

Experimental validation of Artificial Intelligence model for the energy absorption capacity of UHPFRC

Joaquín Abellán-García ^a, Juan Sebastian Guzmán-Guzmán ^b, Jairo Alfredo Sánchez-Díaz ^c & Julián Rojas-Grillo ^b

^a Universidad Politécnica de Madrid, Madrid, España. & Facultad de Ingeniería Civil, Escuela Colombiana de Ingeniería Julio Garavito, Bogotá, Colombia. j.abellang@alumnos.upm.es

^b Facultad de Ingeniería Civil, Escuela Colombiana de Ingeniería Julio Garavito, Bogotá, Colombia. juan.guzman-g@mail.escuelaing.edu.co, julian.rojas-gr@mail.escuelaing.edu.co

^c Facultad de Ingeniería de Sistemas, Escuela Colombiana de Ingeniería Julio Garavito, Bogotá, Colombia. jairo.sanchez@mail.escuelaing.edu.co

Received: May 3th, 2020. Received in revised version: December 18th, 2020. Accepted: December 21th, 2020.

Abstract

This paper investigates the performance of an artificial neural network (ANN) model in predicting the energy absorption capacity (g) of ultra-high-performance fiber reinforced concrete (UHPFRC) under direct tensile test. To avoid overfitting a data division into test and training datasets was carried out. Thereafter the neural networks were trained on the training dataset by using k -fold validation and the result model was evaluated on the test dataset. The model was capable of consider one-fiber or hybrid-two-fibers-blend as reinforced UHPFRC, of a wide range of fibers such as straight steel fibers, hooked end steel fibers, twisted steel fibers, PVA fibers, polyethylene fibers and polypropylene fibers. Experimental works were performed to validate the accuracy of the model on real data. The results demonstrated the efficiency of the model, according to the statistical parameters used for their evaluation, the accuracy and the versatility of the model when new data is considered.

Keywords: UHPFRC; direct tensile test; ANN; modelling; energy absorption capacity.

Validación experimental de un modelo de Inteligencia Artificial para la capacidad de absorción de energía del UHPFRC

Resumen

El artículo investiga la eficiencia de las redes neuronales artificiales (ANN) para la predicción de la capacidad de absorción de energía (g) del concreto de ultra-altas-prestaciones reforzado con fibras (UHPFRC) sometido a tracción directa. Para mejorar el modelo, se dividieron los datos en datos de entrenamiento y testeo. La red se ajustó usando validación k -fold con los datos de entrenamiento y se evaluó con los datos de testeo. El modelo permitió considerar UHPFRC reforzado con una fibra o con mezcla híbrida de dos fibras, de una amplia gama de fibras, tales como fibras de acero rectas, fibras de acero acabadas en gancho, fibras de acero retorcidas, fibras de PVA, fibras de polietileno y fibras de polipropileno. Adicionalmente se realizó una validación experimental de la red. Los resultados demostraron la eficiencia del modelo de acuerdo con los parámetros estadísticos utilizados, así como su precisión y versatilidad para tratar datos nuevos.

Palabras clave: UHPFRC; ensayo de tracción directa; ANN; modelación; capacidad de absorción de energía.

1. Introducción

En los últimos años se han producido importantes avances en las investigaciones relacionadas con concretos especiales [1-3]. Entre éstas podemos resaltar los concretos de ultra alto desempeño reforzados con fibras (UHPFRC por sus siglas en

inglés). Este tipo de concreto cuenta con unas propiedades de resistencia mecánica y durabilidad muy superiores en comparación con los concretos convencionales debido principalmente a la densidad de empaquetamiento de partículas, a la selección exigente de componentes y a unos precisos procesos de amasado [4-12]. Una mezcla típica de

How to cite: Abellán-García, J., Guzmán-Guzmán, J.S., Sánchez-Díaz, J.A. and Rojas-Grillo, J., Validación experimental de un modelo de Inteligencia Artificial para la capacidad de absorción de energía del UHPFRC.. DYNA, 88(217), pp. 150-159, April - June, 2021.

UHPFRC está compuesta por cemento tipo Portland, humo de sílice, polvo de cuarzo, arena fina silícea, superplastificante reductor de agua de alto rango (HRWR), y fibras metálicas [13-15].

Con la finalidad de reducir tanto el coste final de la mezcla como su huella de carbono, en los últimos tiempos se han realizado grandes esfuerzos en analizar la sustitución parcial del cemento y el humo de sílice utilizando materiales cementantes suplementarios [1,5].

Entre las aplicaciones de los UHPFRC en la industria de la construcción podríamos citar la construcción de puentes peatonales, la rehabilitación de estructuras dañadas, el sistema acelerado de construcción de puentes (ABC por sus siglas en inglés), etc. [10,16-20].

El documento ACI239R-18 define al UHPFRC como un concreto con resistencias a la compresión superiores a los 150 MPa y con unas condiciones específicas en cuanto a la ductilidad [21]. Se desprende, por lo tanto, que la finalidad de este concreto no es solo alcanzar una elevada resistencia a la compresión sino desarrollar un comportamiento dúctil [12]. La exigencia de ductilidad conlleva la capacidad de soportar esfuerzos a tracción, pero, sobre todo, que ésta se mantenga más allá de la fisuración de la matriz, permitiendo a estos tipos de concretos la capacidad de absorción de energía [22].

Por otro lado, la combinación de fibras es un método prometedor para mejorar la capacidad de absorción de energía de los UHPFRC, aprovechando la sinergia que, por ejemplo, consiguen las macro y micro fibras desempeñando un papel en dos niveles diferentes [23]. Las micro-fibras controlan las primeras micro-fisuras mientras que las macro-fibras garantizan la ductilidad para deformaciones altas.

El comportamiento mecánico bajo pruebas de tracción directa del UHPFRC puede clasificarse como "ablandamiento por deformación" o "endurecimiento por deformación" [24,25]. El efecto de las fibras cosiendo la fisura generada afecta significativamente al rendimiento en el dominio de endurecimiento y ablandamiento [26]. Según Naaman y Reinhart [27], el endurecimiento por deformación se produce cuando el esfuerzo a la tracción máximo posterior la fisuración de la matriz (σ_{pc}) excede la resistencia a la tracción que produce la aparición de la primera fisura en el concreto (σ_{cc}). Por tanto, la Ec. 1 puede considerarse como condición necesaria y suficiente para el comportamiento de endurecimiento por deformación:

$$\sigma_{pc} \geq \sigma_{cc} \tag{1}$$

La Fig. 1 ilustra cómo en el comportamiento a la tracción del UHPFRC con endurecimiento por deformación se desarrollan tres fases diferentes [24,28]: Zona I, comportamiento elástico hasta σ_{cc} . El nivel de tensión se define por σ_{cc} y su alargamiento unitario asociado ϵ_{cc} ; Zona II, o el dominio del endurecimiento por deformación basado en deformación plástica con activación de las fibras y la aparición de múltiples fisuras. En esta fase se desarrolla la capacidad de absorción de energía (g) por unidad de volumen, que es el área bajo la curva de tensión-deformación hasta σ_{pc} conforme se indica en la Fig. 1 [29]; y Zona III o el dominio del comportamiento de ablandamiento por deformación en el que se produce el desprendimiento de la fibra o "pullout".

