

**Uso de Redes Neuronales en la optimización del proceso de  
diseño de mezclas de concretos reforzados con fibras con alto  
comportamiento de endurecimiento por deformación (HPFRCC)**

**Jairo Alfredo Sánchez Díaz**

**Escuela Colombiana de Ingeniería Julio Garavito  
Decanatura de Ingeniería de Sistemas  
Maestría Gestión de Información  
Bogotá D.C., 8 de julio de 2020**

**Uso de Redes Neuronales en la optimización del proceso de  
diseño de mezclas de concretos reforzados con fibras con alto  
comportamiento de endurecimiento por deformación (HPFRCC)**

**Jairo Alfredo Sánchez Díaz**

**Trabajo de grado para optar al título  
de Magíster en Gestión de Información**

**Director**

**Joaquín Abellán García  
Magíster en Ingeniería ferroviaria**

**Co-directora**

**Victoria Eugenia Ospina Becerra  
PhD en en Redes, Conocimiento y Organizaciones**

**Jurados**

**Ing. Nancy Torres Castellanos  
Ing. Dante Conti Guillén**

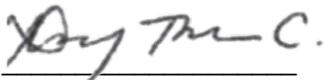
**Escuela Colombiana de Ingeniería Julio Garavito  
Decanatura de Ingeniería de Sistemas  
Maestría Gestión de Información  
Bogotá D.C., 8 de julio de 2020**

© Únicamente se puede usar el contenido de las publicaciones para propósitos de información. No se debe copiar, enviar, recortar, transmitir o redistribuir este material para propósitos comerciales sin la autorización de la Escuela Colombiana de Ingeniería. Cuando se use el material de la Escuela se debe incluir la siguiente nota "Derechos reservados a Escuela Colombiana de Ingeniería" en cualquier copia en un lugar visible. Y el material no se debe notificar sin el permiso de la Escuela.

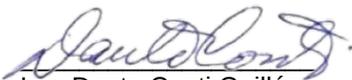
Publicado en \_\_\_\_\_ por la Escuela Colombiana de Ingeniería Julio Garavito. Avenida 13 No 205-59 Bogotá. Colombia  
**TEL: +57 – 1 668 36 00**

## Página de aceptación del jurado

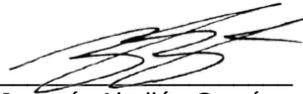
El trabajo de grado de maestría titulado "Uso de Redes Neuronales en la optimización del proceso de diseño de mezclas de concretos reforzados con fibras con alto comportamiento de endurecimiento por deformación (HPFRCC)", presentado por **Jairo Alfredo Sánchez Díaz**, cumple con los requisitos establecidos para optar al título de Magíster en Gestión de información.



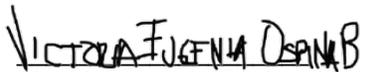
Ing. Nancy Torres Castellanos  
Jurado



Ing. Dante Conti Guillén  
Jurado



Joaquín Abellán García  
Director de trabajo de grado



Victoria Eugenia Ospina Becerra  
Co-directora de trabajo de grado

Bogotá, D.C., \_\_ de \_\_\_\_\_ de \_\_\_\_\_

## Agradecimientos

A Dios, creador de los cielos y la tierra, dueño de la sabiduría, la ciencia y la inteligencia, va dirigido mi agradecimiento principal. Él es quien me provee y me alienta, renueva mis fuerzas en cada nuevo proyecto que inicio y me lleva a lograr los objetivos propuestos conforme a su voluntad. Durante este tiempo, su presencia me mantuvo firme y me animó para no desfallecer. Él tiene un propósito con todos nosotros (Fíate de Jehová de todo tu corazón, Y no te apoyes en tu propia prudencia. Prov. 3:5).

En segundo lugar, debo dar un gran reconocimiento a mi director de trabajo de grado, Joaquín Abellán García, quien me aportó un conocimiento enriquecedor, tiempo, esfuerzo, retroalimentación, consejo, ánimo y humor para concretar los resultados de este trabajo de la mejor manera. Incluyo en este agradecimiento a la doctora Victoria Ospina Becerra co-directora de este, por sus orientaciones para lograr los objetivos de este trabajo en los términos requeridos. También, al personal del laboratorio de sistemas de la Escuela Colombiana de Ingeniería, en especial al ingeniero Gerardo Ospina por su apoyo en la asignación y configuración de los recursos informáticos que requería.

Sin restar importancia, expreso mis mas sinceros agradecimientos a mis padres y mis hermanas, ellos fueron fundamentales en la culminación de este trabajo. La vida académica no se desprende de la personal cuando se está inmerso en la elaboración de trabajos de este tipo, ellos me aportaron todos los días su presencia para que yo contara con disponibilidad y tiempo para dedicarme a elaborar este trabajo de grado y no tener que ocuparme o preocuparme de tareas que hubiesen afectado el logro de este objetivo.

Finalmente, agradezco a mi Jefe, Yoana Marcela Aguirre Torres, Jefe de Control Interno de la Gobernación de Cundinamarca, por facilitarme el tiempo y espacio que necesitaba para realizar este trabajo. A mis compañeras de trabajo, Martha Cecilia Gallego y Jacqueline Fernández Rendón por sus palabras de aliento. También agradezco a mi amiga, Daniela Belén Jarrín por, recordarme lo que significa compromiso y lo que realmente es importante.

## **Resumen**

El Concreto Reforzado con Fibras con Alto Comportamiento de Endurecimiento por Deformación (HPFRCC) se usa en construcciones sismorresistentes donde el alargamiento postfisuración y la capacidad de absorción de energía son propiedades mecánicas relevantes que determinan la calidad de la mezcla. La óptima dosificación de la mezcla se logra generalmente mediante la experimentación en laboratorios de materiales, actividad que resulta costosa ya que los ensayos se hacen en un número limitado de dosificaciones .

Actualmente, existen dosificaciones viables y comprobadas a nivel mundial con componentes que no están disponibles en Colombia y que presentan un alto costo de importación. El uso de materiales nacionales es una alternativa viable, no obstante, se requiere conocer el comportamiento de las propiedades mecánicas del HPFRCC que incluyan materiales del mercado nacional. Por esto, el uso de Redes Neuronales Artificiales (RNA) es una alternativa que permite conocer los posibles resultados de la experimentación con alta precisión y a un costo mucho menor.

El presente estudio plantea diferentes tipos de arquitecturas de RNA, las cuales son entrenadas y evaluadas a fin de identificar el modelo que más se ajusta a los datos. Se seleccionan dos arquitecturas para estimar el alargamiento postfisuración y la capacidad de absorción de energía de dosificaciones de HPFRCC que incluyen fibras disponibles en Colombia y su respectivo costo. Asimismo, se presentan aquellas dosificaciones con mayor probabilidad de éxito en el alargamiento post-fisuración superior al 0,3% y capacidad de absorción de energía superior a 50 kJ/m<sup>3</sup>, al menor coste. De esta manera se contribuye a la toma de decisiones en el desarrollo de HPFRCC con materiales del mercado nacional.

Palabras Clave: Redes Neuronales Artificiales, HPFRCC, Alargamiento postfisuración, Capacidad de absorción de energía.

## **Abstract**

High-Performance Fiber-Reinforced Cementitious Composites (HPFRCC) are used in earthquake resistant constructions where strain hardening and energy absorption capacity are relevant mechanical properties that determine the quality of the mixture. Optimal mixing dosing is usually achieved by experimentation in laboratories, an activity that is a costly as the tests are done with a limited number of dosages.

Currently, there are viable and globally proven dosages with components that are not available in Colombia and have a high import cost. The use of national materials is a viable alternative, however, it is necessary to know the behaviour of the mechanical properties of the HPFRCC that includes materials from the national market. For this reason, the use of Artificial Neural Networks (ANN) is an alternative that provides the possible results of experimentation with high precision at a low cost.

This study proposes different types of ANN architectures, which are trained and evaluated. Two architectures types are selected to estimate the strain hardening and energy absorption capacity of HPFRCC dosages that include fibers available in Colombia and their respective cost. In addition, here are presented dosages with the highest probability of success in strain hardening greater than 0.3% and energy absorption capacity greater than 50 kJ/m<sup>3</sup>, at the lowest cost. In this way, decision-making is contributed for the development of HPFRCC with materials from the national market.

Keywords: Artificial Neural Networks, HPFRCC, Strain Hardening, Energy Absorption Capacity

## Índice General

1. Introducción.....	14
2. Objetivos.....	16
2.1 Objetivo general.....	16
2.2 Objetivos específicos.....	16
2.3 Alcance y limitaciones.....	16
3. Marco teórico y estado del arte de la innovación propuesta.....	18
3.1 Marco teórico.....	18
3.1.1 Concreto reforzado con fibras con alto comportamiento de endurecimiento por deformación –HPFRCC–.....	18
3.1.1.1 Ductilidad del HPFRCC.....	22
3.1.1.2 Resultados experimentales en el Concreto Reforzado con Fibras	24
3.1.2 Inteligencia artificial.....	28
3.1.2.1 Redes Neuronales Artificiales.....	30
3.1.2.1.1 Neurona Artificial.....	31
3.1.2.1.2 Error de Sesgo (bias) y varianza.....	33
3.1.2.1.3 Función de Activación o de Transferencia.....	34
Función de paso (Krenker et al., 2011).....	35
Función Lineal (Ghatak, 2019).....	35
Función logística sigmoidea (Ghatak, 2019).....	35
Función tangente hiperbólica (Ghatak, 2019).....	36
Función lineal rectificada.....	36
3.1.2.1.4 Arquitecturas de RNA.....	37
3.1.2.1.5 Entrenamiento de RNA.....	39
3.1.2.1.5.1 Preparación de datos.....	39
Identificación de datos atípicos o de influencia.....	39
Normalización de datos.....	40
División del conjunto de datos.....	41
3.1.2.1.5.2 Validación cruzada tipo K-Fold.....	41
3.1.2.1.5.3 Hiperparámetros de la RNA.....	42
Algoritmo de aprendizaje (optimizador).....	43
Evaluación del Modelo de RNA.....	44
3.2 Estado del arte.....	46
4 Metodología.....	50
4.1 Construcción del conjunto de datos.....	51
4.2 Arquitecturas de RNA, entrenamiento, validación y selección de modelos..	52
4.3 Identificación de máximos y mínimos.....	53
5. Desarrollo de la metodología, resultados y contribución.....	54
5.1 Diseño, entrenamiento y validación de modelos de RNA.....	54
5.1.1 Análisis del conjunto de datos de dosificaciones.....	54
5.1.1.1 Comportamiento de las variables independientes.....	55

5.1.1.2 Comportamiento de las variables dependientes.....	65
5.1.1.3 Comportamiento de las variables independientes frente al alargamiento post-fisuración (Y1) y la capacidad de absorción de energía (Y2).....	67
5.1.2. Limpieza del conjunto de datos y consolidación de observaciones definitivas.....	79
5.1.2.1 Conjuntos de datos definitivos para alargamiento post-fisuración (Y1) y capacidad de absorción de energía (Y2).....	80
5.1.3 Modelos de RNA para predicción del alargamiento post-fisuración y la capacidad de absorción de energía del HPFRCC.....	89
5.1.3.1 Modelos de RNA para el alargamiento post-fisuración (Y1).....	90
5.1.3.1.1 Modelo de una capa oculta para Y1.....	90
5.1.3.1.2 Modelo de dos capas ocultas para Y1.....	93
5.1.3.1.3 Modelo de tres capas oculta para Y1.....	96
5.1.3.2 Modelos de RNA para la capacidad de absorción de energía (Y2) .....	100
5.1.3.2.1 Modelo de una capa oculta para Y2.....	100
5.1.3.2.2 Modelo de dos capas ocultas para Y2.....	103
5.1.3.2.3 Modelo de tres capas ocultas para Y2.....	106
5.1.3.3 Selección de los mejores modelos para cada variable.....	109
5.1.3.4 Construcción del conjunto de datos de combinaciones.....	113
5.2 Resultados y contribución.....	116
5.2.1 Predicción del alargamiento post-fisuración.....	116
5.2.2 Predicción de la capacidad de absorción de energía.....	117
5.2.3 Identificación de las mezclas optimas HPFRCC – máximos y mínimos. .....	120
6. Conclusiones y recomendaciones.....	123
6.1 Trabajo Futuro.....	123
Referencias.....	125
Abreviaturas.....	132

## Índice de Figuras

Figura 1: Familias de concreto.....	18
Figura 2: Clasificación del concreto reforzado con fibra.....	22
Figura 3: Ablandamiento por tensión.....	23
Figura 4: Endurecimiento por deformación.....	24
Figura 5: Promedio en la proporción de componentes en una mezcla de UHFRC	25
Figura 6: Participación del costo de los componentes en el valor total de una mezcla de UHFRC.....	25
Figura 7: Esquema de configuración de un ensayo de tracción directa.....	26
Figura 8: Ensayos de tracción directa laboratorio de materiales y estructuras de la Escuela Colombiana de Ingeniería.....	27
Figura 9: Evolución inteligencia artificial.....	28
Figura 10: Comparación entre neurona biológica y neurona artificial.....	31
Figura 11: Esquema del funcionamiento de una <i>neurona artificial</i> .....	32
Figura 12: Gráfica de error total de un modelo de RNA. Sesgo y Varianza.....	34
Figura 13: Funciones de activación.....	37
Figura 14: RNA Feed Forward.....	38
Figura 15: Validación cruzada tipo K-fold.....	42
Figura 16: Esquema de transformación de datos de una RNA.....	43
Figura 17: Metodología del estudio.....	50
Figura 18: Comportamiento de las variables X1 a X10 (matriz de concreto).....	57
Figura 19: Comportamiento de las variables X11 y X12 (contenido total de fibra).	59
Figura 20: Cantidad de dosificaciones con fibra 1.....	60
Figura 21: Comportamiento de las variables X19 a X23 (detalles de la fibra 1)....	61
Figura 22: Cantidad de dosificaciones con fibra 2.....	62
Figura 23: Comportamiento de las variables X30 a X34 (detalles de la fibra 2)....	63
Figura 24: Comportamiento de las variables X35 (resistencia a la compresión del concreto).....	65
Figura 25: Distribución de los datos variable de respuesta Y1. Endurecimiento por deformación.....	66
Figura 26: Distribución de los datos variable de respuesta Y2. Capacidad de absorción de energía.....	67
Figura 27: Variables X de la matriz de concreto frente frente a Y1.....	69
Figura 28: Variables X de la matriz de concreto frente frente a Y2.....	70
Figura 29: Comportamiento de Y1 y Y2 según la cantidad de fibras incluidas en la mezcla.....	72
Figura 30: Comportamiento de Y1 y Y2 según las combinaciones de fibra en cada dosificación.....	73
Figura 31: Variables (X19 a X23) de las propiedades de la fibra 1 frente a Y1.....	74
Figura 32: Variables (X19 a X23) de las propiedades de la fibra 1 frente a Y2.....	75
Figura 33: Variables (X30 a X34) de las propiedades de la fibra 2 frente a Y1.....	76

Figura 34: Variables (X30 a X34) de las propiedades de la fibra 2 frente a Y2.....	77
Figura 35: Resistencia a la compresión del concreto (X35) frente a Y1 y Y2.....	78
Figura 36: Distribución de las variables Y1 y Y2 posterior a la limpieza de datos..	79
Figura 37: Variables X de la matriz de concreto frente frente a Y1 posterior a la limpieza de datos.....	81
Figura 38: Variables X de la matriz de concreto frente frente a Y2 posterior a la limpieza de datos.....	82
Figura 39: Comportamiento de Y1 y Y2 según cantidad de fibras posterior a la limpieza de datos.....	83
Figura 40: Comportamiento de Y1 y Y2 según combinaciones de fibra posterior a la limpieza de datos.....	84
Figura 41: Variables (X19 a X23) propiedades fibra 1 frente a Y1 posterior a limpieza de datos.....	85
Figura 42: Variables (X19 a X23) propiedades fibra 1 frente a Y2 posterior a limpieza de datos.....	86
Figura 43: Variables (X30 a X34) propiedades fibra 2 frente a Y1 posterior a limpieza de datos.....	87
Figura 44: Variables (X30 a X34). Propiedades fibra 2 frente a Y2 posterior a la limpieza de datos.....	87
Figura 45: Resistencia a la compresión concreto (X35) frente Y1 y Y2 posterior a limpieza de datos.....	88
Figura 46: Validación cruzada k-fold para Y1 en RNA de 1 capa oculta.....	91
Figura 47: Validación cruzada k-fold para Y1 en RNA de 1 capa oculta 3D.....	92
Figura 48: Validación de RNA de 1 capa oculta con 63 neuronas para Y1.....	92
Figura 49: Validación de RNA de 1 capa oculta con 63 neuronas para Y1 3D.....	93
Figura 50: Validación cruzada k-fold para Y1 en RNA de 2 capas ocultas.....	94
Figura 51: Validación cruzada k-fold para Y1 en RNA de 2 capas ocultas 3D.....	95
Figura 52: Validación de RNA de 2 capas ocultas con 63 y 24 neuronas para Y1.....	95
Figura 53: Validación RNA de 2 capas ocultas con 63 y 24 neuronas para Y1 3D.....	96
Figura 54: Validación cruzada k-fold para Y1 en RNA de 3 capas ocultas.....	97
Figura 55: Validación cruzada k-fold para Y1 en RNA de 3 capas ocultas 3D.....	98
Figura 56: Validación RNA 3 capas ocultas con 63, 24 y 52 neuronas para Y1.....	98
Figura 57: Validación RNA 3 capas ocultas con 63, 24 y 52 neuronas para Y1 3D .....	99
Figura 58: Validación cruzada k-fold para Y2 en RNA de 1 capa oculta.....	100
Figura 59: Validación cruzada k-fold para Y2 en RNA de 1 capa oculta 3D.....	101
Figura 60: Validación de RNA de 1 capa oculta con 67 neuronas para Y2.....	102
Figura 61: Validación de RNA de 1 capa oculta con 67 neuronas para Y2 3D....	102
Figura 62: Validación cruzada k-fold para Y2 en RNA de 2 capas ocultas.....	103
Figura 63: Validación cruzada k-fold para Y2 en RNA de 2 capas ocultas 3D.....	104
Figura 64: Validación de RNA de 2 capas ocultas con 67 y 54 neuronas para Y2. .....	105

Figura 65: Validación RNA de 2 capas ocultas con 67 y 54 neuronas para Y2 3D	105
Figura 66: Validación cruzada k-fold para Y2 en RNA de tres capas ocultas.....	106
Figura 67: Validación cruzada k-fold para Y2 en RNA de 3 capas ocultas 3D.....	107
Figura 68: Validación RNA de 3 capas ocultas con 67, 54 y 57 neuronas para Y2	108
Figura 69: Validación RNA 3 capas ocultas con 67, 54 y 57 neuronas para Y2 3D	109
Figura 70: Curvas suavizadas para RMSE de los modelos de RNA para Y1.....	111
Figura 71: Curvas suavizadas para RMSE de los modelos de RNA para Y2.....	112
Figura 72: Evaluación de entrenamiento de RNA para Y1 con MAE.....	112
Figura 73: Evaluación de entrenamiento de RNA para Y2 con MAE.....	113
Figura 74: Distribución de costes de mezclas de las combinaciones.....	115
Figura 75: Histograma de estimación del alargamiento post-fisuración.....	116
Figura 76: Combinaciones de fibra frente a la respuesta estimada en Y1.....	117
Figura 77: Histograma de estimación de la capacidad de absorción de energía.	118
Figura 78: Combinaciones de fibra frente a la respuesta estimada en Y2.....	119
Figura 79: Distribución costes mezclas de combinaciones con respuesta Y1 y Y2	120
Figura 80: Combinaciones de fibra frente a la respuesta estimada en Y1 y Y2...	121

## Índice de Tablas

Tabla 1: Componentes de la matriz de concreto.....	19
Tabla 2: Fibras de reforzamiento de concreto (metálica o sintética).....	20
Tabla 3: Variables incluidas en la base de datos.....	54
Tabla 4: Resumen de resultados de entrenamiento de RNA para Y1.....	109
Tabla 5: Resumen de resultados de entrenamiento de RNA para Y2.....	110
Tabla 6: Fibras en las dosificaciones de combinaciones de HPFRCC y Coste.....	113
Tabla 7: Matriz de cemento definida para el listado de combinaciones de HPFRCC .....	114
Tabla 8: Resultados optimización multiobjetivo.....	122

# 1. Introducción

El presente estudio se centra en la aplicación de las Redes Neuronales Artificiales (RNA) como herramienta para el aprovechamiento de la información de la dosificación y las propiedades del Concreto Reforzado con Fibras con Alto Comportamiento de Endurecimiento por Deformación (HPFRCC por sus siglas en inglés), con el fin de entender y conocer su comportamiento en función de los materiales que lo componen; en especial, las fibras que incluyen y el impacto de estas en las propiedades mecánicas que lo caracterizan. Asimismo, presenta resultados que pueden orientar la toma de decisiones en el desarrollo, viable económicamente, de este material para su aplicación en el reforzamiento de estructuras sismorresistentes.

Así pues, se lleva a cabo la evaluación de tres tipos de arquitecturas de RNA, seleccionando aquellas que presentan el mejor desempeño para estimar el alargamiento postfisuración y la capacidad de absorción de energía de dosificaciones de HPFRCC, en probetas sometidas a ensayos de tracción directa, que incluyan fibras disponibles en el mercado nacional. Las estimaciones realizadas se evalúan económicamente para seleccionar aquellas dosificaciones con mayor probabilidad de éxito en el alargamiento postfisuración superior al 0,3% y a la capacidad de absorción de energía superior a  $50\text{kJ/m}^3$ , al menor coste.

