

## Modelo predictivo de redes neuronales para estimar la resistencia a compresión de hormigones con materiales cementantes suplementarios y agregados reciclados

Neural network-based model to predict compressive strength of concrete incorporating supplementary cementitious materials and recycled aggregates

Joaquín Abellán García<sup>1</sup>, Fernando Andrés Pineda Varón<sup>2</sup>

<sup>1</sup>PhD, Departamento de Ingeniería Civil y Ambiental, Universidad del Norte, Km 5 Vía Puerto Colombia, Barranquilla, Atlántico, Colombia.

<sup>2</sup>Ingeniero Civil, Escuela Colombiana de Ingeniería Julio Garavito, AK 45 (Autonorte) N.205-59, Bogotá, Cundinamarca, Colombia.

e-mail: andres.pineda-v@mail.escuelaing.edu.co, joaquin.abellan-g@escuelaing.edu.co

---

### RESUMEN

El comportamiento del hormigón incorporando agregados reciclados en sustitución total o parcial de los agregados naturales es diferente del comportamiento del hormigón convencional. Así mismo, la sustitución parcial del cemento por materiales cementantes suplementarios afecta también a dicho comportamiento. Pese a que ambas sustituciones parciales presentan indudables beneficios desde el punto de vista de la sostenibilidad, su efecto en la resistencia a compresión del hormigón es difícil de modelar. Este documento tiene como objetivo predecir la resistencia a la compresión de estos hormigones especiales mediante el uso de redes neuronales artificiales (ANN). Los datos de entrenamiento y testeo para el desarrollo del modelo ANN se prepararon utilizando 309 dosificaciones publicadas en 22 fuentes de literatura diferentes. Los resultados indicaron que el modelo ANN es una herramienta eficiente para predecir la resistencia a la compresión de los hormigones que incorporen agregados reciclados y materiales cementantes suplementarios.

**Palabras-clave:** ANN; agregado reciclado; materiales cementantes suplementarios; resistencia a compresión; sostenibilidad.

---

### ABSTRACT

The behavior of concrete incorporating recycled aggregates in total or partial replacement of natural aggregates is different from the behavior of conventional concrete. Likewise, the partial substitution of cement by supplementary cementitious materials also affects the behavior of concrete. Despite the fact that both partial substitutions have undoubted benefits from the point of view of sustainability, their effect on the compressive strength of concrete is difficult to model. This document aims to predict the compressive strength of these special concretes through the use of artificial neural networks (ANN). Training and testing data for the development of the ANN model were prepared using 309 dosages published in 22 different literature sources. The results indicated that the ANN model is an efficient approach for predicting the compressive strength of concretes that incorporate recycled aggregates and supplementary cementitious materials.

**Keywords:** K-fold validation, ANN, UHPC, supplementary cementitious materials, 7-day compressive strength.

---

### 1. INTRODUCCIÓN

Junto con el rápido desarrollo urbano y las actividades económicas, la generación de residuos de construcción y demolición ha aumentado sustancialmente en muchas partes del mundo, lo que ha conducido a que los desechos sólidos en forma de escombros de construcción sean una de las principales preocupaciones ambientales del mundo hoy en día [1, 2]. Actualmente se estima que la producción de escombros de demoliciones de hormigón mundialmente ronda los mil millones de toneladas por año [3]. Sin embargo, solo una pequeña fracción son utilizados para la producción de nuevas construcciones, especialmente como agregado reciclado

para hormigón, a pesar de los beneficios ambientales y económicos [4]. Esto puede deberse a la falta de conocimiento de las relaciones y efectos de este tipo de agregado en la resistencia a compresión y otras propiedades del hormigón.

Por otro lado, el consumo a nivel mundial de agregados naturales para la construcción, incluyendo hormigones, pavimentos asfálticos y rellenos de carreteras se estima asciende a las 48.3 mil millones de toneladas año [5]. Por lo tanto, un mayor uso de los agregados reciclados actuaría favorablemente sobre el medioambiente y la sociedad en dos formas distintas: (i) reduciendo la necesidad de recursos naturales, y (ii) liberando espacio en los vertederos.

Es cierto que varias investigaciones recientes han demostrado que la incorporación de agregado reciclado en el concreto produce una merma relativa en las propiedades mecánicas y de durabilidad del hormigón [1, 4-8]. Sin embargo, esas mismas investigaciones han demostrado que esas mermas en las propiedades del hormigón al utilizar agregados reciclados se pueden minimizar mediante la adicción de materiales cementantes suplementarios [5].

Los materiales cementantes suplementarios (MCS) son aquellos que por sus propiedades pueden ser utilizados en la industria del hormigón en la sustitución parcial del cemento [9, 10]. Dentro de éstos, podemos encontrar dos grupos. Por un lado están los materiales cementantes con propiedades hidráulicas, que cuentan con la capacidad de reaccionar directamente con el agua para formar productos hidratados estables, como es el caso de la escoria siderúrgica o la ceniza volante tipo C [11, 12]. Por otro lado están las puzolanas, que son materiales inorgánicos o artificiales, silíceos o silico-aluminosos con porcentajes bajos de calcio, magnesio, hierro, potasio y sodio, que por sí solo no tienen valor cementante, pero que son capaces de reaccionar con el agua y el CH liberado del cemento Portland hidratado para formar productos de hidratación secundarios tipo CSH o CASH [13, 14]. Algunos ejemplos de materiales puzolánicos serían la ceniza volante tipo F, el polvo de vidrio reciclado, el residuo de craqueo catalítico usado (FC3R), la ceniza de cascarilla de arroz y el humo de sílice [15-19]

También importante destacar que algunos de los materiales cementantes suplementarios, como las cenizas volantes, el residuo de catalizador de craqueo catalítico usado, las escorias siderúrgicas o el polvo de vidrio reciclado son a su vez subproductos industriales [10, 20-22], por lo que su empleo tiene una aportación adicional a la sostenibilidad final del hormigón.

Conocida por tanto la posibilidad de la utilización conjunta de agregados reciclados con materiales cementantes suplementarios para abordar los problemas planteados anteriormente, sería importante establecer un modelo que relacione sus propiedades con la resistencia a compresión final del hormigón. El objetivo de la presente investigación será ajustar un modelo matemático fiable basado en las redes neuronales artificiales para la predicción de la resistencia a compresión de los hormigones que incorporen agregados reciclados y materiales cementantes suplementarios.

## 2. BASE DE DATOS

### 2.1 Recopilación de datos

Las bases de datos de dosificaciones y resistencias a la compresión a los 28 días de hormigones con diferentes combinaciones de materiales cementantes suplementarios, agregados reciclados y agregados naturales se extrajeron de 22 investigaciones publicadas en revistas científicas y simposios de reconocido prestigio [2, 4-8, 17, 23-37] que cubren una amplia gama de materiales cementantes suplementarios como el humo de sílice, la ceniza volante, la escoria siderúrgica, la ceniza de cascarilla de arroz y las puzolanas naturales. Solo se consideraron para la base de datos aquellas dosificaciones con información de la composición de óxidos del cemento y de todos los materiales cementantes que permiten calcular los índices de reactividad equivalente del hormigón de acuerdo a los estudios de XIE *et al.* [11].

Para realizar el cálculo de los índices de reactividad equivalente del hormigón, primero es necesario calcular los índices de reactividad relativos de cada uno de los materiales cementantes [11]. Estos índices, se calculan para cada material cementante  $i$  (incluyendo cemento y materiales cementantes suplementarios) conforme a las Ecuaciones (1-3) [11]:

$$RM_i = \frac{CaO + MgO + Al_2O_3}{SiO_2} \quad (1)$$

$$SM_i = \frac{SiO_2}{Al_2O_3 + Fe_2O_3} \quad (2)$$

$$AM_i = \frac{Al_2O_3}{Fe_2O_3} \quad (3)$$

donde  $RM_i$  es el índice que evalúa las propiedades hidráulicas del material cementante  $i$  mientras que los índices  $SM_i$  y  $AM_i$  se utilizan para caracterizar la reactividad puzolánica del material  $i$  [11].