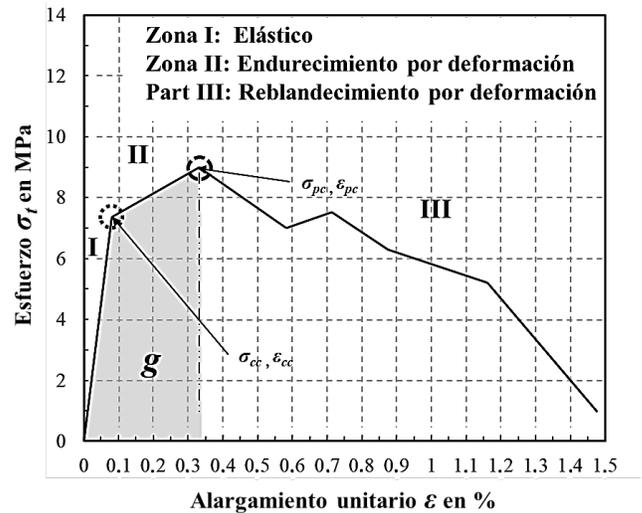


Figura 1. Diagrama esfuerzo-alargamiento unitario de un UHPFRC con comportamiento de endurecimiento por deformación; Fuente: Autores.

g es una de las características más importantes de los UHPFRC [29,30]. Alcanzar un determinado valor de g permite que este tipo de concreto se use como material de refuerzo para estructuras existentes no dúctiles o bien la reducción/eliminación de las barras de acero de refuerzo necesarias, entre otros [16].

Como es obvio, el desarrollo de UHPFRC bajo criterios de su comportamiento a tracción directa requiere de experimentación para poder valorar los efectos clave que cada tipología y cantidad de fibra(s) aporta a dicho comportamiento, debido al efecto complejo de la interacción entre la(s) fibra(s) y el resto de los componentes del concreto. Con frecuencia estas campañas experimentales son costosas y cuentan con importantes tiempos de desarrollo [31].

El objetivo principal de este trabajo de investigación fue desarrollar un modelo basado en redes neuronales artificiales (ANN) para predecir capacidad de absorción de energía de los UHPFRC sometidos a tracción directa. El modelo ANN fue diseñado de tal manera que permite la consideración de refuerzos de un tipo y hasta dos tipos de fibras, de entre una amplia gama de fibras, incluyendo fibras de acero rectas fibras de acero con extremo acabado en gancho, fibras de acero retorcidas, fibras de PVA, fibras de polietileno y fibras de polipropileno. La Fig. 2 muestra una imagen de las fibras que puede considerar el modelo.

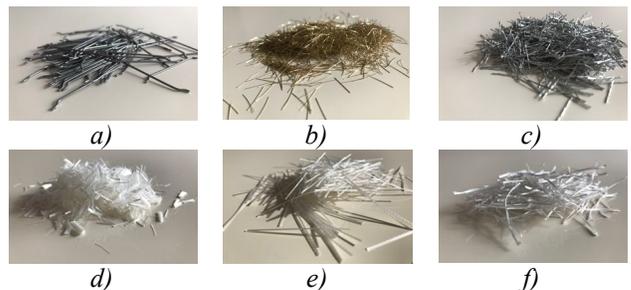


Figura 2. Algunos de los diferentes tipos de fibras para UHPFRC: a) metálica acabada en ganchos (hook-end); b) metálica lisa; c) metálica retorcida (twisted); d) monofilamento de polivinilo de alcohol; e) fibra de polipropileno; f) fibra de polietileno; Fuente: Autor.

La validación cruzada tipo *k-fold* [32] se utilizó durante la selección del número de neuronas en la capa oculta, así como en la determinación del número de veces (*epoch*) que se pasan los datos de entrenamiento por la red neuronal. Además, se realizó una validación experimental para evaluar la precisión del modelo y su habilidad para la predicción en casos reales diferentes a los incluidos en las bases de datos de entrenamiento y testeo.

Este modelo podría de ser de gran utilidad en el desarrollo de nuevas dosificaciones de UHPFRC al permitir preseleccionar aquellos componentes (fibras incluidas) que tengan un mejor comportamiento en el modelo al menor coste, reduciendo el número de ensayos a ejecutar.

Tabla 1.

Propiedades recogidas en la base de datos.

Variable	Descripción
X1	Contenido de cemento en kg/m ³
X2	Contenido de humo de sílice en kg/m ³
X3	Contenido de materiales cementantes (a excepción del cemento y la micro sílice) en kg/m ³
X4	Contenido de harina de cuarzo en kg/m ³
X5	Contenido de agua en kg/m ³
X6	Contenido de superplastificante en kg/m ³
X7	Contenido de arena en kg/m ³
X8	Contenido de agregado grueso en kg/m ³
X9	Tamaño máximo del agregado expresado en micras
X10	Relación agua/binder en peso
X11	Contenido total de fibras en porcentaje sobre el volumen total del concreto
X12	Factor fibra total (χ_T) definido como $\chi_T = \chi_{f1} + \chi_{f2}$
X13	Variable tipo <i>dummy</i> cuyo valor es 1 si la fibra 1 es metálica recta y 0 en caso contrario
X14	Variable tipo <i>dummy</i> cuyo valor es 1 si la fibra 1 es metálica acabada en ganchos (<i>hook end</i>) y 0 en caso contrario
X15	Variable tipo <i>dummy</i> cuyo valor es 1 si la fibra 1 es metálica retorcida (<i>twisted</i>) y 0 en caso contrario
X16	Variable tipo <i>dummy</i> cuyo valor es 1 si la fibra 1 es de polietileno y 0 en caso contrario
X17	Variable tipo <i>dummy</i> cuyo valor es 1 si la fibra 1 es de polipropileno y 0 en caso contrario
X18	Variable tipo <i>dummy</i> cuyo valor es 1 si la fibra 1 es de polivinilo de alcohol y 0 en caso contrario
X19	Resistencia a la tracción del material de la fibra 1 en MPa
X20	Longitud de la fibra 1 en mm (l_{f1})
X21	Diámetro de la fibra 1 en mm (d_{f1})
X22	Contenido de la fibra 1 en porcentaje sobre el volumen total del concreto (V_{f1})
X23	Factor fibra (χ_{f1}) de la fibra 1 definido como $\chi_{f1} = V_{f1} \times l_{f1}/d_{f1}$
X24	Variable tipo <i>dummy</i> cuyo valor es 1 si la fibra 2 es metálica recta y 0 en caso contrario
X25	Variable tipo <i>dummy</i> cuyo valor es 1 si la fibra 2 es metálica acabada en ganchos (<i>hook end</i>) y 0 en caso contrario
X26	Variable tipo <i>dummy</i> cuyo valor es 1 si la fibra 2 es metálica retorcida (<i>twisted</i>) y 0 en caso contrario
X27	Variable tipo <i>dummy</i> cuyo valor es 1 si la fibra 2 es de polietileno y 0 en caso contrario
X28	Variable tipo <i>dummy</i> cuyo valor es 1 si la fibra 2 es de polipropileno y 0 en caso contrario
X29	Variable tipo <i>dummy</i> cuyo valor es 1 si la fibra 2 es de polivinilo de alcohol y 0 en caso contrario
X30	Resistencia a la tracción del material de la fibra 2 en MPa
X31	Longitud de la fibra 2 en mm (l_{f2})
X32	Diámetro de la fibra 2 en mm (d_{f2})
X33	Contenido de la fibra 2 en porcentaje sobre el volumen total del concreto
X34	Factor fibra (χ_{f2}) de la fibra 2 definido como $\chi_{f2} = V_{f2} \times l_{f2}/d_{f2}$
X35	Resistencia a la compresión del concreto

Fuente: Autores.

