



# **Comparación entre regresión tipo LASSO y redes neuronales en la predicción del esfuerzo de fisuración y su elongación asociada del UHPFRC sometido a tracción directa**

**Diego Andrés Chaparro Ruiz**

Escuela Colombiana de ingeniería Julio Garavito

Facultad de ingeniería civil

Bogotá, Colombia

2020



# **Comparación entre regresión tipo LASSO y redes neuronales en la predicción del esfuerzo de fisuración y su elongación asociada del UHPFRC sometido a tracción directa**

**Diego Andrés Chaparro Ruiz**

**Director:**

M.Sc. Ing. Joaquín Abellán García

**Énfasis en estructuras**

Línea de investigación:

Materiales para estructuras en ingeniería civil

Grupo de investigación:

Centro de estudios de estructuras, materiales y construcción

Escuela Colombiana de ingeniería Julio Garavito

Facultad de ingeniería civil

Bogotá, Colombia

2020



## Resumen

La presente investigación tiene como finalidad modelar el comportamiento a tracción directa de los concretos de ultra alto desempeño reforzado con fibras (UHPRFC). Para este análisis se utilizaron los métodos de regresión tipo LASSO y redes neuronales para predecir la tensión y elongación que provocan la primera fisura en el concreto. Para la validación de los modelos desarrollados se utilizaron los siguientes índices estadísticos: error absoluto medio (MAE), raíz del error cuadrático medio (RSME), relación entre el RSME y la desviación estándar de los datos medidos (RSR), error de sesgo medio normalizado (NMBE), coeficiente de eficiencia de Nash-Sutcliff (E), y coeficiente de determinación múltiple ( $R^2$ ).

Para el diseño de mezcla de concretos UHPRFC se agregan fibras de refuerzo para aumentar la resistencia a tracción directa. Estas fibras están distribuidas uniformemente y proporcionan propiedades de ductilidad a los concretos de ultra alto desempeño, ya que estos concretos sin fibra tienen un comportamiento frágil.

En el entrenamiento de los modelos preventivos se utilizaron 934 datos aleatorios del comportamiento a tracción directa del UHPRFC con información sobre los parámetros  $\sigma_{cc}$  y  $\epsilon_{cc}$ , que representan el estado tensional correspondiente a la tensión de fisuración del UHPRFC. Durante el desarrollo algorítmico de los modelos, estos parámetros serán codificados como Y1 y Y2 respectivamente. Para construir un modelo preciso y con resultados adecuados fue necesario la detección y tratamiento de valores atípicos. Al final de este proceso se eliminaron 196 datos de la base de datos, dejando 738 para entrenamiento y testeo de los modelos de regresión LASSO y redes neuronales. Además, se realizó la partición de los datos para facilitar el entrenamiento y testeo y comprobar la eficiencia de la red neuronal y la regresión tipo LASSO. De esta forma, se utilizaron el 75% de los datos disponibles para entrenamiento de los modelos, quedando el 25% restante para labores de validación de los modelos.

Como conclusión del presente trabajo de investigación, se desprende que la herramienta más precisa para la predicción de las variables Y1 y Y2, alcanzándose valores de  $R^2$  de 0,9218 y 0,8075 respectivamente en los subconjuntos de validación. La regresión tipo LASSO alcanzó valores de  $R^2$  para estas mismas variables de 0,6771 y 0,6579 respectivamente, claramente inferiores a los alcanzados por los modelos de redes neuronales.

**Palabras clave:** comportamiento a tracción directa, redes neuronales artificiales, regresión tipo LASSO, UHPRFC.

# Contenido

Página:

<b>Resumen.....</b>	<b>V</b>
<b>Lista de Figuras .....</b>	<b>VIII</b>
<b>Lista de tablas .....</b>	<b>VIII</b>
<b>Introducción.....</b>	<b>10</b>
<b>1. Marco teórico .....</b>	<b>12</b>
1.1. Concreto de ultra altas prestaciones con y sin fibras.....	12
1.2. Modelos matemáticos aplicados a concreto: .....	16
<b>2. Estado del arte .....</b>	<b>18</b>
2.1. Estudio de propiedades del concreto utilizando regresiones polinómicas.....	19
2.2. Estudio de propiedades del concreto utilizando regresiones tipo LASSO.....	19
2.3. Estudio de propiedades del concreto utilizando redes neuronales .....	20
<b>3. Objetivos .....</b>	<b>20</b>
3.1. Objetivo general.....	20
3.2. Objetivos específicos:.....	20
<b>4. Metodología .....</b>	<b>21</b>
4.1. Bases de datos.....	21
4.1.1. Recopilación de datos .....	21
4.1.2. Tratamiento de datos anómalos.....	23
4.1.3. Normalización de datos .....	24
4.1.4. División de las bases de datos .....	24
4.2. Desarrollo analítico .....	25
4.2.1. Regresión tipo LASSO .....	25
4.2.2. Redes neuronales artificiales .....	26
4.2.3. Índices estadísticos empleados en la validación de los modelos .....	27
<b>5. Resultados.....</b>	<b>29</b>
5.1. Regresión tipo LASSO .....	29
5.1.1. Modelos .....	29
5.1.2. Evaluación de los modelos LASSO.....	29
5.2. Redes neuronales .....	31

<b>5.2.1. Modelos .....</b>	<b>31</b>
<b>5.2.2. Evaluación de los modelos de redes neuronales.....</b>	<b>32</b>
<b>6. Conclusiones.....</b>	<b>33</b>
<b>7. Recomendaciones.....</b>	<b>34</b>
<b>8. Bibliografía .....</b>	<b>35</b>

## Lista de Figuras

Figura 1.1 - Cuerpo de prueba dogbone para ensayo de tracción directa conforme a JSCE-08 [1][2]	14
Figura 1.2 - Diagrama esfuerzo-alargamiento unitario de un UHPFRC con comportamiento de endurecimiento por deformación [2] .....	14
Figura 1.3 - Pasarela de Sherbooke.....	15
Figura 1.4 - Pasarela Sakata Mirai .....	16
Figura 1.5 - modelo red neuronal Perceptron .....	18
Figura 4.1 - Esquema de la validación cruzada tipo k-fold utilizada en el entrenamiento de los modelos de regresión [4].....	24
Figura 4.2 - Red neuronal [6].....	26
Figura 5.1 - Gráficos de valores reales versus predichos por los modelos tipo LASSO. ....	30
Figura 5.2 - Promedio de la raíz del error cuadrático medio (RMSE) versus el número de neuronas en la capa oculta usando validación cruzada tipo k-fold. ....	31
Figura 5.3 - Modelos de redes neuronales considerados.....	32
Figura 5.4 - Gráficos de valores reales versus predichos por los modelos de redes neuronales.	33

## Lista de Tablas

Tabla 4.1 - Propiedades de los UHPFRC recopiladas en la base de datos .....	21
Tabla 4.2 - Variables respuesta .....	23
Tabla 5.1 - Modelos tipo LASSO .....	29
Tabla 5.2 - Evaluación de los modelos tipo LASSO.....	30
Tabla 5.3 - Evaluación de los modelos de redes neuronales.....	32

# Introducción

Los concretos del tipo UHPFRC son materiales de nueva generación que permiten diseñar y producir formas complejas de gran resistencia y, a la vez, muy ligeras y esbeltas. Poseen una elevada resistencia a la compresión, a la flexión y al desgaste, así como una gran durabilidad. Se trata de concretos con elevados contenidos de materiales cementantes, con un alto grado de empaquetamiento que es una de las causas fundamentales de sus excelentes propiedades. Para aportar ductilidad, se le adicionan fibras poliméricas, inorgánicas o metálicas. Para el correcto funcionamiento de la fibra, así como para mejorar la homogeneidad del concreto, los agregados habituales son silicios con un tamaño máximo de 1 mm [1].

Las fibras más habituales en el UHPFRC son las fibras de acero de alta resistencia, de 2 o 3 décimas de milímetro de diámetro equivalente, normalmente de aceros recubiertos de cobre o latón. Las proporciones habituales están en unos 150 kilogramos por m<sup>3</sup>, lo que representa un 2% en volumen del concreto. La adición de fibras no sólo es necesaria para alcanzar la resistencia exigida, sino que es necesaria para alcanzar la ductilidad del material. Los UHPFRC deben tener una resistencia a compresión característica mínima de 150 MPa y se controlan no solo a compresión sino a tracción directa y a flexotracción [2]. La rotura en todos los casos debe producirse más allá del Límite de proporcionalidad Tensión-deformación, o sea con cierta ductilidad.

El comportamiento a carga por fatiga es muy demandante en la adherencia de la fibra con la matriz, y por eso afecta de modo importante el comportamiento mecánico del UHPFRC. A medida que la relación longitud de fibras-diámetro se incrementa, la adherencia de las fibras a la matriz se reduce y la sensibilidad a la fatiga se incrementa [3].

## **Comportamiento a tracción directa**

Las pruebas de tensión uniaxiales son difíciles de llevar a cabo apropiadamente y es difícil evitar esfuerzos de flexión o fractura por las mordazas de la máquina [4]. Cuando la proporción de las fibras bien orientadas (fibras paralelas al esfuerzo de tensión) es alta y el comportamiento de tensión del compuesto es elástico –perfectamente plástica o de endurecimiento con deformación elástica– únicamente la porción elástica de la curva esfuerzo-deformación determinada experimentalmente puede ser representativa, ya que la flexión podría ser un factor distorsionador después de que se ha iniciado el agrietamiento. A pesar de las dificultades mencionadas, se han determinado resistencias a la tensión confiables. Las resistencias medias a la tensión para los UHPFRC, se encuentran en el rango de 5 y 20 MPa, siendo valores habituales de 6 a 11 MPa [3].