Obtenidos los índices de reactividad relativos, los índices equivalentes se calculan conforme a las Ecuaciones (4-6):

$$RM = \sum_{i=1}^n RM_i \times wr_i \quad (4)$$

$$SM = \sum_{i=1}^n SM_i \times wr_i \quad (5)$$

$$AM = \sum_{i=1}^n AM_i \times wr_i \quad (6)$$

donde  $RM$ ,  $SM$  y  $AM$  son los índices equivalentes para cada dosificación;  $RM_i$ ,  $SM_i$  y  $AM_i$  son los índices particulares para cada material cementante  $i$ ;  $n$  es el número de materiales cementantes dentro de la dosificación de hormigón; y  $wr_i$  es la relación en peso del material cementante  $i$  respecto a la suma en peso de todos los materiales cementantes de la dosificación.

Bajo los condicionantes anteriormente expuestos, un total de 309 dosificaciones fueron recopiladas con la finalidad de ser utilizadas como datos de entrenamiento y testeo del modelo.

## 2.2 Normalización de datos

Después de la elaboración de la base de datos, el siguiente paso consiste en la normalización de éstos. Los datos brutos de la base de datos, recopilados de los artículos y publicaciones, comprenden identidades diferentes que tienen magnitudes y unidades de medida diferentes. Por ejemplo, el contenido en cemento está expresado en  $kg/m^3$  mientras que el tamaño máximo del agregado está recogido en su valor en milímetros. Por lo tanto, es necesario normalizar los datos de entrada para que su magnitud se equipare y no tengan más influencia unos que otros durante el ajuste del modelo [38–41]. El preprocesamiento o la normalización de los datos elimina la posibilidad de sesgo de las redes neuronales artificiales hacia las diferentes identidades, transformando todos los datos de entrada y salida mediante un cambio de escala [42]. Como es lógico, a la hora de interpretar los resultados obtenidos por los modelos matemáticos será necesario realizar la transformación inversa a los valores obtenidos. La presente investigación emplea una escala lineal en el rango  $[0, 1]$  para la normalización de datos, como se muestra en la **Ecuación (7)**:

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (7)$$

donde  $x_{norm}$  es el valor normalizado de la variable  $x$ , mientras que  $x_{max}$  y  $x_{min}$  son los valores máximos y mínimos de esta variable recogida en la base de datos.

## 2.3 División de datos: datos de entrenamiento y datos de testeo

Para facilitar el entrenamiento y el testeo de los modelos algorítmicos, la base de datos fue dividida aleatoriamente en dos subconjuntos: subconjunto de datos de entrenamiento y subconjunto de datos de testeo. El 80% de las observaciones se utilizaron para fines de entrenamiento y el 20% restante se utilizó para medir la eficiencia los modelos entrenados. Ambos subconjuntos contenían todas las posibilidades en cuanto agregados (finos y gruesos, reciclados y naturales), materiales cementantes suplementarios y otras variables de entrada definidas en el modelo.

Para determinar la eficiencia del modelo algorítmico mientras se definen sus parámetros los datos de entrenamiento se pueden subdividir a su vez en un subconjunto de datos de entrenamiento y otro de datos de validación. Pese a ello, existe el riesgo de que la evaluación sobre el subconjunto de datos de validación

pueda tener una alta dependencia en cuáles observaciones se hayan escogido para la validación y cuáles se hayan escogido para el entrenamiento de los modelos, lo que podría derivar en una evaluación poco confiable del modelo [39, 43]. Una solución frecuente en tales situaciones es emplear la validación cruzada tipo *k-fold* (ver Figura 1). Esta metodología está basada en la división de los datos disponibles en el subconjunto de datos de entrenamiento en  $k$  particiones, planteando  $k$  modelos idénticos y entrenando a cada uno usando  $k - 1$  particiones como datos de entrenamiento mientras se valora la eficiencia del modelo en la partición restante. La valoración de la eficiencia del modelo en el subconjunto de validación es entonces la resultante del promedio de las  $k$  valoraciones de validación obtenidos [39, 44]. En esta investigación se empleó la validación cruzada tipo *k-fold* con  $k = 5$ . La e valoración de la eficiencia del modelo se determinó mediante la raíz cuadrada del error cuadrático medio (RMSE por sus siglas en inglés) promedio de las  $k$  predicciones, tal y como se observa en la Figura 1.



**Figura 1:** Esquema de la validación cruzada tipo *k-fold*.

### 3. METODOLOGÍA

#### 3.1 Introducción

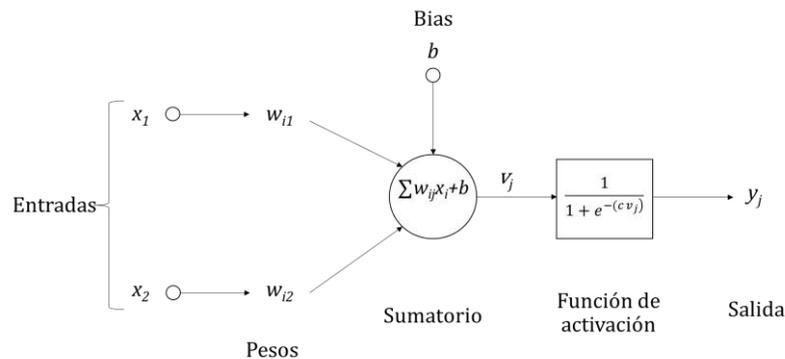
En las últimas décadas hemos vivido una más que notable proliferación de las aplicaciones de metodologías estadísticas y de inteligencia artificial a los diferentes campos de la ciencia [45]. Entre estas aplicaciones podríamos destacar las relativas en el campo de la ingeniería civil a la detección de daños estructurales, la detección y cuantificación de recursos hídricos subterráneos, la optimización de materiales y la ingeniería de tráfico, etc. [46-48]. Por su parte, y dentro de las aplicaciones en la ingeniería de los materiales, el análisis de las propiedades del hormigón en función de su dosificación es una de las áreas de mayor interés científico [49-53].

El presente estudio utiliza redes neuronales regresivas del tipo *feed-forward* para la predicción de la resistencia a la compresión a los 28 días de los hormigones que incorporan materiales cementantes suplementarios y agregados reciclados en su dosificación. Para la construcción de estos algoritmos de inteligencia artificial se hizo uso del lenguaje de programación R versión 3.6.0 [54]. En particular, los modelos se crearon mediante la función *neuralnet* [55].

#### 3.2 Redes neuronales artificiales (ANN)

Las redes neuronales artificiales son un modelo computacional vagamente inspirado en el comportamiento observado en su homólogo biológico. Se basan en un conjunto de elementos procesadores, llamados neuronas artificiales, con elevados niveles de interconexión entre ellos, y que reciben, procesan y envían señales unos a otros [56]. El perceptrón constituye el modelo ANN más sencillo. Este modelo fue desarrollado por Rosenblatt en 1959 [57]. La arquitectura del perceptrón está definida por dos entradas, una única neurona en la capa oculta y una salida, conforme se aprecia en la Figura 2 [56, 57]. Para aplicaciones más complejas, como es el caso que nos ocupa, se puede recurrir a arquitecturas más densas como las del tipo perceptrón multicapa *feed-forward* que consisten en perceptrones colocados de forma multicapa los cuales contienen una capa de entrada, una de salida y una o más capas ocultas [51].