2. Metodología

2.1 Base de de datos

Recopilación de datos

Con la finalidad de poder desarrollar los modelos matemáticos, 500 datos de dosificaciones de UHPFRC con información sobre el comportamiento a tracción directa fueron recogidos de varios estudios científicos publicados en los últimos 20 años. En la base de datos se contemplan tanto dosificaciones con un solo tipo de fibra (denominada en la base de datos como fibra 1), como dosificaciones con mezclas binarias de fibra (fibra 1 y fibra 2).

La presencia de variables cualitativas en la base de datos, específicamente el tipo de fibra, se ha resuelto mediante variables tipo *dummy* o dicotómicas, cuyo valor es 1 si la fibra es del tipo considerado y 0 en caso contrario.

Las variables independientes recogidas en la base de datos, así como su codificación se pueden observar en la Tabla 1.

Con la finalidad de restar posibles efectos matemáticos de la ordenación de la fibra en la mezcla de UHPFRC, la base de datos considerada se ha duplicado permutando la ordenación de la fibra. Por lo tanto, el número de observaciones consideradas en el tratamiento de datos fue de 1000.

Tratamiento de datos anómalos

La detección y tratamiento de valores atípicos es fundamental para construir un modelo preciso que obtenga resultados adecuados, ya que estos datos anómalos pueden influir mucho en el modelo resultante [33]. Por lo tanto, se realizó un análisis estadístico, mediante diagramas *bagplot*, de cada variable frente a la variable respuesta *g* para identificar posibles valores atípicos [34]. El diagrama *bagplot* es un diagrama de dispersión basado en el diagrama "Box and whisker plot" de Tukey [35].

Sin embargo, confiar en el uso de esta metodología sin un análisis crítico de los datos también podría ser una práctica peligrosa. Algunos de los datos sospechosos señalados por diagramas *bagplot* podrían indicar el comportamiento real de los datos, mientras que el resto de las observaciones podrían simplemente agruparse de forma muy próxima. La Fig. 3 muestra el diagrama *bagplot* para el par de variables capacidad de absorción de energía *g* (expresada en kJ/m³) y factor fibra total χ_T . El gráfico muestra como posibles anómalos algunas dosificaciones con micro fibras monofilamento de PVA (ver Fig. 2 d) cuyo diámetro es inferior a los 50 micrones, al ubicarse por fuera de la elipse. Sin embargo, su ubicación por fuera de la elipse se debe únicamente al reducido valor de su diámetro, lo que conlleva a un elevado valor de χ_T .

Al final de este proceso, se eliminaron 404 observaciones de la base de datos, dejando 596 para entrenamiento y testeo de los modelos ANN.

Normalización de datos

Previo al desarrollo de los modelos predictivos de redes neuronales es necesario realizar la normalización de los datos. La normalización de los datos elimina la posibilidad de sesgo de la red neuronal debido a la diferente naturaleza y magnitud de las diferentes variables consideradas [36]. En el presente trabajo se utilizó el rango [0, 1] para la normalización de datos, acorde a la Ec. (1).

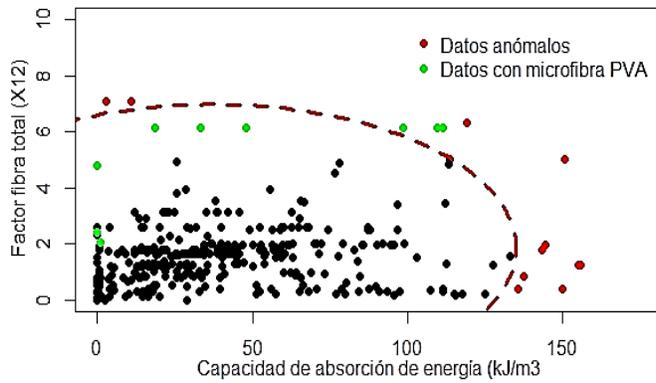


Figura 3. Diagrama bagplot para el par de variables capacidad de absorción de energía (kJ/m3) y factor fibra total (X12). Fuente: Autores.

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (1)$$

donde x_{norm} representa al valor normalizado de la variable x , mientras que x_{max} y x_{min} representan los valores máximos y mínimos de este valor en la base de datos respectivamente.

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

Para facilitar el entrenamiento y el testeo de los modelos de redes neuronales, la base de datos fue dividida al azar en conjuntos de datos de entrenamiento y testeo. Se usaron el 80% de las observaciones para fines de entrenamiento y el 20% restante se empleó para medir la eficiencia de los modelos entrenados. Ambos subconjuntos contenían todos los tipos de fibras considerados en la base de datos total.

Para evaluar el modelo matemático mientras se ajustan sus parámetros (como el número de neuronas en las capas ocultas o las veces que hay que pasar los datos de entrenamiento por el modelo), los datos de entrenamiento se pueden dividir a su vez en un conjunto de entrenamiento y validación. Sin embargo, existe el riesgo de que la evaluación sobre el subconjunto de validación pueda depender enormemente de qué observaciones se hayan seleccionado para la validación y cuáles se hayan seleccionado para el entrenamiento de los modelos, lo que podría conducir a una evaluación poco confiable del modelo [32].

Una solución habitual en tales situaciones es utilizar la validación cruzada tipo k -fold (ver Fig. 4). Este procedimiento se basa en la división de las observaciones disponibles en k particiones, planteando k modelos idénticos y entrenando a cada uno usando $k - 1$ particiones como datos de entrenamiento mientras se evalúa el modelo en la partición restante. El puntaje de validación para el modelo empleado es entonces el resultante del promedio de los k puntajes de validación obtenidos [32]. En este trabajo de investigación se utilizó la validación cruzada tipo k -fold con $k = 5$. La evaluación del modelo se midió mediante la raíz cuadrada del error cuadrático medio (RMSE por sus siglas en inglés) promedio de las k modelaciones, conforme se observa en la Fig. 4.



Figura 4. Esquema de la validación cruzada tipo k -fold. Fuente: Autores.

3. Investigación analítica

3.1 Introducción

En los últimos tiempos se ha producido una notoria proliferación de las aplicaciones de las diferentes ramas de inteligencia artificial en una gran variedad de campos de la ciencia. Entre las aplicaciones encontradas en el campo de la ingeniería civil se pueden destacar la detección de daños estructurales, la optimización de materiales, la detección y cuantificación de recursos hídricos subterráneos y la ingeniería de tráfico [37,38]. Dentro de las aplicaciones en la ciencia de materiales la predicción de las propiedades del concreto en función de sus componentes es una de las áreas de mayor producción científica [7,39-42].

La presente investigación emplea técnicas de regresión basadas las redes neuronales del tipo $feed-forward$ de una sola capa oculta para la predicción de la capacidad de absorción de energía de los UHPFRC. Para el desarrollo de los citados modelos matemáticos se utilizó el lenguaje de programación estadístico R versión 3.6.0 [43]. Específicamente, se utilizó la función $neuralnet$ [44] para el desarrollo de los modelos de redes neuronales.

3.2 Redes neuronales artificiales (ANN)

Las ANN son paradigmas de procesamiento de datos, cuya conceptualización está inspirada en las estructuras neuronales biológicas que operan en el sistema nervioso central de un organismo. Los modelos ANN están compuestos de un gran número de elementos procesadores, llamados neuronas, interconectados, recibiendo y enviando información [37]. El modelo ANN más sencillo conocido como perceptrón fue desarrollado por Rosenblatt en 1959 [45]. El perceptrón está constituido por dos entradas, una única neurona en la capa oculta y una salida, conforme se aprecia en la Fig. 5 [37,45]. Para aplicaciones más complejas, se puede recurrir a arquitecturas de 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.