Inicialmente, el estudio reúne los datos, obtenidos de la literatura científica, de dosificaciones de Concretos Reforzados con Fibra con Alto Comportamiento de Endurecimiento por Deformación, los cuales incluyen los resultados del alargamiento postfisuración y de la capacidad de absorción de energía. Los datos son analizados y tratados con el fin de obtener un conjunto de datos confiable que garantice un adecuado entrenamiento de los modelos de RNA propuestos.

Posteriormente, se definen tres tipos de arquitecturas de RNA para cada propiedad mecánica del HPFRCC en estudio, modificando la cantidad de capas ocultas y neuronas en cada capa. Las RNA se entrenan con el conjunto de datos obtenidos de la literatura científica, luego se evalúan con los resultados de las funciones de pérdida MSE (Error Cuadrático Medio) y RMSE (Raíz Cuadrada del Error Cuadrático Medio) y, por último, se seleccionan dos arquitecturas, una por cada propiedad mecánica estudiada, que presentan el mínimo error en la validación del entrenamiento.

Finalmente, se construye un conjunto de datos de 4592 dosificaciones de HPFRCC con una matriz de concreto fija, modificando la cantidad y el tipo de fibra adicionada a la mezcla. Las fibras se varían en su contenido en volumen entre 0 y

5% con un máximo de dos tipos de fibras por cada dosificación. Siete tipos de fibras disponibles en el mercado nacional: cuatro metálicas y tres sintéticas son planteadas en el conjunto de dosificaciones. Seguido a esto, se estiman el alargamiento postfisuración y la capacidad de absorción de energía de estas dosificaciones y se calcula el coste de la fibra. Una vez desarrollados los modelos, mediante identificación de mínimos y máximos, se seleccionan aquellas mezclas con mayor probabilidad de éxito para las propiedades mecánicas estudiadas, al menor coste posible, las cuales se presentan como resultado del estudio.

En el capítulo 2 de este documento se plantean los objetivos del presente estudio y se mencionan los alcances y limitaciones del mismo. El capítulo 3 contempla el marco teórico y el estado del arte, se incluye una breve explicación del HPFRCC y de redes neuronales artificiales; también se presenta el estado de desarrollo del HPFRCC así como la aplicación de RNA en la ingeniería civil. El capítulo 4 describe la metodología utilizada en el estudio. Finalmente, el capítulo 5 presenta el desarrollo de la metodología, los resultados de las estimaciones de los modelos de RNA y la selección de las mezclas con mayor probabilidad de éxito.

## **2. Objetivos**

### **2.1 Objetivo general**

Identificar mediante modelos de redes neuronales artificiales e identificación de máximos y mínimos, las dosificaciones de fibras accesibles en el mercado colombiano de mayor probabilidad de éxito bajo criterios de alargamiento post-fisuración superior a 0.3%, capacidad de absorción de energía superior a 50 kJ/m<sup>3</sup> y menor coste posible.

### **2.2 Objetivos específicos**

- Identificar los tipos de redes neuronales (feed-forward, Deep feed-forward) y las arquitecturas (número de neuronas, número de capas ocultas), así como las funciones de activación y algoritmos de aprendizaje más adecuadas para optimizar el diseño de mezclas de HPFRCC.
- Establecer los resultados de simulaciones de comportamiento con matrices cementantes producidas con materiales y fibras accesibles en el mercado local.
- Determinar los costes de las mezclas de concreto simuladas con los precios del mercado local

### **2.3 Alcance y limitaciones**

El estudio tiene como alcance máximo la identificación de las dosificaciones de HPFRCC con el mejor comportamiento de las propiedades mecánicas evaluadas y al menor coste posible. El estudio no llegará a la comprobación experimental de las mezclas con mayor probabilidad de éxito. Adicionalmente, el estudio no incluye otro tipo de arquitecturas de redes neuronales diferentes a las mencionadas, dadas las limitaciones en recursos tecnológicos y tiempo necesarios para la obtención y el procesamiento de datos.

Sumado a lo anterior, los resultados de los modelos seleccionados no se validan con datos experimentales adicionales que debían ser suministrados por el laboratorio de materiales de la Escuela Colombiana de Ingeniería. Esto, dado a

que la situación actual respecto a las restricciones de movilidad y ordenes de confinamiento en el país no hacen posible llevar a cabo los ensayos experimentales. Como resultado, no es posible presentar el nivel de aplicabilidad de los modelos de RNA en el desarrollo de HPFRCC para la industria de la construcción.

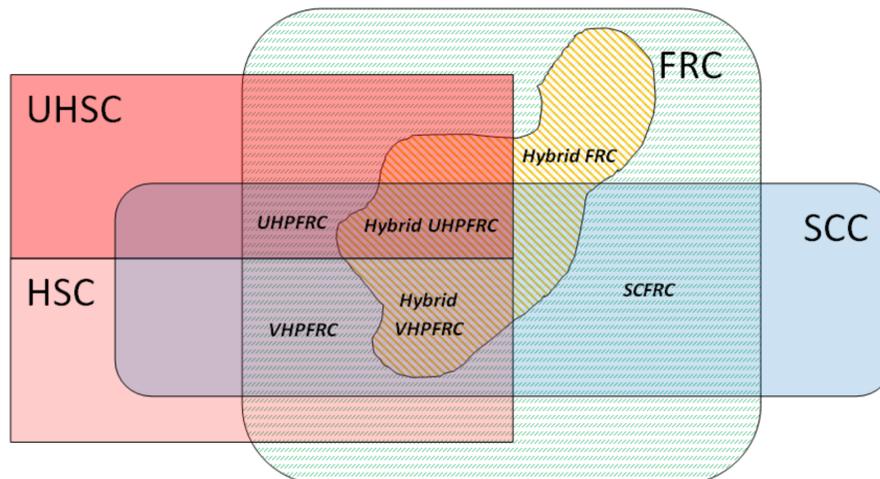
### 3. Marco teórico y estado del arte de la innovación propuesta

#### 3.1 Marco teórico

##### 3.1.1 Concreto reforzado con fibras con alto comportamiento de endurecimiento por deformación –HPFRCC–

El concreto es uno de los materiales más esenciales en las construcciones civiles. El avance constante de la ciencia y la tecnología ha permitido el desarrollo de concretos especiales como los concretos de altas prestaciones (Abellán García et al., 2020). Estos concretos de *altas prestaciones podrían* clasificarse en diferentes familias (Serna Ros et al., 2012), (ver Figura 1) as cuales se caracterizan por propiedades mecánicas específicas buscadas según la aplicación que se les requiera. Una de estas familias incluye al HPFRCC, que tiene características específicas de ductilidad o capacidad para soportar esfuerzos de tracción mediante una respuesta de endurecimiento por deformación. En este tipo de concretos especiales, el alargamiento postfisuración y la capacidad de absorción de energía son las propiedades mecánicas relevantes que determinan su éxito en el mejoramiento sísmico de estructuras existentes y, en general, en estructuras que requieren de alta resistencia, ductilidad y durabilidad. Algunas de sus aplicaciones incluyen la reparación y fortalecimiento de estructuras, puentes, entre otros (Tayeh et al., 2019).

Figura 1: Familias de concreto



Fuente: (Serna Ros et al., 2012)

El HPFRCC es una mezcla de dos partes principales 1) la matriz de concreto y 2) la fibra (metálica o sintética).

La matriz de concreto (cementitious matrix) del HPFRCC se compone habitualmente de cemento, humo de sílice (microsilice o microsilica), harina de cuarzo (polvo de cuarzo o filler de cuarzo molido), arena silícea, agua y superplastificante reductor de agua de alto rango (HRWR por sus siglas en inglés), desarrollado a partir de éter de policarboxilato. Debido a restricciones de costos y medioambientales, estas mezclas pueden incluir materiales cementantes suplementarios para sustituir parcialmente el cemento y el humo sílice, tales como ceniza volante (fly ash), ceniza de cascara de arroz, escoria siderúrgica, polvo de carbonato de calcio, polvo de vidrio reciclado, entre otros (ver Tabla 1).

*Tabla 1: Componentes de la matriz de concreto*



Cemento



Humo de Sílice



Arena Silícea



Carbonato de calcio



Escoria Alto Horno



Escoria Arco Eléctrico



Polvo de Vidrio



Metacaolín



FCC



#### Ceniza Volante

*Fuente: (Abellán García et al., 2020; Abellán, Torres, Núñez, et al., 2018)*

El abanico disponible en el mercado para fibras de refuerzo es muy amplio e incluye tanto fibras metálicas como sintéticas, por ejemplo, de acero acabada en ganchos (H), acero retorcido (T), nylon, polipropileno (PP), polietileno de alta densidad (PE), polivinilo alcohol (PVA), entre otras. La incorporación de estas fibras en una dosificación específica (en volumen de la mezcla) modifican la ductilidad del material (ver Tabla 2).

*Tabla 2: Fibras de reforzamiento de concreto (metálica o sintética)*



Micro acero corta



Micro acero larga



Ganchos acero pequeña



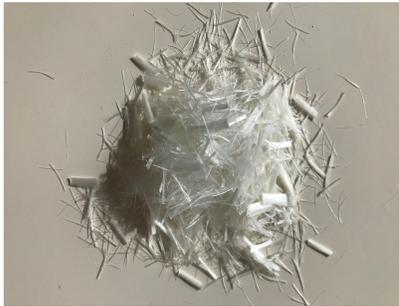
Ganchos acero grande



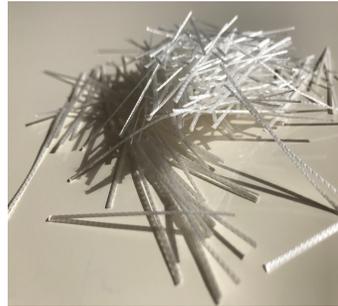
Retorcida acero



Nylon (nacional)



Polivinilo de alcohol (PVA)



Polipropileno (PP)



Polietileno (PE)

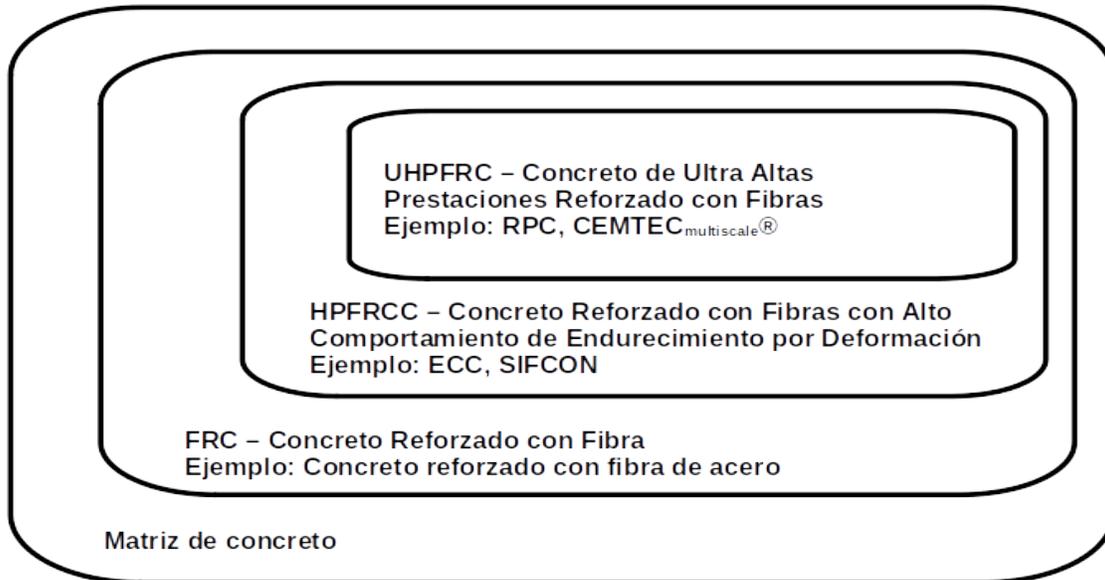
---

Fuente: (Abellán, 2020)

El concreto reforzado con fibra (FRC), al igual que el concreto de alta resistencia (HSC), ha tenido un gran avance en los últimos años reduciendo cada vez más la porosidad y alcanzando bajos niveles de permeabilidad, debido al empleo de modelos de empaquetamiento de partículas para su diseño (de Larrard & Sedran, 2002; De Larrard & Sedran, 1994; Funk & Dinger, 1994). Este elevado empaquetamiento de partículas es el responsable de las características de la matriz cementante de los HPFRCC, que además proporciona una mayor adherencia con la fibra.

En resumen, los concretos especiales reforzados con fibra han sido desarrollados (ver Figura 2) para alcanzar alta resistencia y durabilidad. No obstante, este material no es comúnmente usado en las estructuras debido al desconocimiento por parte de la industria, a la ausencia de códigos locales de diseño y a la carencia de una relación adecuada costo-diseño para su aplicación comercial (Tayeh et al., 2019).

Figura 2: Clasificación del concreto reforzado con fibra



Fuente: (Tayeh et al., 2019)

### 3.1.1.1 Ductilidad del HPFRCC

La ductilidad del HPFRCC se mide mediante el ensayo de tracción directa. Cuando el HPFRCC es sometido a tensión (tracción directa) se mide la fuerza aplicada y la elongación del material (ductilidad). En la medición de estos parámetros se toman dos puntos principales:

A) El límite de elasticidad (de la región elástica): está definido por la tensión de fisuración, que es el punto de fuerza de tensión al momento de presentarse la primera fisura y se conoce como  $\sigma_{cc}$ . La elongación correspondiente a este punto es identificada como  $\epsilon_{cc}$ . El cambio físico que sufre el material desde el inicio de la aplicación de la fuerza de tensión hasta este punto puede denominarse pendiente de elasticidad. De aquí en adelante, el material entra en endurecimiento por deformación, el concreto experimenta múltiple fisuración sin perder su capacidad de resistencia de la fuerza de tensión.

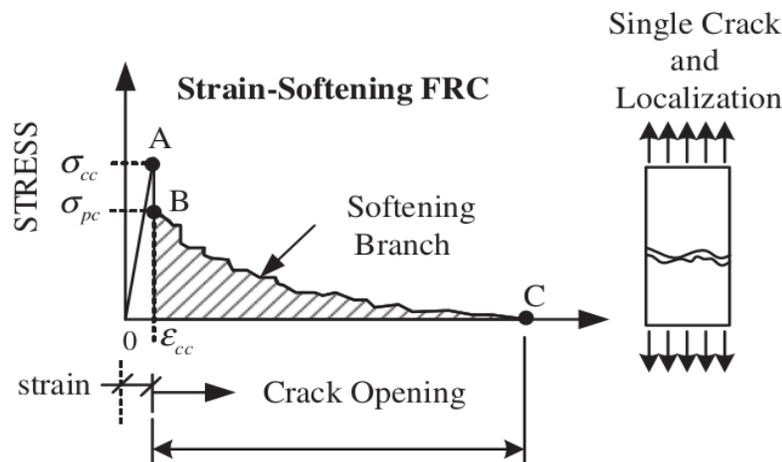
B) El límite del endurecimiento por deformación: es el punto de fuerza de tensión al momento de falla del material, es decir, cuando el material cede a la tensión aplicada y la capacidad para resistir la fuerza de tensión se pierde (apertura de la fisura). El esfuerzo máximo resistido por el material se identifica como  $\sigma_{pc}$  y la elongación alcanzada en este punto se conoce como  $\epsilon_{pc}$ : alargamiento postfisuración. Desde este punto hasta que se produce la falla el material entra en ablandamiento por deformación.

El esfuerzo de tensión generalmente se mide en Megapascales (MPa). La elongación o alargamiento unitario del material se mide en porcentaje, esto es, el porcentaje de aumento de la distancia (en la misma dirección de la fuerza aplicada), con respecto a la inicial, entre los dos puntos desde donde es aplicada la fuerza.

Para que se presente ductilidad (endurecimiento por deformación) la fuerza  $\sigma_{pc}$  debe ser obligatoriamente mayor o igual a la fuerza  $\sigma_{cc}$  ( $\sigma_{pc}/\sigma_{cc} \geq 1$ ) (Park et al., 2012). Para el HPFRCC, esta condición física se presenta en todos los casos, a diferencia de los concretos no reforzados con fibra (HSC, UHSC, UHPC, entre otros) para los cuales no se observa  $\sigma_{pc}$ .

La Figura 3 representa el comportamiento del concreto no reforzado con fibras cuando es sometido a fuerzas de tracción directa. Este no presenta endurecimiento por deformación. El material pasa de la pendiente de elasticidad a la apertura de la fisura directamente. La fibra que se adiciona a la matriz de concreto evita que esto suceda, es decir, le da ductilidad al material.

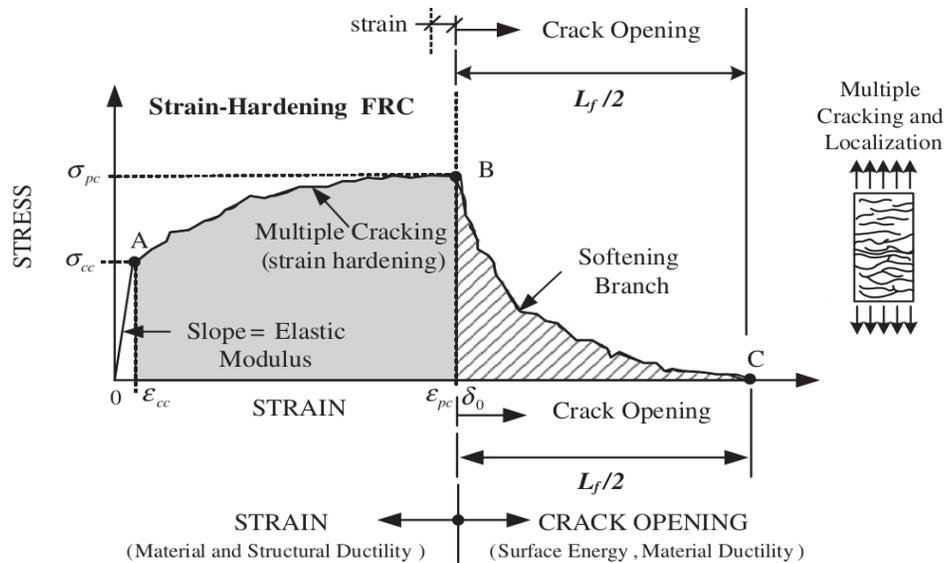
Figura 3: Ablandamiento por tensión



Fuente: (Park et al., 2012)

La Figura 4 presenta al HPFRCC y su comportamiento cuando se somete a esfuerzo de tracción directa. Este tipo de compuesto presenta el endurecimiento por deformación dado el alargamiento postfisuración. La adición de la fibra le da la capacidad de absorción de energía (área color gris bajo la curva de endurecimiento por deformación) que le permite soportar una fuerza mayor a la presentada en la primera fisuración. El punto de fuerza  $\sigma_{pc}$  es mayor a  $\sigma_{cc}$ .

Figura 4: Endurecimiento por deformación



Fuente: (Park et al., 2012)

### 3.1.1.2 Resultados experimentales en el Concreto Reforzado con Fibras

Como ya se mencionó, el uso de los Concretos Reforzados con Fibra depende directamente de una dosificación adecuada que maximice sus propiedades y de un costo de producción comercialmente viable. Es por esto que se debe considerar el coste final de la mezcla en referencia al costo de los materiales de la matriz de concreto y la fibra (metálica y/o sintética), de tal forma que el valor de la producción del concreto sea bajo y con un adecuado comportamiento mecánico que lo haga atractivo para la comercialización. Esto quiere decir, que se debe obtener un equilibrio entre las propiedades mecánicas del compuesto y el costo de su producción.

En teoría, una mayor cantidad de volumen de fibra en la mezcla de HPFRCC se traduce en un mejoramiento del endurecimiento por deformación. Sin embargo, el impacto en el costo de la mezcla es considerablemente alto dada la participación del costo de la fibra en el coste total de la mezcla (Abellán, Torres, & Núñez, 2018)

En las mezclas más comunes de HPFRCC y Concreto de Ultra Altas Prestaciones Reforzado con Fibras (UHPFRC), que se observan en la literatura científica, el porcentaje (en volumen) de fibra está entre el 1 y el 3%, siendo la fibra metálica la de mayor uso en una proporción del 2% en promedio (ver Figura 5). Adicionalmente, el 2% de fibra es la proporción identificada de mejor beneficio

económico (Tayeh et al., 2019). Cabe resaltar que los precios de las fibras, así como la calidad de estas, varían de un país a otro. Actualmente, no existe literatura científica que ofrezca información en términos económicos y de propiedades mecánicas del HPFRCC que permitan identificar la proporción de componentes de mezcla que optimice los resultados esperados para el caso de Colombia.

Figura 5: Promedio en la proporción de componentes en una mezcla de UHFRC



Fuente: (Abellán, Torres, & Núñez, 2018)

En el estudio realizado por Abellán et al. (2018), se utilizaron 128 datos y se promediaron las proporciones de componentes para una mezcla de UHPFRC: el 2% en volumen de fibra metálica en el total de la composición del material tiene una representación del 37% en el coste total del UHPFRC (ver Figura 6), estos datos reflejan el nivel de importancia que tiene la fibra en el coste total de la mezcla.