Aunque pueden usarse para evaluar las características de fractura, los especímenes de tensión con huecos estrechos y alargados no son medios confiables para la evaluación directa de la tensión de un UHPFRC.

Los huecos estrechos y alargados perturban la tendencia natural del material a tener grietas múltiples, y cuando se inicia una sola grieta, el espécimen entra en flexión. Si se ignora esta flexión en los cálculos, la resistencia a tensión uniaxial es sobreestimada. Por este motivo, la base de datos utilizada en esta investigación no contendrá resultados con especímenes con huecos [5].

Parámetros del gráfico tensión deformación:

El esfuerzo interno  $\sigma$  que está sometido un cuerpo por la aplicación de dos fuerzas que actúan en sentido opuesto, y tiende a estirarlo. Lógicamente se considera que las tensiones que tiene cualquier sección perpendicular a dichas fuerzas son normales a esa sección, y poseen sentidos opuestos a las fuerzas que intentan alargar el espécimen [4].

La deformación  $\epsilon$  en todo elemento estructural sometido a la acción de cargas se deforma. En la mayoría de los casos las deformaciones son imperceptibles, y deben ser medidas con el auxilio de instrumentos del tipo LVDT (transformador diferencial de variación lineal). Podemos definir la deformación de un elemento estructural como una alteración del estado físico debido a una fuerza mecánica externa, a una variación de temperatura, a un deslizamiento de mordazas en apoyos, etc. La deformación puede ser elástica, cuando desaparece al cesar la acción que lo produce, por lo que las partículas elementales del cuerpo vuelven a su posición inicial; y permanente, cuando persiste después de desaparecer la causa que lo ha producido. El elemento en el primer caso tiene un comportamiento elástico y en el segundo un comportamiento plástico o inelástico [4].

# 1.Marco teórico

Los concretos de ultra alto desempeño reforzados con fibras (UHPFRC), tiene cada vez más aplicaciones en las grandes estructuras en todo el mundo teniendo en cuenta sus propiedades (mecánicas y durabilidad). Las excelentes propiedades de alto desempeño de este material se deben principalmente al empaquetamiento de partículas, a sus componentes y a los rigurosos procesos de amasado. Estas propiedades sobresalientes, tanto mecánicas como de durabilidad, ayudan a la disminución de material en la construcción y disminuye los costos de las infraestructuras en las que se emplea UHPFRC.[6-8]

Los concretos de ultra alto desempeño (UHPC) tienen un comportamiento frágil, por lo que es necesario implementar fibras en el concreto (UHPFRC). La correcta adición de fibras proporciona un alto desempeño a tracción directa y a flexión [4].

En este trabajo de investigación se desarrollaron modelos predictivos de comportamiento a la tracción directa de los UHPFRC, centrándonos en la tensión y elongación que producen la primera fisura en el concreto. Finalmente se compararon los desempeños de los modelos de regresión tipo LASSO y redes neuronales en la predicción del comportamiento a la tracción directa de los UHPFRC.

## 1.1. Concreto de ultra altas prestaciones con y sin fibras

### **Concreto de ultra-altas Prestaciones (UHPC):**

Es un tipo de concreto que permite diseñar y producir formas complejas de gran resistencia y, a la vez, muy ligeras y esbeltas. Posee una elevada resistencia a la compresión, a la flexión y al desgaste, así como una gran durabilidad. Es un concreto de baja porosidad que consigue una baja absorción de agua y una excelente durabilidad. Se suele fabricar con agregados silicios con un tamaño máximo de 1 mm, siendo el tamaño máximo de agregado más habitual de 0,6 mm [7].

El UHPC tiene una resistencia a compresión de 150 MPa, a flexión de 18 MPa y a tracción directa de 5 MPa[2]. Esto quiere decir que, comparado con un concreto convencional, es siete veces más resistente a compresión, y cinco veces más resistente a flexión y a tracción directa. Adicionalmente, en aspectos de durabilidad es muy superior pues presenta una muy baja permeabilidad al agua (< 2 mm) y a la penetración del ion cloruro (< 1000 Coulomb).

Este producto ayuda a disminuir el uso de materiales de construcción. Permite la disminución de consumo de concreto por la reducción de secciones en elementos estructurales y la disminución de cuantías de refuerzo en elementos estructurales [9].

### **Concreto de ultra-altas prestaciones reforzado con fibras (UHPFRC):**

Los concretos (UHPFRC, por sus siglas en inglés) se caracterizan por tener propiedades de resistencia mecánica y durabilidad muy superior en comparación con los concretos convencionales debido principalmente a la densidad de empaquetamiento de partículas. Se definen como concretos reforzados con fibras que poseen un comportamiento en la deformación después de la primera fisura, posee la cualidad de ser dúctil, tiene resistencia a compresión mayores de 150 MPa y tracción mayor de a 6 Mpa. Las fibras ayudan a que los concretos UHPFRC tengan un mayor desempeño en el desarrollo de las resistencias a tracción y a flexión [2].

Una mezcla típica de UHPFRC está compuesta por cemento tipo Portland, humo de sílice, polvo de cuarzo, arena fina silíceo, superplastificante reductor de agua de alto rango (HRWR), y fibras metálicas. El uso de estos materiales favorece igualmente la durabilidad de las estructuras debido a la ausencia de porosidad, al menor ancho de las fisuras y la compacidad de la matriz que limitan la entrada y circulación de agentes agresivos [10].

### **Comportamiento a tracción directa del (UHPFRC):**

El espécimen típico para determinar el comportamiento a tracción directa del UHPFRC es el *dogbone* que se presenta en la Figura 1.1 [11]. El comportamiento a la tracción de los UHPFRC con endurecimiento por deformación se desarrolla en 3 fases diferentes. En la Zona 1 el nivel de tensión se define por  $\sigma_{cc}$  y su alargamiento unitario asociado  $\epsilon_{cc}$ . Tras ésta se encuentra la zona 2, o el dominio del endurecimiento por deformación, basada en la 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 la tensión-deformación hasta  $\sigma_{pc}$ , y su alargamiento unitario asociado  $\varepsilon_{pc}$ . Finalmente, en la zona 3, o el dominio del comportamiento de ablandamiento por deformación, se produce el arrancamiento de la fibra. Lo anterior mencionado se puede observar de mejor manera en la Figura 1.2.

El comportamiento constitutivo típico a tracción directa del UHPFRC reforzado con la suficiente cantidad de fibras, para obtener endurecimiento tras la rotura de la matriz se puede observar en la figura 1.2. En esta se puede distinguir 3 fases, claramente diferenciadas como son: una rama elástica, una rama de endurecimiento y una rama de ablandamiento tras la rotura [4].



Figura 1.1 - Cuerpo de prueba dogbone para ensayo de tracción directa conforme a JSCE-08 [11][4]

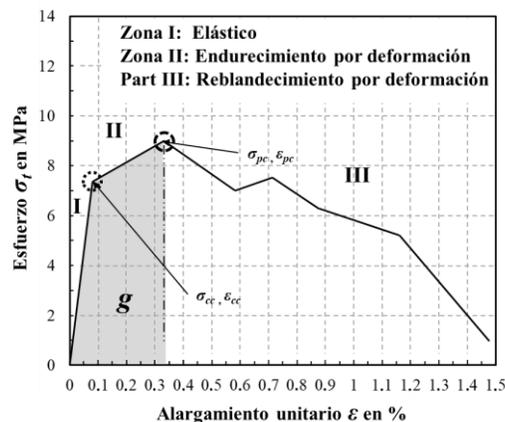


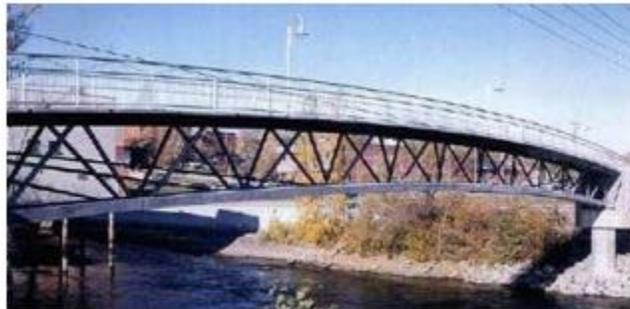
Figura 1.2 - Diagrama esfuerzo-alargamiento unitario de un UHPFRC con comportamiento de endurecimiento por deformación [4]

### **Aplicaciones del concreto UHPFRC:**

Desde que se introdujo en la ingeniería civil hace ya más de dos décadas, la experiencia en el empleo de UHPCFR en múltiples aplicaciones ingenieriles nos muestra las claves que lo hacen realmente competitivo en sus usos prácticos, como son la reducción de peso propio y carga muerta (lo que posibilita por ejemplo la reducción de acciones sísmicas de diseño), la esbeltez alcanzada en las construcciones (pequeño ratio del cociente altura/vano de un puente), la elevada ductilidad y resistencia a flexión, la efectividad de las uniones entre elementos, así como la reducción de gastos en mantenimiento por la mejora de la durabilidad[12,13] .

Además, el impulso de este material incita a que se innove en las formas constructivas y en los procesos de fabricación y montaje, avocando a la ingeniería que renueve sus métodos y desarrolle tecnologías más vanguardistas. El UHPFRC se ha usado alrededor del mundo sobre todo en la construcción de puentes de carretera y pasarelas peatonales, en paneles de protección y aplicaciones arquitectónicas [6].

