa que se recorrieron todos los ejemplos de entrenamiento 100 veces. Cada vez que se presentaba un lote de datos al modelo, se realizaban ajustes en los pesos del modelo para reducir la pérdida y mejorar la capacidad del modelo para hacer predicciones precisas. Se utilizó un tamaño de lote de 32, lo que significa que se presentaban 32 ejemplos a la vez para actualizar los pesos del modelo.

Resultados

Perdida en el proceso de entrenamiento de la Red Neuronal Artificial

Una pérdida de 0.0016 después de 100 épocas indica que el modelo de red neuronal ha logrado ajustarse bastante bien a los datos de entrenamiento. La pérdida se refiere a la diferencia entre las salidas reales y las salidas predichas por el modelo. Cuanto menor sea la pérdida, más cercanas son las predicciones del modelo a los valores reales.

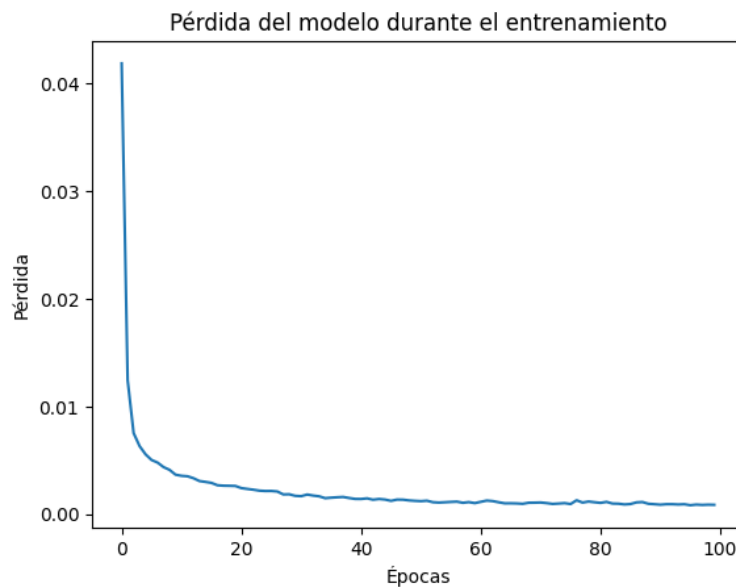


Figura 9 Perdida del modelo durante el entrenamiento

Esto indica que el modelo ha aprendido las relaciones subyacentes en los datos de entrenamiento de manera efectiva y es capaz de hacer predicciones precisas.

Es importante tener en cuenta que la evaluación del modelo solo en los datos de entrenamiento puede llevar a un sesgo optimista. Para obtener una evaluación más completa

del rendimiento del modelo, es necesario también evaluarlo en conjuntos de datos de prueba o validación que no se utilizaron durante el entrenamiento. Esto ayuda a determinar si el modelo está generalizando bien y no está sobre ajustando los datos de entrenamiento.

Resultados de las variables de entrenamiento

El gráfico muestra la relación entre los valores reales de la resistencia a la compresión y los valores pronosticados por el modelo de red neuronal durante el entrenamiento con un coeficiente de determinación R^2 de 0.97.

Al observar el gráfico, se puede ver que la mayoría de los puntos se ajustan bastante cerca de la línea roja, que representa una relación lineal perfecta entre los valores reales y los valores pronosticados. Esto sugiere que el modelo ha aprendido con éxito las características y patrones subyacentes de los datos de entrenamiento, y es capaz de hacer predicciones muy cercanas a los valores reales.

En general, un coeficiente de determinación R^2 de 0.97 y una distribución cercana de los puntos a la línea roja indican un buen ajuste del modelo a los datos de entrenamiento y una capacidad predictiva sólida en términos de pronóstico de la resistencia a la compresión.




Figura 10 Resultados de las variables de entrenamiento vs. los valores reales

Resultados de las variables de prueba

De igual manera, se realizó este gráfico de relación entre los datos de prueba y los valores pronosticados del modelo. En este observa que los valores siguen muy estrechamente a la línea roja de tendencia demostrando así que el modelo es capaz de predecir adecuadamente. Esta información se puede corroborar con el valor del R2, ya que tiene un 95%. Lo que indica que el modelo predice el 95% de los resultados de los datos. Es importante mencionar que los datos de prueba son los datos pertenecientes a las tesis de la Universidad Central.