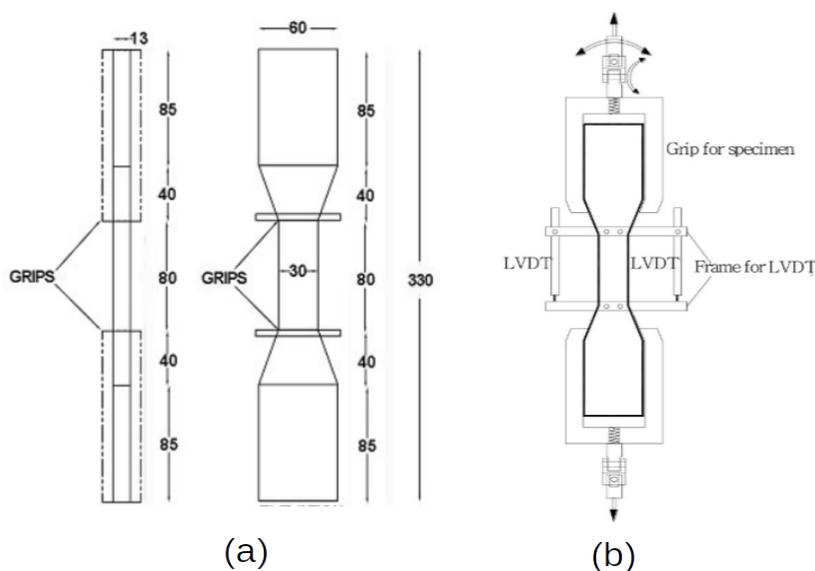
Figura 6: Participación del costo de los componentes en el valor total de una mezcla de UHFRC.



Fuente: (Abellán, Torres, & Núñez, 2018)

Mediante la experimentación se puede obtener la óptima dosificación de componentes que maximice las propiedades mecánicas relevantes, al tiempo que se reduce el coste total de la mezcla. Esta es una actividad costosa que requiere materiales, tiempo, uso de laboratorios, etcétera (Demir, 2008); lo cual limita la cantidad de mezclas de HPFRCC que se pueden realizar para obtener resultados del comportamiento mecánico. Así, la información obtenida también es limitada y resulta insuficiente para entender el comportamiento del HPFRCC, es decir, la influencia de los componentes y la variación del costo según la modificación de la dosificación de los componentes. La Figura 7 muestra un esquema de la configuración del ensayo a tracción: las medidas típicas de un espécimen para realizar el ensayo y la aplicación de la fuerza al mismo, según las recomendaciones de la Sociedad Japonesa de Ingeniería Civil (JSCE-08), Adicionalmente, la Figura 8 muestra imágenes tomadas del laboratorio de materiales y estructuras de la Escuela Colombiana de Ingeniería de los ensayos realizados para mezclas de HPFRCC: los especímenes fabricados, la prueba de fuerza de tensión aplicada y los especímenes con multifisuración.

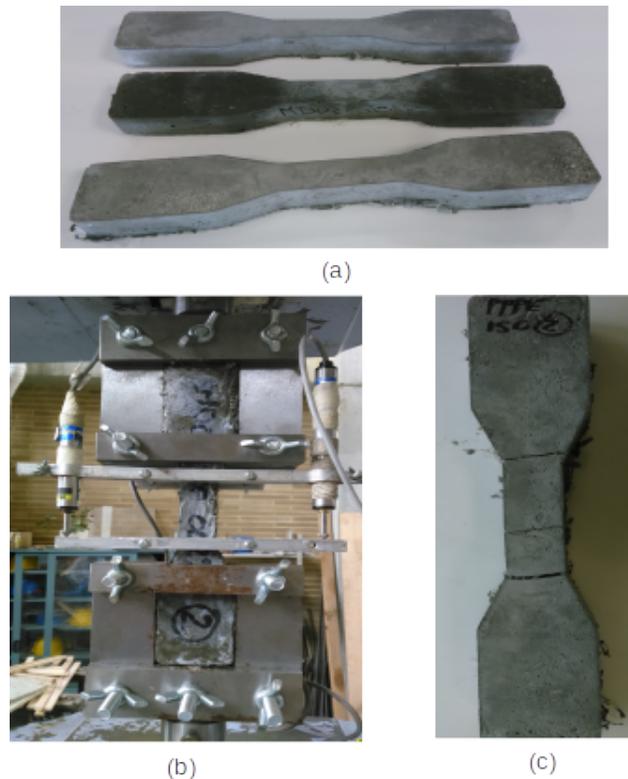
*Figura 7: Esquema de configuración de un ensayo de tracción directa.*



*(a) Dimensiones de un espécimen hueso de perro conforme a la recomendación de la JSCE, (b) Ensayo de tracción.*

*Fuente: (Li et al., 2019; SRIDHAR & PRASAD, 2019)*

*Figura 8: Ensayos de tracción directa laboratorio de materiales y estructuras de la Escuela Colombiana de Ingeniería.*



*(a) especímenes para ensayo. (b) ensayo de tracción directa. (c) estado del espécimen posterior al ensayo (multifisuración del concreto) .*

*Fuente: laboratorio de materiales y estructuras de la Escuela Colombiana de Ingeniería.*

La ductilidad es la propiedad más importante para poder utilizar un material como refuerzo en aplicaciones sismorresistentes (Chao et al., 2016; Khan et al., 2018; Massicotte et al., 2013). De acuerdo con (Wille et al., 2014), las mezclas de concretos HPFRCC pueden clasificarse como muy dúctiles cuando la energía absorbida medida en el ensayo de tracción directa es superior a los 50 kJ/m<sup>3</sup>. Por otra parte, de acuerdo a las investigaciones de (Wille et al., 2014), si el compuesto es capaz de alcanzar una elongación máxima postfisuración ( $\epsilon_{pc}$ ) igual o superior al 0.3%, aseguraría que el material de refuerzo sería capaz de resistir más allá de la elongación del acero de refuerzo en fluencia ( $\epsilon_{fy}=0.21\%$ ). Esto último es requisito indispensable para las aplicaciones de HPFRCC con concreto convencional, como es el caso del reforzamiento sísmico (Massicotte et al., 2013; Wille et al., 2011, 2014).

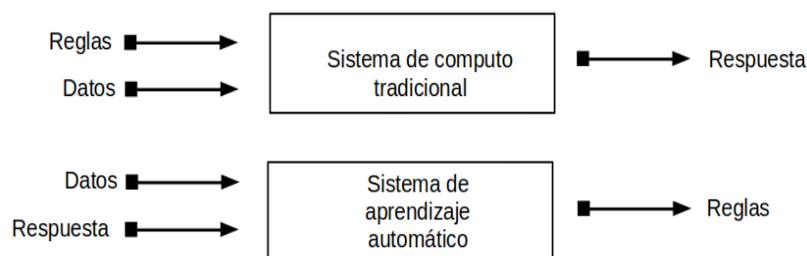
Por consiguiente, una mezcla de HPFRCC con una capacidad de absorción de energía superior a  $50 \text{ kJ/m}^3$  ( $g > 50 \text{ kJ/m}^3$ ) y alargamiento post-fisuración superior o igual a 0.3% ( $\epsilon_{pc} \geq 0.3\%$ ), es adecuada para la aplicación en el reforzamiento de estructuras con capacidades sismoresistentes, no obstante, la mezcla debe ser económicamente viable.

### 3.1.2 Inteligencia artificial

La inteligencia artificial (IA) es el estudio e implementación de técnicas mediante el uso de herramientas computacionales, basadas en inteligencia humana (habilidad para adquirir, entender y aplicar conocimiento) (Plant, 1994). Es un campo de aplicación de las ciencias de la computación, no obstante, no es la creación de sistemas de cómputo comunes (Patterson, 1990). Se trata en sí de lograr la automatización de tareas que requieren un esfuerzo intelectual y que normalmente son desarrolladas por un humano (Chollet & Allaire, 2017).

La IA busca emular el desarrollo del conocimiento tal como lo hacen los seres humanos, a través de la lógica. Se analiza una situación dada, se concluye respecto a los efectos de esta y se aprende de esta experiencia. Así, el objetivo de la IA es crear, generar o desarrollar técnicas, en herramientas computacionales, capaces de cumplir una tarea que requiera un cierto grado de inteligencia (Patterson, 1990). Esto quiere decir, que tenga la capacidad de aprender desde los datos que recibe de un contexto dado, interpretar si el entorno requiere de una reacción y generar una respuesta adecuada: entendimiento del entorno (Chollet & Allaire, 2017). La Figura 9 muestra la diferencia entre un sistema de cómputo común y uno que tiene la capacidad de aprender de los datos y e interpretar o deducir su comportamiento (Chollet & Allaire, 2017).

Figura 9: Evolución inteligencia artificial.



Fuente: (Chollet & Allaire, 2017)

a aplicación de la IA requiere un área de conocimiento (dominio de la ciencia) o avance tecnológico sobre el cual se va a soportar la herramienta o modelo de IA (Plant, 1994). Los modelos o herramientas de IA normalmente tienen tres componentes (Plant, 1994):

- 1) Conocimiento: usa datos interpretados en un contexto dado por un problema o situación y sus efectos (ejemplos, experiencia).
- 2) Una arquitectura de modelo de inteligencia artificial: programación no convencional que se soporta en estadística, matemática y en los dominios de conocimiento, relacionados a los datos, que le permite procesarlos e interpretarlos.
- 3) Interfaz hombre máquina: que permite interactuar a un humano con la maquina de IA, bien sea para prepararla, configurarla y/o programarla, o para hacer uso de ella.

La IA se usa en varios campos, como en: robótica, representación del conocimiento, modelos de aprendizaje (aprendizaje automático o machine learning), técnicas de inferencia, toma de decisiones, comprensión del lenguaje natural, reconocimiento de patrones, entre otros (Patterson, 1990; Plant, 1994).

El Aprendizaje Automático (Machine Learning) es uno de los campos más conocidos de la IA, el cual tuvo un desarrollo significativo desde la década de los 90, gracias a equipos de cómputo más robustos y avanzados. De manera general, las técnicas de aprendizaje automático observan un paquete de datos, aprenden de ellos y los interpretan. Posteriormente, evalúan su interpretación para verificar que tan preciso es y hacen un ajuste a su aprendizaje hasta que llegue a ser lo más preciso posible. Una herramienta de estas necesita tres elementos básicos (Chollet & Allaire, 2017):

- 1) Los datos de entrada: normalmente se interpretan como variables que generan un escenario o un efecto específico.
- 2) Los datos de salida: son las variables de respuesta, que representan el efecto o resultados asociados a los datos de entrada.
- 3) Un método de evaluación: la herramienta de aprendizaje automático toma los datos de entrada y salida, genera un modelo de interpretación de los datos (el resultado de la herramienta de aprendizaje automático), el cual, posteriormente, genera unos nuevos datos de salida. La evaluación consiste en comparar los datos de salida originales con los datos de salida generados por el modelo y verificar que tan acertados son estos últimos frente a los originales.

Una de esas herramientas de aprendizaje automático se conoce como Red Neuronal Artificial (RNA), estas permiten obtener una interpretación de los datos, mediante un modelo matemático no lineal (Chollet & Allaire, 2017; Krenker et al., 2011), que representan una situación específica de algún campo de la ciencia o el conocimiento humano.

### **3.1.2.1 Redes Neuronales Artificiales**

Las RNA son herramientas flexibles, robustas y efectivas que se usan para resolver problemas complejos que no se pueden tratar con facilidad con métodos estadísticos (Lazarevska et al., 2014). Se caracterizan por su habilidad de aprendizaje experimental (Gupta, 2013) y por definir un modelo de interpretación de los datos a partir de los que se le suministran para explicar la relación existente entre ellos o aproximarse a esto (Deperlioglu & Kose, 2011).

Una RNA es un esquema de un modelo matemático no lineal que simula el funcionamiento de una red neuronal biológica (Krenker et al., 2011), o lo que hasta ahora se conoce (Basheer & Hajmeer, 2000). Sus aplicaciones incluye el análisis multivariado de datos, clasificación, reconocimiento de patrones, entre otros (Basheer & Hajmeer, 2000).

En el funcionamiento de la RNA existe semejanza a la biológica en dos aspectos (Gupta, 2013):

- 1) La red adquiere el conocimiento: mediante un proceso de aprendizaje que parte de los datos que recibe, haciendo uso de un algoritmo, la red aprende de los datos y los interpreta.
- 2) La red almacena el conocimiento. La fuerza de conexión (Srinivasulu & Jain, 2006) entre las neuronas artificiales o la fuerza de flujo de información (Beck, 2018) (sinapsis) y el estado de activación de los nodos en la red neuronal (Montaño, 2002), es la forma de almacenar el conocimiento. Esto representa la importancia que tiene la conexión en el modelo matemático que construye.

La ventaja de las RNA se centra en la no existencia de un “modelo” inicial, es decir, no requiere un modelo de ecuación inicial. La RNA adapta un modelo basado en los datos que se le suministren, la precisión del modelo depende directamente de la cantidad de datos experimentales que se tenga, que, por cierto, es recomendable tener la mayor cantidad de datos posible (Gupta, 2013).

La RNA más utilizada es el perceptrón multicapa (MLP, por sus siglas en inglés) feed forward (alimentación hacia adelante), usado con mayor frecuencia para

predecir una o más variables de respuesta. Un MLP es la unión de varios perceptrones que construyen un modelo no lineal de hiperparámetros. Cabe resaltar que un modelo MLP es una “caja negra” que no permite observar la relación entre las variables analizadas (Beck, 2018) .

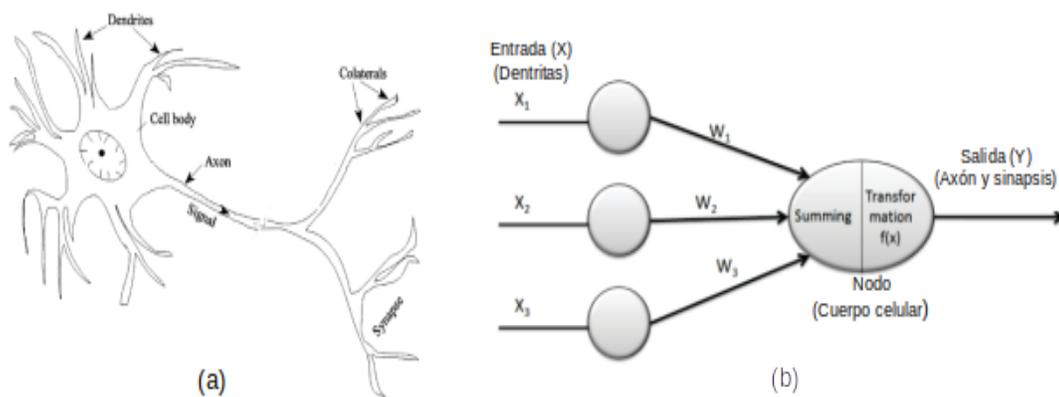
### 3.1.2.1.1 Neurona Artificial

La neurona, que es el elemento básico de una red neuronal biológica, incluye cuatro partes principales: dendritas (dendrites), cuerpo celular (soma o cell body), axón (axon) y sinapsis (synapse, las cuales definen el esquema de analogía de las neuronas artificiales (Basheer & Hajmeer, 2000; Harsh et al., 2016).

En el caso de las Redes Neuronales Artificiales, la neurona artificial es la unidad básica (asimilada a la neurona biológica) que podría dividirse en: entrada (y peso de entrada), nodo (suma y función de activación) y salida (Basheer & Hajmeer, 2000; Harsh et al., 2016). La Figura 10 muestra un paralelo gráfico entre una neurona biológica y una artificial.

En la práctica, una neurona artificial, a través de las entradas, recibe información ( $x$ ) a la que se asigna un peso ( $w$ ) que multiplica el valor de la entrada ( $w*x$ ). El nodo de la neurona artificial suma cada entrada multiplicada por su peso ( $\sum w*x$ ), adicionando el sesgo o bias ( $b$ ). El nodo posteriormente procesa esta suma ( $\sum w*x+b$ ), mediante una función de activación ( $f$ ). Como resultado de esto, la neurona artificial genera una salida ( $y$ ) (Krenker et al., 2011).

Figura 10: Comparación entre neurona biológica y neurona artificial

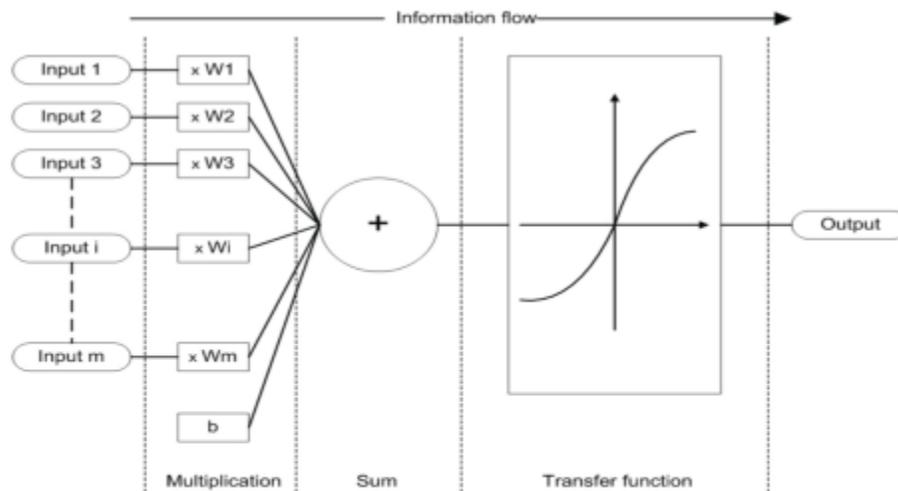


(a) neurona biológica, (b) neurona artificial.

Fuente: (Basheer & Hajmeer, 2000; Lazarevska et al., 2014)

La Figura 11 parte (a) muestra la representación gráfica de la operación matemática anteriormente descrita, mientras que la parte (b) muestra la notación de la función, que se desarrolla en el nodo, para determinar la variable de salida.

Figura 11: Esquema del funcionamiento de una neurona artificial



(a)

$$Output = f \left[ \sum_{i=1}^m (Input_i * W_i) + b \right]$$

(b)

(a) Representación gráfica, (b) notación de la función matemática en la neurona artificial.

Fuente: (Abdollahzadeh et al., 2011; Krenker et al., 2011)

El coeficiente de peso expresa la importancia relativa de cada variable de entrada, cuantifican la fuerza de la señal de cada entrada al nodo (Lazarevska et al., 2014) o la intensidad de interacción de la variable (González-Salcedo et al., 2017).

Un coeficiente positivo podría entenderse como una señal que acelera o fortalece la conexión con el nodo, mientras que una señal negativa se interpretaría como una señal limitada o inhibida; cuando el peso es igual a cero significa que no hay señal o conexión al nodo (se suprime la entrada) (Lazarevska et al., 2014).

La tarea básica de aprendizaje de una RNA es ajustar los coeficientes de pesos de las entradas en cada nodo hasta encontrar los más adecuados, entendiendo como

“adecuado” aquel capaz de reproducir las propiedades estadísticas de los datos (Krenker, Bešter, and Kos 2011, Montañó 2002).

Una variable de entrada puede originarse en el entorno (los datos de entrada suministrados) o como salida de otra neurona. Asimismo, la salida de una neurona puede ser la variable de respuesta del modelo o una variable de entrada de otro perceptrón.

Una RNA está dividida en tres secciones: capa de entrada, capas ocultas y capa de salida. La capa de entrada y la capa de salida están conectadas con el exterior, esto quiere decir, a los datos de entrada y datos de salida respectivamente. Un perceptrón no tiene una capa oculta. La forma en la que se encuentran interconectados los perceptrones define la arquitectura de la RNA (Abellán, 2020; Ghafari et al., 2015).

### **3.1.2.1.2 Error de Sesgo (bias) y varianza**

El sesgo (bias en inglés) hace referencia a la desviación de la función de la RNA, es decir, cuantifica la desviación del modelo de RNA frente al modelo matemático “real” (que es desconocido), el cual explica perfectamente la variable de salida en función de las variables de entrada (James et al., 2017).

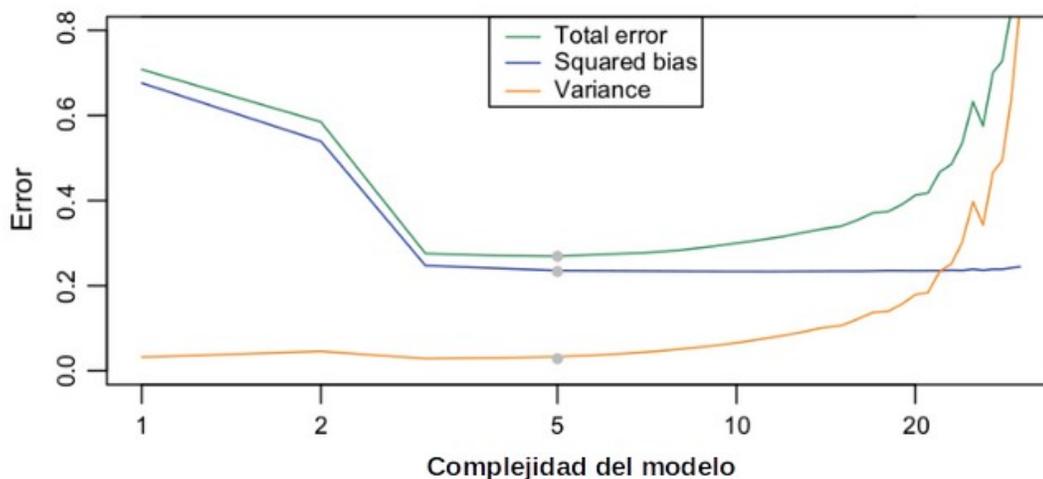
El sesgo se puede presentar cuando un modelo resulta simple o básico para un conjunto de datos que responde a uno más complejo, esto es, que no existe adecuada “coincidencia” del modelo con los datos. El sesgo podría reducirse definiendo y entrenando un modelo más complejo, ampliando el tiempo o cantidad de veces de entrenamiento del modelo, haciendo uso de un algoritmo de optimización diferente, usando una arquitectura de RNA diferente o modificando los hiperparámetros de la arquitectura actual (Ghatak, 2019).