Una de las primeras aplicaciones en obras infraestructura fue un puente peatonal en Canadá. Se trata de una viga triangulada de 60 m de luz sobre el río Magog, conocida como la Pasarela de Sherbooke (ver figura 1.3).



**Figura 1.3 – Pasarela de Sherbooke[14]**

Otras aplicaciones de puentes peatonales serían la pasarela Sakata Mirai en Japón (Figura 1.4), de 50 m de luz y la Pasarela de la Paz, de 120 m de luz y sección en pi de 1.3 m de canto, en Corea del Sur.



**Figura 1.4 – Pasarela Sakata Mirai [11]**

Por otro lado, su aplicación a la construcción de elementos de poco espesor como cubiertas pone de manifiesto todas las propiedades de este material. Un reconocido ejemplo se halla en una de las estaciones de tren en Canadá construida en 2004. La estación de Shawnessy es una singular estructura de UHPFRC cuyas láminas de cubierta tienen un espesor de tan sólo 20 mm.

## **1.2. Modelos matemáticos aplicados a concreto:**

Un modelo matemático es uno de los tipos de modelos científicos que emplea algún tipo de formulismo matemático para expresar relaciones, proposiciones sustantivas de hechos, variables, parámetros, entidades y relaciones entre variables de las operaciones, para estudiar comportamientos de sistemas complejos ante situaciones observables en la vida real.

### **Regresiones polinómicas:**

En estadística, la regresión polinómica es una forma de regresión en la que la relación entre la variable independiente  $x$  y la variable dependiente  $y$  es modelada como un polinomio de grado  $n$  en  $x$ . La regresión polinómica se ajusta a una relación no lineal entre el valor de  $x$  y la correspondiente media condicional de  $y$ , denotada  $E(y | x)$ . Aunque la regresión polinómica se ajusta a un modelo no lineal a los datos, como un problema de estimación estadística, es lineal, en el sentido de que la función de regresión  $E(y | x)$  es lineal en los parámetros desconocidos que se calculan a partir de los datos. Por esta razón, la regresión polinómica se considera un caso especial de regresión lineal múltiple.

La regresión polinómica consiste en agregar una curvatura al modelo introduciendo de la forma más sencilla nuevos predictores que se obtiene al elevar todos o algunos de los predictores originales a distintas potencias el predictor original.

Partiendo del modelo lineal

$$y_i = \beta_0 + \beta_1 * x_1 + \epsilon_i \quad (1)$$

**Se obtiene un modelo polinómico de grado d a partir de la ecuación**

$$y_i = \beta_0 + \beta_1 * x + \beta_2 * x^2 + \beta_3 * x^3 + \dots + \beta_d * x^d + \epsilon_i \quad (2)$$

**Regresión tipo LASSO (*least absolute shrinkage and selection operator*):**

Es un método que combina un modelo de regresión con un procedimiento de contracción de algunos parámetros hacia cero y selección de variables, aplicando una restricción o una penalización sobre los coeficientes de regresión. Esto quiere decir que el modelo va a ignorar algunas de las características predictivas, lo que puede ser considerado un tipo de selección automática de características. El incluir menos características supone un modelo más sencillo de interpretar que puede poner de manifiesto las características más importantes del conjunto de datos. En el caso de que exista cierta correlación entre las características predictivas, Lasso tenderá a escoger únicamente una de ellas.

La ecuación que rige la regresión tipo LASSO se presenta en la ecuación (3), donde el parámetro  $\lambda$  es aquel que minimiza el valor de  $RSS_{lasso}$ .

$$RSS_{lasso} = \sum_{i=1}^n ((y_i - f(x_i))^2 + \lambda \sum_{j=1}^p (|\beta_j|) \quad (3)$$

donde  $\lambda \geq 0$  es el parámetro de penalización. Si  $\lambda$  tiene un valor lo suficiente elevado, algunos de los coeficientes de las variables predictivas pueden llegar a reducirse hasta exactamente 0, por lo que el método actúa como selector de características, y la interpretación del modelo se facilita al crear modelos más simples [10,15].

**Regresión con modelos de redes neuronales:**

Los modelos de redes neuronales pueden ser considerados como nuevos paradigmas inspirados en el funcionamiento de sistemas nerviosos biológicos. Una de las razones del uso de las redes neuronales es que no necesitan el cumplimiento de supuestos teóricos como en los modelos estadísticos clásicos. El modelo del Perceptrón multicapa es equivalente a un modelo de regresión lineal, debido a la similitud de la variable de salida (variable respuesta Y) que se relaciona aplicando la función de activación

(función identidad) sobre una combinación lineal de pesos (coeficientes) con las variables de entrada (variables predictoras).

### El modelo red neuronal perceptron

El perceptrón es el modelo más simple de red neuronal artificial constando de una capa de entrada, una capa oculta y una de salida [16]. Es un modelo de gran uso y resulta eficiente para modelar muchas situaciones del mundo real. La estructura del perceptron está conformada por una capa de entrada con dos neuronas, que permite recibir los valores de las variables predictoras; una neurona en la capa oculta, donde se realiza la acumulación de la entrada (entrada neta) y la aplicación de la función de transferencia (generalmente una función umbral) para obtener la salida esperada, y la capa oculta de salida donde se compara la salida esperada con la salida observada. La diferencia entre el valor estimado y el valor real de la variable respuesta sería el error o residual. El esquema del perceptrón se presenta en la Figura 1.5.

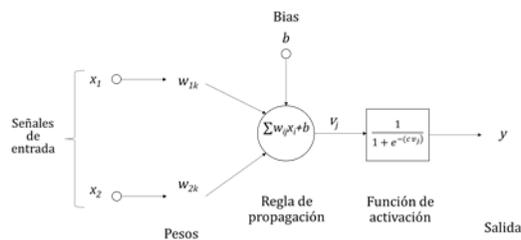


Figura 1.5 – modelo red neuronal Perceptron

La única neurona de salida del perceptron realiza la suma ponderada para obtener la entrada neta y restar un valor de umbral. El resultado se aplica a la función de transferencia. Los valores de los pesos ( $w_{1k}$ ,  $w_{2k}$ ) pueden fijarse o hallarse utilizando diferentes algoritmos de entrenamiento de la red, lo que se conoce como entrenamiento del modelo de redes neuronales.

## 2. Estado del arte

A continuación, se presentan algunos avances de los estudios más recientes y relevantes relacionados con los concretos de ultra altas prestaciones reforzados con fibras (UHPFRC, por sus siglas en inglés). También se tiene una comparación de las

propiedades de la regresión polinomial, LASSO Y redes neurales, implementando modelos matemáticos predictivos.

## **2.1. Estudio de propiedades del concreto utilizando regresiones polinómicas**

Abellán et al. [17] presentaron un estudio sobre aplicaciones de regresiones polinómicas a concretos UHPC mediante técnicas de diseños de experimentos. Algunos de los objetivos del estudio fueron:

- Optimización de las respuestas individuales para la mezcla de UHPC maximizando la compresión de 28 días (Criterio I) y determinando el contenido mínimo de cemento para alcanzar los 150 MPa sin cura térmica (Criterio II).
- Caracterización química de cemento, humo de sílice, polvo de micro caliza y vidrio reciclado.
- Slump Flow Test.
- Determinación experimental de la resistencia a la compresión de 28 días
- Optimización de las respuestas individuales (resistencias a diferentes edades) para una mezcla de UHPC autocompactante

## **2.2. Estudio de propiedades del concreto utilizando regresiones tipo LASSO**

Abellán-García[10] presentó unos modelos predictivos basados en regresiones tipo LASSO para el comportamiento a flexión de los UHPFRC. Entre los objetivos del estudio podemos destacar:

- Predicción de la deflexión en mm correspondiente al esfuerzo que provoca la aparición de la primera fisura  $\delta_{LOP}$
- Predicción del módulo de rotura o esfuerzo máximo post-fisuración durante el ensayo de flexión (MOR).
- Predicción del límite de proporcionalidad o esfuerzo que provoca la primera fisura en el concreto durante el ensayo de flexión.
- Predicción de la deflexión en mm correspondiente al esfuerzo máximo a flexión  $\delta_{MOR}$ .

Como conclusión de este estudio se llegó a que los modelos tipo LASSO son de gran utilidad en el desarrollo de dosificaciones de UHPFRC sometidos a flexión, ya que, debido a su precisión, permiten preseleccionar las combinaciones de componentes (materiales cementantes, agregados y fibras).

## 2.3. Estudio de propiedades del concreto utilizando redes neuronales

Existen diferentes estudios sobre el uso de redes neuronales artificiales para la predicción del comportamiento de los concretos tipo UHPC y UHPFRC. Entre ellos podemos citar los de Abellán-García[10,18], Abellán-García et al. [19,20] y Ghafari et al. [21]. Algunas de las variables analizadas en estos estudios fueron:

- Resistencia a la compresión a 12 días con cura térmica.
- Slump Flow, resistencia a la compresión de 28 días y resistencia a la compresión de 2 días con cura térmica.
- Resistencia a la compresión de 7, 28, 90 y 365 días.
- Slump Flow y resistencia a la compresión a los 1, 7 y 28 días.
- Límite de proporcionalidad (LOP), su deflexión correspondiente ( $\delta_{LOP}$ ), módulo de Ruptura (MOR), y su correspondiente deflexión ( $\delta_{MOR}$ ) de UHPFRC bajo flexión.