En la Figura 2 se observa el funcionamiento del perceptrón, donde  $x_1$  y  $x_2$  son las variables de entrada aplicadas a la neurona, y  $w_{i1}$  y  $w_{i2}$  son los pesos de la conexión que interconecta cada entrada con la neurona oculta. Además, se agrega un término independiente denominado *bias*. La función de suma ponderada calcula la entrada neta ( $v_j$ ) que recibe la neurona de la capa oculta [58], tal y como se muestra en la Ecuación (8):



**Figura 2:** Diagrama esquemático del perceptrón.

La función de suma ponderada calcula la entrada neta ( $v_k$ ) que recibe la neurona [58], tal y como se muestra en la Ecuación (8):

$$v_k = \sum_{i=1}^n w_{ik} x_i + b \quad (8)$$

donde  $v_k$  es el resultado de la regla de propagación, siendo la suma que recibe la  $k$ -ésima neurona de la capa precedente;  $w_{ik}$  representa el peso de la conexión entre la  $k$ -ésima neurona y la  $i$ -ésima neurona;  $x_i$  es el valor de entrada que la  $i$ -ésima neurona procesa y transmite; y  $b$  es el *bias* [40, 59].

La función de activación recibe la entrada proporcionada por la función de suma ponderada y la procesa obteniendo así la salida de la neurona y aportando el carácter no lineal del proceso. En la presente investigación se adopta la función de activación sigmoide logarítmica que se muestra en la Ecuación (9):

$$y_j = \frac{1}{1 + e^{-(c v_j)}} \quad (9)$$

donde  $C$  representa la constante que define la pendiente de la región semi lineal.

Tal y como se puede apreciar en la Ecuación (9), la función sigmoide logarítmica toma el valor calculado por la función de suma ponderada ( $v_j$ ) y lo condensa en un único valor correspondiente al rango entre 0 y 1 [60], acorde a la normalización de datos realizada previamente.

Por otro lado, el proceso por el cual se ajustan los pesos de las conexiones del modelo de redes neuronales para producir una determinada respuesta es lo que se conoce como *entrenar* a la red. Este proceso es realizado por los algoritmos de aprendizaje en dos etapas diferentes: en la primera se asignan aleatoriamente pesos a todas las conexiones entre las neuronas y se genera un flujo de las señales hacia adelante desde la capa de entrada hasta la de salida. El resultado obtenido se compara con los valores reales también conocidos como valores objetivo. En la siguiente etapa del entrenamiento del modelo, los pesos y el *bias* en las capas ocultas se ajustan en un flujo de información en sentido desde la salida hasta la entrada (es decir, de atrás hacia adelante) con el objetivo de minimizar el error entre los valores predichos por el modelo y los valores objetivo. Es importante destacar que la asignación inicial de pesos tiene una importancia crucial en el ajuste final del modelo [61]. Para evitar modelos mediocres debido a casos de convergencia local por una desafortunada asignación inicial de pesos, una posibilidad consiste en analizar el rendimiento de un mismo modelo con diferentes asignaciones de pesos iniciales, seleccionando aquella asignación inicial que minimiza el error

entre las repuestas conocidas y las predichas por el modelo [61, 62]. En el presente trabajo se han probado 100 asignaciones iniciales por cada uno de los modelos desarrollados.

Por otro lado, el algoritmo de aprendizaje más común para el entrenamiento de modelos de redes neuronales del tipo perceptrón multicapa *feed-forward* es el algoritmo de propagación hacia atrás o *retropropagación* (BP por sus siglas en inglés) desarrollado por Rumelhart et al. [63]. El BP es un algoritmo de entrenamiento cuyo funcionamiento para el ajuste iterativo de los pesos se basa en un gradiente descendente diseñado para minimizar el error cuadrático medio entre la salida del modelo y los valores reales de respuesta [64]. Además de este algoritmo de aprendizaje existen otros entre los que podemos destacar el algoritmo de retropropagación resiliente (Rprop). El aprendizaje con el algoritmo Rprop presenta dos ventajas principales sobre el entrenamiento con BP: menor tiempo de convergencia y la no necesidad de una tasa de aprendizaje (*learning ratio*). En Rprop sólo se tiene en cuenta el signo de la derivada para determinar la dirección de la actualización de los pesos [64, 65]. Para los lectores interesados en mayor información sobre el algoritmo Rprop se recomienda consultar las referencias [64, 65].

En el presente trabajo de investigación se utilizó Rprop como algoritmo de entrenamiento de los modelos ANN.

### 3.3 Variables de entrada al modelo ANN

Se utilizaron catorce variables de entrada en la definición del modelo:

- C - Contenido en cemento expresado en  $\text{kg/m}^3$
- HS - Contenido en humo de sílice expresado en  $\text{kg/m}^3$
- MCS - Contenido en materiales cementantes suplementarios (a excepción del humo de sílice) expresado en  $\text{kg/m}^3$
- RM - Índice de reactividad hidráulica de los cementantes
- SM - Índice de reactividad puzolánica de los cementantes (lado del silíceo)
- AM - Índice de reactividad puzolánica de los cementantes (lado del aluminio)
- AFN - Contenido en agregado fino natural expresado en  $\text{kg/m}^3$
- AFR - Contenido en agregado fino reciclado expresado en  $\text{kg/m}^3$
- AGN - Contenido en agregado grueso natural expresado en  $\text{kg/m}^3$
- AGR - Contenido en agregado grueso reciclado expresado en  $\text{kg/m}^3$
- AGUA - Contenido en agua expresado en  $\text{kg/m}^3$
- HRWR - Contenido en superplastificante expresado en porcentaje sobre el peso del cemento
- AC - Relación agua cemento en peso
- TMA - Tamaño máximo del agregado en mm

Es importante destacar que el hecho de separar el humo de sílice del resto de materiales cementantes suplementarios está motivado porque éste, además de por su elevada reactividad puzolánica [8, 36], afecta positivamente a la resistencia a compresión por su capacidad de reducir la porosidad del hormigón debido a su reducido tamaño de partícula, incrementando así la densidad de empaquetamiento de la mezcla [15, 66, 67].

El rango de variación de todas las variables consideradas en la base de datos se presenta en la Tabla 1, donde R28 representa la resistencia a compresión a los 28 días.

**Tabla 1:** Rango de variación y estadísticas de las variables consideradas en la presente investigación.

	C	HS	MCS	RM	SM	AM	AFN	AFR
<b>Máximo</b>	575.0	86.0	228.0	3.8	5.4	3.1	1,426.0	1,050.0
<b>Mínimo</b>	110.0	0.0	0.0	1.4	1.8	0.0	0.0	0.0
<b>Promedio</b>	329.3	3.9	41.8	3.4	2.6	1.7	624.7	60.9
<b>Desviación Estándar</b>	85.6	11.4	66.4	0.4	0.7	0.6	249.3	187.0

	AGN	AGR	AGUA	HRWR	AC	TMA	R28 (MPa)
<b>Máximo</b>	4,048.0	1,280.0	257.0	10.0	1.0	35.0	84.4
<b>Mínimo</b>	0.0	0.0	90.0	0.0	0.3	7.0	4.5
<b>Promedio</b>	589.3	511.6	188.7	0.8	0.5	21.7	37.6

<b>Desviación Estándar</b>	515.7	410.6	27.7	1.4	0.1	6.0	11.1
----------------------------	-------	-------	------	-----	-----	-----	------

### 3.4 Evaluación del desempeño del modelo ANN

Para evaluar el desempeño de modelo desarrollado en este estudio se emplearon seis indicadores estadísticos: el error absoluto medio (MAE), la raíz del error cuadrático medio (RMSE), la relación entre el RMSE y la desviación estándar de los datos medidos (RSR), el error de sesgo medio normalizado (NMBE), el coeficiente de eficiencia (E), y el coeficiente de determinación múltiple ( $R^2$ ). Las expresiones de cálculo de estos indicadores estadísticos se presentan en las ecuaciones **Ecuaciones (10) - (15)**.

$$MAE = \frac{1}{n} \sum_{i=1}^n |a_i - \hat{a}_i| \quad (10)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (a_i - \hat{a}_i)^2}{n}} \quad (11)$$

$$RSR = \frac{RMSE}{\sqrt{\frac{1}{n} \sum_{i=1}^n (a_i - \bar{a}_i)^2}} \quad (12)$$

$$NMBE(\%) = \frac{\frac{1}{n} \sum_{i=1}^n (a_i - \hat{a}_i)}{\hat{a}_i} \times 100 \quad (13)$$

$$E = 1 - \frac{\sum_{i=1}^n (a_i - \hat{a}_i)^2}{\sum_{i=1}^n (a_i - \bar{a}_i)^2} \quad (14)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (a_i - \hat{a}_i)^2}{\sum_{i=1}^n (\hat{a}_i)^2} \quad (15)$$