Al mencionar los modelos (y entrenamiento) de RNA se debe hacer referencia a otro tipo de error conocido como varianza. Este no es igual al sesgo, por el contrario, este se presenta cuando se tiene un modelo de RNA muy complejo para el conjunto de datos estudiado y que lleva a una gran exactitud del conjunto inicial de datos con el modelo. La varianza podría reducirse aumentando el número de datos, aplicando métodos de regularización o reduciendo la complejidad del modelo (Ghatak, 2019).

De lo anterior, puede indicarse que el sesgo está asociado a la suboptimización (underfitting) del modelo, mientras que la varianza a la sobreoptimización (overfitting).

Finalmente, el error total en una RNA resulta de la suma del sesgo y la varianza. Es necesario que entre los dos errores exista un equilibrio con el fin de reducir la posibilidad suboptimización o sobreoptimización del modelo (Ghatak, 2019). La Figura 12 muestra gráficamente la relación entre los dos errores mencionados frente a la complejidad del modelo de RNA, se espera que el error total sea el menor posible (representado por el punto gris).

Figura 12: Gráfica de error total de un modelo de RNA. Sesgo y Varianza



Fuente: (Ghatak, 2019)

### 3.1.2.1.3 Función de Activación o de Transferencia

En el nodo de la neurona artificial se define una función de activación o de transferencia. Esta función determina la salida o respuesta del nodo (Krenker et al., 2011). La función de activación o de transferencia se encarga de “regular” la señal de respuesta de un nodo, en otras palabras, transforma la suma total de los datos de entrada multiplicados por su peso para determinar si el nodo puede generar una salida y el valor de esta (Lazarevska et al. 2014). Esta salida posterior a la función tiene una representación significativa (Ghatak, 2019).

Existen varios tipos de funciones: de paso, lineal, logística sigmoidea, tangente hiperbólica, lineal rectificadora (ReLU), entre otras (Abellán, 2020; Krenker et al., 2011; Montaña, 2002). Dependiendo la función seleccionada se aporta la transformación no lineal del modelo (Abellán, 2020).

El uso de la función de activación limita los valores de salida del nodo a un rango específico, evitando gran dispersión de los valores de salida (González et al.,

2012; Lazarevska et al., 2014). Las funciones de activación pueden ser lineales o no lineales (Ghatak, 2019). La función de activación que se observa con uso más frecuente es la logística sigmoidea (Abellán, 2020; Ghatak, 2019; González-Salcedo et al., 2017; Gupta, 2013; Harsh et al., 2016; Lazarevska et al., 2014).

### **Función de paso** (Krenker et al., 2011)

$$Y = \begin{cases} 1 & \text{si } (w * x) \geq \text{límite} \\ 0 & \text{si } (w * x) < \text{límite} \end{cases} \quad (1)$$

Es una función de tipo binaria. Solo dos posibles valores como respuesta, generalmente 1 y 0. La función (ecuación 1) se establece respecto a un límite o umbral, dependiendo si el valor evaluado en la función está por encima o por debajo de dicho límite, esta función asigna uno de los dos resultados posibles. Este tipo de función se usa normalmente para tareas de clasificación y se asigna la mayoría de las veces al nodo ubicado en la capa de salida

### **Función Lineal** (Ghatak, 2019)

Es una función de tipo línea recta. No es la más adecuada como función de activación para datos complejos. Al usar funciones lineales en todos los nodos, el modelo resultado de la red neuronal va a ser lineal y es prudente tener en cuenta que la mayoría de los problemas reales no tienen un comportamiento lineal. El rango de salida de estas funciones está entre  $-\infty$  y  $+\infty$ . La Figura 13 (a) muestra gráficamente una función lineal.

### **Función logística sigmoidea** (Ghatak, 2019)

$$f(Z) = \frac{1}{1 + e^{(-\lambda Z)}} \quad (2)$$

Es una función de tipo no lineal. Convierte una entrada lineal a una salida no lineal, los valores de respuesta están entre 0 y 1. Esta función se define como se muestra en la ecuación 2. El parámetro  $\lambda$  es una constante usada para controlar la pendiente de la región semilineal (Abellán, 2020; Ghafari et al., 2015).

Esta función presenta la tendencia a agrupar los valores en 1 o en 0. Cuando los valores son fuertemente negativos, los resultados de la función de activación tienden a estancarse en 0, mientras que cuando son fuertemente positivos los resultados de la función tienden a estancarse en 1. En la línea punteada de la Figura 13 (b) está representada gráficamente la función logística sigmoidea.

**Función tangente hiperbólica (Ghatak, 2019)**

$$f(Z) = \frac{e^Z - e^{-Z}}{e^Z + e^{-Z}} \quad (3)$$

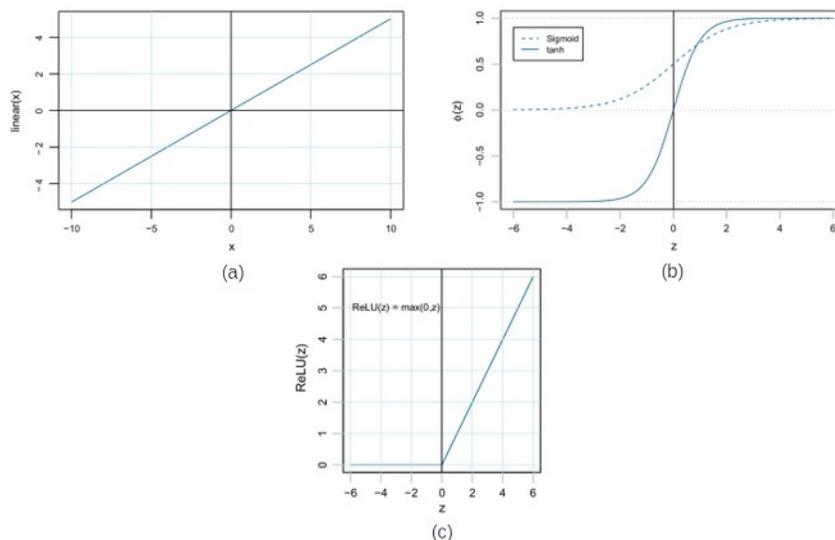
Esta función también es sigmoidea (no lineal). El rango de salida de la respuesta es de -1 hasta 1. Los valores negativos ofrecen valores de respuesta negativos, mientras que los valores positivos presentan valores de respuesta igualmente positivos. La respuesta cero de esta función se da cuando el valor de entrada es cero. Esta función se define según la ecuación 3. Gráficamente la función se muestra en la Figura 13 (b)

**Función lineal rectificada**

$$f(Z) = \max(Z, 0) \quad (4)$$

Esta función lleva a cero los valores de entrada negativos (Chollet & Allaire, 2017; Ghatak, 2019), mientras que, para los valores positivos, el valor de salida es el mismo de entrada a la función. El rango de los valores de salida de esta función es 0 y  $+\infty$  (Ghatak, 2019). La función se define según la ecuación 4. Se usa con mayor frecuencia en las neuronas de las capas ocultas de la RNA y resulta de un desempeño de entrenamiento más rápido en redes de gran tamaño. En algunos casos, puede ser una desventaja que “desaparezca” los valores negativos (Ghatak, 2019). La representación gráfica de la función se muestra en la figura Figura 13 (c).

Figura 13: Funciones de activación



(a) Lineal, (b) Sigmoidea logística y Tangencial hiperbólica, (c) Lineal rectificada.  
Fuente: (Ghatak, 2019)

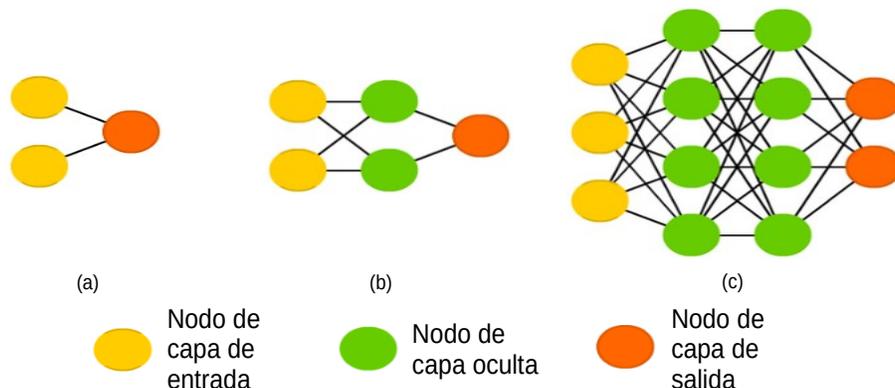
#### 3.1.2.1.4 Arquitecturas de RNA

La forma en la que se presenta la interconexión de los perceptrones (o neuronas artificiales) se conoce como tipología o arquitectura de una RNA (Krenker et al., 2011). Como ya se mencionó, la arquitectura de una RNA tiene al menos tres partes: capa de entrada, capas ocultas y capa de salida, cada una de estas con un número determinado de nodos.

La capa de entrada está definida para las variables independientes y un nodo se asigna a cada una de estas. Dichos nodos funcionan como sensores de recepción de los valores de entrada (Abellán, 2020) y no como procesadores de datos. La capa de salida agrupa a los nodos generando los valores de respuesta del modelo, un nodo por cada variable de respuesta. En estos nodos se da el último procesamiento de los datos.

Entre la capa de entrada y de salida se encuentran las capas ocultas (o capa oculta), que son un conjunto específico de nodos que procesan los datos que entrega la capa precedente para generar un valor de salida que se suministra a un nodo en otra capa oculta o en la capa de salida (Ghatak, 2019). La Figura 14 muestra diferentes arquitecturas de RNA según la cantidad de nodos y capas.

Figura 14: RNA Feed Forward.



(a) Perceptrón, (b) RNA de una capa oculta, (c) RNA de dos capas ocultas.

Fuente: <https://www.asimovinstitute.org/neural-network-zoo/>

La conexión que puede darse entre nodos genera una gran variedad de tipologías de RNA, no obstante, las mismas pueden dividirse en dos clases de tipologías: acíclica y semicíclica, esto dependiendo del sentido de flujo de la información en la RNA (Krenker et al., 2011).

En la tipología acíclica, también conocida como arquitectura de RNA Feed Forward, la información fluye de los nodos de entrada a los nodos de salida (pasando por los nodos de la capa oculta) en un solo sentido (Ghatak, 2019; Krenker et al., 2011). En esta tipología no existen conexiones entre nodos de la misma capa, ni conexiones de flujo de información hacia nodos de una capa anterior (Montaño, 2002). Es la arquitectura más usada dentro las RNA (Ghatak, 2019). No existen limitaciones en cuanto al número de nodos por capa, la cantidad de capas ocultas o el uso de función de activación. Las arquitecturas mostradas en la Figura 14 son tipo *Feed Forward*.

Existen otro tipo de arquitecturas como RNA Convolucionales, RNA de Memoria de Largo y Corto Plazo (LSTM por sus siglas en inglés Long Short Term Memory), RNA Recurrentes Cerradas, entre otras.

Seleccionar el tipo de tipología de red neuronal es solo el principio para interpretar o representar un modelo para un conjunto de datos específicos a través de RNA. Para ello, es necesario conocer la cantidad de nodos en la capa o capas ocultas y que la arquitectura aprenda de los datos. Independientemente del tipo de arquitectura que se seleccione, así como la cantidad de nodos en las capas ocultas, conocer los valores de peso de entrada de los datos para cada nodo, así

como del sesgo, es la actividad de aprendizaje que una RNA debe realizar a través de un entrenamiento (Krenker et al., 2011).

### **3.1.2.1.5 Entrenamiento de RNA**

#### **3.1.2.1.5.1 Preparación de datos**

##### **Identificación de datos atípicos o de influencia**

En el conjunto de datos de variables de entrada y de respuesta se pueden observar datos atípicos (outliers) o datos de influencia (leverage points), que hacen referencia a dos tipos de datos con características diferentes.

Los datos atípicos son valores lejanos del intervalo “común” de una variable que resultan “extraños” frente al conjunto de datos totales. Estos pueden presentarse o surgir principalmente por errores en la recolección de datos (Bishop, 2006; James et al., 2017). Entrenar una RNA sin el tratamiento de estos datos anómalos, que se asociarían a una mayor variación de los datos (James et al., 2017), hacen que un modelo se oriente a ajustarse a los datos anómalos, perdiendo robustez (Bishop, 2006), y un posterior bajo desempeño en la predicción de las variables de respuestas frente a datos nuevos. Una gran cantidad de datos atípicos en el dataset puede llevar a un modelo sesgado (Chandwani et al., 2015) y a un aumento del error en el modelo (Shi et al., 2017).

La identificación de puntos anómalos podría hacerse evaluando los residuos para un valor  $\hat{y}$  estimado, esto para el caso de una regresión lineal (James et al., 2017). Sin embargo, para el caso de un modelo de RNA esto no es aplicable, pues el modelo RNA, en el entrenamiento, intentará ajustarse a dichos puntos.

Por otra parte, en el caso de los datos de influencia, estos hacen referencia a valores que no están en el intervalo común de variable, pero que no resultan “extraños”. Es decir, es posible que la variable tome este tipo de valores, aunque resulte inusual (James et al., 2017). Podría suceder que se confundan los datos anómalos con los de influencia, empero, no es conveniente eliminar estos últimos ya que se estaría perdiendo información relevante para el entrenamiento del modelo de RNA.

Por lo anterior, es necesario dar tratamiento a los datos a fin de identificar aquellos anómalos o de influencia, revisando la validez de estos y confirmando con la fuente del dato (si esto es posible) para verificar si la variable puede tomar este tipo de valores, de no ser así, es conveniente eliminarlos.

El tratamiento debe ser cuidadoso, a fin de no perder información del conjunto de datos. El conocimiento de los datos (dominio de la ciencia) y lo que estos representan es relevante para identificar un dato anómalo y garantizar que no se pierde información que sea necesaria para interpretar la situación en análisis.

Para tratar datos atípicos o anómalos es conveniente observar gráficamente el comportamiento o distribución de las variables independientes frente a las variables de respuesta, en algunos casos, los datos atípicos se muestran por sí mismos (Everitt & Hothorn, 2011), en otros casos, no es tan sencillo identificar los datos atípicos.

Los diagramas de caja bivariados (bivariate boxplot) se pueden usar para identificar valores atípicos. Estos se construyen usando medidas de ubicación, escala y correlación. En un gráfico de dispersión de dos variables se trazan las líneas de regresión  $x$  sobre  $y$  y  $y$  sobre  $x$ . La intersección de estas líneas sirve como centro para dibujar dos elipses, la primera con los límites del primer cuartil y la segunda con el tercer cuartil; esta última delimita los datos que son potencialmente atípicos (un diagrama de bigotes en dos dimensiones). El ángulo que forman las dos líneas de regresión será más pequeño (agudo) cuando la correlación (en valor absoluto) entre variables es mayor (Everitt & Hothorn, 2011).

### **Normalización de datos**

El proceso de normalización consiste en llevar los datos originales de algunas (o todas) variables de entrada a un rango específico y generalmente es necesaria cuando existe gran variabilidad en los valores que toman los datos, esto quiere decir, que el rango de los mismos es amplio (Jammal, Peshawa & Rezhna Hassan, 2014).

En el entrenamiento de RNA, la normalización de los datos debe hacerse por requerimiento del algoritmo o buscando mejorar o facilitar el proceso de aprendizaje del modelo (Shanker et al., 1996). El modelo de RNA puede adaptarse a la heterogeneidad de los datos, no obstante, el proceso de aprendizaje puede hacerse más complicado y lento (Chollet & Allaire, 2017), lo que puede traducirse en costo computacional. Adicionalmente, la normalización de datos elimina la posibilidad de sesgo en los modelos (Abellán, 2020).

Las ventajas de la normalización de los datos pueden observarse o no en el procesamiento de estos, aunque también dependen de el algoritmo de aprendizaje usado, de la complejidad del modelo y del tamaño del conjunto de datos (Shanker et al., 1996).

Se pueden listar tres métodos de estandarización que son comúnmente usados: 1) escala lineal con mínimo 0 y máximo 1, detallada en la ecuación 5 (Abellán, 2020; Jammal, Peshawa & Rezhna Hassan, 2014); 2) escala lineal con mínimo -1 y máximo 1, que se calcula conforme a la ecuación 6 (Jammal, Peshawa & Rezhna Hassan, 2014); y 3) escala normal con media 0 y desviación estándar 1, definida según ecuación 7 (Chollet & Allaire, 2017; Jammal, Peshawa & Rezhna Hassan, 2014).

$$x' = \frac{x - \min}{\max - \min} \quad (5)$$

$$x' = 2 \cdot \left( \frac{x - \min}{\max - \min} \right) - 1 \quad (6)$$

$$x' = \left( \frac{x - \mu}{\sigma} \right) \quad (7)$$

La selección del método de normalización en el entrenamiento de RNA depende directamente del tipo de modelo y su objetivo (clasificación o regresión), además de la función de activación utilizada. Es conveniente usar escala lineal cuando se trata de problemas de regresión lineal y de escala normal cuando se trata de modelos de clasificación (Chollet & Allaire, 2017; Ghatak, 2019).

Se requiere desnormalizar los datos, una vez se tengan resultados de estimación del RNA para poder interpretarlos. No es estrictamente necesario normalizar todas las variables de un conjunto de datos, esto depende, principalmente, de la dispersión y de la naturaleza del problema al tratar con un modelo de RNA.

### **División del conjunto de datos**

El conjunto de datos debe ser separado en dos partes: *train* y *test*. El modelo de RNA se entrena con un conjunto de datos y la evaluación no debe ser realizada con el mismo conjunto de datos. La evaluación del modelo debe hacerse con un conjunto de datos que, hasta el momento, este no haya “visto” (Chollet & Allaire, 2017). En general, el conjunto de datos puede ser dividido en 80% *train* y 20% *test* (Ghafari et al., 2012; Naderpour et al., 2010; Parichatprecha & Nimityongskul, 2009), 75% *train* y 25% *test* (Abellán-García 2020; Abellán 2020), 70% *train* y 30% *test* (Chandwani et al., 2015; Hakim et al., 2011).

#### **3.1.2.1.5.2 Validación cruzada tipo K-Fold**

Una practica adecuada para garantizar confiabilidad en el entrenamiento (*train*) de los modelos de RNA es usar la validación cruzada K-fold, en especial cuando el

conjunto de datos es relativamente pequeño. Al dividir el conjunto de datos en dos partes, train y test, y evaluar el modelo con este último, se corre el riesgo de tener diferencias significativas entre ambos conjuntos y el consecuente impacto sobre el error del modelo. (Abellán-García, 2020; Chollet & Allaire, 2017)

Así, este consiste en la división del conjunto de datos de entrenamiento en un número K de subconjuntos de datos (en los que se garantiza uniformidad de la distribución de los datos). Un modelo de RNA se entrena con K-1 conjuntos de datos y se evalúa con el conjunto de datos restante. Al finalizar el entrenamiento se tienen K resultados de error del modelo, los cuales se promedian para obtener el resultado total del error del modelo entrenado. La Figura 15 presenta de manera gráfica el esquema de organización y uso de los K subconjuntos de datos. Generalmente, se usa un valor K de 4 o 5 (Chollet & Allaire, 2017)

Figura 15: Validación cruzada tipo K-fold



Fuente: (Abellán-García, 2020; Chollet & Allaire, 2017)

La validación cruzada tipo K-fold se presenta adecuada en procesos de ajuste de los hiperparámetros de un modelo de RNA (por ejemplo, el número de neuronas) (Abellán-García, 2020; Chollet & Allaire, 2017)

### 3.1.2.1.5.3 Hiperparámetros de la RNA

Los resultados de un modelo RNA y su capacidad para interpretar los datos (minimización del error) dependen específicamente de la arquitectura del modelo. El desempeño de una RNA depende de la selección de los hiperparámetros que la definen, estos funcionan como variables externas al modelo que no dependen de los datos. Como hiperparámetros de una RNA se puede listar el número de capas, el número de neuronas por cada una, la función de activación, la tasa de

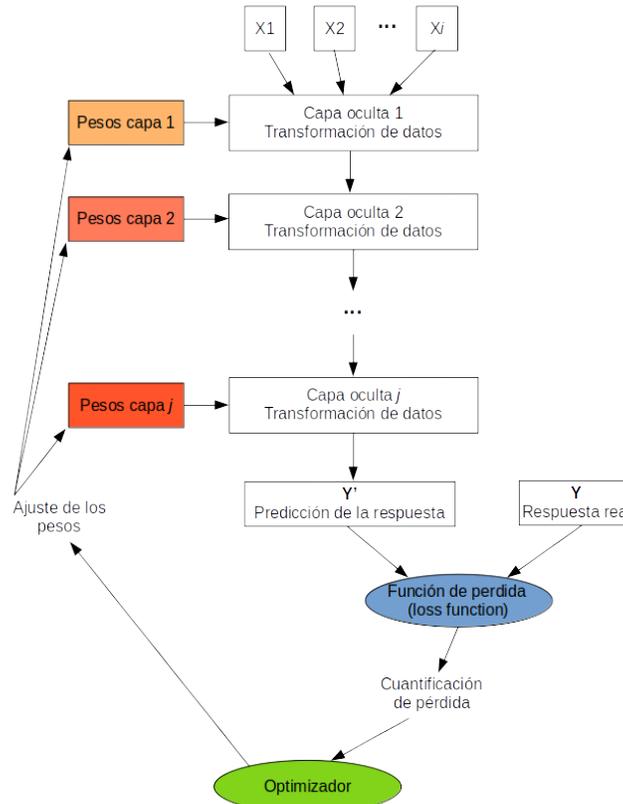
aprendizaje (learning rate), los ciclos de entrenamiento (epoch), entre otros (Torres, 2018).