## 3. Objetivos

### 3.1. Objetivo general

Modelar el esfuerzo de fisuración y su elongación asociada a tracción directa de los concretos de Ultra Alto Desempeño reforzados con fibras (UHPFRC) mediante algoritmos de inteligencia artificial (regresión tipo LASSO y redes neuronales).

### 3.2. Objetivos específicos:

- Desarrollar un modelo de redes neuronales artificiales (ANN) para predecir el esfuerzo de fisuración y su elongación asociada de los UHPFRC sometiendo los especímenes a tracción directa.
- Desarrollar un método de análisis de regresión tipo LASSO que realiza selección de variables y regulación para mejorar la exactitud e interpretabilidad.
- Comparar los modelos desarrollados en su eficacia y precisión para estimar los parámetros seleccionados (Y1 y Y2)

## 4. Metodología

Este proyecto está enmarcado en la investigación llevada a cabo por el ingeniero Joaquín Abellán García sobre optimización de concretos de altas prestaciones reforzados con fibras y aplicaciones sismo resistentes. En este trabajo la metodología consistirá en utilizar los modelos predictivos del comportamiento en la predicción del esfuerzo de fisuración  $\sigma_{cc}$  y su elongación asociada  $\varepsilon_{cc}$  producidos en ensayo de tracción directa de los UHPFRC.

### 4.1. Bases de datos

En la base de datos se tiene almacenado sistemáticamente un conjunto de datos para su posterior uso.

#### 4.1.1. Recopilación de datos

Para el entrenamiento de los modelos predictivos se utilizaron 934 datos del comportamiento a tracción directa del UHPFRC con información sobre los parámetros  $\sigma_{cc}$  y  $\varepsilon_{cc}$ . Es relevante destacar que esta base de datos contiene tanto dosificaciones con un solo tipo de fibra (fibra 1), como mezclas de UHPFRC con mezclas binarias de fibra (indicadas en la base de datos como fibra 1y fibra 2). Las bases de datos consideradas corresponden a la investigación doctoral del ing. Joaquin Abellán.

También es relevante resaltar es la presencia de variables cualitativas dentro de la base de datos, específicamente relacionadas con el tipo de fibra. Estas variables son incorporadas en los modelos matemáticos mediante variables tipo *dummy* o dicotómicas.

Las variables de entrada a los modelos, recopiladas en la base de datos, así como su codificación, se muestran en la Tabla 4.1.

**Tabla 4.1 – Propiedades de los UHPFRC recopiladas en la base de datos**

Variable	Descripción	Variable	Descripción
X1	Contenido de cemento (kg/m <sup>3</sup> )	X31	Diámetro de la fibra 2 en mm
X2	Contenido de humo de sílice (kg/m <sup>3</sup> )	X32	Relación lf/df de la fibra 2
X3	Otros materiales cementantes (kg/m <sup>3</sup> )	X33	Contenido de la fibra 2 en kg/m <sup>3</sup>
X4	Agua (kg/m <sup>3</sup> )	X34	Contenido de la fibra 2 en porcentaje sobre el volumen total del concreto
X5	HRWR (kg/m <sup>3</sup> )	X35	Factor fibra ( $\chi_f$ ) de la fibra 2

X6	Harina de cuarzo (kg/m <sup>3</sup> )	X36	Contenido de binder (cemento, humo de sílice y materiales cementantes) en kg/m <sup>3</sup>
X7	Contenido total de fibras en porcentaje sobre el volumen total	X37	Tamaño máximo del agregado en mm
X8	Factor fibra total	X38	Volumen de la pasta (cemento, humo de sílice, materiales cementantes, agua y aditivos) respecto del volumen total del concreto
X9	Contenido total de fibras en kg/m <sup>3</sup>	X39	Relación agua/cemento en peso
X10	Variable tipo dummy cuyo valor es 1 si la fibra 1 es metálica recta y 0 en caso contrario	X40	Relación agua/binder en peso
X11	Variable tipo dummy cuyo valor es 1 si la fibra 1 es metálica acabada en ganchos y 0 en caso contrario	X41	Relación agua/polvos totales (binder + harina de cuarzo) en peso
X12	Variable tipo dummy cuyo valor es 1 si la fibra 1 es metálica retorcida y 0 en caso contrario	X42	Contenido de arena en kg/m <sup>3</sup>
X13	Variable tipo dummy cuyo valor es 1 si la fibra 1 es de polietileno y 0 en caso contrario	X43	Polvos totales (kg/m <sup>3</sup> )
X14	Variable tipo dummy cuyo valor es 1 si la fibra 1 es de polipropileno y 0 en caso contrario	X44	Agregados y fibra en % sobre el volumen total
X15	Variable tipo dummy cuyo valor es 1 si la fibra 1 es de polivinilo de alcohol y 0 en caso contrario	X45	Agregados sobre polvos totales en volumen
X16	Resistencia a la tracción del material de la fibra 1 en MPa	X46	Agregados y fibra sobre polvos totales en volumen
X17	Longitud de la fibra 1 en mm	X47	Arena y harina de cuarzo sobre cemento en peso
X18	Diámetro de la fibra 1 en mm	X48	Arena y harina de cuarzo sobre binder en peso
X19	Relación lf/df de la fibra 1	X49	Arena, harina de cuarzo y fibra sobre binder en peso
X20	Contenido de la fibra 1 en kg/m <sup>3</sup>	X50	Arena y harina de cuarzo sobre cemento en peso
X21	Contenido de la fibra 1 en porcentaje sobre el volumen total del concreto	X51	Agregados y harina de cuarzo sobre binder en peso
X22	Factor fibra ( $\chi_f$ ) de la fibra 1	X52	Agregados, harina de cuarzo y fibra sobre binder en peso
X23	Variable tipo dummy cuyo valor es 1 si la fibra 2 es metálica recta y 0 en caso contrario	X53	Tipos de fibra utilizados
X24	Variable tipo dummy cuyo valor es 1 si la fibra 2 es metálica acabada en ganchos y 0 en caso contrario	X54	Número de componentes del binder
X25	Variable tipo dummy cuyo valor es 1 si la fibra 2 es metálica retorcida y 0 en caso contrario	X55	Número de materiales no reactivos incluyendo harina de cuarzo
X26	Variable tipo dummy cuyo valor es 1 si la fibra 2 es de polietileno y 0 en caso contrario	X56	Numero de tipos de agregado

X27	Variable tipo dummy cuyo valor es 1 si la fibra 2 es de polipropileno y 0 en caso contrario	X57	Resistencia a compresión en MPa
X28	Variable tipo dummy cuyo valor es 1 si la fibra 2 es de polivinilo de alcohol y 0 en caso contrario	X58	Ancho del espécimen sometido a tracción directa en mm
X29	Resistencia a la tracción del material de la fibra 2 en MPa	X59	Espesor del espécimen sometido a tracción directa en mm
X30	Longitud de la fibra 2 en mm	X60	Longitud del vástago del espécimen sometido a tracción directa en mm

Por otro lado, las variables que se van a estudiar, es decir, las variables respuestas de los modelos de regresión se presentan en la Tabla 4.2.

**Tabla 4.2 – Variables respuesta**

Variable	Descripción
Y1	Tensión de fisuración a tracción directa en MPa ( $\sigma_{cc}$ )
Y2	Alargamiento unitario bajo tensión de fisuración en % ( $\epsilon_{cc}$ )
$\widehat{Y1}_{LASSO}$	Estimación de Y1 mediante regresión tipo LASSO
$\widehat{Y2}_{LASSO}$	Estimación de Y2 mediante regresión tipo LASSO
$\widehat{Y1}_{ANN}$	Estimación de Y1 mediante redes neuronales
$\widehat{Y2}_{ANN}$	Estimación de Y2 mediante redes neuronales

#### 4.1.2. Tratamiento de datos anómalos

La detección y tratamiento de valores atípicos es un paso obligatorio para construir un modelo preciso con resultados adecuados, debido a que estos datos anómalos pueden influir mucho en el modelo resultante [22]. Debido a esto, se realizó un análisis estadístico, mediante diagramas *bagplot*, de cada variable frente a cada variable respuesta (Y1 y Y2) para identificar y eliminar los valores atípicos [23]. El diagrama *bagplot* es un diagrama de dispersión basado en el diagrama "Box and whisker plot" de Tukey [24].

Al final de este proceso, se eliminaron 196 observaciones de la base de datos, dejando 738 para entrenamiento y testeo de los modelos de regresión (LASSO y redes neuronales).

### 4.1.3. Normalización de datos

Antes de proceder al desarrollo de los modelos predictivos entre la regresión tipo LASSO y redes neuronales. Es necesario hacer el proceso de la normalización de datos que tiene con objeto minimizar la abundancia de datos, elimina la posibilidad de sesgo de la regresión tipo LASSO Y redes neuronales debido a la diferente naturaleza y magnitud de las diferentes variables consideradas. La normalización de datos se hace mediante la fórmula (4).