En la Fig. 5 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 para cada conexión entrada-neurona oculta. Además, se agrega un término independiente conocido como bias. La función de suma ponderada calcula la entrada neta (vk) que recibe la neurona [467], tal y como se muestra en la Ec. (2):

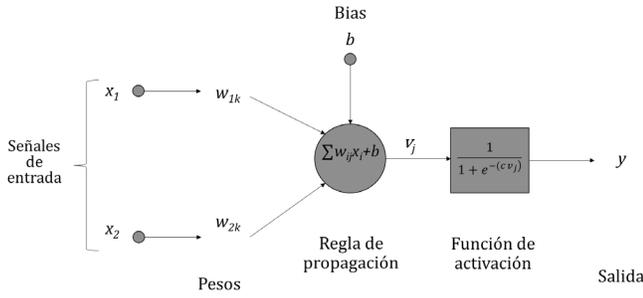


Figura 5. Esquema del perceptrón.
Fuente: Autores

$$v_k = \sum_{i=1}^n w_{ik}x_i + b \quad (2)$$

Donde v_k representa la regla de propagación, que es la suma que recibe la k -ésima neurona de la capa precedente; w_{ik} es el peso asignado por la k -ésima neurona de la conexión con la i -ésima neurona; x_i es el valor de entrada que la i -ésima neurona transmite; y b es el bias descrito anteriormente [47].

La función de activación procesa la entrada obtenida de la función de suma ponderada y define la salida de la neurona. Algunos ejemplos de funciones de activación incluyen las funciones lineal, rampa, tanh (tangente hiperbólica), sigmoide logarítmica y relu (función de unidad lineal rectificadora) [32].

La función sigmoide logarítmica toma el valor calculado por la función de suma ponderada (v_k) y lo condensa en un único valor correspondiente al rango entre 0 y 1 [48]. La presente investigación utiliza la función de activación sigmoide logarítmica que se muestra en la Ec. (5):

$$y_j = \frac{1}{1 + e^{-(cv_j)}} \quad (3)$$

Donde C es una constante usada para controlar la pendiente de la región semi lineal.

Por otro lado, el proceso por el cual se ajustan los pesos de las conexiones de la red neuronal para producir un determinado resultado es lo que se conoce como entrenar a la red. Este entrenamiento lo realizan los algoritmos de aprendizaje en dos pasos principales: en el primero se asignan pesos aleatorios a todas las conexiones entre las neuronas y se genera un flujo hacia delante de la señal desde la capa de entrada hasta la de salida. El resultado se compara con los valores reales. En el siguiente paso, los pesos y el bias en las capas ocultas se modifican 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. El algoritmo de aprendizaje más común para el entrenamiento de redes perceptrón multicapa feed-forward es el algoritmo de propagación hacia atrás o retropropagación (BP por sus siglas en inglés) desarrollado por [49]. El BP es un algoritmo de entrenamiento basado en un gradiente descendente iterativo diseñado para minimizar el error cuadrático medio entre la salida real del modelo y los valores reales de respuesta [50]. Además del BP existen otros algoritmos de

aprendizaje entre los que podemos destacar la retropropagación resiliente (Rprop). La 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 la Rprop, solo se tiene en cuenta el signo de la derivada para indicar la dirección de la actualización de los pesos [50,51]. Para los lectores interesados en mayor información sobre Rprop se recomienda consultar las referencias [50] y [51].

En el presente trabajo de investigación se utilizó Rprop como algoritmo de aprendizaje.

3.3 Evaluación del desempeño de los modelos matemáticos

La precisión del modelo ANN desarrollado en este estudio se evaluó utilizando seis evaluadores de rendimiento estadístico diferentes: el error absoluto medio (MAE), la raíz del error cuadrático medio (RSME), la relación entre el RSME y la desviación estándar de los datos medidos (RSR), el error de sesgo medio normalizado (NMBE), la eficiencia de Nash-Sutcliffe (E), y coeficiente de determinación múltiple (R^2). La formulación matemática de estos indicadores estadísticos se puede observar en las Ecs. (4) - (8) respectivamente.

$$MAE = \frac{1}{n} \sum_{i=1}^n |a_i - \hat{a}_i| \quad (4)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (a_i - \hat{a}_i)^2}{n}} \quad (5)$$

$$RSR = \sqrt{\frac{RMSE}{\frac{1}{n} \sum_{i=1}^n (a_i - \hat{a}_i)^2}} \quad (6)$$

$$NMBE(\%) = \frac{\frac{1}{n} \sum_{i=1}^n (a_i - \hat{a}_i)}{\hat{a}_i} \times 100 \quad (7)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (a_i - \hat{a}_i)^2}{\sum_{i=1}^n (\hat{a}_i)^2} \quad (8)$$

Donde: a es el valor real de la respuesta; \hat{a} representa el valor promedio de los valores reales, \hat{a} es la respuesta estimada por el modelo y n es el número total de observaciones del conjunto de datos.

El estadístico MAE sirve para cuantificar la precisión de un modelo comparando los valores predichos frente a los reales. Para un sistema predictivo perfecto el valor óptimo de MAE es cero [38]; El RMSE es uno de los índices estadísticos más frecuentes para la valoración de modelos predictivos [52]. El RMSE compara los valores estimados con los valores reales y calcula la raíz cuadrada del error residual promedio. Un valor de RMSE de cero indicaría un sistema predictivo perfecto [53]; El parámetro estadístico RSR incluye los beneficios del estadístico RMSE incorporando un factor de normalización. A menor valor de RSR mejor es la predicción del modelo [52]; El NMBE suministra información sobre el sesgo medio en las estimaciones de un modelo. Un NMBE negativo indica una

predicción excesiva y un NMBE positivo indica una predicción insuficiente del modelo [54]; El coeficiente de determinación (R2) refleja la bondad del ajuste del modelo a la variable que quiere explicar [55]. Un valor R2 cercano a la unidad indica una buena asociación entre los valores observados y los calculados. Un uso combinado de las métricas de puntaje narradas anteriormente puede proporcionar una estimación imparcial de la capacidad de predicción de los modelos matemáticos [53].

Tabla 2. Dosificaciones y resistencia a la compresión de UHPC (sin fibras).

UHPC	C	SF	SCM1	SCM2	W	HRWR	SS	$f_{28}(MPa)$
D1	1	0.083	0.498	0.530	0.338	0.033	1.365	138
D2	1	0.167	0.537	0.349	0.343	0.035	1.393	156
D3	1	0.250	0.508	0.280	0.351	0.035	1.358	159

Fuente: Autores.

Tabla 3. Tipos y características de las fibras empleadas en la campaña experimental.

Fibra	Tipo	$d_f(mm)$	$l_f(mm)$	Res. (MPa)	Tracción
F1	Metálica recta	0.20	13	2600	
F2	Metálica recta	0.20	6	2600	
F3	Metálica hook end	0.50	35	2000	
F4	Metálica hook end	0.75	60	1600	
F5	Metálica twisted	0.50	13	1700	
F6	Polietileno	0.67	50	650	
F7	Polipropileno	0.72	48	550	
F8	PVA	0.025	6	1600	

Fuente: Autores.