El ajuste de los hiperparámetros depende, en gran medida, del algoritmo de aprendizaje de la RNA, asimismo, la selección de este depende de factores como la herramienta que se use para entrenar la red, la naturaleza del problema a tratar con la RNA, el tipo de datos, etcétera.

### Algoritmo de aprendizaje (optimizador)

El optimizador es el motor de aprendizaje de una RNA. A través del algoritmo de aprendizaje se realiza el ajuste de los pesos en cada capa del modelo, según la evaluación del resultado que hace la función de pérdida (loss function) en cada iteración del modelo (la cantidad de observaciones que procesa el modelo y la cantidad de veces que lo hace) (Chollet & Allaire, 2017; Manaswi, 2018). La Figura 16 muestra un esquema de la transformación de los datos que se da en un modelo RNA durante su entrenamiento.

Figura 16: Esquema de transformación de datos de una RNA



Fuente: (Chollet & Allaire, 2017)

Inicialmente, el modelo asigna valores de peso de manera aleatoria que generan predicciones muy alejadas de los datos reales. A medida que el modelo se reentrena con los mismo datos, el optimizador va ajustando los pesos en la dirección correcta de manera que la pérdida en el modelo disminuye (Chollet & Allaire, 2017).

El algoritmo central en deep learning (por lo tanto, también en RNA) y el más conocido es el de Entrenamiento de Propagación Hacia Atrás (BP – backpropagation) (Chollet & Allaire, 2017; Mushgil et al., 2015). Sin embargo, la literatura científica hace mención a varios algoritmos: Resilient Back Propagation (Rprop) (Cruz, Peixoto, and Magalhães 2011; Mushgil, Alani, and George 2015; Treadgold and Gedeon 1996; Abellán-García 2020; Montaña 2002; Saini 2008; Abellán 2020; Prasad, Singh, and Lal 2013), Levenberg-Maquardt (LMA) (González-Salcedo et al., 2017), SGD, RMSprop, Adagrad, Adadelta, Adam, entre otros (Chollet & Allaire, 2017; Ghatak, 2019; Manaswi, 2018; Torres, 2018).

Dependiendo de la herramienta que se use para entrenamiento y validación de la RNA, el problema y datos a tratar (regresión, clasificación, etc) y en algunos casos la cantidad de datos, se selecciona el optimizador (algoritmo de aprendizaje) para la RNA.

En la aplicación de RNA en ingeniería civil se observa con mayor uso los algoritmo de aprendizaje: BP (Abounia Omran et al., 2014; Bal & Buyle-Bodin, 2013; Getahun et al., 2018; González Salcedo et al., 2012; Hakim et al., 2011; Naderpour et al., 2010; Shi et al., 2017), Rprop (Abellán-García 2020; Abellán 2020), LMA (Bharathi et al., 2017; Chandwani et al., 2015; Uysal & Tanyildizi, 2012). Lo anterior teniendo en cuenta el uso de herramientas como MATLAB o R (librerías neuralnet o nnet). En el uso de R con librerías Tensorflow y Keras no se observó literatura científica aplicada a ingeniería civil, no obstante, (Chollet & Allaire, 2017) hace uso del algoritmo RMSprop en aplicación de RNA en tareas de regresión.

## **Evaluación del Modelo de RNA**

Algunos parámetros estadísticos son usados para evaluar modelos de RNA, entre estos se incluyen Media de los Errores Absolutos (MAE), Media de los Errores Cuadrados (MSE) y Raíz Cuadrada Media de los Errores Cuadrados (RMSE). Aquellos que presentan los resultados en las unidades de la variable de respuesta del moldeo facilitan el análisis de los resultados. Así, cuando los resultados de las mediciones toman valores cercanos a cero estos indican que el modelo RNA se ajusta y responde a los datos (D. N. Moriasi et al., 2007).

Se podrían listar seis parámetros adicionales que se usan para evaluar los modelos de regresión y que aplican para la evaluación de los resultados de un modelo RNA: 1) Error Promedio (AE), 2) Media del Porcentaje de Error Absoluto (MAPE), 3) Coeficiente de Eficiencia (E), 4) Relación del RMSE y la Desviación Estándar de los Datos (RSR), 5) Media del Error de Sesgo Normalizado (NMBE), y 6) Coeficiente de Correlación ( $R^2$ ) (Abellán-García 2020).

Los ocho parámetros listados se definen como indican las ecuaciones 8 al 16. Donde:

$a_i$  es el valor real de la variable de respuesta ,

$\hat{a}_i$  es el valor estimado por la RNA,

$\bar{a}_i$  es la media de los valores reales de respuesta, y

$n$  el número de observaciones

El MSE y RMSE son los parámetros que pueden ser usados para evaluar un modelo de regresión (Chollet & Allaire, 2017; Ghatak, 2019).

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

$$MSE = \frac{\sum_{i=1}^n (a_i - \hat{a}_i)^2}{n} \quad (9)$$

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

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

$$MAPE = \frac{100}{n} \sum_{i=1}^n \frac{|a_i - \hat{a}_i|}{|a_i|} \quad (12)$$

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

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

$$NMBE(\%) = \frac{\frac{1}{n} \sum_{i=1}^n (a_i - \hat{a}_i)}{\bar{a}_i} \times 100 \quad (15)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (a_i - \hat{a}_i)^2}{\sum_{i=1}^n (\hat{a}_i)^2} \quad (16)$$

### 3.2 Estado del arte

La literatura científica, disponible de los estudios realizados para evaluar el alargamiento postfisuración y/o la capacidad de absorción de energía en el concreto, presenta una cantidad de información importante en cuanto a los componentes que usan, como el diseño de la mezcla, las variables que influyen en el comportamiento del concreto y las propiedades mecánicas. Además, se han encontrado estudios que incluyen hasta veintinueve tipos de mezclas detallando los resultados obtenidos para cada una de estas.

(Wang & Li, 2007) realizaron una investigación con doce tipos de mezclas. Llevaron a cabo un análisis de las propiedades mecánicas del concreto divididas en dos grupos: en el primero, seis mezclas en las que se varió la cantidad de ceniza volante y, en el segundo, las seis mezclas restantes, en las cuales se modificó la cantidad de ceniza de incinerador de residuos. Las doce mezclas incluyeron un 2% en volumen de fibra Polivinilo de Alcohol (PVA). Los resultados del estudio se enfocaron en maximizar el alargamiento postfisuración de las mezclas.

Por otro lado, (Kim et al., 2012) estudiaron dieciséis tipos de mezclas. Se usaron al menos trece tipos de componentes en la mezcla y cuatro matrices de concreto base a las que se les adicionaron dos tipos de fibra en dos diferentes cantidades en volumen. Concluyen que las dosificaciones estudiadas que utilizan fibras de acero deformado de alta resistencia son sensibles a la resistencia de la matriz y las fibras retorcidas aprovechan mejor las matrices de mayor resistencia que las fibras acabadas en gancho debido su torsión.

Del mismo modo, (Park et al., 2012) presentaron dieciséis tipos de mezclas. La matriz base del concreto estuvo conformada por seis compuestos a los que se les adicionó cuatro tipos de fibra en cuatro cantidades diferentes del volumen. Presentaron como conclusión que las mezclas con fibra retorcida produce el mejor rendimiento en términos de comportamiento de endurecimiento por deformación.

Asimismo, (Yoo & Kim, 2019) estudiaron doce tipos de mezclas de concreto, en donde la matriz base de la mezcla se compuso de seis componentes y en la cual se adicionaron cuatro tipos de fibras (acero y PE). Las mezclas variaron según el aumento del volumen de cada tipo de fibra en la composición evaluada. El estudio concluye que la resistencia a la tracción y el agrietamiento mejoró mediante el uso de fibra retorcida y fibra recta con una relación de aspecto más alta; la capacidad

de deformación y la capacidad de absorción de energía mejoró significativamente al reemplazar una porción de fibras de acero con fibras de polietileno; y una alta absorción de energía (251 kJ/m<sup>3</sup>) fue exitosamente desarrollada usando solo un 2% de combinación de fibra metálica y polietileno.

Finalmente, (Li et al., 2019) analizaron experimentalmente veintinueve tipos de mezclas. En la evaluación del alargamiento postfisuración se incluyeron ocho componentes que conforman la matriz base, las mezclas de concreto y tres tipos de fibra adicionadas en dos niveles de volumen diferentes. Las conclusiones del estudio se orientan a evaluar la influencia de los tipos de fibra adicionada al concreto en el alargamiento postfisuración del mismo.

Todos los estudios listados anteriormente proporcionan datos confiables en cuanto a las propiedades mecánicas del concreto; sin embargo, ninguno presenta información de los costes de las mezclas de concreto evaluadas. No se observa un análisis relacionado a la optimización de la mezcla pensando en la viabilidad de la comercialización del concreto.

Así, aunque todos estos estudios presentaran resultados de optimización teniendo en cuenta variables económicas, los componentes utilizados en las mezclas estudiadas se producen fuera del país y el análisis en términos económicos no tendría aplicación en Colombia. Por ende, la importación de los componentes para su uso en Colombia modificaría el valor de los materiales y generaría así un coste más elevado en la mezcla.

En el caso de los materiales nacionales para mezclas de HPFRCC, los precios de la fibra son diferentes, como también la calidad de estas. La literatura científica mencionada presenta el comportamiento mecánico de las mezclas, no obstante, es necesario conocer el comportamiento del HPFRCC producido con componentes del mercado local.

Identificar la mezcla óptima de concreto (diseño de mezcla) que maximice las propiedades mecánicas (o alcance las deseadas), requiere de gran experiencia si se espera conseguir con ensayo y error, aunque podría este resulta un proceso poco eficiente (Adeli, 2001). En ingeniería civil se han aplicado diferentes métodos observándose no confiables o de baja precisión, además de poco flexibles (Adeli, 2001; Getahun et al., 2018; González-salcedo, 2012; Hakim et al., 2011). Del mismo modo, las dosificaciones de concreto a nivel mundial se han establecido bajo tablas generalizadas que han recopilado los resultados de la experimentación o formulas analíticas con un amplio componente empírico (González-salcedo, 2012), aunque no son suficientes para las necesidades actuales, dados los desarrollos tecnológicos en concreto que agregan más o nuevos componentes y

que modifican el comportamiento de sus propiedades (Parichatprecha & Nimityongskul, 2009).

La literatura científica al respecto denota que las RNA han tenido un papel importante en los avances alcanzados en cuanto a la predicción de las propiedades mecánicas del concreto, siendo una de las más estudiadas la resistencia a la compresión, específicamente en las familias de HSC, partiendo de los datos de la mezcla del concreto. Gracias a los avances en tecnologías de la computación, la inteligencia artificial (IA) ha tenido un gran campo de aplicación en la Ingeniería, siendo la predicción de propiedades una de ellas. En las RNA estudiadas de este tipo, las variables de entrada del modelo son los datos de la mezcla y las variables de salida son las propiedades mecánicas de compresión (Khosravani et al., 2019). Frente a otros métodos se ha observado ventajas en el uso de RNA; (Ghafari et al., 2015) compara los resultados de la predicción de la resistencia a la compresión del concreto entre dos métodos usados: 1) el diseño estadístico de mezcla de concreto y 2) Red Neuronal Artificial, concluyendo que se observa una mayor precisión de los modelos de RNA debido a la naturaleza no lineal.

Si bien es cierto, las RNA presentan mayor desarrollo en predicción de la resistencia a la compresión, existen otros estudios que usan las RNA para predecir el comportamiento de otro tipo de propiedades. (Adeli, 2001) hace un resumen de los campos de aplicación de las RNA en ingeniería civil recolectando información de literatura científica publicada entre los años 1989 y 2000, en los que se mencionan campos como programación y gerencia de proyectos de construcción, estimación de costos, uso de recursos naturales, entre otros. Igualmente, (Lazarevska et al., 2014) presenta el uso de las RNA para determinar la resistencia al fuego de las columnas de concreto reforzado, concluyendo que se evidencia como una herramienta adecuada para predicción del comportamiento; además, (González-Salcedo et al., 2017) usan RNA para predecir las propiedades mecánicas del concreto reforzado con fibras metálicas en estado fresco, entre las que se incluyen resistencia a la tensión, a la cortante y a la flexión, y tenacidad a flexión, concluyendo que el uso de RNA es confiable.

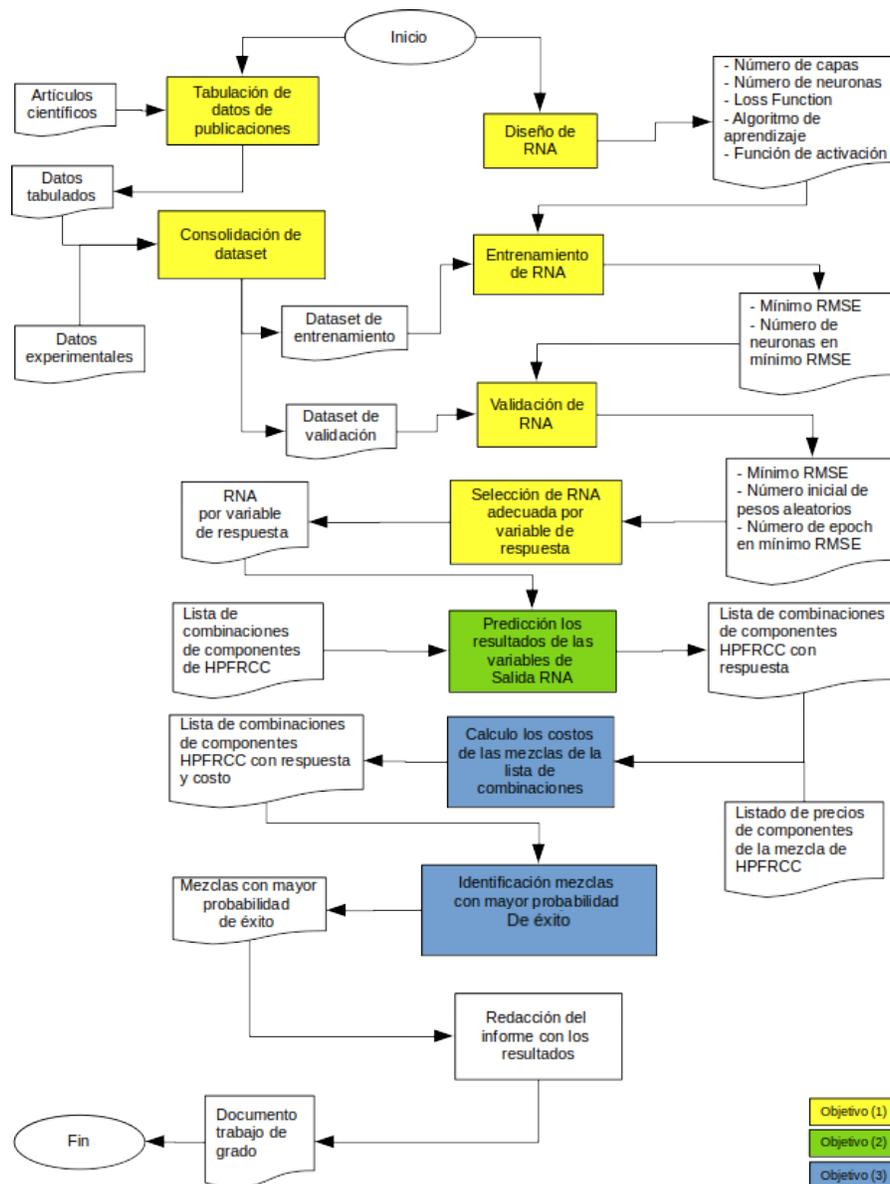
En conclusión, en la ingeniería civil existe una creciente aplicación de las Redes Neuronales Artificiales observando casos en el modelamiento del comportamiento de materiales y predicción de propiedades mecánicas, entre otros. También, se han hecho usos de herramientas como modelos analíticos, métodos estadísticos e inteligencia artificial, siendo este último el de mayor crecimiento y aceptación. Los resultados de la literatura científica encontrada al respecto precisan que los modelos de RNA evaluados reportan una gran precisión al comparar sus resultados con datos experimentales (Getahun et al., 2018).

En la literatura científica consultada no se logró observar el uso de redes neuronales para la estimación de la capacidad de absorción de energía y alargamiento postfisuración en HPFRCC.

## 4 Metodología

Para lograr los objetivos planteados se define una metodología que se esquematiza en la Figura 17. Se inicia con la construcción del *dataset* (listado de registros que agrupan los valores de las variables de entrada y las variables de respuesta), a través de la obtención de datos disponibles en artículos científicos,

Figura 17: Metodología del estudio



Fuente: construcción propia

relacionados a los estudios experimentales del comportamiento mecánico de concretos FRC sometidos a tracción directa y la inclusión de algunos datos experimentales del laboratorio de materiales y estructuras de la Escuela Colombiana de Ingeniería, obtenidos con anterioridad al inicio del presente estudio.

Al mismo tiempo, se definen los tipos de arquitectura de RNA y se diseñan las mismas de acuerdo a las variables de entrada y variables de salida. Del mismo modo, se usan tres tipos de arquitectura por variable de salida (dos variables de salida): capacidad de absorción de energía y alargamiento post-fisuración. Esta etapa incluye la definición del método de evaluación que permite identificar los modelos más ajustados.

Una vez diseñadas las RNA y consolidado el *dataset*, se entrenan y validan las RNA para seleccionar seis modelos adecuados (uno por variable de salida por cada tipo de arquitectura). La selección se hace de acuerdo a los resultados de los parámetros de evaluación.

Posteriormente, se hace la estimación de variables de salida, ingresando a los modelos de RNA seleccionados, un listado de combinaciones de valores para las variables de entrada. Estas combinaciones contendrán los valores de una matriz cementicia de altas prestaciones desarrollada en Colombia (Abellán et al., 2020a), así como fibras accesibles en el mercado nacional. De allí, se obtiene un *dataset* que agrupa registros de variables de entrada y resultados de las variables de salidas estimadas.

En este punto, se asignan los costos de los componentes, se calculan los costes de cada mezcla y se seleccionan aquellas con mayor probabilidad de éxito bajo los criterios definidos para sus propiedades mecánicas deseadas: alargamiento postfisuración superior a 0.3%, capacidad de absorción de energía superior a 50 kJ/m<sup>3</sup> y el menor coste posible.

Todas las actividades de procesamiento de datos se trabajan en R, haciendo uso de dos servidores del laboratorio de sistemas de la Escuela Colombiana de Ingeniería, dos servidores asignados por OSIRIS y tres equipos adicionales de uso personal.

#### **4.1 Construcción del conjunto de datos**

La consolidación de los datos consiste en la reunión del mayor número posible de mezclas de HPFRCC y las propiedades mecánicas observadas para

endurecimiento por deformación. Se requiere un número considerable de datos para garantizar seriedad en el del modelo a desarrollar. El total de datos esta conformado por datos procedentes de diversas publicaciones científicas tabulados y recopilados para el proyecto. En total se hace referencia a 77 artículos que aportan un total de 490 observaciones. El total de observaciones tienen una revisión inicial para seleccionar aquellas que contienen el mínimo de datos según las variables necesarias para el estudio que se plantea.

La consolidación del conjunto de datos se enfoca en el análisis inicial de los mismos por cada una de las variables de respuesta con el fin de identificar y eliminar datos anómalos o atípicos y, de esta manera, obtener el conjunto de datos definitivo. Por otro lado, la limpieza de datos se realiza por variable de entrada en relación a cada variable de respuesta de manera independiente, por lo que al finalizar el proceso se tienen dos conjuntos de datos definitivos, uno para el alargamiento postfisuración y otro para la capacidad de absorción de energía.

Los conjuntos de datos definitivos se dividen, cada uno, en dos partes: 1) *Training set* y 2) *Test set*, con los que se realiza el entrenamiento y validación de las RNA, respectivamente.

## **4.2 Arquitecturas de RNA, entrenamiento, validación y selección de modelos**

El diseño consiste en la esquematización de tres tipos de RNA y en cada una se definen: 1) número de neuronas de capa de entrada, 2) número de neuronas en la capa o capas ocultas, 3) la variable de salida o respuesta, 4) la función de pérdida (*loss function*), 5) algoritmo de aprendizaje, y 6) función de activación. Los tres tipos de arquitectura (para cada variable de respuesta de manera independiente) que se usan en el presente estudio son:

- 1) Red de una capa oculta Feed Forward (OHLFF)
- 2) Red de dos capas ocultas Feed Forward (THLFF)
- 3) Red Deep Feed Forward (DFF)

Se realiza el entrenamiento (usando el *training set*) mediante validación cruzada tipo K-fold para evitar los problemas de sobreajuste. Los resultados de esta primera parte permiten conocer la cantidad adecuada de neuronas por capa oculta. Posteriormente, se hace la validación del modelo (usando el *test set*) y de esta manera se conocen los resultados definitivos del modelo (uno por cada arquitectura): error, aleatorio de pesos iniciales y número de veces que se requiere pasar los datos por el modelo de entrenamiento (número de epoch).