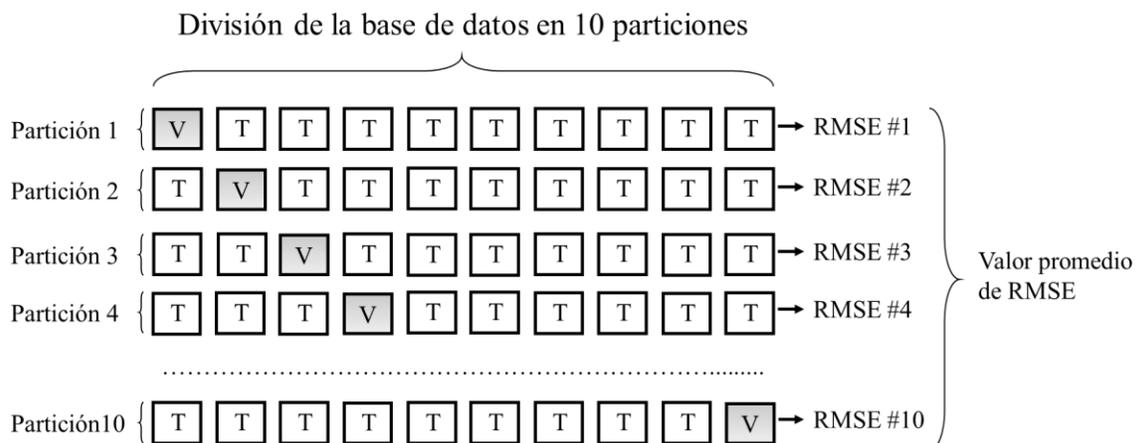
$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (4)$$

Donde  $x_{norm}$  es el valor normal de la base de datos, mientras que  $x_{max}$  y  $x_{min}$  representan los valores máximos y mínimos en la base de datos.

### 4.1.4. División de las bases de datos

Es necesaria la partición de los datos para facilitar el entrenamiento y testeo y comprobar la eficiencia de la red neuronal y la regresión tipo LASSO.

Para este proyecto es necesario modelar redes, se utiliza la técnica de validación cruzada tipo *k-fold*. Este método no es demasiado preciso debido a la variación de resultados obtenidos para diferentes datos de entrenamiento. Para la evaluación puede depender de gran medida como es la división entre datos de entrenamiento y de prueba. Los puntajes de validación pueden tener una gran variación con respecto a la división de validación. Esto llevaría a una evaluación poco confiable de los modelos.



**Figura 4.1 - Esquema de la validación cruzada tipo k-fold utilizada en el entrenamiento de los modelos de regresión [10].**

## 4.2. Desarrollo analítico

Para el desarrollo de la investigación fue necesario contar con algunas de las aplicaciones de la inteligencia artificial como la regresión tipo LASSO [10] y las redes neuronales artificiales de tipo *feed-forward* [25]. Para la creación, entrenamiento y validación de los modelos matemáticos se utilizó el lenguaje de programación estadístico R[26]. Estos modelos nos ayudan a estimar los parámetros Y1 y Y2 en función de las propiedades y características del UHPFRC descritas en la Tabla 4.1.

### 4.2.1. Regresión tipo LASSO

Este método se fundamenta en el análisis de regresión que se encarga de hacer la selección de variables y regulación, mejorando la exactitud e interpretabilidad de los modelos estadísticos. Un modelo como este con un gran número de predictores puede suponer un desafío a la hora de su interpretación ya sea para su selección de variable.

El método LASSO es una alternativa al ajuste por *ridge regression* que permite superar su principal desventaja, la incapacidad de excluir predictores del modelo. El método LASSO, al igual que *ridge regression*, fuerza a que las estimaciones de los coeficientes de los predictores tiendan a cero. La diferencia es que Lasso sí es capaz de fijar algunos de ellos exactamente a cero, lo que permite además de reducir la varianza, realizar selección de predictores[10,15].

Este método abarca desde las regresiones polinómicas hasta la inteligencia artificial y aprendizaje automático. Al incluir menos características supone un modelo más sencillo de interpretar que puede poner de manifiesto las características más importantes del conjunto de datos. En el caso de que exista cierta correlación entre las características predictivas, la regresión tipo LASSO tenderá a escoger sólo una de ellas.

El procedimiento de este método se basa en técnicas de regularización que contrae los coeficientes estimados, reduciendo de manera significativa su varianza. En la regresión polinómica se eligen los parámetros  $\beta_0, \beta_1, \dots, \beta_p$  que ayuda a minimizar la suma de cuadrados de los residuos (RSS), conforme se muestra en la ecuación (5):

$$RSS = \sum_{i=1}^n \left( y_i - \beta_0 - \sum_{j=1}^p (\beta_j * x_{ij}) \right)^2 \quad (5)$$

Los coeficientes de la regresión tipo LASSO reducen la expresión (6), que es un desarrollo de la ecuación (3) presentada anteriormente:

$$RSS = \sum_{i=1}^n \left( y_i - \beta_0 - \sum_{j=1}^p (\beta_j * x_{ij}) \right)^2 + \lambda \sum_{j=1}^p (|\beta_j|) \quad (6)$$

#### 4.2.2. Redes neuronales artificiales

Consiste en un conjunto de unidades, llamadas neuronas artificiales, conectadas entre sí para transmitirse señales. La información de entrada atraviesa la red neuronal (donde se somete a diversas operaciones) produciendo unos valores de salida.

Cada neurona está conectada con otras a través de unos enlaces. En estos enlaces el valor de salida de la neurona anterior es multiplicado por un valor de peso. Estos pesos en los enlaces pueden incrementar o inhibir el estado de activación de las neuronas adyacentes. Del mismo modo, a la salida de la neurona, puede existir una función limitadora o umbral, que modifica el valor resultado o impone un límite que no se debe sobrepasar antes de propagarse a otra neurona. Esta función se conoce como función de activación.

Estos sistemas aprenden y se forman a sí mismos, en lugar de ser programados de forma explícita, y sobresalen en áreas donde la detección de soluciones o características es difícil de expresar con la programación convencional. Para realizar este aprendizaje automático, normalmente se intenta minimizar una función de pérdida que evalúa la red en su total. Los valores de los pesos de las neuronas se van actualizando, buscando reducir el valor de la función de pérdida. Este proceso se realiza mediante la propagación hacia atrás, que es el algoritmo de aprendizaje (o entrenamiento) clásico para redes neuronales del tipo *feed forward*.

El objetivo de la red neuronal es resolver los problemas de la misma manera que el cerebro humano, aunque las redes neuronales son más abstractas. Las redes neuronales actuales suelen contener desde unos miles a unos pocos millones de unidades neuronales. Las redes neuronales se han utilizado para resolver una amplia variedad de tareas, como la visión por computador y el reconocimiento de voz, que son difíciles de resolver usando la ordinaria programación basado en reglas.

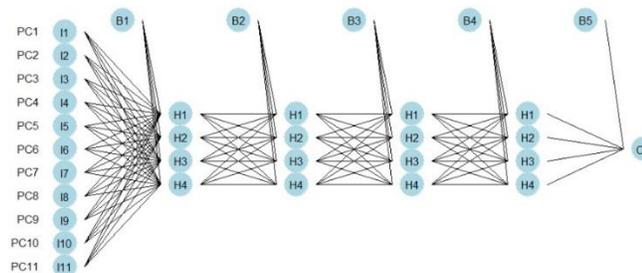


Figura 4.2 – Red neuronal [19]

En este proyecto se utilizó la arquitectura de perceptrones multicapa *feed-forward* de una sola capa oculta. Sin embargo, las redes neuronales pueden tener varias capas de neuronas (ver Figura 4.2.), que se encuentran conectadas a todas las celdas de la siguiente capa, y cuenta por lo menos con una capa oculta.

El entrenamiento de la red se ejecuta hacia atrás con el fin de reducir el error.

Si tomamos como referencia el perceptrón mostrado en la Figura 1.5, podemos explicar el proceso de predicción de la red. La función de propagación se encarga de transformar las diferentes entradas que provienen de la sinapsis en el potencial de la neurona. Normalmente se usa como función de propagación la suma ponderada de las entradas ( $x_1, x_2, x_3, \dots, x_i$ ) multiplicadas por los pesos ( $w_1, w_2, w_3, \dots, w_i$ ). En esta función se interpreta como un regulador de las señales que se emiten entre neuronas al ponderar las salidas que entran a la neurona.

Función de propagación:

$$v_k = \sum_{i=1}^n w_{ik} * x_i + b \quad (7)$$

Donde  $v_k$  es la suma que recibe la k-ésima neurona de la capa precedente,  $w_{ik}$  es el peso asignado por la k-ésima neurona al vínculo formado con la i-ésima neurona,  $x_i$  es el valor de entrada que la i-ésima neurona transmite (si la capa precedente es la capa de entrada de la red,  $x_i$  es una observación de la i-ésima variable exploratoria del problema), y b es un valor ajustado.

### 4.2.3. Índices estadísticos empleados en la validación de los modelos

La medición del rendimiento de las redes se realizó calculando los parámetros estadísticos como 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-Sutcliff (E), y el coeficiente de determinación múltiple ( $R^2$ ). La formulación de estos índices se expone en las ecuaciones (8)-(13).

#### **RMSE** – raíz del error cuadrático medio

Compara los valores observados con los valores objetivos y calcula la raíz cuadrada del error residual promedio, señalando el error en las unidades del componente de interés. El valor óptimo es cero, lo que indica que el ajuste es perfecto. Es una de las estadísticas de índice más utilizadas [27].

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

**MAE** – Error medio en valor absoluto

Se basa en las diferencias absolutas entre lo medido y lo estimado. Para un sistema predictivo perfecto, donde cero es el valor óptimo [28].

$$MAE = \frac{1}{n} \sum_{i=1}^n |a_i - \hat{a}_i| \quad (9)$$

**RSR** - Desviación estándar de los datos medidos

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 [29].

$$RSR = \frac{RMSE}{\sqrt{\frac{1}{n} \sum_{i=1}^n (a_i - \bar{a}_i)^2}} \quad (10)$$

**E** – Coeficiente de eficiencia o coeficiente de Nash

Mide cuánto de la variabilidad de las observaciones es explicada por la simulación. Si la simulación es perfecta, E=1. Por el contrario, si se intentase ajustar las observaciones con el valor promedio, entonces E=0 [30].