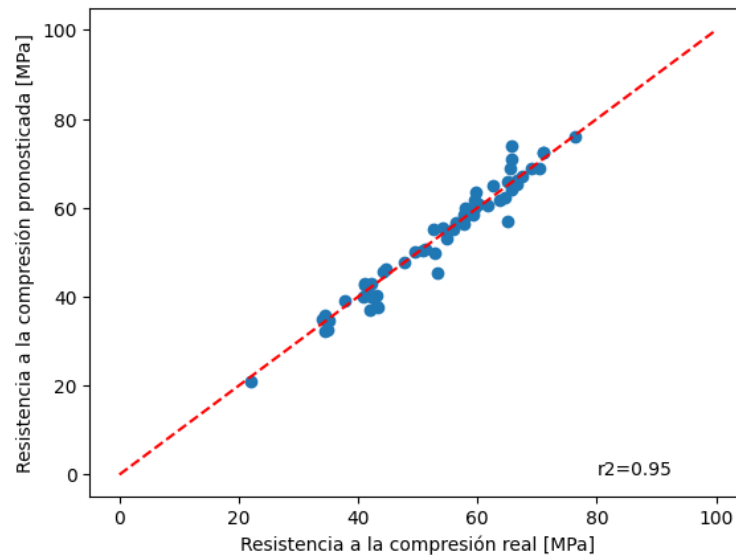


Figura 11 Resultados de las variables de prueba vs. los valores reales

Resultados de las variables de validación

En el mismo sentido, se realizó este gráfico de relación entre los datos de validación y los valores pronosticados del modelo. En este observa que los valores de la respuesta siguen muy estrechamente a la línea roja de tendencia demostrando así que el modelo es capaz de predecir adecuadamente la resistencia a la compresión. Esta información se puede corroborar con el valor del R2, ya que el 97% de las respuestas son explicadas por el modelo. En otras palabras, las variables predictoras que tienen los datos de la Universidad Central son capaces de predecir los resultados de la resistencia a la compresión de la Universidad San Francisco de Quito.

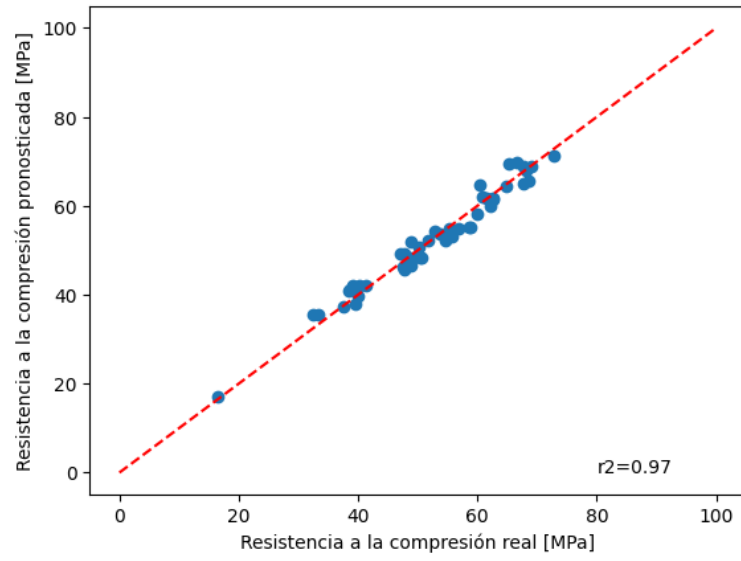


Figura 12 Resultados de las variables de validación vs. los valores reales

IV. CONCLUSIONES

En conclusión, en este trabajo se ha desarrollado un método complementario al diseño de mezclas de hormigón mediante el uso de redes neuronales para estimar la resistencia a la compresión del hormigón. A través de una revisión bibliográfica previa, se ha recopilado información relevante sobre el diseño de mezclas de hormigón, que ha servido como base para entrenar una red neuronal.

La implementación de la red neuronal se realizó utilizando la biblioteca Keras en Python. Se utilizó una arquitectura de red con capas densas y función de activación ReLU en las capas ocultas, y una capa de salida con activación lineal. La red se entrenó utilizando los datos de entrenamiento y se evaluó su rendimiento usando los datos de prueba. Los resultados obtenidos fueron muy prometedores, con una pérdida baja de 0.0016 en los datos de prueba, lo que indica que la red neuronal ha aprendido correctamente las relaciones entre las características de los componentes del hormigón y su resistencia a la compresión.

Además, se llevó a cabo un análisis comparativo entre los datos pronosticados por la red neuronal y los datos reales provenientes de ensayos realizados por la USFQ. Se calculó el coeficiente de determinación R^2 para evaluar la precisión de las predicciones de la red neuronal. Los resultados mostraron un alto coeficiente de determinación de 0.97 en el conjunto de validación, lo que indica una concordancia significativa entre los valores pronosticados y los valores reales de resistencia a la compresión del hormigón.

En resumen, el método propuesto ha demostrado ser efectivo y prometedor en la estimación de la resistencia a la compresión del hormigón en la etapa de diseño de mezcla. La utilización de redes neuronales como herramienta complementaria permite una estimación más precisa y eficiente de la resistencia a la compresión, utilizando variables establecidas por

normativas que garantizan la calidad del hormigón y que deben ser consideradas de manera obligatoria.