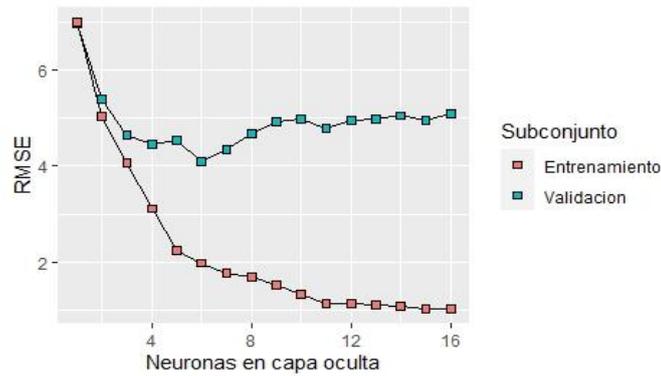
siendo  $a$  la respuesta real o valor objetivo;  $\bar{a}$  la media del objetivo,  $\hat{a}$  el valor predicho por el modelo ANN y  $n$  el número total de observaciones.

El estadístico MAE se basa en las diferencias absolutas entre los valores objetivo y los predichos por el modelo predictivo. Para una asociación perfecta entre valores objetivos y predichos, el valor óptimo de MAE es cero [47]; El RMSE es uno de los índices para medir la precisión de los sistemas de regresión más extendidos [68]. Su cómputo se basa en la comparación de los valores predichos por el modelo con los valores objetivo y calcula la raíz cuadrada del error residual promedio, señalando el error en las unidades de la variable respuesta, en nuestro caso en MPa. El valor óptimo de RMSE para un sistema predictivo perfecto es cero. Sin embargo, el RMSE proporciona más peso a los datos de mayor magnitud [38]; Por ello, el indicador RSR añade a los beneficios del índice RMSE un factor de estandarización. Un valor bajo del RSR indica una mejor predicción del modelo [68]; El estadístico NMBE proporciona información sobre el sesgo medio en las predicciones de un modelo. Un NMBE negativo señala una predicción excesiva y un NMBE positivo señala una predicción insuficiente del modelo [62]; El coeficiente de eficiencia (E), propuesto por Nash y Sutcliffe [69] es uno de los índices estadísticos más ampliamente utilizados para evaluar el rendimiento de modelos predictivos. Un valor de E próximo a 1 indica una buena precisión del modelo; El coeficiente de determinación ( $R^2$ ) se define como la proporción de la varianza total de la variable explicada por la regresión [70]. Las estadísticas de  $R^2$  dependen de las relaciones lineales entre los valores predichos por el modelo y los valores objetivo y, en ocasiones, pueden proporcionar resultados sesgados cuando esta relación no es lineal o cuando los valores contienen muchos valores atípicos. Para una asociación perfecta entre los valores objetivo y predichos, el valor de  $R^2$  es la unidad. Un uso combinado de las métricas de evaluación del modelo expuestas anteriormente puede proporcionar una estimación imparcial de la capacidad predictiva del modelo matemático [38].

#### 4. METODOLOGÍA

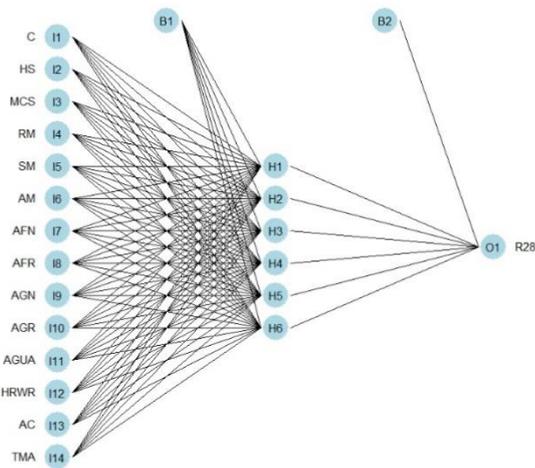
##### 4.1 Arquitectura de la red neuronal

Elegir la arquitectura más apropiada para el modelo de ANN, es decir, el número de neuronas en la capa oculta es el primer paso importante en el desarrollo algorítmico. La **Figura 3** representa el valor de RMSE obtenido durante el proceso de entrenamiento por validación cruzada tipo *k-fold* para diferentes números de neuronas en la capa oculta. Hay que precisar que dicha **Figura 3** solo representa el valor de RMSE correspondiente a la asignación de pesos iniciales de mejor rendimiento de entre las 100 probadas para las distintas neuronas en la capa oculta en el subconjunto de validación.



**Figura 3.** Valor de promedio RMSE versus número de neuronas en capa oculta obtenido durante la validación cruzada tipo *k-fold* para los subconjuntos de entrenamiento y validación.

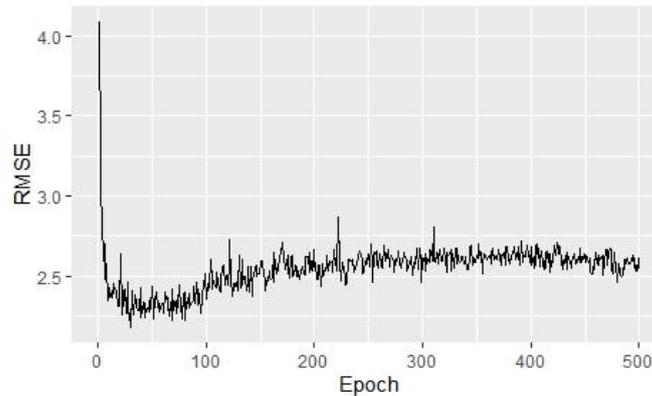
Debido al sobreajuste del modelo al incrementar el número de neuronas, puede observarse que para los datos de entrenamiento el promedio de RMSE obtenido decrece con el aumento del número de neuronas. Esto no ocurre con el subconjunto de datos de validación [39], que es el que se utiliza para la selección de la arquitectura del modelo. De acuerdo con esto, el mejor rendimiento de RMSE se alcanzó cuando se cuenta con seis neuronas en la capa oculta. Por lo tanto, se seleccionó la arquitectura que se muestra en la **Figura 4**.



**Figura 4.** Modelo ANN seleccionado.

Sin embargo, el valor RMSE mínimo de 4,09 MPa alcanzado para esta configuración parece un error todavía muy alto, considerando que supone más del 10% del valor promedio de las observaciones de la base de datos. Por lo tanto, es deseable mejorar el rendimiento del modelo. Una forma común de mejorar el rendimiento de la red neuronal consiste en pasar los datos de entrenamiento a través de la red varias veces. Para definir el número de veces que es necesario pasar los datos de entrenamiento por la red (*epochs*), se vuelve a recurrir a la validación cruzada tipo *k-fold*. La **Figura 5** representa el valor promedio de RSME en la validación *k-fold* versus el número de *epochs*.

De acuerdo con la **Figura 5**, el mínimo valor de RMSE obtenido en la validación *k-fold* se produce cuando los datos de entrenamiento se pasan 30 veces por la red. A partir de ese número el modelo empieza a perder precisión. Por lo tanto, el modelo definitivo mostrado en la **Figura 4** se entrena 30 veces con los datos de entrenamiento. Después de este proceso, se puede observar una mejora significativa, habiendo reducido el RMSE obtenido de 4.09 a 2.18 MPa.