Al final, se selecciona un modelo de RNA para el alargamiento postfisuración y otro para la capacidad de absorción de energía, que presentan el menor error (MAE, RMSE).

### **4.3 Identificación de máximos y mínimos**

Un *dataset* construido con todas las posibles combinaciones de los valores que pueden tomar las variables de entrada para el HPRFCC se ingresa a cada RNA seleccionada con el fin de procesarlo y estimar los valores de respuesta. En otras palabras, la predicción del alargamiento postfisuración y capacidad de absorción de energía. Las variables X (X1 a X10 y X35) correspondientes al concreto se toman de una mezcla previamente optimizada con componentes colombianos (Abellán et al., 2020a). Adicionalmente, las combinaciones de fibras para la optimización son fibras disponibles en el mercado colombiano

Finalmente, mediante un procedimiento de identificación de valores máximos para las variables de respuesta con los mínimos valores de coste permite identificar las mezclas con mayor probabilidad de éxito.

## 5. Desarrollo de la metodología, resultados y contribución

### 5.1 Diseño, entrenamiento y validación de modelos de RNA

#### 5.1.1 Análisis del conjunto de datos de dosificaciones

Para el desarrollo de los modelos de RNA se recolectan 490 datos de dosificaciones de UHPFRC y HPFRCC que detallan el comportamiento a tracción directa de estas. (Es importante resaltar que los estudios científicos consultados fueron publicados durante los últimos 20 años). Asimismo, la base de datos que se construye contempla dosificaciones con uno o dos tipos de fibra (metálica y sintética).

La tabla Tabla 3 presenta el detalle de las variables que conforman la base de datos construidas. Las variables X1 a X35 representan cada uno de los componentes de las dosificaciones y algunas de sus características; mientras que las variables Y1 y Y2 representan las propiedades mecánicas objeto de estudio: endurecimiento por deformación (alargamiento postfisuración) y capacidad de absorción de energía, respectivamente. Del mismo modo, las características de los dos tipos de fibra (sea metálica y/o sintética) están definidas en dos grupos de variables: de X13 a X23 para la fibra 1 y de X24 a X34 para la fibra 2. Existen tres tipos de situaciones, en cuanto a la fibra, que se pueden presentar en las dosificaciones: 1) Incluyen solo un tipo de fibra (identificada en las variables de fibra 1), 2) Incluyen dos tipos de fibra (identificadas en las variables de fibra 1 y fibra 2), y 3) dosificaciones que no incluyen fibras.

*Tabla 3: Variables incluidas en la base de datos*

Variable	Descripción	Tipo	Unidad
X1	Contenido de cemento	Numérica	kg/m <sup>3</sup>
X2	Contenido de humo de sílice	Numérica	kg/m <sup>3</sup>
X3	Contenido de materiales cementantes (a excepción del cemento y la micro sílice)	Numérica	kg/m <sup>3</sup>
X4	Contenido de harina de cuarzo	Numérica	kg/m <sup>3</sup>
X5	Contenido de agua	Numérica	kg/m <sup>3</sup>
X6	Contenido de superplastificante	Numérica	kg/m <sup>3</sup>
X7	Contenido de arena	Numérica	kg/m <sup>3</sup>
X8	Contenido de agregado grueso	Numérica	kg/m <sup>3</sup>
X9	Tamaño máximo del agregado	Numérica	µm
X10	Relación en peso de agua/binder <sup>1</sup>	Numérica	NA

1 Binder: conglomerado de materiales cementosos en la mezcla

X11	Contenido total de fibras	Numérica	% vol
X12	Factor fibra total ( $\chi_T$ ) definido como $\chi_T = \chi_{f1} + \chi_{f2}$	Numérica	%
X13	Fibra 1 metálica recta (1=presente, 0=ausente)	Dicotómica	NA
X14	Fibra 1 metálica acabada en ganchos (1=presente, 0=ausente)	Dicotómica	NA
X15	Fibra 1 metálica retorcida (1=presente, 0=ausente)	Dicotómica	NA
X16	Fibra 1 polietileno (1=presente, 0=ausente)	Dicotómica	NA
X17	Fibra 1 polipropileno (1=presente, 0=ausente)	Dicotómica	NA
X18	Fibra 1 polivinilo de alcohol (1=presente, 0=ausente)	Dicotómica	NA
X19	Resistencia a la tracción fibra 1	Numérica	MPa
X20	Longitud de la fibra 1 ( $l_{f1}$ )	Numérica	mm
X21	Diámetro de la fibra 1 ( $d_{f1}$ )	Numérica	mm
X22	Contenido de fibra 1 ( $V_{f1}$ )	Numérica	% vol
X23	Factor fibra 1 ( $\chi_{f1}$ ) definido como $\chi_{f1} = V_{f1} \times l_{f1} d_{f1}$	Numérica	%
X24	Fibra 2 metálica recta (1=presente, 0=ausente)	Dicotómica	NA
X25	Fibra 2 metálica acabada en ganchos (1=presente, 0=ausente)	Dicotómica	NA
X26	Fibra 2 metálica retorcida (1=presente, 0=ausente)	Dicotómica	NA
X27	Fibra 2 polietileno (1=presente, 0=ausente)	Dicotómica	NA
X28	Fibra 2 polipropileno (1=presente, 0=ausente)	Dicotómica	NA
X29	Fibra 2 polivinilo de alcohol (1=presente, 0=ausente)	Dicotómica	NA
X30	Resistencia a la tracción fibra 2	Numérica	MPa
X31	Longitud de la fibra 2 ( $l_{f2}$ )	Numérica	mm
X32	Diámetro de la fibra 2 ( $d_{f2}$ )	Numérica	mm
X33	Contenido de fibra 2 ( $V_{f2}$ )	Numérica	% vol
X34	Factor fibra 2 ( $\chi_{f2}$ ) definido como $\chi_{f2} = V_{f2} \times l_{f2} d_{f2}$	Numérica	%
X35	Resistencia a la compresión del concreto	Numérica	MPa
Y1	Endurecimiento por deformación ( $\varepsilon_{pc}$ )	Numérica	%
Y2	Capacidad de absorción de energía ( $g$ )	Numérica	kJ/m <sup>3</sup>

*Fuente: construcción propia*

### 5.1.1.1 Comportamiento de las variables independientes

Los 490 datos obtenidos, vistos de manera independiente, pueden proporcionar información de los valores que toman y la distribución que poseen. Las figuras 18, 19, 21, 23 y 24 muestran gráficamente la dispersión de los valores por cada variable y los posibles datos atípicos (señalados como puntos rojos); no obstante,

la identificación de estos datos debe hacerse al relacionar estas variables frente a las de respuesta.

El contenido de cemento está expresado en kilogramos por metro cúbico. Toma valores entre 211.6 y 1412.9, la media es de 765.7 y la mediana de 791.6. El 75% de los datos se encuentran entre el valor mínimo y 820. La mayor dispersión de los datos se observa para aquellos valores por debajo de la mediana, sin embargo, se evidencian varios posibles puntos atípicos mayores a 820. Se marcan como datos atípicos aquellos por debajo de 310 y superiores a 1100. La Figura 18 X1 presenta gráficamente los resultados mencionados.

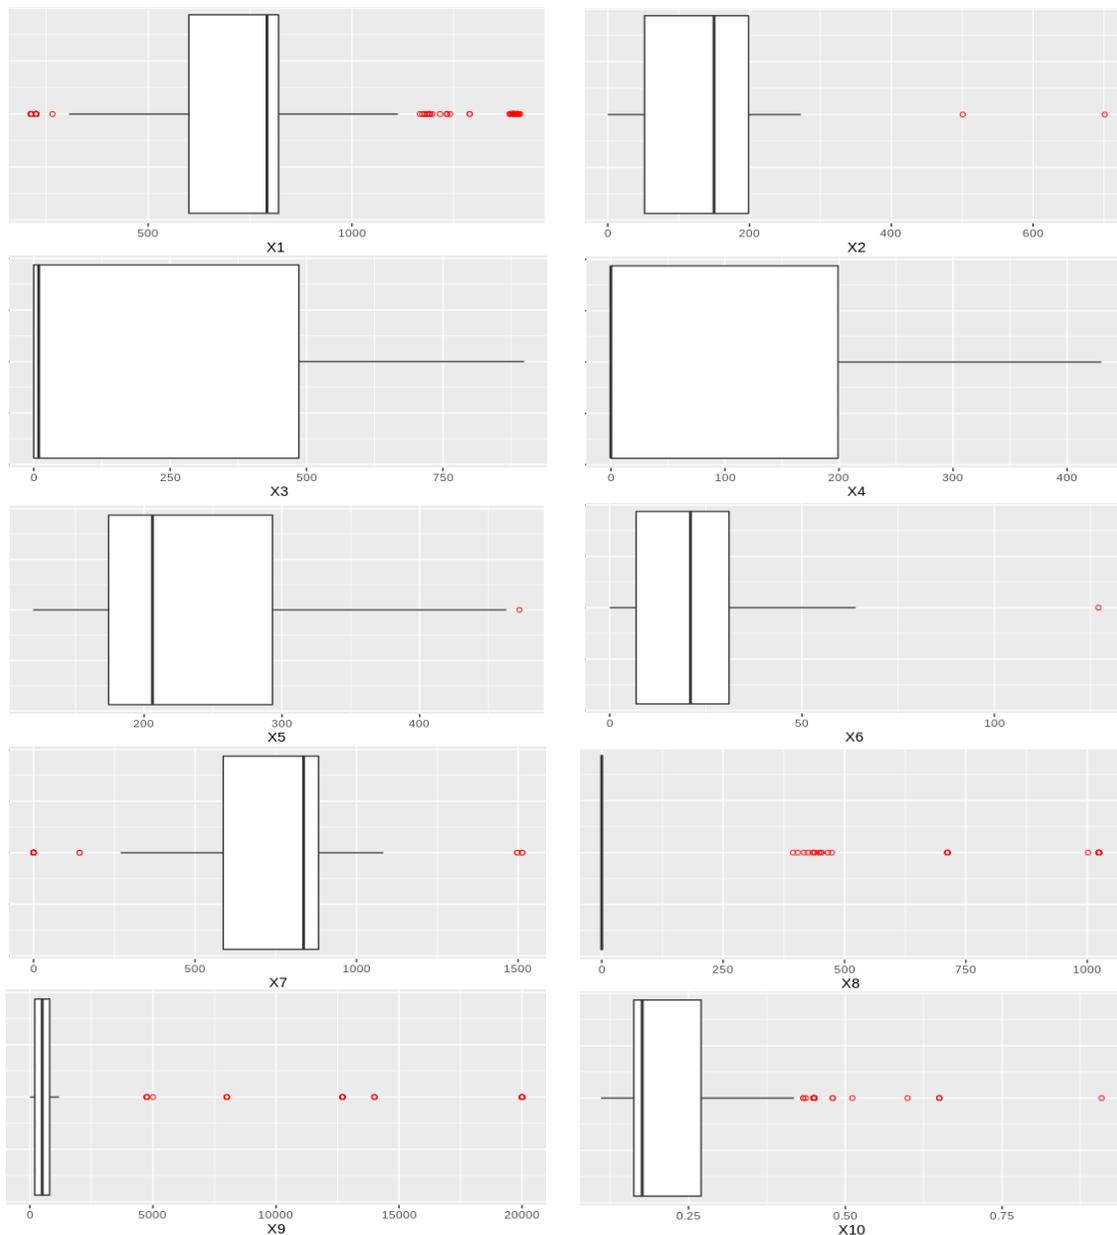
El humo de sílice está expresado en kilogramos por metro cúbico. Los valores oscilan entre 0 y 701.3. La media de los valores es de 126 y la mediana de 150. Tres cuartas partes de los datos son menores a 198.7. Esta variable no presenta una dispersión marcada, aunque, se observan datos posiblemente atípicos que están por encima de 270. La Figura 18 X2 presenta gráficamente los resultados mencionados.

Asimismo, la cantidad de materiales cementantes se miden (en el conjunto de datos construido) en kilogramos por metro cúbico. El valor mínimo encontrado para esta variable es de 0 y el valor máximo de 898.7. La media para esta variable se calcula en 225.08 y una mediana de 9.21, lo que evidencia una marcada dispersión de datos pese a que no se registran datos atípicos. El 50% de los datos están por debajo de 9.24 y un 25% adicional a estos datos están entre 9.24 y 485.9. La Figura 18 X3 presenta gráficamente estos resultados.

El contenido de harina de cuarzo en las dosificaciones está medido en kilogramo por metro cúbico. La cantidad mínima en las dosificaciones recolectadas es de 0 y el valor máximo observado es de 430. La media y mediana de las observaciones se calculan en 84.09 y 0, respectivamente. El 50% de los datos es cero, por lo que la dispersión en esta variable se presenta en el 50% de los datos restantes. La Figura 18 X4 presenta gráficamente estos resultados.

La cantidad de agua en las dosificaciones recolectadas está medida en kilogramos por metro cúbico. La menor cantidad de agua en las dosificaciones es de 119.4 mientras que la mayor cantidad se observa en 474.4. El promedio de cantidad de agua para el total de observaciones es de 241.1, mientras que la mediana es de 206. Se evidencia una mayor dispersión de valores en la segunda mitad de los datos, en los cuales se presentan posibles datos atípicos. El 75% de los datos toman valores menores a 291.1. La Figura 18 X5 presenta gráficamente estos resultados.

Figura 18: Comportamiento de las variables X1 a X10 (matriz de concreto).



Fuente: Construcción propia

Las dosificaciones presentan una cantidad de superplastificante que varía entre 0 y 127.04 kilogramos por metro cúbico (ambos datos atípicos). La media y la mediana de los datos observados se encuentran en 21.850 y 21, respectivamente. Estos resultados evidencian una baja dispersión de los valores que puede tomar esta variable, adicional a lo anterior, se observa que el 75% de los datos se

encuentran entre el valor mínimo y 31.02. Tanto el valor máximo como el mínimo del conjunto de datos en esta variable son incoherentes de acuerdo a lo que representan. La Figura 18 X6 presenta gráficamente estos resultados.

El contenido de arena en las dosificaciones está medido en kilogramo por metro cúbico, este varía entre 0 y 1512.9. La media de la cantidad de este componente se observa en 751.1, mientras que la mediana es de 836. El 75% de los datos están por debajo de 882.6. Se observa una leve concentración de los datos que adopta esta variable entre la 836 y 882, lo que evidencia una mayor dispersión en los valores menores a estos. Se observan posibles datos atípicos en las observaciones con valores menores a 60 y superiores a 1100. Figura 18 X7 presenta gráficamente estos resultados.

El agregado grueso, otro de los componentes que se incluye como variable en las dosificaciones recolectadas, se encuentran en su inmensa mayoría sobre cero, es decir, una amplia proporción de dosificaciones recopiladas no incluyen agregado grueso, el valor mínimo es de cero y el máximo de 1024. La media de los datos se calcula en 46.54, mientras que la mediana es 0. La concentración de datos en cero es tal que cualquier valor diferente a cero es identificado como dato atípico. La Figura 18 X8 presenta gráficamente estos resultados.

El tamaño del agregado, medido en micrómetros, toma valores entre 0 y 20.000. La media de las observaciones se calcula en 1407, mientras que la mediana en 500. Pese al valor de la media, la mayoría de los datos se encuentran distribuidos entre 0 y 1000 por lo que los datos superiores a este valor podrían considerarse atípicos. Figura 18 X9 presenta gráficamente estos resultados.

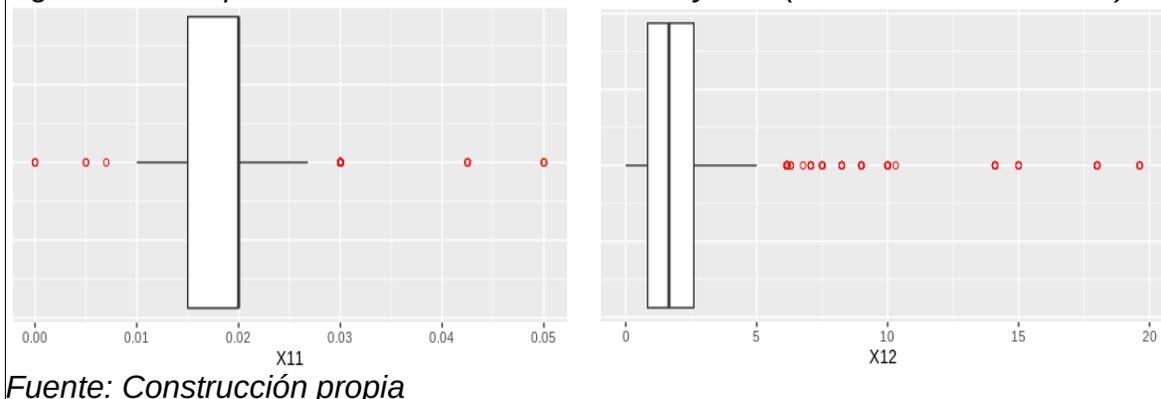
Finalmente, la relación agua/binder en la mezcla observada es otra de las variables de entrada contempladas en el conjunto de datos. Este valor no se presenta con una unidad específica de medida, es una proporción de la cantidad de agua en la mezcla frente a la cantidad de materiales cementantes. Los valores que toma esta variable se encuentran entre un mínimo de 0.1105 y un máximo de 0.9088 (Valores por encima de 0.3 no son normales para este tipo de concreto). No obstante, los datos se encuentran agrupados entre el mínimo y un valor de 0.40. Los valores observados fuera de este rango podrían considerarse atípicos. Sin embargo, se debe tener en cuenta que esta variable es el resultado de la relación de variables ya listadas. La media de estas observaciones se encuentra en 0.2264 y la mediana en 0.1760. La Figura 18 X10 presenta gráficamente estos resultados.

En cuanto a las variables que cuantifican el contenido de fibra en la mezcla de concreto se tienen dos medidas: 1) El total de fibra en porcentaje del volumen total

de la mezcla y 2) El factor de fibra total. Esta última variable está en función de los diámetros, las longitudes y volúmenes de las fibras que hacen parte de la dosificación.

El volumen total de la fibra se encuentra entre los valores de 0 y 5% (0.05), siendo más comunes aquellas dosificaciones con contenidos entre 1.5 (0.015) y 2% (0.02). La mediana de estos datos es de 2 (0.02) y la media de 1,85 (0.0185). En la Figura 19 X11 se identifican como posibles datos anómalos los porcentajes menores a 1% (0.01) y mayores a 2.7% (0,027).

*Figura 19: Comportamiento de las variables X11 y X12 (contenido total de fibra)*



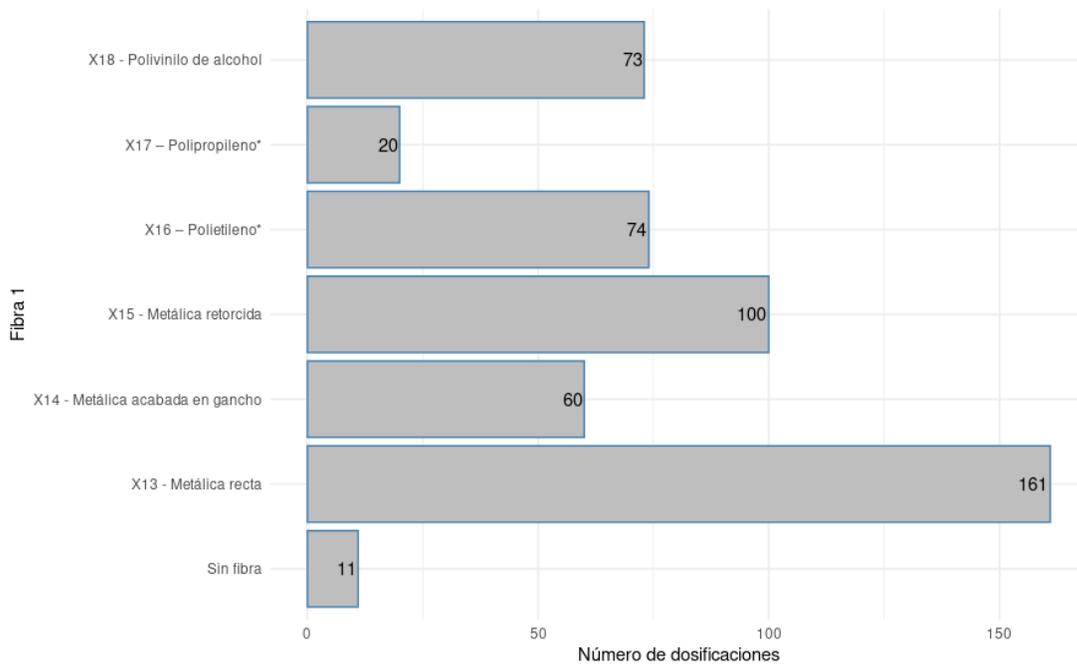
*Fuente: Construcción propia*

El factor total de fibra varía entre 0 y 19.625, presentando una media de 2,711 y mediana de 1,65. La mayoría de los datos observados se agrupan entre los valores 0 y 5, aunque el 75% de los valores son menores o iguales a 2.6. La Figura 19 X12 presenta posibles datos atípicos para aquellos valores superiores a 5.