Tabla 4. Dosificaciones consideradas en la campaña experimental.

N	UHPC	F1	F2	F3	F4	F5	F6	F7	F8
1	D2	1%	-	-	-	-	-	-	-
2	D2	-	1%	-	-	-	-	-	-
3	D2	-	-	1%	-	-	-	-	-
4	D2	-	-	-	1%	-	-	-	-
5	D2	-	-	-	-	1%	-	-	-
6	D2	-	-	-	-	-	1%	-	-
7	D2	-	-	-	-	-	-	1%	-
8	D2	-	-	-	-	-	-	-	1%
9	D2	2%	-	-	-	-	-	-	-
10	D2	-	2%	-	-	-	-	-	-
11	D2	-	-	2%	-	-	-	-	-
12	D2	-	-	-	2%	-	-	-	-
13	D2	-	-	-	-	2%	-	-	-
14	D2	-	-	-	-	-	2%	-	-
15	D2	-	-	-	-	-	-	2%	-
16	D2	-	-	-	-	-	-	-	2%
17	D1	2%	-	-	-	-	-	-	-
18	D1	-	-	-	2%	-	-	-	-
19	D1	-	-	-	-	-	2%	-	-
20	D1	-	-	-	-	-	-	2%	-
21	D3	2%	-	-	-	-	-	-	-
22	D3	-	-	-	2%	-	-	-	-
23	D3	-	-	-	-	-	2%	-	-
24	D3	-	-	-	-	-	-	2%	-
25	D2	1%	-	-	-	-	2%	-	-
26	D2	-	-	-	1%	-	2%	-	-

Fuente: Autores.

4. Investigación experimental

4.1 Materiales

Para la campaña experimental se usaron tres dosificaciones diferentes de concretos de ultra altas prestaciones (UHPC) cuyas dosificaciones y propiedades se muestran en la Tabla 2.

Además, la campaña experimental consideró diferentes tipos de fibras cuyas características se presentan en la Tabla 3.

Por último, las dosificaciones de UHPFRC consideradas para el ensayo a tracción directa se presentan en la **Tabla 4**, donde el contenido de fibras se expresa en % sobre el volumen.

4.2 Configuración del ensayo de tracción directa

La geometría del cuerpo de prueba *dogbone*, así como la configuración del ensayo se estableció de acuerdo con el JSCE-08 [56] conforme se puede observar en la Fig. 6. La sección del vástago de los cuerpos de prueba $30 \times 30 \text{ mm}^2$ siendo su longitud de 80 mm. La alineación de la configuración de tracción se verificó cuidadosamente antes de probar usando una plomada. Las muestras se instalaron con cuidado para evitar cualquier influencia de excentricidad. Se usó una máquina de prueba universal que realiza el control de desplazamiento a una velocidad fija de 0.5 mm/min de acuerdo con JSCE-08 [56]. Las condiciones de contorno en ambos extremos de la configuración del ensayo de tracción fueron fijas. Se instalaron dos LVDT (transformadores diferenciales variables lineales) en ambos lados de la muestra del *dogbone*, para medir su alargamiento. El valor promedio de los dos LVDT se usó para el cálculo del alargamiento unitario (ϵ_{pc}) y la capacidad de absorción de energía g .

5. Resultados y discusión

5.1 Arquitectura de la red neuronal

Seleccionar la arquitectura del modelo de redes neuronales, en nuestro caso el número de neuronas en la capa oculta es el primer paso importante en el desarrollo del modelo. La Fig. 7 representa el efecto del número de neuronas de la capa oculta en el valor del RMSE obtenido durante el entrenamiento con validación cruzada tipo *k-fold*. Debe destacarse que la Fig. 7 solo representa el valor de RMSE correspondiente a la asignación de pesos iniciales de mejor rendimiento de entre las 100 probadas para cada una de las arquitecturas calculadas. De acuerdo con esto, el mejor valor promedio del RMSE en la validación se logró cuando se cuenta con tres neuronas en la capa oculta, por lo que se seleccionó el modelo presentado en la Fig. 8.



Figura 6. Cuerpo de prueba *dogbone* y configuración del ensayo de tracción directa conforme a JSCE-08 [56]

Fuente: Autores.

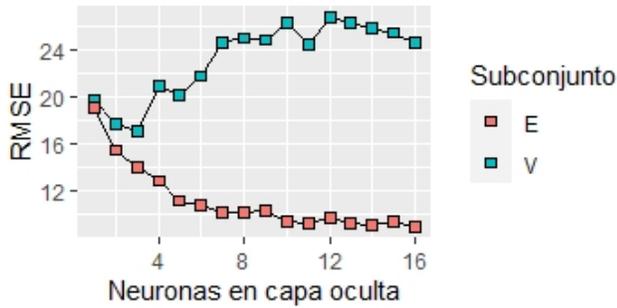


Figura 7. Promedio de la raíz del error cuadrático medio (RMSE) versus el número de neuronas en la capa oculta en los subconjuntos de datos de entrenamiento (E) y validación (V).
Fuente: Autores.

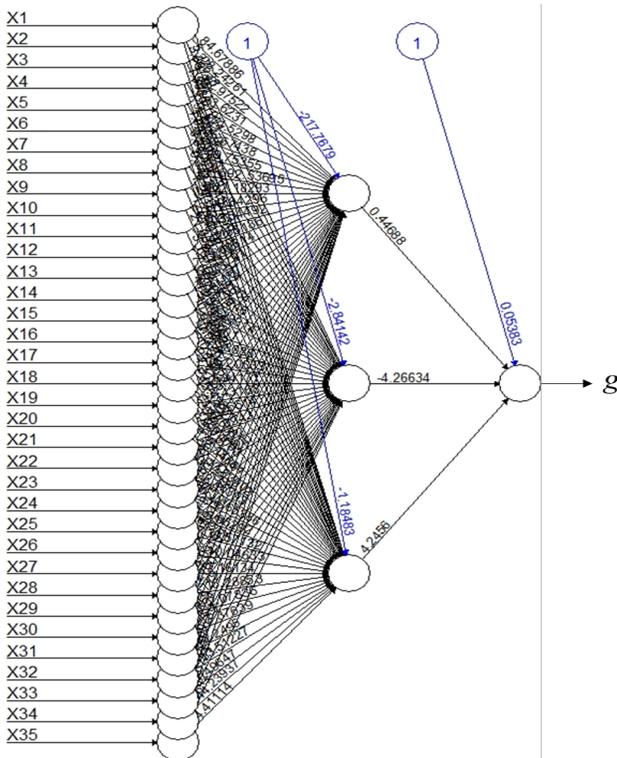


Figura 8. Modelo de redes neuronales desarrollado con *neuralnet* para predecir la capacidad de absorción de energía (g) de los UHPFRC
Fuente: Autores.

Sin embargo, el valor RMSE mínimo de 17.05 kJ/m^3 alcanzado para esta configuración parece un error todavía muy alto teniendo en cuenta que el valor promedio de la base de datos es de 50.63 kJ/m^3 . Una forma habitual de mejorar el rendimiento de la red neuronal consiste en pasar los datos de entrenamiento a través de la red varias veces [32]. Para determinar las veces necesarias (*epochs*), se vuelve a utilizar la validación cruzada tipo *k-fold*. La Fig. 9 representa el valor promedio de RSME en la validación *k-fold* versus el número de *epochs*. Después de este análisis se decidió adoptar el modelo representado en la Fig. 8 entrenado 41 veces con los datos de entrenamiento, pues a partir de este número no hay mejoras en el rendimiento del modelo.