**Figura 5.** Valor de RMSE versus número de veces que se pasan los datos de entrenamiento por la red.

#### 4.2 Evaluación del modelo ANN

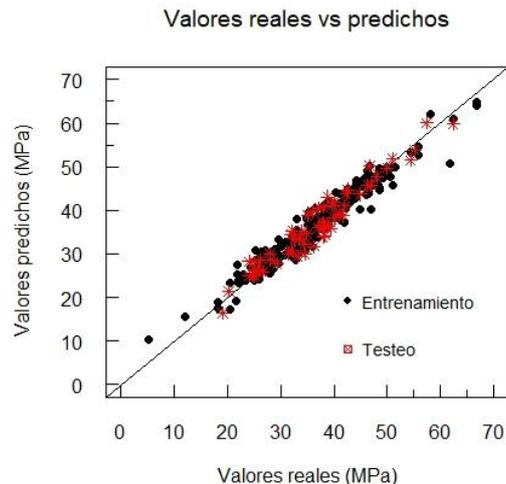
Los resultados de la evaluación del modelo mediante los índices estadísticos expuestos en la sección 3.3. para los datos de entrenamiento y testeo se presentan en la **Tabla 2**.

**Tabla 2.** Índices estadísticos de evaluación del modelo sobre los datos de entrenamiento y testeo

Conjunto	MAE (MPa)	RMSE (MPa)	RSR	NMBE (%)	E	R <sup>2</sup>
Entrenamiento	1.65	2.18	0.20	0.02	0.96	0.96
Testeo	2.03	2.34	0.23	0.17	0.95	0.95

De acuerdo con la Tabla 2, los indicadores estadísticos empleados para la evaluación del modelo indican una precisión similar en los datos de entrenamiento y testeo. Esto confirma el buen desempeño de la validación cruzada *k-fold* utilizada como procedimiento para evitar el sobreajuste del modelo ANN [39] durante el proceso de entrenamiento.

Acorde a la Tabla 2 el modelo propuesto pronosticó la resistencia a compresión de los hormigones que incorporan materiales cementantes suplementarios y agregados reciclados con unos valores de MAE y RMSE de 2.03 y 2.34 MPa en el subconjunto de testeo. Estos valores representan en torno al 6% del valor medio de las resistencias a compresión de la base de datos, por lo que pueden considerarse pequeños. Además, los valores obtenidos para los estadísticos RSR, NMBE y E también se encuentran próximos a los valores óptimos de estos indicadores, confirmado el buen desempeño del modelo. Esto último se reafirma por un lado con el valor de R<sup>2</sup> de 0.95, muy próximo a la unidad, y por otro por la Figura 6 en la que se observa claramente que los valores predichos y los valores reales se encuentran muy próximos entre sí.



**Figura 6.** Gráfico comparativo entre valores reales de resistencia a compresión y valores de resistencia a compresión predichos por el modelo ANN.

#### 4.3 Análisis CWA del modelo ANN

Los modelos de redes neuronales artificiales son con frecuencia etiquetados como *black-box*, debido a la creencia de que proporcionan poca información explicativa sobre las variables de entrada con respecto a la variable respuesta. Sin embargo, el algoritmo CWA (*Connection Weight Approach*) desarrollado por OLDEN *et al.* [71, 72] permite examinar la conexión entre las señales de entrada y de salida. Este método proporciona una metodología adecuada para cuantificar con exactitud la importancia de cada variable de entrada en la respuesta final del modelo utilizando los pesos de las conexiones de la red neuronal. El análisis CWA mantiene las contribuciones relativas de cada peso de conexión tanto en magnitud como en signo, lo que puede definirse como una ventaja [71–74]. Esta técnica ha sido reportada recientemente en el análisis de hormigones especiales mediante ANN [75, 76].

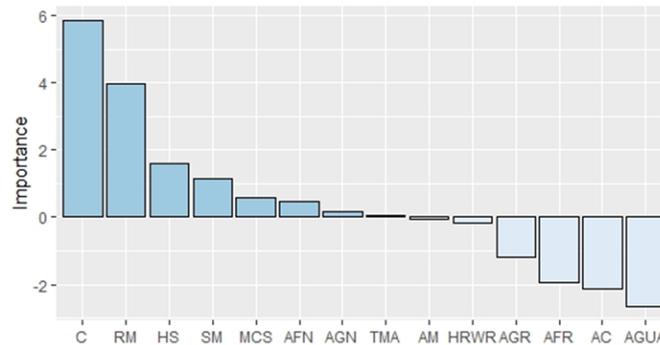
La metodología CWA se utilizó en este estudio para evaluar la importancia de cada variable de entrada en la resistencia a la compresión a los 28 días del concreto con la utilización de agregados reciclados y materiales cementantes suplementarios.

Los resultados obtenidos del análisis CWA se presentan en la Figura 7 donde es posible observar que las variables de entrada con efecto positivo más importantes fueron el contenido de cemento y el índice RM. Esto coincide con los resultados de diferentes investigadores, que concluyen que una buena forma de paliar las mermas en resistencia producidas por el uso de agregados reciclados son la adición de cemento o de materiales cementantes suplementarios con elevada reactividad hidráulica (que es lo que mide el índice RM) [26, 29, 37].

Las siguientes variables con importancia positiva serían el humo de sílice y el índice SM. Esto confirmaría que una forma de fomentar el uso de materiales reciclados sería el empleo conjunto de materiales cementantes suplementarios [5], siendo más beneficiosos aquellos que presenten reactividad hidráulica elevada [26, 29, 37], como sería el caso de las escorias y la ceniza volante tipo C, que aquellos que presenten elevada reactividad puzolánica, como sería el caso del humo de sílice, la ceniza de cascarilla de arroz y la ceniza volante tipo F. El uso de humo de sílice además cuenta con la restricción de uso que representa su elevado coste, por lo que estaría desaconsejado frente a otros materiales cementantes suplementarios, especialmente frente a las escorias y cenizas volantes tipo C.

Por otro lado, los efectos negativos más significativo en la resistencia a la compresión del concreto a 28 días utilizando los materiales reciclados corresponde en orden al contenido de agua, la relación agua-cemento, el agregado fino reciclado y el agregado grueso reciclado. El efecto negativo del agua y la relación de agua-cemento en la resistencia es un efecto bien conocido. En cuanto a los agregados reciclados se ha demostrado mediante varias investigaciones experimentales [23, 29, 37] que a mayor cantidad de agregados reciclados, la resistencia a la compresión del concreto disminuye debido a la alta porosidad, menor resisten-

cia y la elevada absorción de agua de estos agregados. Por otro lado, estas investigaciones también indican que el agregado reciclado genera una mayor porosidad en el hormigón y una menor densidad.



**Figura 7.** Resultado del análisis CWA indicando la importancia de las variables de entrada en la resistencia a compresión del hormigón.

## 5. RESULTADOS Y DISCUSIÓN

Esta investigación propone un modelo preciso basado en redes neuronales de una capa oculta para predecir la resistencia a la compresión a los 28 días del hormigón con agregados reciclados y/o materiales cementantes suplementarios. Para evitar el sobreajuste del modelo a los datos de entrenamiento, se empleó la validación cruzada tipo *k-fold*. En base a los resultados de este trabajo, se extraen las siguientes conclusiones:

1. El modelo propuesto con 6 neuronas en la capa oculta y entrenado 30 veces con los datos de entrenamiento presenta el menor error en la validación cruzada tipo *k-fold* durante el entrenamiento de la red. Esto justifica su selección.
2. Los resultados del uso combinado de las métricas de rendimiento, que incluyeron MAE, RMSE, RSR, E, NMBE y  $R^2$ , proporcionaron una información imparcial que confirmó la idoneidad del modelo propuesto.
3. Los resultados del análisis CWA confirmaron los efectos negativos en la resistencia a compresión del empleo de agregados reciclados.
4. Los resultados del análisis CWA señalaron a los materiales cementantes suplementarios como una posible solución para limitar la pérdida de resistencia producida por el empleo de agregados reciclados. Son especialmente recomendables aquellos materiales cementantes suplementarios que posean elevada reactividad hidráulica, como sería el caso de las escorias y la ceniza tipo C, frente aquellos que posean alta reactividad puzolánica, como el humo de sílice, la ceniza de cascarilla de arroz o la ceniza volante tipo F.