V. REFERENCIAS BIBLIOGRÁFICAS

- Abata, J., & Eugenia, M. (2014). Hormigones de alta Resistencia ($f'c=46$ MPa) utilizando agregados del sector de Guayllabamba y cemento campeón especial – Lafarge [UCE]. <http://www.dspace.uce.edu.ec/handle/25000/3001>
- Andino, J., & Mauricio, R. (2015). Hormigones de alta resistencia ($f_c=62$ MPa) utilizando agregados del sector de Pifo y cemento armado especial Lafarge [UCE]. <http://www.dspace.uce.edu.ec/handle/25000/4574>
- Berzosa López, M. H. (2014). Diseño de homigones de alta resistencia($f'c=42$ MPa). Utilizando agregados del sector de Pifo, fibras metálicas Cemento Lafarge Armaduro especial y aditivos hiperfluidificantes [UCE]. <http://www.dspace.uce.edu.ec/handle/25000/3003>
- Chugá, M., & Geovanny, E. (2014). Diseño de hormigones de alta resistencia ($f'c= 44$ MPa), utilizando agregados del sector de Ambuquí, fibras metálicas, cemento Lafarge Armaduro Especial y aditivos hiperfluidificantes [UCE]. <http://www.dspace.uce.edu.ec/handle/25000/3005>
- Cruz, F., & Alexis, H. (2014). Hormigones de alta Resistencia ($f_c=53$ MPa) utilizando agregados del sector de Pifo y cemento armado especial – Lafarge [UCE]. <http://www.dspace.uce.edu.ec/handle/25000/2849>
- García, J. A., & Varón, F. A. P. (2023). Modelo predictivo de redes neuronales para estimar la resistencia a compresión de hormigones con materiales cementantes suplementarios y agregados reciclados. *Matéria (Rio de Janeiro)*, 27(2), e13218. <https://doi.org/10.1590/S1517-707620220002.1318>
- Géron, A. (2019). *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow, 2nd Edition*. O'Reilly Media, Incorporated.
- Idrovo, R., & Oswaldo, S. (2014). Diseño de hormigones de alta resistencia ($f'c=40$ MPa), utilizando agregados del sector de Pifo, fibras metálicas, Cemento Lafarge Armaduro especial y aditivos hiperfluidificantes [UCE]. <http://www.dspace.uce.edu.ec/handle/25000/3004>
- Iza, T., & de las Mercedes, C. (2014). Hormigones de alta Resistencia ($f'c=59$ MPa) utilizando agregados del sector de Pifo y cemento armado especial – Lafarge [UCE]. <http://www.dspace.uce.edu.ec/handle/25000/3010>
- Jiménez, M. (2021). Resultados de Laboratorio 7,8 y Proyecto Final.

- López, M., & David, L. (2014). Hormigones de alta Resistencia ($f'c=42$ MPa) utilizando agregados del sector de Guayllabamba y cemento campeón especial – Lafarge [UCE]. <http://www.dspace.uce.edu.ec/handle/25000/2999>
- Mora, O., & Martí, O. (2020). Estudio de la relación entre la resistencia a la compresión y el módulo de elasticidad estático para hormigones fabricados con cemento por rendimiento y compuesto en el Ecuador [USFQ]. <https://repositorio.usfq.edu.ec/handle/23000/8822>
- Morales, D. A. (2017). TÉCNICAS DE INTELIGENCIA ARTIFICIAL APLICADAS A PROBLEMAS DE INGENIERÍA CIVIL. *Universidad & ciencia*, 6, 164–175. <https://revistas.unica.cu/index.php/uciencia/article/view/195>
- Muñoz, N., & Maricel, A. (2014). Diseño de hormigones de alta resistencia ($f'c= 40$ MPa), utilizando agregados del sector de Ambuquí, fibras metálicas, cemento Lafarge armaduro especial y aditivos hiperfluidificantes [UCE]. <http://www.dspace.uce.edu.ec/handle/25000/3008>
- Nielsen, M. A. (2015). *Neural networks and deep learning* (Vol. 25). Determination press San Francisco, CA, USA.
- Ochoa, C., & Gonzalo, A. (2014). Hormigones de alta Resistencia ($f'c=56$ MPa) utilizando agregados del sector de Pifo y cemento armaduro especial – Lafarge [UCE]. <http://www.dspace.uce.edu.ec/handle/25000/3002>
- Salcedo, L. O. G., Zúñiga, A. P. G., Arjona, S. D., & Will, A. L. E. (2012). Red Neuronal Artificial para estimar la resistencia a compresión, en concretos fibro-reforzados con polipropileno [Artificial neural network to predict the compressive strength, in polypropylene fiber-reinforced concrete]. *Ventana Informática*, 26. <https://doi.org/10.30554/ventanainform.26.217.2012>
- Serrano, C., & Roberto, J. (2014). Hormigones de alta Resistencia ($f'c=50$ MPa) utilizando agregados del sector de Pifo y cemento armaduro especial – Lafarge [UCE]. <http://www.dspace.uce.edu.ec/handle/25000/3022>
- Tipanluisa, P., & Jaqueline, M. (2014). Hormigones de alta Resistencia ($f'c=44$ MPa) utilizando agregados del sector de Guayllabamba y cemento campeón especial – Lafarge [UCE]. <http://www.dspace.uce.edu.ec/handle/25000/3013>
- Vega, R., & Enrique, C. (2014). Diseño de hormigones de alta resistencia ($f'c=44$ MPa), utilizando agregados del sector de Pifo, fibras metálicas, cemento Lafarge Armaduro Especial y aditivos hiperfluidificantes [UCE]. <http://www.dspace.uce.edu.ec/handle/25000/3000>