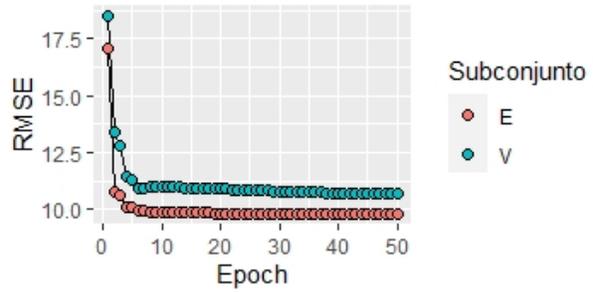


Figura 9. Valor de RMSE versus número de veces que se pasan los datos de entrenamiento por la red para los subconjuntos de datos de entrenamiento (E) y validación (V).
Fuente: Autores.

5.2 Evaluación del modelo

Los valores obtenidos de los parámetros estadísticos utilizados para la evaluación de los modelos de redes neuronales se presentan en las Tabla 5.

Tabla 5. Evaluación de los modelos ANN sobre los conjuntos de entrenamiento y testeo

Datos	MAE	RMSE	RSR	NMBE	R ²
Entrenamiento	7.345	9.788	0.363	0.006%	0.868
Testeo	7.641	9.842	0.423	-2.725%	0.823
Experimentales	4.887	4.887	0.360	-21.741%	0.890

Fuente: Autores.

Los valores de los índices de evaluación sobre los subconjuntos de entrenamiento mediante validación cruzada tipo *k-fold* y testeo fueron similares. Esto demuestra el correcto desempeño de la validación cruzada *k-fold* durante el entrenamiento de la red.

La Fig. 10 muestran la comparativa entra los valores reales y los predichos por los modelos de redes neuronales.

5.3 Discusión

Los modelos de redes neuronales propuestos constituyen una herramienta matemática precisa para la predicción de la capacidad de absorción de energía de los UHPFRC reforzados con hasta dos tipos distintos de fibras.

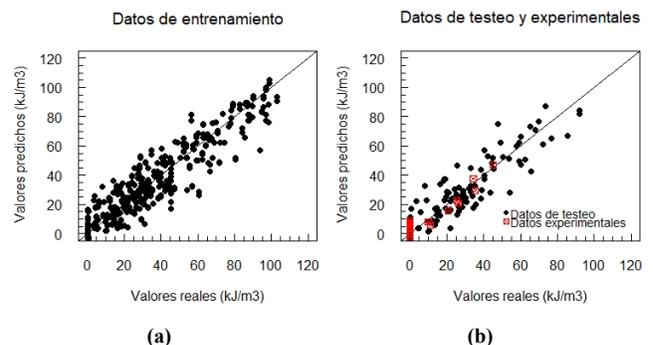


Figura 10. Gráficos de valores reales de capacidad de absorción de energía versus predichos por el modelo en los subconjuntos de datos de entrenamiento, testeo y experimentales.
Fuente: Autores.

Acorde a los resultados de la evaluación del modelo mostrados en la Tabla 5, se puede concluir que el modelo propuesto es válido para la predicción de la capacidad de absorción de energía de los UHPFRC, incluso cuando se trata de datos experimentales diferentes a los de entrenamiento y testeo. Sin embargo, es importante destacar que en este caso el modelo tiende a sobre estimar los valores de g , de acuerdo con el dato de NMBE presentado en la Tabla 5. Este problema afecta especialmente a aquellas mezclas que no presentan endurecimiento por deformación y por tanto su valor real de g es nulo.

El modelo propuesto puede ser de gran utilidad en el desarrollo de nuevas dosificaciones de UHPFRC ya que permite preseleccionar para la campaña experimental las combinaciones de componentes (como por ejemplo las fibras disponibles) que obtengan los mejores resultados en el modelo al menor costo. Esto permitiría reducir el tiempo y costo necesarios para la campaña experimental.

6. Conclusiones y futuras líneas de investigación

El presente trabajo analizó la viabilidad del empleo de modelos de redes neuronales en la predicción de la capacidad de absorción de energía de los UHPFRC sometidos a tracción directa con hasta dos tipos de fibras diferentes. Con base en los resultados obtenidos pueden extraerse las siguientes conclusiones:

1. El modelo de regresión propuesto demostró su alta precisión en la predicción de la capacidad de absorción de energía del UHPFRC sometido a tracción directa. Los valores obtenidos en los índices estadísticos de evaluación (MAE, RMSE, RSR, NMBE, R^2) en el conjunto de datos de testeo fueron de 0.764, 0.738, 0.876 y 0.803 respectivamente.
2. La arquitectura de red neuronal seleccionada mediante validación cruzada tipo k -fold contó con tres neuronas en la capa oculta.
3. Los resultados de evaluación del modelo sobre los datos experimentales modelos de regresión basados en redes neuronales obtuvieron mayores valores de correlación R^2 que incluso los medidos en los subconjuntos de testeo. Sin embargo, el valor de NMBE indica que en los datos experimentales el modelo tiende a sobre estimar los resultados.
4. En general, los resultados de validación del modelo en los datos experimentales corroboran la versatilidad del modelo para ser empleado en nuevos datos.
5. El modelo desarrollado puede ser de gran utilidad en futuras investigaciones de nuevas dosificaciones de UHPFRC ya que permite seleccionar para la campaña experimental aquellas combinaciones de fibras y materiales disponibles que, al menor costo, obtengan los mejores resultados en el modelo. Esto permitiría reducir los recursos necesarios para la campaña experimental.

Futuras trabajos de pesquisa a desarrollar incluyen el uso de otras metodologías de inteligencia artificial, como por ejemplo *random forest* y *boosting* para la predicción de otras propiedades de los UHPFRC como el módulo de elasticidad y las propiedades de durabilidad. La finalidad de

estas investigaciones es la de ofrecer modelos matemáticos que ayuden a la investigación y desarrollo de estos concretos especiales, reduciendo costes de la campaña experimental necesaria.

Agradecimientos

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.