Finalmente, el modelo matemático propuesto puede servir de ayuda en el desarrollo de campañas experimentales de búsqueda de dosificaciones óptimas de hormigones incorporando agregados reciclados y materiales cementantes suplementarios, ya que permite preseleccionar para la campaña experimental aquellos materiales disponibles que presenten mejores resultados en el modelo a menor coste, mayor beneficio ambiental o una combinación de ambos.

## 6. AGRADECIMENTOS

Los autores agradecen a la Dirección de Tecnología OSIRIS de la Escuela Colombiana de Ingeniería Julio Garavito por el apoyo y disposición de los servidores para correr los algoritmos de inteligencia artificial sobre los que se trata en el presente trabajo.

## 7. BIBLIOGRAFIA

- [1] NADERPOUR, H., HOSSEIN, A., FAKHARIAN, P., Compressive strength prediction of environmentally friendly concrete using artificial neural networks, <https://doi.org/10.1016/j.jobte.2018.01.007>. *Journal of Building Engineering*, v. 16, n. October 2017, pp. 213–219, 2018.
- [2] DUAN, Z. H., KOU, S. C., POON, C. S., Prediction of compressive strength of recycled aggregate concrete using artificial neural networks, <https://doi.org/10.1016/j.conbuildmat.2012.04.063>. *Construction and Building Materials*, v. 40, pp. 1200–1206, 2013.
- [3] MALEŠEV, M., RADONJANIN, V., MARINKOVIĆ, S., Recycled concrete as aggregate for structural concrete production, <https://doi.org/10.3390/su2051204>. *Sustainability*, v. 2, n. 5, pp. 1204–1225, 2010.
- [4] MARDANI-AGHABAGLOU, A., TUYAN, M., RAMYAR, K., Mechanical and durability performance of concrete incorporating fine recycled concrete and glass aggregates, <https://doi.org/10.1617/s11527-014-0342-3>. *Materials and Structures/Materiaux et Constructions*, v. 48, n. 8, pp. 2629–2640, 2015.
- [5] SURYA, M., LAKSHMY, P., RAO, V. V. L. K., Bond behaviour of recycled aggregate concrete, [https://doi.org/10.1007/978-981-13-0362-3\\_77](https://doi.org/10.1007/978-981-13-0362-3_77). *Lecture Notes in Civil Engineering*, v. 11, n. December 2016, pp. 971–983, 2019.
- [6] POON, C. S., LAM, L., KOU, S. C., *et al.*, Rate of pozzolanic reaction of metakaolin in high-performance cement pastes, [https://doi.org/10.1016/S0008-8846\(01\)00581-6](https://doi.org/10.1016/S0008-8846(01)00581-6). *Cement and Concrete Research*, v. 31, n. 9, pp. 1301–1306, 2001.
- [7] KOU, S. C., XING, F., The Effect of Recycled Glass Powder and Reject Fly Ash on the Mechanical Properties of Fibre-Reinforced Ultrahigh Performance Concrete, <https://doi.org/10.1155/2012/263243>. *Hindawi Publishing Corporation Advances in Materials Science and Engineering*, n. May, 2012.
- [8] ÇAKIR, Ö., SOFYANLI, Ö.Ö., Influence of silica fume on mechanical and physical properties of recycled aggregate concrete, <https://doi.org/10.1016/j.hbrcej.2014.06.002>. *HBRC Journal*, v. 11, n. 2, pp. 157–166, 2015.
- [9] NEIRA-MEDINA, A., ABELLAN-GARCIA, J., TORRES-CASTELLANOS, N., Flexural behavior of environmentally friendly ultra-high-performance concrete with locally available low-cost synthetic fibers, <https://doi.org/10.1080/19648189.2021.1938686>. *European Journal of Environmental and Civil Engineering*, v. June, pp. 1–20, 2021.
- [10] ABELLAN-GARCIA, J., SANTOFIMO-VARGAS, M. A., TORRES-CASTELLANOS, N., Analysis of metakaolin as partial substitution of ordinary Portland cement in Reactive Powder Concrete, <https://doi.org/10.1520/ACEM20190224>. *Advances in Civil Engineering Materials*, v. 9, n. 1, pp. 368–386, 2020.
- [11] XIE, T., YANG, G., ZHAO, X., *et al.*, A unified model for predicting the compressive strength of recycled aggregate concrete containing supplementary cementitious materials, <https://doi.org/10.1016/j.jclepro.2019.119752>. *Journal of Cleaner Production*, v. 251, p. 119752, 2020.
- [12] ABELLÁN-GARCÍA, J., NÚÑEZ-LÓPEZ, A., TORRES-CASTELLANOS, N., *et al.*, Factorial design of reactive powder concrete containing electric arc slag furnace and recycled glass powder, <https://doi.org/http://doi.org/10.15446/dyna.v87n213.82655>. *Dyna*, v. 87, n. 213, pp. 42–51, 2020.
- [13] ŠERELIS, E., VAITKEVIČIUS, V., KERŠEVIČIUS, V., Mechanical Properties and Microstructural Investigation of Ultra-High Performance Glass Powder Concrete, <https://doi.org/10.5755/j01.sace.14.1.14478>. *Journal of Sustainable Architecture and Civil Engineering*, v. 1, n. 14, pp. 5–11, 2016.
- [14] SHI, C., WU, Z., XIAO, J., *et al.*, A review on ultra high performance concrete: Part II. Hydration, microstructure and properties, <https://doi.org/10.1016/j.conbuildmat.2015.10.088>. *Construction and Building Materials*, v. 96, n. October, pp. 368–377, 2015.
- [15] ABELLÁN, J., FERNÁNDEZ, J., TORRES, N., *et al.*, “Development of cost-efficient UHPC with local materials in Colombia,” in *Proceedings of Hipermat 2020 - 5th International Symposium on UHPC and Nanotechnology for Construction Materials*, 2020, pp. 97–98.
- [16] LI, Z., RANGARAJU, P. R., “Development of UHPC Using Ternary Blends of Ultra- Fine Class F Fly Ash , <https://doi.org/10.21838/uhpc.2016.64>. Meta-kaolin and Portland Cement,” in *First International Interactive Symposium on UHPC*, 2016, n. September, pp. 1–12.
- [17] TANGCHIRAPAT, W., BURANASING, R., JATURAPITAKKUL, C., *et al.*, Influence of rice husk-bark ash on mechanical properties of concrete containing high amount of recycled aggregates, <https://doi.org/10.1016/j.conbuildmat.2007.05.004>. *Construction and Building Materials*, v. 22, n. 8, pp. 1812–1819, 2008.
- [18] ABELLÁN-GARCÍA, J., NÚÑEZ-LÓPEZ, A., TORRES-CASTELLANOS, N., *et al.*, Effect of FC3R on the properties of ultra-high-performance concrete with recycled glass, <https://doi.org/10.15446/dyna.v86n211.79596>. *Dyna*, v. 86, n. 211, pp. 84–92, 2019.
- [19] ABELLÁN-GARCÍA, J., TORRES-CASTELLANOS, N., FERNÁNDEZ-GÓMEZ, J.A., *et al.*, Ultra-high-performance concrete with local high unburned carbon fly ash, <https://doi.org/http://doi.org/10.15446/dyna.v88n216.89234>. *Dyna*, v. 88, n. 216, pp. 38–47, 2021.