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

**NMBE** - Error de sesgo medio normalizado

Proporciona información sobre el sesgo medio en la estimación de un modelo. Si se tiene un NMBE negativo indica una predicción excesiva y un NMBE positivo indica una predicción insuficiente del modelo [31].

$$NMBE(\%) = \frac{\frac{1}{n} \sum_{i=1}^n (a_i - \hat{a}_i)}{\bar{a}_i} \times 100 \quad (12)$$

**R<sup>2</sup>** – Coeficiente de determinación

Compara la precisión del modelo con la precisión de un modelo de referencia superficial en el que la predicción es la media de todas las muestras. Las estadísticas de (R<sup>2</sup>) dependen de las relaciones lineales entre los valores observados y objetivos y en ocasiones pueden proporcionar resultados sesgados cuando esta relación no es lineal o cuando los valores contienen muchos valores atípicos.

$$R^2 = 1 - \frac{\sum_{i=1}^n (a_i - \hat{a}_i)^2}{\sum_{i=1}^n (\hat{a}_i)^2} \quad (13)$$

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

## 5. Resultados

Se presenta a continuación los resultados de los métodos de la regresión tipo LASSO y la regresión de redes neuronales.

### 5.1. Regresión tipo LASSO

#### 5.1.1. Modelos

Los modelos obtenidos para las variables Y1 y Y2, ajustados mediante el uso de la validación cruzada tipo *k-fold* se observan en la tabla 5.1.

**Tabla 5.1 – Modelos tipo LASSO**

	Modelo			Modelo			Modelo	
Término	$\widehat{Y1}_{LASSO}$	$\widehat{Y2}_{LASSO}$	Término	$\widehat{Y1}_{LASSO}$	$\widehat{Y2}_{LASSO}$	Término	$\widehat{Y1}_{LASSO}$	$\widehat{Y2}_{LASSO}$
Indepen.	12,37376	0,00470	X21			X42		-0,00001
X1			X22		-0,00061	X43		0,00018
X2	0,00416	0,00003	X23	0,23984	-0,00512	X44		
X3		-0,00002	X24	0,28072	0,01141	X45		-0,00937
X4			X25	0,33944	0,00037	X46		-0,00001
X5	0,05136		X26	-0,36882	-2,04005	X47		-0,00393
X6		-0,00009	X27	-0,51163	-0,03139	X48		
X7	89,52223	0,29123	X28	-0,50802	-0,02367	X49	0,28353	
X8	0,03319		X29	0,00007		X50	0,27858	
X9	0,00217	0,00008	X30		0,00013	X51		
X10	0,23490	-0,00226	X31	-0,23688	-0,00799	X52	0,00394	
X11	0,80759	0,01480	X32	0,00007		X53	-0,68309	-0,00046
X12	0,49776	0,00349	X33		0,00009	X54		0,007650
X13	-0,30758	-0,01031	X34			X55		-0,00511
X14	-0,00302	-0,02909	X35		-0,00336	X56		
X15	-0,51386	-0,01573	X36		0,00016	X57	0,00324	-0,00001
X16	0,00009		X37		-0,00001	X58	-0,04091	-0,00010
X17		0,00016	X38			X59	0,02048	-0,00024
X18	-0,78960	-0,02292	X39		-0,00020	X60	-0,010849	
X19	0,00004		X40			$\lambda$	0,010474	0,037238
X20		0,00004	X41	-23,00792				

#### 5.1.2. Evaluación de los modelos LASSO

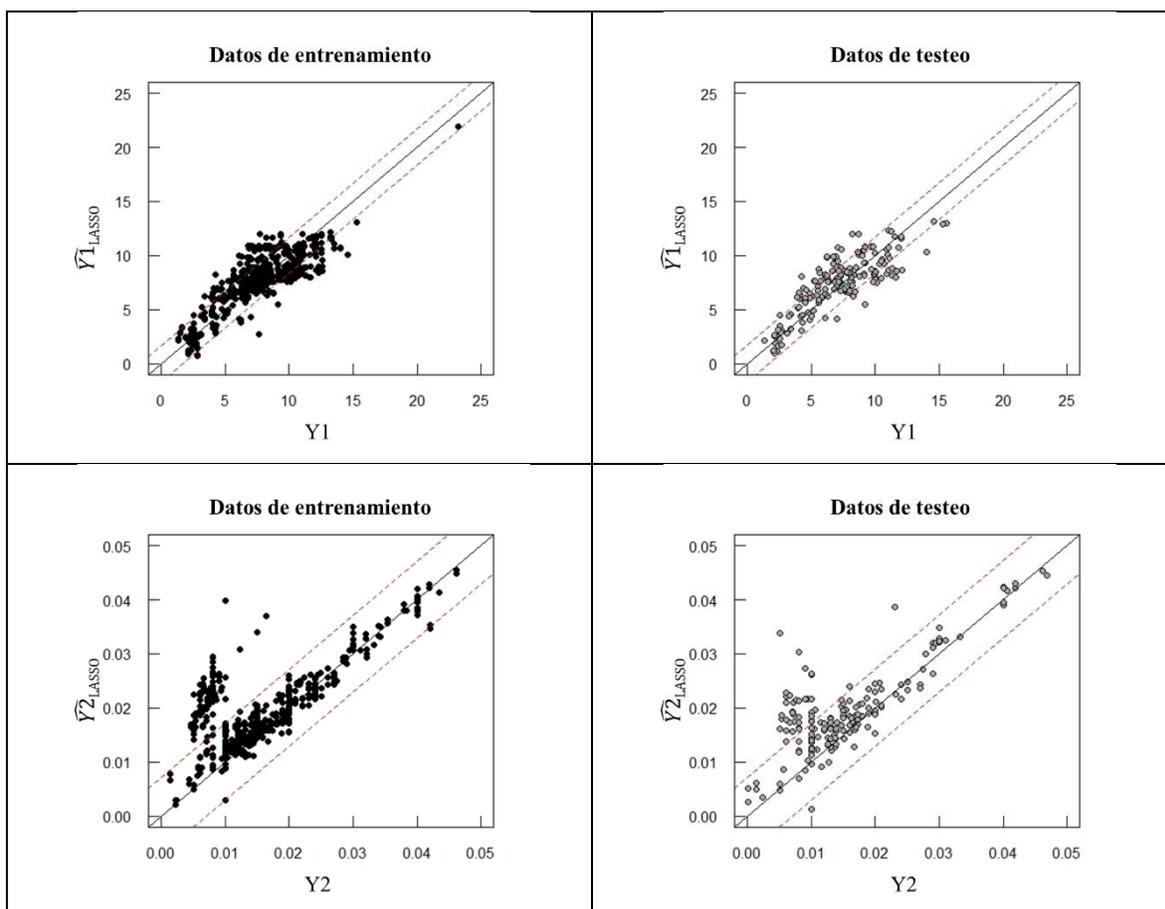
Los valores obtenidos de los parámetros estadísticos utilizados para la evaluación de los modelos tipo LASSO se presentan en la Tabla 5.2.

**Tabla 5.2 – Evaluación de los modelos tipo LASSO**

Modelo	Conjunto	RMSE	MAE	RSR	E	NMBE	R <sup>2</sup>
$\widehat{Y1}_{LASSO}$	Entrenamiento	1,6685	1,3526	0,5774	0,6666	-3,618%	0,6771
	Testeo	1,6811	1,3678	0,5798	0,6638	-4,592%	0,6814
$\widehat{Y2}_{LASSO}$	Entrenamiento	0,0071	0,0045	0,7503	0,4369	-24,877%	0,6146
	Testeo	0,0071	0,0050	0,7514	0,4353	-29,541%	0,6579

Los valores que se obtuvieron de los índices estadísticos de evaluación sobre los subconjuntos de entrenamiento y testeo fueron similares. Esto da a entender que el modelo tipo LASSO tiene un correcto desempeño a la hora de seleccionar las variables, y así mejorar la exactitud e interpretabilidad de los modelos. Los valores Error de sesgo medio normalizado (NMBE) son negativos y esto tiende a que el modelo sobre estima la respuesta. Los modelos de regresión tipo LASSO tienen una precisión aceptable en la predicción de todos los parámetros del comportamiento a tracción directa.

La Figura 5.1 muestra la comparativa entre los valores reales y los predichos por los modelos tipo LASSO para los subconjuntos de entrenamiento y testeo. Las líneas rojas punteadas indican el intervalo del error estándar de la predicción para cada conjunto de datos a ambos lados de la recta principal a 45°.



**Figura 5.1 – Gráficos de valores reales versus predichos por los modelos tipo LASSO.**

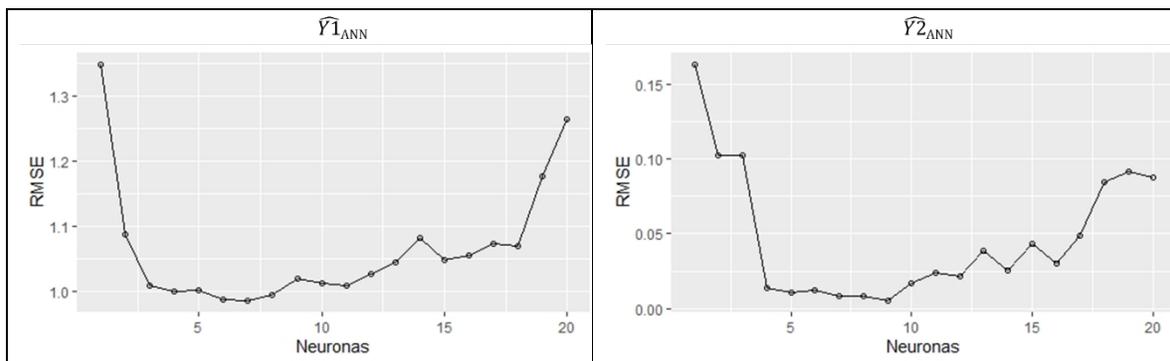
En la gráfica anterior nos muestra como gran parte de los valores reales y los predichos por los modelos tipo LASSO, se encuentran sobre la recta de 45° dentro del intervalo correspondiente al error estándar de la predicción, pero también se encuentra un porcentaje de valores fuera del intervalo del error estándar.