Referencias

- [1] Abellán, J., Fernández, J., Torres, N. and Núñez, A., Statistical optimization of ultra-high-performance glass concrete. *ACI Materials Journal*, 117(1), pp. 243-254, 2020. DOI: 10.14359/51720292.
- [2] Abellán-García, J., Nuñez-Lopez, A. and Arango-Campo, S., Pedestrian bridge over Las Vegas Avenue in Medellín. First Latin American infrastructure in UHPFRC, in: Serna, P., A. Llano-Torre, J.R., Martí-Vargas, J. and Navarro-Gregori, Eds., BEFIB 2020, RILEM Bookseries, Valencia, Spain, 2020, pp. 864-872. DOI: 10.1007/978-3-030-58482-5_76.
- [3] Abellán-García, J., Fernández-Gómez, J.A., Torres-Castellanos, N. and Núñez-López, A.M., Machine learning prediction of flexural behavior of UHPFRC, in: Serna, P., Llano-Torre, A., Martí-Vargas, J.R. and Navarro-Gregori, J., Eds., Fibre Reinf. Concr. Improv. Innov. BEFIB 2020., RILEM Bookseries, Valencia, Spain, 2020, pp. 570-583. DOI: 10.1007/978-3-030-58482-5_52.
- [4] Abellán, J., Torres, N., Núñez, A. y Fernández, J., Influencia del exponente de Fuller, la relación agua conglomerante y el contenido en policarboxilato en concretos de muy altas prestaciones, en: IV Congr. Int. Ing. Civ., Havana, Cuba, 2018.
- [5] Abellán, J., Fernández, J., Torres, N. and Núñez, A., Development of cost-efficient UHPC with local materials in Colombia, in: Proc. Hipermat 2020 - 5th Int. Symp. UHPC Nanotechnol. Constr. Mater., Kassel, Germany, 2020, pp. 97-98.
- [6] Soliman, N.A. and Tagnit-Hamou, A., Using particle packing and statistical approach to optimize eco-efficient ultra-high-performance concrete. *ACI Materials Journal*, 114(6), pp. 847-858, 2017. DOI: 10.14359/51701001.
- [7] Ghafari, E., Costa, H., Nuno, E. and Santos, B., RSM-based model to predict the performance of self-compacting UHPC reinforced with hybrid steel micro-fibers, *Construction and Building Materials*, 66, pp. 375-383, 2014. DOI: 10.1016/j.conbuildmat.2014.05.064.
- [8] Schmidt, C. and Schmidt, M., 'Whitetopping' of asphalt and concrete pavements with thin layers of Ultra-High-Performance Concrete - Construction and economic efficiency, in: Fröhlich, M.S. and Piotrowski, S., Eds., 3rd Int. Symp. UHPC Nanotechnol. High Perform. Constr. Mater., Kassel University, Kassel, Germany, 2012, pp. 921-927. ISBN online: 978-3-86219-264-9.
- [9] Abbas, S., Nehdi, M.L. and Saleem, M.A., Ultra-High Performance Concrete: mechanical performance, durability, sustainability and implementation challenges, *International Journal of Concrete Structures and Materials*. 10(2), pp. 271-295, 2016. DOI: 10.1007/s40069-016-0157-4.
- [10] Nehdi, M., Abbas, S. and Soliman, A., Exploratory study of

- ultra-high performance fiber reinforced concrete tunnel lining segments with varying steel fiber lengths and dosages, *Engineering Structures*, 101, pp. 733-742, 2015. DOI: 10.1016/j.engstruct.2015.07.012.
- [11] Toledo-Filho, R.D., Koenders, E.A.B., Formagini, S. and Fairbairn, E.M.R., Performance assessment of Ultra High Performance Fiber Reinforced Cementitious composites in view of sustainability, *Materials & Design*, 36, pp. 880-888, 2012. DOI: 10.1016/j.matdes.2011.09.022.
- [12] Abellán, J., Torres, N., Núñez, A. and Fernández, J., Ultra high performance fiber reinforced concrete: state of the art, applications and possibilities into the latin american market, in: XXXVIII Jornadas Sudam. Ing. Estructural, Lima, Peru, 2018.
- [13] Tagnit-Hamou, A., Soliman, N.A. and Omran, A., Green Ultra - High - Performance Glass Concrete, First International Interactive Symposium on UHPC, 2016.
- [14] Richard, P. and Cheyrezy, M., Composition of reactive powder concretes, *Cement and Concrete Research*, 25(7) pp. 1501-1511, 1995. DOI: 10.1016/0008-8846(95)00144-2.
- [15] De Larrard, F. and Sedran, T., Mixture-proportioning of high-performance concrete, *Cement and Concrete Research*, 32(11), pp. 1699-1704, 2002. DOI: 10.1016/S0008-8846(02)00861-X.
- [16] Tayeh, B.A., Abu-Bakar, B.H., Megat-Johari, M.A. and Voo, Y.L., Utilization of ultra-high performance fibre concrete (UHPC) for rehabilitation - A review, *Procedia Engineering*, 54, pp. 525-538, 2013. DOI: 10.1016/j.proeng.2013.03.048.
- [17] Soliman, N.A. and Tagnit-Hamou, A., Using glass sand as an alternative for quartz sand in UHPC, *Construction and Building Materials*, 145, pp. 243-252, 2017. DOI: 10.1016/j.conbuildmat.2017.03.187.
- [18] Kalny, M., Kvasnicka, V. and Komanec, J., First practical applications of UHPC in the Czech Republic, *Proceedings Hipermat 2016 - 4th International Symposium on UHPC*, Kassel, Germany, 2016, pp. 147-148.
- [19] Abellán, J., Núñez, A. and Arango, S., Pedestrian bridge of UNAL in Manizales: a new UHPFRC application in the Colombian building market, *Proceedings of Hipermat 2020 - 5th International Symposium on UHPC and Nanotechnology for Construction Materials*, Kassel, Germany, 2020, pp. 43-44.
- [20] Rai, B. and Wille, K., Development and testing of High / Ultra-High early strength concrete, in: Middendorf, B., Fehling, E. and Wetzel, A., Eds., *Proceedings of Hipermat 2020 - 5th International Symposium on UHPC and Nanotechnology for Construction Materials*, University of Kassel, Germany, Kassel, Germany, 2020, pp. 7-8.
- [21] ACI Committe 239R, ACI - 239 Committee in Ultra-High Performance Concrete, ACI, Toronto, Canada, 2018.
- [22] Serna-Ros, P., López-Martínez, J.Á. and Camacho-Torregosa, E., UHPFRC: de los componentes a la estructura, *Symposium Latinoamericano Sobre Concreto Autocompactante*, 2012, pp. 1-21.
- [23] Wu, Z., Shi, C., He, W. and Wu, L., Effects of steel fiber content and shape on mechanical properties of ultra high performance concrete, *Construction and Building Materials*, 103, pp. 8-14, 2016. DOI: 10.1016/j.conbuildmat.2015.11.028.
- [24] Wille, K., Kim, D. and Naaman, A.E., Strain hardening UHP-FRC with low fiber contents. *Materials and Structures*, 44, pp. 538-598, 2011.
- [25] Pyo, S., El-Tawil, S. and Naaman, A.E., Direct tensile behavior of ultra-high performance fiber reinforced concrete (UHP-FRC) at high strain rates, *Cement and Concrete Research*, 88, pp. 144-156, 2016. DOI: 10.1016/j.cemconres.2016.07.003.
- [26] Martin-Sanz, H., Chatzi, E. and Brühwiler, E., The use of Ultra High Performance fibre reinforced cement-based composites in rehabilitation projects: a review, in: 9th International Conference on Fracture Mechanics of Concrete and Concrete Structures, 2016. DOI: 10.21012/fc9.219.
- [27] Naaman, A.E. and Reinhart, H.W., Proposed classification of HPPFRC composites based on their tensile response, *Materials and Structures*, 39(5), pp. 547-555, 2006. DOI: 10.1617/s11527-006-9103-2
- [28] Wille, K., El-tawil, S. and Naaman, A.E., Properties of strain hardening ultra-high performance fiber reinforced concrete (UHP-FRC) under direct tensile loading, *Cement & Concrete Composites*, 48, pp. 53-66, 2014. DOI: 10.1016/j.cemconcomp.2013.12.015.
- [29] Yoo, D.Y. and Kim, M.J., High energy absorbent ultra-high-performance concrete with hybrid steel and polyethylene fibers, *Construction and Building Materials*, 209, pp. 354-363, 2019. DOI: 10.1016/j.conbuildmat.2019.03.096
- [30] Li, V., Tensile strain-hardening behavior of polyvinyl alcohol engineered cementitious composite, *ACI Materials Journal*, 98(6), pp. 483-492, 2001.
- [31] Zhang, J. and Zhao, Y., Experimental investigation and prediction of compressive strength of Ultra-High Performance Concrete (UHPC) containing supplementary cementitious materials, *Hindawi Advances in Materials Science and Engineering*, 2017, art. 4563164. DOI: 10.1155/2017/4563164.
- [32] Chollet, F. and Allaire, J.J., *Deep learning with R*, Manning Publications Co., New Jersey, USA, 2018.
- [33] Atkinson, A. and Riani, M., *Robust diagnostic regression analysis*, Springer US, New York, USA, 2000.
- [34] Härdle, W.K. and Simar, L., *Applied multivariate statistical analysis*, Springer-Verlag GmbH, Berlin, Germany, 2012.
- [35] Everitt, B. and Hothorn, T., *MVA: An introduction to applied multivariate analysis with R*, 2015.
- [36] Chandwani, V. and 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*, 4(4), pp. 2949-2956, 2014.
- [37] Adeli, H., *Neural networks in civil engineering: 1989 – 2000*. *Computer-Aided Civil and Infrastructure Engineering*, 16, pp. 126-142, 2001.
- [38] Aderaw, M., Muse, S. and Abiero, Z.C., Artificial neural network based modelling approach for strength prediction of concrete incorporating agricultural and construction wastes, *Construction and Building Materials*, 190, pp. 517-525, 2018. DOI: 10.1016/j.conbuildmat.2018.09.097
- [39] Ghafari, E., Costa, H. and Júlio, E., Statistical mixture design approach for eco- efficient UHPC, *Cement & Concrete Composites*, 55, pp. 17-25, 2015. DOI: 10.1016/j.cemconcomp.2014.07.016.
- [40] Ghafari, E., Bandarabadi, M., Costa, H. and Júlio, E., Prediction of fresh and hardened state properties of UHPC: comparative study of statistical mixture design and an artificial neural network model, *Journal of Materials in Civil Engineering*, 27, art. 04015017, 2015. DOI: 10.1061/(ASCE)MT.1943-5533.0001270.
- [41] Bharathi, S.D., Manju, R. and Premalatha, J., Prediction of compressive strength for Self- Compacting Concrete (SCC) using artificial intelligence and regression analysis, *International Journal of ChemTech Research*, 10(8), pp. 263-275, 2017.
- [42] Zhang, J. and Zhao, Y., Prediction of compressive strength of Ultra-High Performance Concrete (UHPC) containing supplementary cementitious materials, in: *Proceedings - 2017 International Conference on Smart Grid and Electrical*