- [20] ABELLÁN, J., FERNÁNDEZ, J., TORRES, N., *et al.*, Statistical Optimization of ultra-high-performance glass concrete, <https://doi.org/10.14359/51720292>. *ACI Mater Journal*, v. 117, n. 1, pp. 243-254, 2020.
- [21] CAMACHO TORREGROSA, E., Dosage optimization and bolted connections for UHPFRC ties, Ph.D Dissertation, Polytechnic University of Valencia, Spain, 2013.
- [22] ABELLÁN-GARCÍA, J., FERNÁNDEZ-GÓMEZ, J., TORRES-CASTELLANOS, N., *et al.*, Tensile behavior of normal strength steel fiber green UHPFRC, <https://doi.org/10.14359/51725992>. *ACI Materials Journal*, v. 118, n. 1, pp. 127-138, 2021.
- [23] FAWZY, Y. A., Impact of recycled gravel obtained from low or medium concrete grade on concrete properties, <https://doi.org/10.1016/j.hbrcej.2016.04.003>. *HBRC Journal*, v. 14, n. 1, pp. 1-8, 2018.
- [24] OZBAKKALOGLU, T., GHOLAMPOUR, A., XIE, T., Mechanical and durability properties of recycled aggregate concrete: Effect of recycled aggregate properties and content, [https://doi.org/10.1061/\(ASCE\)MT.1943-5533.0002142](https://doi.org/10.1061/(ASCE)MT.1943-5533.0002142). *Journal of Materials in Civil Engineering*, v. 30, n. 2, 2018.
- [25] ZHENG, C., LOU, C., DU, G., *et al.*, Mechanical properties of recycled concrete with demolished waste concrete aggregate and clay brick aggregate, <https://doi.org/10.1016/j.rinp.2018.04.061>. *Results in Physics*, v. 9, n. April, pp. 1317-1322, 2018.
- [26] LIMA, C., CAGGIANO, A., FAELLA, C., *et al.*, Physical properties and mechanical behaviour of concrete made with recycled aggregates and fly ash, <https://doi.org/10.1016/j.conbuildmat.2013.04.051>. *Construction and Building Materials*, v. 47, pp. 547-559, 2013.
- [27] PEREIRA, P., EVANGELISTA, L., DE BRITO, J., The effect of superplasticizers on the mechanical performance of concrete made with fine recycled concrete aggregates, <https://doi.org/10.1016/j.cemconcomp.2012.06.009>. *Cement and Concrete Composites*, v. 34, n. 9, pp. 1044-1052, 2012.
- [28] FAN, C. C., HUANG, R., HWANG, H., *et al.*, The effects of different fine recycled concrete aggregates on the properties of Mortar, <https://doi.org/10.3390/ma8052658>. *Materials*, v. 8, n. 5, pp. 2658-2672, 2015.
- [29] DILBAS, H., ŞİMŞEK, M., ÇAKIR, Ö., An investigation on mechanical and physical properties of recycled aggregate concrete (RAC) with and without silica fume, <https://doi.org/10.1016/j.conbuildmat.2014.02.057>. *Construction and Building Materials*, v. 61, n. June, pp. 50-59, 2014.
- [30] POON, C. S., KOU, S. C., Properties of steam cured recycled aggregate concrete, *Proceedings of the International Conference on Sustainable Waste Management and Recycling: Construction Demolition Waste*, n. January 2004, pp. 1-12, 2004.
- [31] TÜFEKÇİ, M. M., ÇAKIR, Ö., An Investigation on Mechanical and Physical Properties of Recycled Coarse Aggregate (RCA) Concrete with GGBFS, *International Journal of Civil Engineering*, v. 15, n. 4, pp. 549-563, 2017.
- [32] WU, X., PAN, Y., JIAO, Y., Influence of fly ash as cement replacement on chloride penetration and frost resistance of recycled concrete, <https://doi.org/10.4028/www.scientific.net/AMR.250-253.1031>. *Advanced Materials Research*, v. 250-253, n. September, pp. 1031-1037, 2011.
- [33] LETELIER, V., ORTEGA, J. M., TARELA, E., *et al.*, Mechanical performance of eco-friendly concretes with volcanic powder and recycled concrete aggregates, <https://doi.org/10.3390/su10093036>. *Sustainability (Switzerland)*, v. 10, n. 9, 2018.
- [34] MANZI, S., MAZZOTTI, C., BIGNOZZI, M. C., Short and long-term behavior of structural concrete with recycled concrete aggregate, <https://doi.org/10.1016/j.cemconcomp.2013.01.003>. *Cement and Concrete Composites*, v. 37, n. 1, pp. 312-318, 2013.
- [35] AL-AZZAWI, A. A., Mechanical properties of recycled aggregate concrete, *ARPN Journal of Engineering and Applied Sciences*, v. 11, n. 19, pp. 11233-11238, 2016.
- [36] CORINALDESI, V., MORICONI, G., Influence of mineral additions on the performance of 100% recycled aggregate concrete, <https://doi.org/10.1016/j.conbuildmat.2009.02.004>. *Construction and Building Materials*, v. 23, n. 8, pp. 2869-2876, 2009.
- [37] ÇAKIR, O., Experimental analysis of properties of recycled coarse aggregate (RCA) concrete with mineral additives, <https://doi.org/10.1016/j.conbuildmat.2014.06.032>. *Construction and Building Materials*, v. 68, pp. 17-25, 2014.
- [38] CHANDWANI, V., AGRAWAL, V., NAGAR, R., Modeling slump of ready mix concrete using genetic algorithms assisted training of Artificial Neural Networks, <https://doi.org/10.1016/j.eswa.2014.08.048>. *Expert Systems with Applications*, v. 42, n. 2, pp. 885-893, 2015.
- [39] CHOLLET, F., ALLAIRE, J. J., *Deep Learning with R*, New Jersey, Manning Publications Co., 2018.
- [40] ABELLÁN-GARCÍA, J., GUZMÁN-GUZMÁN, J. S., SÁNCHEZ-DÍAZ, J. A., *et al.*, Experimental validation of Artificial Intelligence model for the energy absorption capacity of UHPFRC, <https://doi.org/https://doi.org/10.15446/dyna.v88n217>. *Dyna*, v. 88, n. 217, pp. 150-159, 2021.
- [41] ABELLÁN-GARCÍA, J., Comparison of artificial intelligence and multivariate regression in modeling the flexural behavior of UHPFRC, <https://doi.org/http://doi.org/10.15446/dyna.v87n214.86172>. *Dyna*, v. 87, n. 214, pp. 239-248, 2020.