## 5.2. Redes neuronales

### 5.2.1. Modelos

Los modelos de las redes neuronales son computacionales, siendo una de las herramientas matemáticas más precisas para la predicción del comportamiento. Este modelo es una red que aprende examinando los registros individuales, generando una predicción para cada registro y realizados ajustes a las ponderaciones cuando realiza una predicción incorrecta. Este proceso se repite muchas veces y la red sigue mejorando sus predicciones hasta haber alcanzado uno o varios criterios de parada.

En la Figura 5.2. se pueden observar los resultados de la validación cruzada para diferentes números de neuronas en la capa oculta de los diferentes modelos de redes neuronales artificiales.



**Figura 5.2 – Promedio de la raíz del error cuadrático medio (RMSE) versus el número de neuronas en la capa oculta usando validación cruzada tipo k-fold.**

Se determinó el número máximo de neuronas en la capa oculta que son 20. La Figura 5.2, 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*. De acuerdo con este gráfico, el modelo que predice la variable Y1 alcanza el mejor valor RMSE cuando se cuenta con 7 neuronas en la capa oculta, mientras que para la variable Y2 el mejor valor RMSE se obtuvo cuando se cuenta con 9 neuronas en la capa oculta. Por tanto, se seleccionan los modelos presentados en la Figura 5.3.

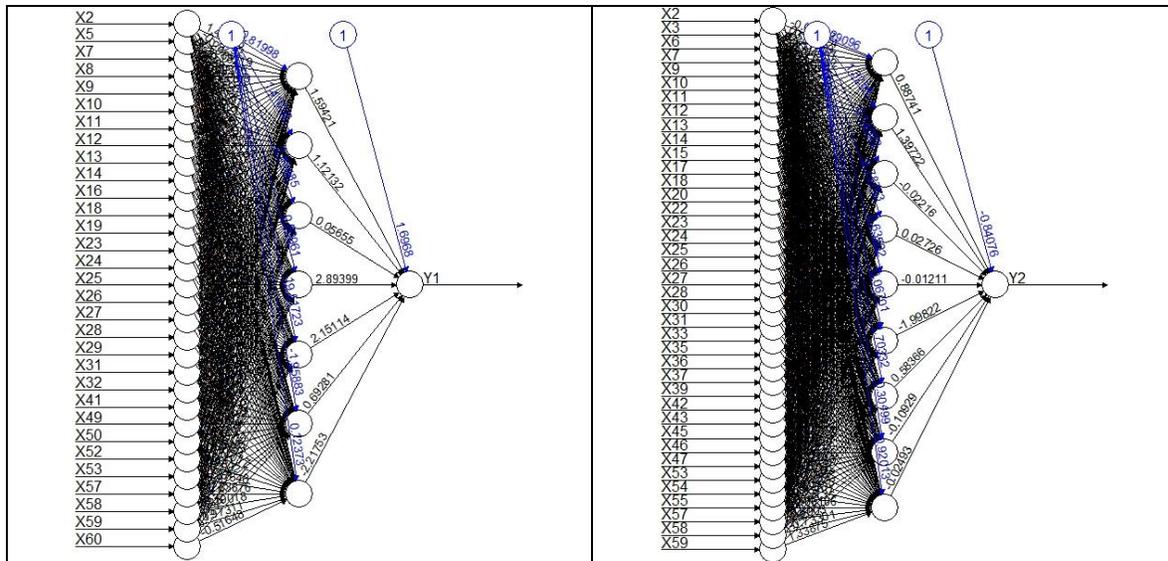


Figura 5.3 – Modelos de redes neuronales considerados.

## 5.2.2. Evaluación de los modelos de redes neuronales

Los valores obtenidos de los parámetros estadísticos utilizados para la evaluación de los modelos de redes neuronales se presentan en la Tabla 5.3.

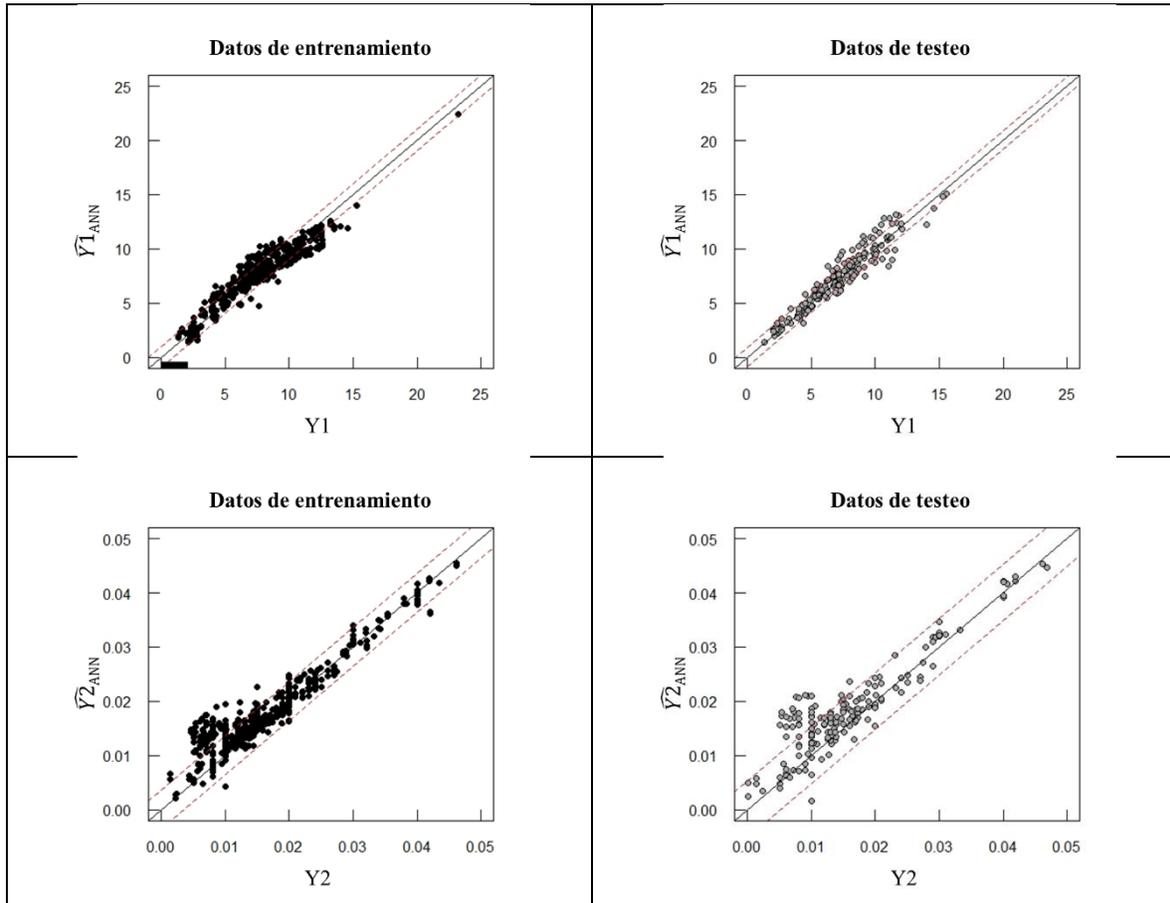
Tabla 5.3 – Evaluación de los modelos de redes neuronales

Modelo	Conjunto	RMSE	MAE	RSR	E	NMBE	R <sup>2</sup>
$\widehat{Y1}_{ANN}$	Entrenamiento	0,9852	0,7987	0,3409	0,8837	-2,136%	0,8908
	Testeo	0,8454	0,6318	0,2916	0,9149	-2,323%	0,9218
$\widehat{Y2}_{ANN}$	Entrenamiento	0,0036	0,0025	0,38256	0,8536	-13,306%	0,9110
	Testeo	0,0051	0,0038	0,5476	0,7001	-20,791	0,8075

Los valores que se obtuvieron de los índices estadísticos de evaluación sobre los subconjuntos de entrenamiento y testeo varían muy poco. Esto da a entender que los modelos de redes neuronales tienen coeficientes de correlación muy parecido a todos los casos y se tiende a acercarse a 1. En la evaluación de los modelos de redes neuronales los valores Error de sesgo medio normalizado (NMBE) son negativos y esto tiende a que el modelo sobre estime las variables respuesta.

La Figura 5.4 muestra la comparativa entre los valores reales y los predichos por los modelos de redes neuronales para los subconjuntos de entrenamiento y testeo. Las

líneas rojas punteadas indican el intervalo del error estándar de la predicción para cada conjunto de datos a ambos lados de la recta principal a 45°.