- Automation, 2017, pp. 522-525. DOI: 10.1109/ICSGEA.2017.150.
- [43] R Core Team, R: a language and environment for statistical computing, Vienna, Austria, [online]. 2018. Available at: <https://www.r-project.org/>.
- [44] Friitsch, S., Guenther, F., Suling, M. and Mueller, S., Neuralnet: training of neural Networks, 2016.
- [45] Rosenblatt, F., The perceptron: a probabilistic model for information storage and organization in the brain, Cornell Aeronautical Laboratory 65(6), pp. 386-408, 1958.
- [46] Anderson, J.A., Cognitive and psychological computation with neural models, IEEE Transactions on Systems, Man, and Cybernetics 13,(5), pp. 799-816, 1983.
- [47] Liu, C., An introduction to artificial neural Networks and computational mechanics, Comput Meth Appl Mech Eng. 28(191), pp. 31-45, 2002.
- [48] Hudson-Beale, M., Neural Network toolbox user's guide, MathWorks J., 2012.
- [49] Rumelhart, D., Hinton, G. and Williams, R., Learning internal representations by error propagation, in: Rumelhart, D. and McClelland, J., Eds., Parallel distributed processing: explorations in the microstructures of cognition, 1986, pp. 318-362.
- [50] Mushgil, H.M., Alani, H.A. and George, L.E., Comparison between resilient and standard back propagation algorithms efficiency in pattern recognition, International Journal of Scientific & Engineering Research, 6(3), pp. 773-778, 2015.
- [51] Prasad, N., Singh, R. and Lal, S.P., Comparison of back propagation and resilient propagation algorithm for spam classification, in: Proceedings of International Conference on Computational Intelligence, 2013, pp. 29-34. DOI: 10.1109/CIMSim.2013.14.
- [52] Moriasi, D.N., Arnold, J.G., Liew, M.W. Van Bingner, R.L., Harmel, R.D. and Veith, T.L., Model evaluation guidelines for systematic quantification of accuracy in watershed in simulations, American Society of Agricultural and Biological Engineers, 50(3), pp. 885-900, 2007.
- [53] Chandwani, V., Agrawal, V. and Nagar, R., Modeling slump of ready mix concrete using genetic algorithms assisted training of Artificial Neural Networks, Expert Systems with Applications, 42(2), pp. 885-893, 2015. DOI: 10.1016/j.eswa.2014.08.048.
- [54] Srinivasulu, S. and Jain, A., A comparative analysis of training methods for artificial neural network rainfall - runoff models, Applied Soft Computing, 6, pp. 295-306, 2006. DOI: 10.1016/j.asoc.2005.02.002.
- [55] Gupta, S., Using artificial neural network to predict the compressive strength of concrete containing nano-silica, Civil Engineering and Architecture, 1(3), pp. 96-102, 2013. DOI: 10.13189/cea.2013.010306.
- [56] Yokota, H., Rokugo, K. and Sakata, N., (JSCE-2008) Recommendations for design and construction of High Performance Fiber Reinforced Cement Composites with Multiple Fine Cracks (HPFRCC), 2008. DOI: /10.1016/j.dci.2010.01.003.
- J. Abellán-García**, es estudiante de doctorado del Departamento de Ingeniería Civil de la Universidad Politécnica de Madrid (UPM), Madrid, España. Es profesor en la Escuela Colombiana de Ingeniería Julio Garavito, Bogotá, Colombia. Obtuvo el grado de ingeniero civil de la Universidad Politécnica de Valencia (UPV), España en el año 2006, y MSc. en Diseño, Construcción y Mantenimiento de Infraestructuras Ferroviarias por la Universidad Politécnica de Cataluña (UPC), España en 2011. Sus áreas de interés investigativo incluyen los concretos de ultra-altas prestaciones, la optimización estadística de materiales, la inteligencia artificial y el comportamiento sísmico de las estructuras. ORCID: 0000-0002-0353-322X
- J.S. Guzmán-Guzmán** es estudiante de maestría del programa de Maestría en ingeniería civil con énfasis en ingeniería estructural de la Escuela Colombiana de Ingeniería Julio Garavito, Bogotá, Colombia. Es ingeniero civil por la Universidad Militar Nueva Granada, Colombia en 2016. ORCID: 0000-0003-4167-0628
- J. Sánchez.Díaz**, es estudiante de maestría de la Facultad de Ingeniería de Sistemas de la Escuela Colombiana de Ingeniería Julio Garavito, Bogotá, Colombia. Es trabajador público en la Gobernación de Cundinamarca, Bogotá, Colombia. Obtuvo el grado en Ingeniería Industrial en la Escuela Colombiana de Ingeniería Julio Garavito en 2006, así como el grado de Esp. en Ingeniería de la Calidad en la Universidad Pontificia Javeriana, Colombia, en 2011. ORCID: 0000-0002-8069-2662
- J.S. Rojas-Grillo** es estudiante de ingeniería civil de último semestre en la Escuela Colombiana de Ingeniería Julio Garavito, Bogotá, Colombia. ORCID: 0000-0002-4581-0176