- [42] CHANDWANI, V., NAGAR, R., Applications of Artificial Neural Networks in Modeling Compressive Strength of Concrete : A State of the Art Review, *International Journal of Current Engineering and Technology*, v. 4, n. 4, pp. 2949-2956, 2014.
- [43] ABELLÁN-GARCÍA, J., GUZMÁN-GUZMÁN, J. S., Random forest-based optimization of UHPFRC under ductility requirements for seismic retrofitting applications, <https://doi.org/10.1016/j.conbuildmat.2021.122869>. *Construction and Building Materials*, v. 285, 2021.
- [44] ABELLÁN-GARCÍA, J., K -fold Validation Neural Network Approach for Predicting the One-Day Compressive Strength of UHPC, <https://doi.org/10.1520/ACEM20200055>. *Advances in Civil Engineering Materials*, v. 10, n. 1, pp. 223-243, 2021.
- [45] ———, Dosage optimization and seismic retrofitting applications of Ultra-HighPerformance Fiber Reinforced Concrete (UHPFRC), Ph.D. Dissertation, Polytechnic University of Madrid, 2020.
- [46] ADELI, H., *Neural Networks in Civil Engineering : 1989 – 2000*, Computer-Aided Civil and Infrastructure Engineering, v. 16, pp. 126-142, 2002.
- [47] ADERAW, M., MUSE, S., ABIERO, Z. C., Artificial neural network based modelling approach for strength prediction of concrete incorporating agricultural and construction wastes, <https://doi.org/10.1016/j.conbuildmat.2018.09.097>. *Construction and Building Materials*, v. 190, pp. 517-525, 2018.
- [48] ABELLÁN-GARCÍA, J., FERNÁNDEZ-GÓMEZ, J. A., TORRES-CASTELLANOS, N., *et al.*, “Machine Learning Prediction of Flexural Behavior of UHPFRC,” In: Serna, P., Llano-Torre, A., Martí-Vargas, J.R., *et al.* (eds), [https://doi.org/10.1007/978-3-030-58482-5\\_52](https://doi.org/10.1007/978-3-030-58482-5_52). *Fibre Reinforced Concrete: Improvements and Innovations. BEFIB 2020.*, v. 4, n. September, Valencia, Spain, RILEM Bookseries, pp. 570–583, 2020.
- [49] GHAFARI, E., COSTA, H., NUNO, E., *et al.*, RSM-based model to predict the performance of self-compacting UHPC reinforced with hybrid steel micro-fibers, <https://doi.org/10.1016/j.conbuildmat.2014.05.064>. *Construction and Building Materials*, v. 66, n. September, pp. 375-383, 2014.
- [50] GHAFARI, E., COSTA, H., JÚLIO, E., “Statistical mixture design approach for eco- efficient UHPC”, <https://doi.org/10.1016/j.cemconcomp.2014.07.016>. *Cement and Concrete Composites*, v. 55, n. September, pp. 17-25, 2015.
- [51] GHAFARI, E., BANDARABADI, M., COSTA, H., *et al.*, Prediction of Fresh and Hardened State Properties of UHPC: Comparative Study of Statistical Mixture Design and an Artificial Neural Network Model, [https://doi.org/10.1061/\(ASCE\)MT.1943-5533.0001270](https://doi.org/10.1061/(ASCE)MT.1943-5533.0001270). *Journal of Materials in Civil Engineering*, v. 27, n. 11, p. 04015017, 2015.
- [52] BHARATHI, S. D., MANJU, R., PREMALATHA, J., Prediction of Compressive Strength for Self- Compacting Concrete ( SCC ) using Artificial Intelligence and Regression Analysis, *International Journal of ChemTech Research*, v. 10, n. 8, pp. 263-275, 2017.
- [53] ZHANG, J., ZHAO, Y., Prediction of compressive strength of ultra-high performance concrete (UHPC) containing supplementary cementitious materials, <https://doi.org/10.1109/ICSGEA.2017.150>. *Proceedings - 2017 International Conference on Smart Grid and Electrical Automation, ICSGEA 2017*, v. 2017-Janua, pp. 522-525, 2017.
- [54] R CORE TEAM, “R: A Language and Environment for Statistical Computing,” Vienna, Austria, 2018.
- [55] FRIITSCH, S., GUENTHER, F., SULING, M., *et al.*, “neuralnet: Training of Neural Networks,” 2016.
- [56] ADELI, H., *Neural Networks in Civil Engineering. Computer-Aided Civil and Infrastructure Engineering*, v. 16, pp. 126-142, 2001.
- [57] ROSENBLATT, F., *The Perceptron: A probabilistic model for information storage and organization in the brain*, Cornell Aeronautical Laboratory, v. 65, n. 6, pp. 386-408, 1958.
- [58] ANDERSON, J. A., *Cognitive and Psychological Computation with Neural Models*, *IEEE Transactions on Systems, Man, and Cybernetics*, v. 13, n. 5, pp. 799-816, 1983.
- [59] LIU, C., *An Introduction to Artificial Neural Networks and Computational Mechanics*, *Comput Meth Appl Mech Eng*, v. 28, n. 191, pp. 31-45, 2002.
- [60] HUDSON BEALE, M., *Neural Network Toolbox User’s Guide*, *The MathWorks Journal*, 2012.
- [61] SCARDI, M., HARDING, L. W., Developing an empirical model of phytoplankton primary production: A neural network case study, [https://doi.org/10.1016/S0304-3800\(99\)00103-9](https://doi.org/10.1016/S0304-3800(99)00103-9). *Ecological Modelling*, v. 120, n. 2-3, pp. 213-223, 1999.
- [62] SRINIVASULU, S., JAIN, A., A comparative analysis of training methods for artificial neural network rainfall - runoff models, <https://doi.org/10.1016/j.asoc.2005.02.002>. *Applied Soft Computing*, v. 6, pp. 295-306, 2006.
- [63] RUMELHART, D., HINTON, G., WILLIAMS, R., “Learning internal representations by error propagation,” In: Rumelhart, D., and McClelland, J. (eds), *Parallel distributed processing: explorations in the microstructures of cognition*, 8th ch., pp. 318-362, 1986.
- [64] MUSHGIL, H. M., ALANI, H. A., GEORGE, L. E., Comparison between Resilient and Standard Back Propagation Algorithms Efficiency in Pattern Recognition, *International Journal of Scientific & Engineering Research*, v. 6, n. 3, pp. 773-778, 2015.

- [65] PRASAD, N., SINGH, R., LAL, S. P., “Comparison of back propagation and resilient propagation algorithm for spam classification”, in *Proceedings of International Conference on Computational Intelligence, Modelling and Simulation*, pp. 29-34, 2013. <https://doi.org/10.1109/CIMSim.2013.14>.
- [66] ABELLÁN, J., TORRES, N., NÚÑEZ, A., *et al.*, “Ultra high performance fiber reinforced concrete: state of the art, applications and possibilities into the latin american market,” in *XXXVIII Jornadas Sudamericanas de Ingeniería Estructural*, 2018.
- [67] ABELLÁN, J., NÚÑEZ, A., ARANGO, S., “Pedestrian bridge of UNAL in Manizales : A new UPHFRC application in the Colombian building market,” in *Proceedings of Hipermat 2020 - 5th International Symposium on UHPC and Nanotechnology for Construction Materials*, 2020, n. July, pp. 43-44.
- [68] MORIASI, D. N., ARNOLD, J. G., LIEW, M. W. Van, *et al.*, Model evaluation guidelines for systematic quantification of accuracy in watershed in simulations, *American Society of Agricultural and Biological Engineers*, v. 50, n. 3, pp. 885-900, 2007.
- [69] NASH, E., SUTCLIFFE, V., River flow forecasting through conceptual models. Part I - A discussion of principles, *Journal of Hydrology*, v. 10, pp. 282-290, 1970.
- [70] GUPTA, S., Using Artificial Neural Network to Predict the Compressive Strength of Concrete containing Nano-silica, <https://doi.org/10.13189/cea.2013.010306>. *Civil Engineering and Architecture*, v. 1, n. 3, pp. 96-102, 2013.
- [71] OLDEN, J. D., JOY, M. K., DEATH, R. G., An accurate comparison of methods for quantifying variable importance in artificial neural networks using simulated data, <https://doi.org/10.1016/j.ecolmodel.2004.03.013>. *Ecological Modelling*, v. 178, n. 3-4, pp. 389-397, 2004.
- [72] OLDEN, J. D., JACKSON, D. A., Illuminating the “black box”: A randomization approach for understanding variable contributions in artificial neural networks, [https://doi.org/10.1016/S0304-3800\(02\)00064-9](https://doi.org/10.1016/S0304-3800(02)00064-9). *Ecological Modelling*, v. 154, n. 1-2, pp. 135-150, 2002.
- [73] ABELLÁN-GARCÍA, J., FERNÁNDEZ-GÓMEZ, J., TORRES-CASTELLANOS, N., Properties prediction of environmentally friendly ultra-high-performance concrete using artificial neural networks, <https://doi.org/10.1080/19648189.2020.1762749>. *European Journal of Environmental and Civil Engineering*, v. 0, n. 0, pp. 1-25, 2020.
- [74] ABELLÁN-GARCÍA, J., Four-layer perceptron approach for strength prediction of UHPC, <https://doi.org/10.1016/j.conbuildmat.2020.119465>. *Construction and Building Materials*, v. 256, 2020.
- [75] ———, Artificial Neural Network Model for Strength Prediction of Ultra-High-Performance Concrete, <https://doi.org/10.14359/51732710>. *ACI Materials Journal*, v. 118, n. 4, pp. 3-14, 2021.
- [76] ———, Neural network-based prediction of 7-days compressive strength of UHPC incorporating SCM, <https://doi.org/10.1590/S1517-707620210004.1380>. *Revista Materia*, v. 26, n. 4, 2021.

## ORCID

Joaquin Abellan-García <https://orcid.org/0000-0002-0353-322X>  
Andrés Fernando Pineda Varón <https://orcid.org/0000-0001-7683-2792>