**Figura 5.4 – Gráficos de valores reales versus predichos por los modelos de redes neuronales.**

En la figura 5.4 nos muestra como la mayoría de los valores reales y los predichos por los modelos de redes neuronales, se encuentran dentro del intervalo correspondiente al error estándar de la predicción, pero también se encuentra un porcentaje pequeño valores fuera del intervalo del error estándar. Como puede observarse, estos gráficos presentan un mayor número de puntos dentro del intervalo marcado por las líneas rojas (error estándar) que los obtenidos para las regresiones tipo LASSO (Figura 5.1).

## 6. Conclusiones

La presente investigación tiene como finalidad analizar los modelos matemáticos sobre la regresión tipo LASSO y redes neuronales, para los concretos UHPFRC para

comportamiento a tracción directa. Pueden extraerse las siguientes conclusiones del presente estudio:

- Los índices matemáticos de la regresión tipo LASSO presentaron un buen comportamiento y alta precisión en la predicción del esfuerzo de fisuración y su elongación asociada del UHPFRC sometido a tracción directa
- Al comparar el modelo de regresión tipo LASSO y el modelo redes neuronales se analiza que las redes neuronales tienen mayores coeficientes de correlación  $R^2$  y se aproximan a 1. Esto nos da a entender que tiene un mayor desempeño debido a su naturaleza no lineal y a su capacidad de iterar las variables independientes, tal como se presenta en la figura 5.3.
- La menor precisión se observa para todos los modelos en la estimación de  $Y_2$  ( $\epsilon_{cc}\%$ ), lo que indica la dificultad en la modelación de la elongación correspondiente a la aparición de la primera fisura.
- Los modelos desarrollados pueden ser de utilizad a la hora de desarrollar nuevas dosificaciones de UHPFRC en aplicaciones donde sea importante determinar la tensión de fisuración y su deformación asociada.

## 7. Recomendaciones

A toda persona que desee realizar un trabajo de investigación relacionado con la predicción de las propiedades del UHPFRC se le realizan la siguiente recomendación:

- Antes de proceder al desarrollo de los modelos predictivos entre la regresión tipo LASSO y redes neuronales. Es necesario hacer el proceso de la normalización de datos que tiene con objeto minimizar o eliminar datos que no se necesitan, elimina la posibilidad de sesgo

## 8. Bibliografía

- [1] Abellan, J., Torres, N., Núñez, A., 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.
- [2] ACI Committe 239, ACI – 239 Committee in Ultra-High Performance Concrete, (2018).
- [3] Abbas, S., Nehdi, M.L., Saleem, M.A., “Ultra-High Performance Concrete: Mechanical Performance, Durability, Sustainability and Implementation Challenges,” *Int. J. Concr. Struct. Mater.* 10 (2016) 271–295. doi:10.1007/s40069-016-0157-4.
- [4] Abellán-García, J., Fernández-Gómez, J., Torres-Castellanos, N., Núñez-López, A., Tensile behavior of normal strength steel fiber green UHPFRC, *ACI Mater. J.* (n.d.).
- [5] Pyo, S., El-Tawil, S., Naaman, A.E., Direct tensile behavior of ultra high performance fiber reinforced concrete (UHP-FRC) at high strain rates, *Cem. Concr. Res.* 88 (2016) 144–156. doi:10.1016/j.cemconres.2016.07.003.
- [6] Abellán-García, J., Nuñez-Lopez, A., Arango-Campo, S., PEDESTRIAN BRIGDE OVER LAS VEGAS AVENUE IN MEDELLÍN . FIRST LATIN AMERICAN INFRASTRUCTURE IN, in: BEFIB 2020, Valencia (Spain), 2020: pp. 24–32.
- [7] Abellán, J., Torres, N., Núñez, A., Fernández, J., CONCRETOS DE MUY ALTAS PRESTACIONES REFORZADOS CON FIBRAS: ESTADO DEL ARTE, APLICACIONES Y POSIBILIDADES EN EL MERCADO LATINOAMERICANO., in: XXXVIII Jornadas Sudam. Ing. Estructural, Lima, 2018. doi:XXXVIIIJSIE-07-001.
- [8] Wille, K., Naaman, A.E., Ultra-high performance concrete and fiber reinforced concrete : achieving strength and ductility without heat curing, (2012) 309–324. doi:10.1617/s11527-011-9767-0.
- [9] Abellán, J., Núñez, A., Arango, S., Pedestrian bridge of UNAL in Manizales : A new UHPFRC application in the Colombian building market, in: Proc. Hipermat 2020 - 5th Int. Symp. UHPC Nanotechnol. Constr. Mater., Kassel, Germany, 2020: pp. 43–44.
- [10] Abellán-García, J., Comparison of artificial intelligence and multivariate regression in modeling the flexural behavior of UHPFRC, *Dyna.* 87 (2020) 239–248. doi:http://doi.org/10.15446/dyna.v87n214.86172.
- [11] Yokota, H., Rokugo, K., Sakata, N., (JSCE-2008) Recommendations for Design and Construction of High Performance Fiber Reinforced Cement Composites with Multiple Fine Cracks (HPFRCC), (2008). doi:http://dx.doi.org/10.1016/j.dci.2010.01.003.
- [12] Martin-Sanz, H., Chatzi, E., Brühwiler, E., The use of Ultra High Performance Fibre Reinforced cement-based Composites in rehabilitation projects: a review, (2016). doi:10.21012/fc9.219.
- [13] Shi, C., Wu, Z., Xiao, J., Wang, D., Huang, Z., Fang, Z., A review on ultra high performance concrete: Part I. Raw materials and mixture design, *Constr. Build.*

- Mater. 101 (2015) 741–751. doi:10.1016/j.conbuildmat.2015.10.088.
- [14] Tagnit-Hamou, A., Soliman, N.A., Omran, A., “Green Ultra - High - Performance Glass Concrete,” First Int. Interact. Symp. UHPC – 2016. 3 (2016) 1–10.
- [15] Friedman, J., Hastie, T., Tibshirani, R., Regularization Paths for Generalized Linear Models via Coordinate Descent, *J. Stat. Softw.* 33 (2010) 1–22. doi:10.1016/j.expneurol.2008.01.011.
- [16] Rosenblatt, F., The Perceptron: A probabilistic model for information storage and organization in the brain, *Cornell Aeronaut. Lab.* 65 (1958) 386–408.
- [17] Abellán, J., Fernández, J., Torres, N., Núñez, A., Statistical optimization of ultra-high-performance glass concrete, *ACI Mater. J.* 117 (2020) 243–254. doi:10.14359/51720292.
- [18] Abellán-García, J., Four-layer perceptron approach for strength prediction of UHPC, *Constr. Build. Mater.* 256 (2020). doi:10.1016/j.conbuildmat.2020.119465.
- [19] Abellán-García, J., Fernández-Gómez, J.A., Torres-Castellanos, N., MACHINE LEARNING PREDICTION OF FLEXURAL BEHAVIOR OF UHPFRC, in: BEFIB 2020, Valencia, Spain, 2020: pp. 1–12.
- [20] Abellán-García, J., Fernández-Gómez, J., Torres-Castellanos, N., Properties prediction of environmentally friendly ultra-high-performance concrete using artificial neural networks, *Eur. J. Environ. Civ. Eng.* 0 (2020) 1–25. doi:10.1080/19648189.2020.1762749.
- [21] Ghafari, E., Bandarabadi, M., Costa, H., Júlio, E., Prediction of Fresh and Hardened State Properties of UHPC: Comparative Study of Statistical Mixture Design and an Artificial Neural Network Model, *J. Mater. Civ. Eng.* 27 (2015) 04015017. doi:10.1061/(ASCE)MT.1943-5533.0001270.
- [22] Atkinson, A., Riani, M., *Robust Diagnostic Regression Analysis*, Springer US, New York, 2000.
- [23] Härdle, W.K., Simar, L., *Applied Multivariate Statistical Analysis*, Springer-Verlag GmbH, Berlin, 2012.
- [24] Everitt, B., Hothorn, T., *MVA: An Introduction to Applied Multivariate Analysis with R*, (2015).
- [25] Günther, F., Fritsch, S., neuralnet: Training of Neural Networks, *R J.* 2 (2010) 30–38. doi:10.1109/SP.2010.25.
- [26] R Core Team, “R: A Language and Environment for Statistical Computing,” Vienna, Austria, 2018. <https://www.r-project.org/>.
- [27] Chandwani, V., Agrawal, V., Nagar, R., Modeling slump of ready mix concrete using genetic algorithms assisted training of Artificial Neural Networks, *Expert Syst. Appl.* 42 (2015) 885–893. doi:10.1016/j.eswa.2014.08.048.
- [28] Aderaw, M., Muse, S., Abiero, Z.C., Artificial neural network based modelling approach for strength prediction of concrete incorporating agricultural and construction wastes, *Constr. Build. Mater.* 190 (2018) 517–525. doi:10.1016/j.conbuildmat.2018.09.097.
- [29] Moriasi, D.N., Arnold, J.G., Liew, M.W. Van, Bingner, R.L., Harmel, R.D., Veith, T.L., MODEL EVALUATION GUIDELINES FOR SYSTEMATIC QUANTIFICATION OF ACCURACY IN WATERSHED SIMULATIONS, *Am. Soc. Agric. Biol. Eng.* 50 (2007) 885–900.

- [30] Nash, E., Sutcliffe, V., RIVER FLOW FORECASTING THROUGH CONCEPTUAL MODELS. PART I- A DISCUSSION OF PRINCIPLES \*, J. Hydrol. 10 (1970) 282–290.
- [31] Srinivasulu, S., Jain, A., A comparative analysis of training methods for artificial neural network rainfall – runoff models, Appl. Soft Comput. 6 (2006) 295–306. doi:10.1016/j.asoc.2005.02.002.