Las variables X13 a X18 incluyen información sobre la existencia de fibra 1 en las dosificaciones de concreto del conjunto de datos. Se trata de variables dicotómicas, por lo que solo toman dos posibles valores: 1 o 0. Debido a esto, no es válido hacer un análisis de dispersión; sin embargo, estos datos permiten conocer qué cantidad de dosificaciones incluyen cada tipo de fibra. Las seis variables son excluyentes, esto significa que en una dosificación únicamente una de ellas puede tomar el valor 1. La Figura 20 muestra la cantidad de observaciones que contienen cada uno de los tipos de fibra disponibles. Las fibras metálicas son las de mayor frecuencia en las dosificaciones: la recta está presente en 161, la metálica retorcida en 100 y la metálica acabada en gancho está presente en 60. En el caso de las fibras sintéticas: la de mayor presencia es la de polietileno con 74 dosificaciones, seguida de polivinilo de alcohol con 73 y, finalmente, la fibra de polipropileno es la de menor cantidad con 20. Un total de 11

dosificaciones no incluyen fibra. Cabe resaltar que se encontraron 9 con una fibra que es combinación de polietileno y polipropileno que fueron sumadas a ambos tipos de fibra con un valor de 0.5.

Figura 20: Cantidad de dosificaciones con fibra 1.



\* 9 dosificaciones tienen una fibra que es combinación de polietileno y polipropileno

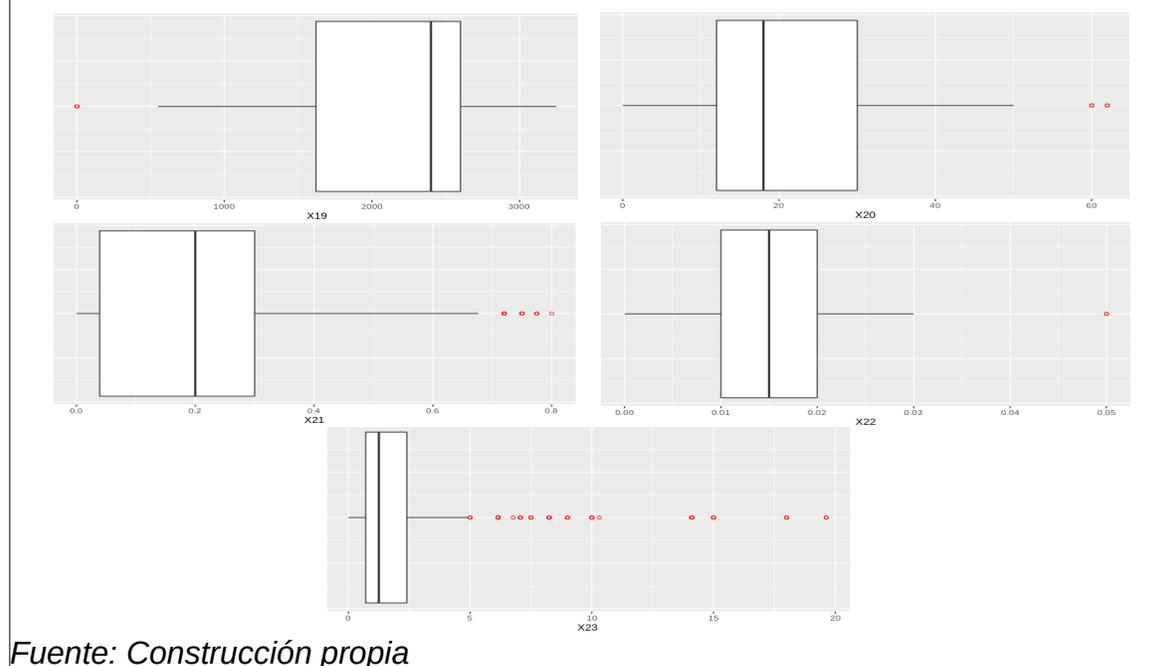
Fuente: Construcción propia

Las variables que representan las propiedades de la fibra 1 en las dosificaciones del concreto, se presentan gráficamente en la Figura 21. En esta se incluye la resistencia a la tracción, longitud y diámetro de fibra, contenido de fibra del total del volumen y el factor de fibra. Los valores que toman estas variables no permiten reconocer datos atípicos (aunque se reflejen gráficamente) debido a que los valores corresponden a diferentes tipos de materiales y características físicas de la fibra. Sería necesario separar las variables X19 a X23 por cada tipo de fibra (ver Figura 20) lo cual no se realiza en el dataset para no aumentar la cantidad de variables de entrada. No obstante, los datos se analizan a fin de observar el rango de variabilidad en cada una.

La resistencia a la tracción de la fibra 1, medida en mega pascales, varía entre 0 y 3250, con una media de 2153 y mediana de 2400. El 50% de los valores están entre 2400 y 3250. El dato mínimo de 0 corresponde a las dosificaciones que no

incluyen fibra como parte de sus componentes. La Figura 21 X19 presenta el comportamiento de los datos de esta variable.

*Figura 21: Comportamiento de las variables X19 a X23 (detalles de la fibra 1).*



*Fuente: Construcción propia*

La longitud de la fibra 1, cuantificada en milímetros, tiene valores entre un mínimo de 0 (esto es que no hay fibra) y un máximo de 62. Los datos presentan una media y mediana de 20.83 y 18, respectivamente. El 75% de las dosificaciones presentan fibras con longitud menor o igual a 30, esto significa que existe un número menor de fibras con una longitud superior a 30mm. La Figura 21 X20 presenta el comportamiento de los datos de esta variable.

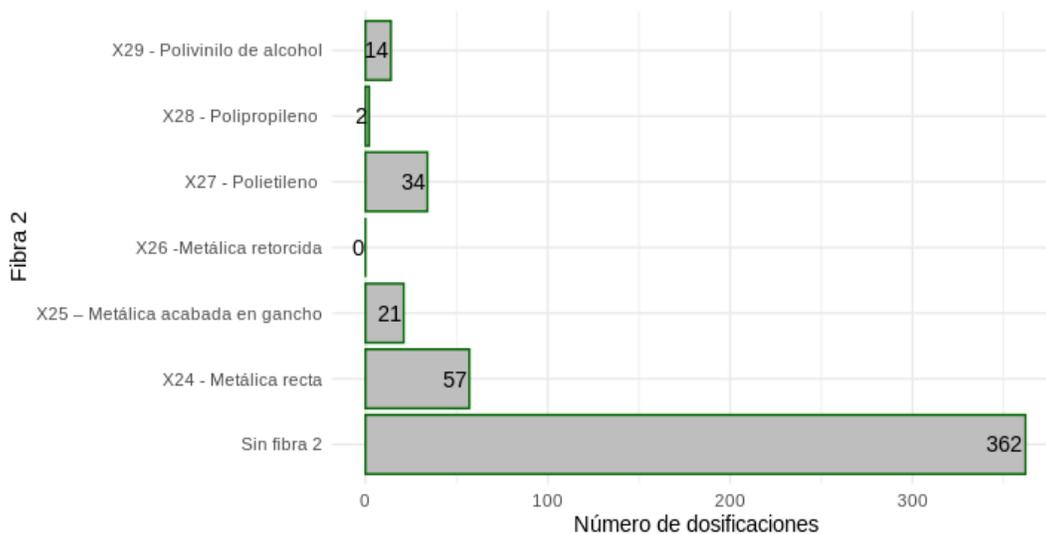
El diámetro de la fibra 1, medida en milímetros, toma valores entre 0 y 0.8. La media de los datos se observa en 0.2378 mientras que la mediana es de 0.2. El 75% de los datos se encuentra entre 0 (ausencia de fibra) y 0.3, por lo que la mayor dispersión de los datos se observa en valores de diámetro superiores a 0.3. La figura Figura 21 X21 presenta el comportamiento de los datos de esta variable.

El contenido de fibra 1, en porcentaje del volumen total de la mezcla, varía entre 0 y 5% (0.05). No obstante, la mayor concentración de valores del volumen de la fibra 1 se encuentra entre 0 y 3% (0.03). La media de los datos es de 1,596% (0.01596), mientras que la mediana es de 1,5% (0.015). La figura Figura 21 X22 presenta el comportamiento de los datos de esta variable.

Finalizando con esta figura, el factor de fibra 1 está en función de las variables X20, X21 y X22, la cual toma valores entre 0 y 19.62. La media y mediana se observan en 2.47 y 1.25, respectivamente. El 75% de los datos se encuentran entre 0 y 2.4. Aunque, gráficamente se marcan datos atípicos aquellos valores superiores a 5, estos no se consideran como tal debido a que estos datos son posibles dadas las diferentes características físicas de cada tipo de fibra. La figura Figura 21 X23 presenta el comportamiento de los datos de esta variable.

Por otra parte, las variables X24 a X29 contienen la información del tipo de fibra 2 que hacen parte de las dosificaciones de concreto del conjunto de datos, al igual que las variables X13 a X18, estas solo toman dos posibles valores: 1 o 0. El análisis que se realiza permite conocer la cantidad de dosificaciones que contienen dos tipos de fibra. Las seis variables también son excluyentes, solo una de ellas puede tomar el valor 1. La Figura 22 presenta gráficamente los datos de fibra dos en las dosificaciones.

Figura 22: Cantidad de dosificaciones con fibra 2.



Fuente: Construcción propia

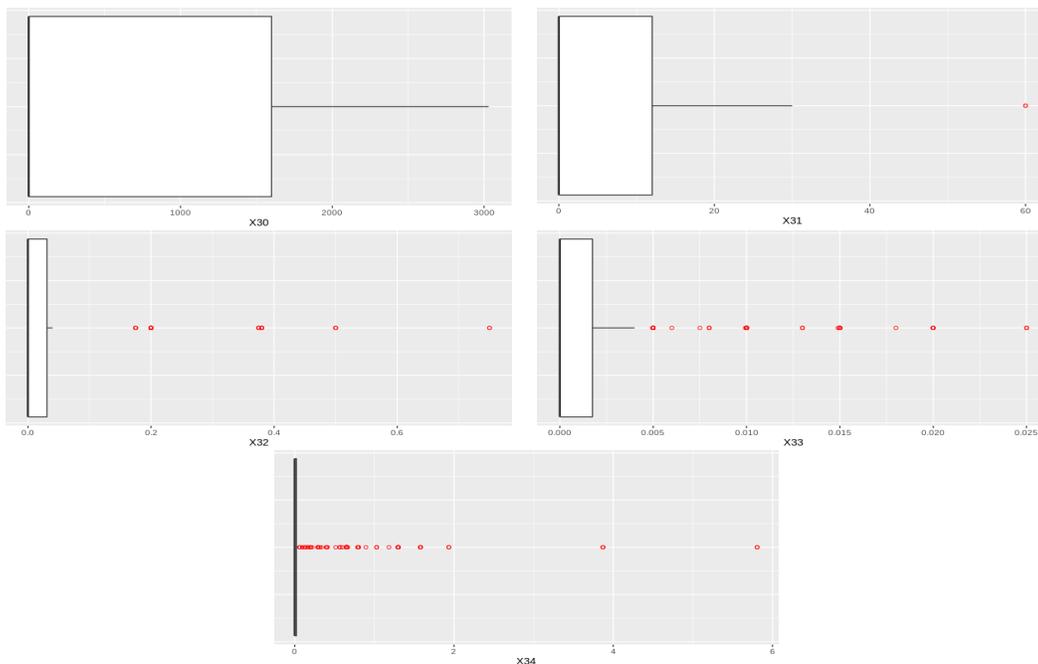
Un total de 128 dosificaciones incluyen dos tipos de fibras, 351 contienen un solo tipo de fibra (fibra 1) y 11 no contienen fibra (362 “sin fibra 2” en la Figura 22). Las fibras metálicas son las de mayor frecuencia como fibra 2 en las dosificaciones: la recta está presente en 57 y la metálica acabada en gancho está presente en 21. En el caso de la metálica retorcida, no aparece como fibra 2 en ninguna dosificación. Algunas dosificaciones pueden contener el mismo tipo de fibra, pero con diferentes propiedades físicas (longitud y diámetro). Las fibras sintéticas se

presentan como fibra 2: el polietileno en 34 dosificaciones, el polivinilo de alcohol en 14 dosificaciones y la fibra de polipropileno en 2 mezclas.

Las propiedades de la fibra 2 en las dosificaciones se presentan gráficamente en la Figura 23, (resistencia a la tracción, longitud y diámetro de fibra, contenido de fibra del total del volumen y el factor de fibra). Los resultados para estas variables están inclinados a cero, esto por el elevado número de observaciones que presentan una sola fibra. En cada variable presentada a continuación, un número cercano al 75% de los datos toman el valor de 0 (ausencia de fibra 2) por lo que la mediana también toma el valor de 0.

La resistencia a la tracción de las fibra 2, medida en mega pascales, alcanza un máximo de 3030. La media se observan en 665.9. Los datos diferentes a cero se encuentran relativamente dispersos. La Figura 23 X30 presenta el comportamiento de los datos de esta variable.

Figura 23: Comportamiento de las variables X30 a X34 (detalles de la fibra 2)



Fuente: construcción propia.

La longitud de la fibra 2, medida en milímetros, tiene valor máximo de 60. La media de los datos se calcula en 4.15. El 25% de los datos es menor a 30, por lo que en la gráfica los valores superiores a 30 los marca como atípicos. La Figura 23 X31 presenta el comportamiento de los datos de esta variable.

El diámetro de la fibra 2, expresada en milímetros, alcanza un máximo de 0.75. La media de los datos se observa en 0.045. Para esta variable aquellos valores superiores a la media se marcan como atípicos, sin embargo, esto obedece a que la mayoría de las fibras 2 son sintéticas, las cuales presentan un diámetro mucho menor que las metálicas. Los diámetros marcados como atípicos corresponden a datos de fibras metálicas. La Figura 23 X32 presenta el comportamiento de los datos de esta variable.

El porcentaje de contenido de fibra 2 (del volumen total de la mezcla) tiene un máximo de 2.5% (0.025). Pese a que gráficamente se marcan datos atípicos en volúmenes iguales o superiores al 0.5% (0.005), los mismos son posibles. La media de los datos es de 0.26% (0.002599). La Figura 23 X33 presenta el comportamiento de los datos de esta variable.

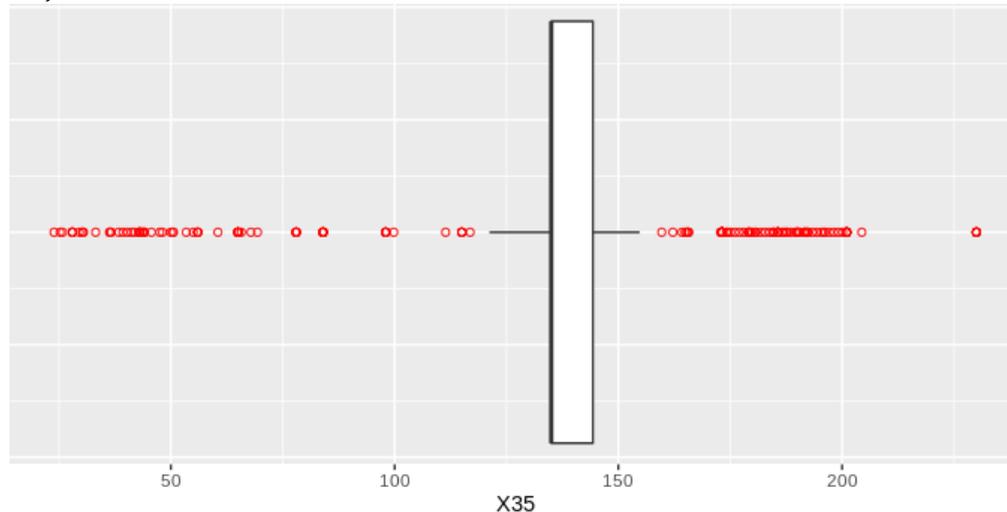
El factor de fibra 2 está en función de las variables X31, X32 y X33. Toma un máximo de 5.80 con una media de 0.2189. Los datos están concentrados cerca a cero, aunque existen datos superiores a 0.025 que gráficamente se marcan como atípicos. Empero, como estos valores dependen de los que toman otras tres variables, los valores observados son posibles. La Figura 23 X34 presenta el comportamiento de los datos de esta variable.

Finalmente, la última de las variables que hace parte del conjunto de datos es la resistencia a la compresión (X35) del concreto, medida en mega pascales. Hace referencia a una de las propiedades mecánicas del concreto, esto es, el comportamiento del concreto bajo fuerza de presión. Sus valores están entre un mínimo de 23.9 y un máximo de 230. La media y la mediana se calculan en 135.25 y 135 respectivamente, lo que implica que los datos tienen una dispersión relativamente uniforme. La mayoría de los valores se concentran entre los 120 y 160 (una proporción no menor al 75% de los datos). Gráficamente se observan posibles datos atípicos como aquellos que están por debajo de 120 y por encima de 160. La Figura 24 presenta el comportamiento de los datos de esta variable.

Mediante el análisis realizado a cada una de las variables se podrían identificar las posibles observaciones a excluir del conjunto de datos dada la presencia de datos atípicos. Cabe resaltar que la identificación de un dato atípico en una variable genera la supresión de la observación completa (las 37 variables). No obstante, es necesario comparar los datos en cada variable frente a las variables de respuesta, con el fin de observar con mayor detalle el comportamiento de los datos, pues no es posible identificar datos atípicos o anómalos sin verificar la relación de estos datos con las variables de respuesta. En el presente estudio, ambas variables de respuesta se evalúan independiente la una de la otra, por esto, se generan dos

conjuntos de datos, uno para cada variable de respuesta (con la exclusión de los datos anómalos), los cuales difieren según la cantidad de observaciones atípicas que se excluyen. Es decir, es posible que existan observaciones que resulten identificadas como datos atípicos para la variable Y1 y no para Y2 y viceversa.

Figura 24: Comportamiento de las variables X35 (resistencia a la compresión del concreto)



Fuente: construcción propia

### 5.1.1.2 Comportamiento de las variables dependientes

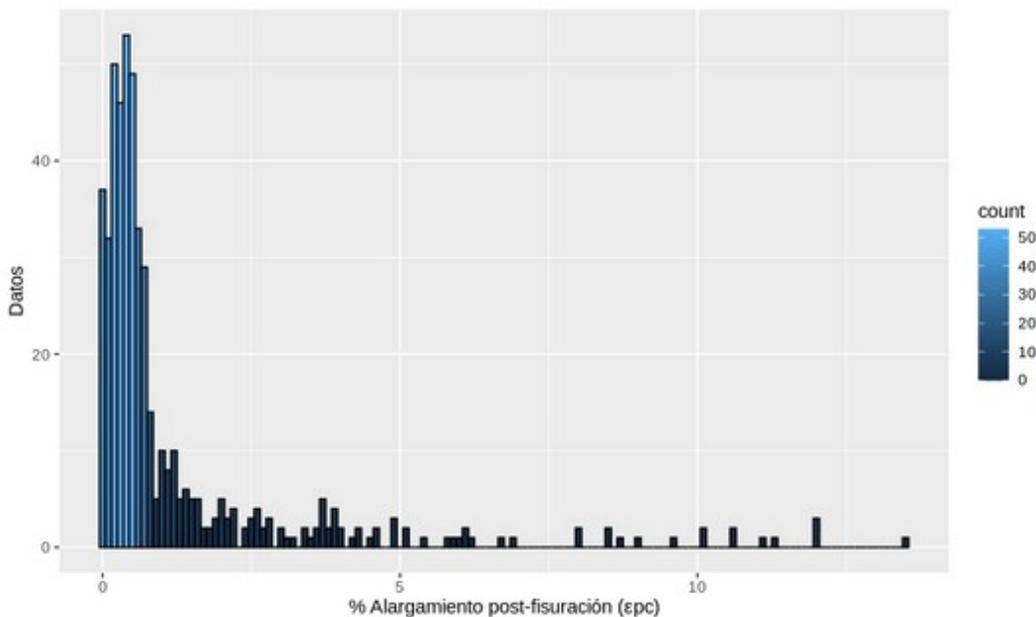
Las variables de respuesta toman valores que se observan dispersos. En el caso de Y1 los valores están entre el 0 y el 13,55% de alargamiento postfisuración. Sin embargo, el 80% de los datos se encuentran entre el 0 y 1,54%, registrando una media de 1,27% y mediana de 0,493%. Para la variable Y2, los valores se distribuyen entre 0 y 1278,13 kJ/m<sup>3</sup>, pero el 80% se encuentran en un intervalo de 0 y 95,73 kJ/m<sup>3</sup>, con una media de 87,12 kJ/m<sup>3</sup> y mediana de 33,53 kJ/m<sup>3</sup>.

Las figuras 25 y 26 muestran la situación de las variables de respuesta anteriormente descrita, en ambos casos se observan valores considerablemente alejados de la concentración principal de los datos. Esta situación afecta los resultados que pueda generar una RNA, por lo cual, es necesario hacer revisión de los datos a fin de identificar datos anómalos que pueden haberse generado en el proceso de tabulación de los datos de la literatura científica.

La dispersión de las variables de respuesta se puede cuantificar con la desviación estándar, la cual se calcula en 2,124 puntos porcentuales para Y1 y 177,544 kJ/m<sup>3</sup>

para Y2. Dada esta situación, se hace necesaria la revisión de las observaciones de las variables de respuesta frente a las variables independientes (X1 a X35). Es posible que el conjunto de observaciones contenga datos anómalos, por lo cual es pertinente depurar los datos con el fin de reducir su varianza. Así, realizar el entrenamiento de un modelo de RNA con la varianza actual de los datos puede conducir a obtener modelos con resultados de error bastante altos y la sobreoptimización del mismo orientado a al ajuste a los datos atípicos, situación que generaría un modelo inadecuado para predicción de las propiedades mecánicas para nuevas dosificaciones.

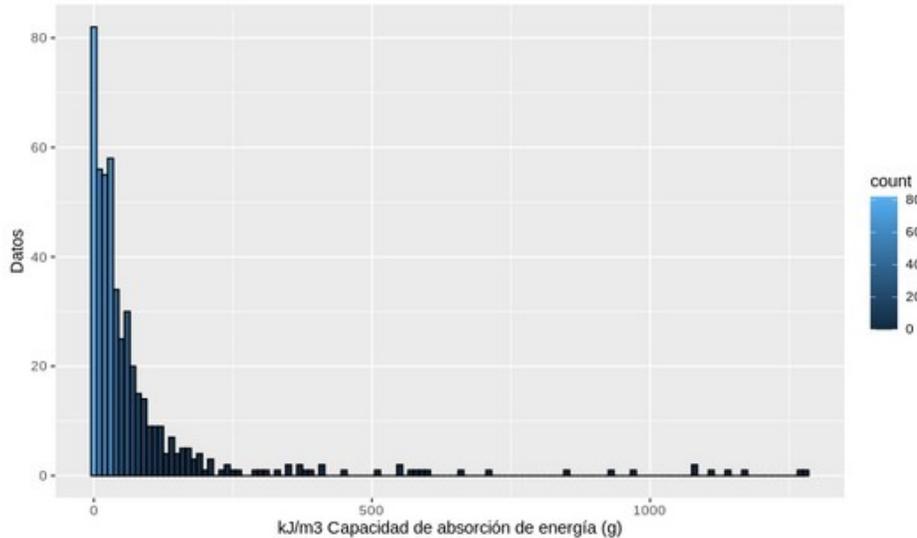
*Figura 25: Distribución de los datos variable de respuesta Y1. Endurecimiento por deformación*



*Fuente: Construcción propia*

Al analizar el comportamiento de las variables de entrada (o independientes) frente a las dos variables de respuesta se observa diferencias en la dispersión de los datos y la posible influencia de los valores que toman frente a los resultados de Y1 y Y2. El análisis que se realiza presenta información importante para un ajuste de la base de datos con la eliminación de datos anómalos.

Figura 26: Distribución de los datos variable de respuesta Y2. Capacidad de absorción de energía



Fuente: construcción propia

### 5.1.1.3 Comportamiento de las variables independientes frente al alargamiento post-fisuración (Y1) y la capacidad de absorción de energía (Y2)

Para las variables X1 a X12, que comprenden los componentes de la matriz de concreto y el contenido total de fibra, el comportamiento de la dispersión de los datos respecto a la variable de respuesta Y1 y Y2 se muestra en las figuras 27 y 28, respectivamente. La variable X se presenta en el eje vertical y la variable Y en el eje horizontal para mejorar la visualización de los datos. La elipse delimita los datos anómalos (aquellos puntos fuera de la elipse). En algunas variables se ve una considerable cantidad de datos con esta característica. A continuación se describe el detalle de los resultados del análisis mencionado para cada una de las variables.

Contenido de cemento (X1): presenta valores altos en Y1 y Y2 cuando su contenido está entre 500 y 750 kg/m<sup>3</sup>. Los límites de la elipse que encierra los datos de menos dispersos están entre 200 y 1300 kg/m<sup>3</sup> para el caso de Y1 y entre 50 y 1300 kg/m<sup>3</sup> para Y2. En lo relacionado a los valores de respuesta, en Y1 los límites están entre 0 y 1.8% (aproximadamente), mientras que para Y2 los límites se marcan entre 0 y 180 kJ/m<sup>3</sup>. Alrededor del contenido de 800 kg/m<sup>3</sup> se encuentra la mayor concentración de observaciones.

Contenido de humo de sílice (X2): los valores más altos para Y1 y Y2 se observan en contenidos entre 0 y 175 kg/m<sup>3</sup>. No obstante, alrededor de este último valor se presentan los valores más altos en ambas variables de respuesta. La elipse encierra valores entre 0 y 400 kg/m<sup>3</sup> para X2, en el caso de Y1 los límites son 0 y 2% y de 0 y 180 kJ/m<sup>3</sup> para Y2.

Contenido de materiales cementantes (X3): el alargamiento postfisuración y la capacidad de absorción de energía tienden a ser mayores a medida que el contenido de los materiales cementantes aumentan. Sin embargo, presenta una leve concentración de datos para X3=0 que toma valores relativamente altos para Y1. La elipse agrupa datos con valores para X1 entre 0 y 780 kg/m<sup>3</sup> (aproximadamente) frente a Y1 y entre 0 y 600 kg/m<sup>3</sup> para Y2. Los límites de las variables de respuesta se observan entre 0 y 3% aproximadamente para la variable Y1 y entre 0 y 180 kJ/m<sup>3</sup> para Y2.

Contenido de harina de cuarzo (X4): en las observaciones que toman el valor de 0 kg/m<sup>3</sup>, se presentan los mayores valores de Y1 y Y2, no obstante, muchos se marcan como posibles datos atípicos ya que están por fuera de la elipse (entre 0 y 2.5% para Y1 y entre 0 y 180 kJ/m<sup>3</sup> para Y2). La elipse encierra valores entre 0 y 200 kg/m<sup>3</sup> para X4 frente a la variable Y1 y entre 0 y 420 kg/m<sup>3</sup> frente a Y2.

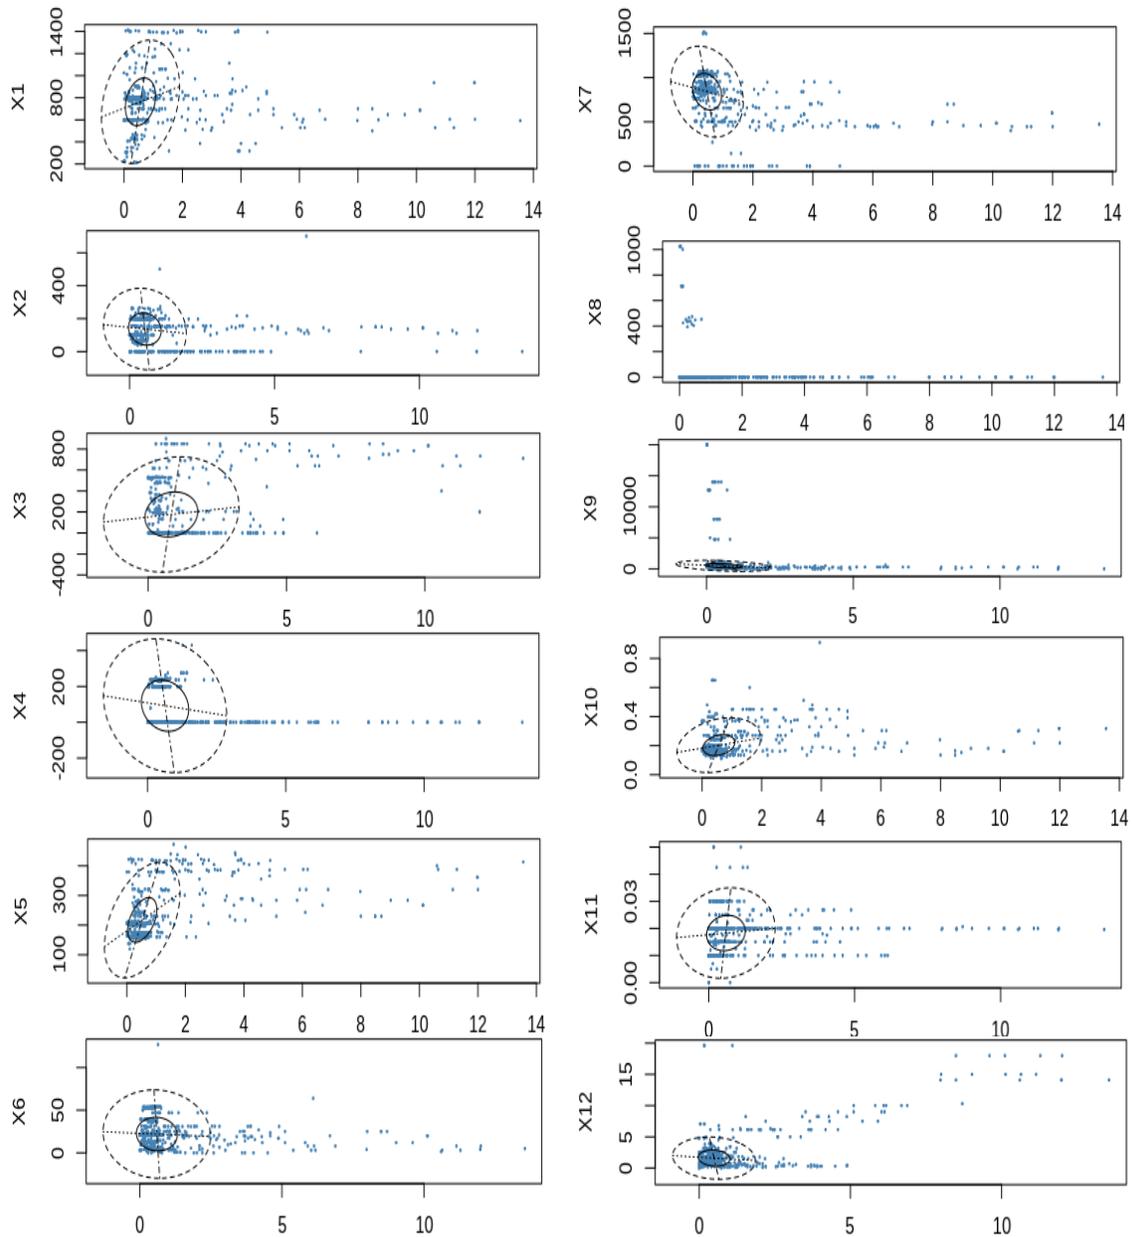
Cantidad de agua (X5): la mayor cantidad de observaciones se agrupan entre valores de 150 y 320 kg/m<sup>3</sup>, los cuales se relacionan a valores de Y1 menores a 1,8% y con valores que alcanzan hasta los 1300 kJ/m<sup>3</sup> para Y2. No existe una tendencia marcada para determinar el comportamiento de los valores altos de Y1 y Y2. Los valores dentro de la elipse en X5 se limitan entre 0 y 400 kg/m<sup>3</sup> frente a Y1 y entre 0 y 450 kg/m<sup>3</sup> para Y2. En el caso de los límites de las variables de respuesta estos se observan entre 0 y 1,8% para Y1 y entre 0 y 160 kJ/m<sup>3</sup> (aproximadamente) para Y2.

Cantidad de superplastificante (X6): se observan valores altos para Y1 cuando X6 toma valores entre 0 y 45 kg/m<sup>3</sup> y valores altos en Y2 cuando X6 se ubica en un rango entre 0 y 25 kg/m<sup>3</sup>. Los valores superiores a 2% en Y1 y superiores a 200 kJ/m<sup>3</sup> en Y2, se marcan como posibles datos atípicos. La elipse encierra datos que toman valores entre 0 y 75 kg/m<sup>3</sup> para el caso de X6.

Contenido de arena (X7): los valores cercanos a los 500 kg/m<sup>3</sup> tienen como respuesta un mayor alargamiento postfisuración y capacidad de absorción de energía. Los valores en Y1 superiores a 1.8% y en Y2 superiores a 180 kJ/m<sup>3</sup> se marcan como posibles observaciones atípicas. Frente a los valores que toma X7 se observan valores de 0 que también se marcan como posibles atípicos. La elipse encierra datos con valores de 0 a 1.8% para Y1, de 250 a 180 kJ/m<sup>3</sup> para

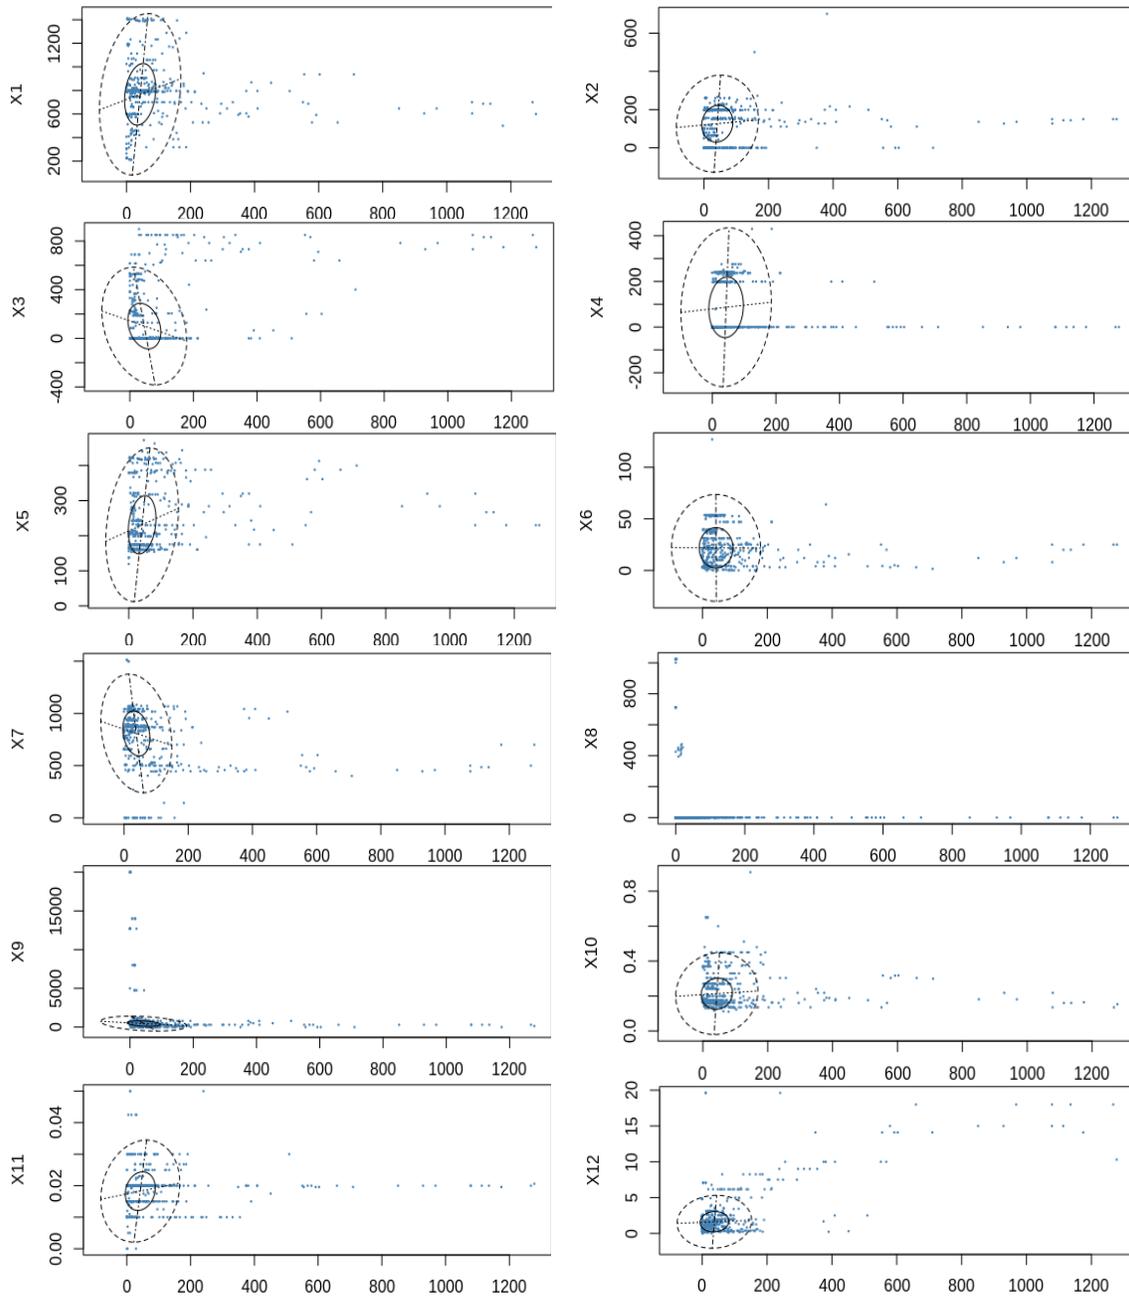
Y2 y de 250 (aproximadamente) a 1300 kg/m<sup>3</sup> (aproximadamente) en contenido de arena.

Figura 27: Variables X de la matriz de concreto frente a Y1



Fuente: construcción propia

Figura 28: Variables X de la matriz de concreto frente a Y2



Fuente: construcción propia

Contenido de agregado grueso (X8): dado que toma el valor de cero para una amplia mayoría de las dosificaciones, no es posible delimitar los datos atípicos mediante la elipse. No obstante, en las gráficas se observa que en X8 los valores

diferentes a cero podrían tomarse atípicos. Adicionalmente, para el valor de 0 en X8, Y1 puede tomar cualquier valor entre 0 y 13.55%, de igual forma, Y2 puede tomar cualquier valor entre 0 y 1300 kJ/m<sup>3</sup>.

Tamaño del agregado (X9): los valores cercanos a cero están relacionados a las respuestas más altas tanto en Y1 como en Y2. La mayor cantidad de datos en X9 toman valores en Y1 menores a 2% y menores a 180 kJ/m<sup>3</sup> en Y2 (ambos valores marcados como límite superior en las elipses de cada variable). En X9 el límite de la elipse está en 1200 micrómetros aproximadamente.

Relación agua/binder (X10): la concentración de valores en X10 está entre 0.1 y 0.45, aunque los valores más altos para el alargamiento postfisuración se observan en una relación agua/binder entre 0.1 y 0.2, mientras que los valores más altos en Y2 pueden darse también para valores 0.3 en esta relación. El límite de la elipse para Y1 es de 2%, en Y2 es de 180 kJ/m<sup>3</sup> y para X9 el límite es 0.4.

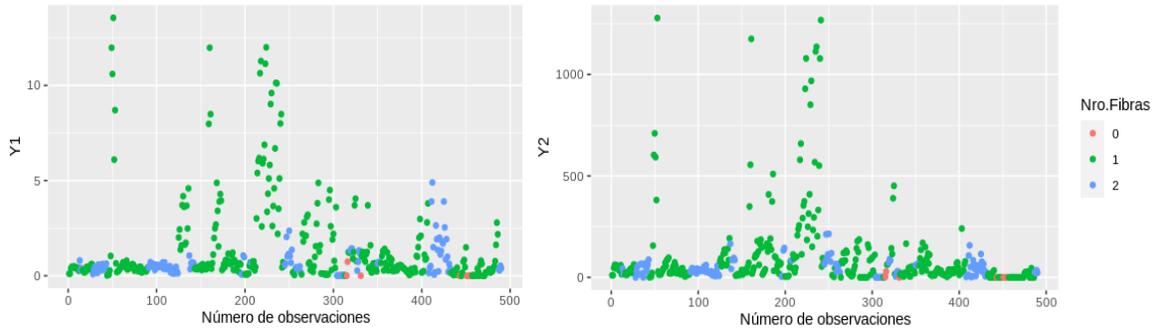
Volumen total de fibra (X11): los valores más altos de Y1 y Y2, en relación con el volumen total de la fibra, están ubicados para contenidos del 1 y 2%, siendo este último el valor de respuestas más tanto en Y1 como en Y2. Los límites de la elipse para la variable X11 se fijan en 0.5 y 3.5%. Para Y1 el límite es cercano al 2% y para Y2 el límite es 180 kJ/m<sup>3</sup>.

Factor fibra total (X12): la variable se relaciona a valores de respuesta altos en Y1 y Y2 cuando X12 está por encima de 10, esto es, alargamiento postfisuración superior a 7,5% y capacidad de absorción de energía superior a 600 kJ/m<sup>3</sup>. Se observan valores de Y1 entre 5 y 7,5% y valores de Y2 entre 200 y 400 kJ/m<sup>3</sup> cuando X12 está alrededor de 6 y 10 (aproximadamente). La mayor concentración de observaciones de X12 (menores a 5) presentan, con mayor frecuencia, respuestas en Y1 menores al 2% y en Y2 menores a 200 kJ/m<sup>3</sup>. Sin embargo, también se observan valores de factor total de fibra cercanos a cero que superan dichos valores. 0 y 5 son los límites dibujados para X12 en la elipse.

Las variables X13 a X18 y X24 a X29 incluyen la información de los tipos de fibra contenidos en las mezclas de concreto. La relación de estas variables con el alargamiento postfisuración y la capacidad de absorción de energía se observan en las figuras 29 y 30.

En general, los valores altos en Y1 y Y2 se dan para dosificaciones con una sola fibra. Para el caso de las mezclas con dos fibras, Y1 toma valores menores a 2,5% con la salvedad de cinco observaciones. En el caso de Y2 las dosificaciones de dos fibras no presentan capacidad de absorción de energía superior a 250 kJ/m<sup>3</sup>.

Figura 29: Comportamiento de Y1 y Y2 según la cantidad de fibras incluidas en la mezcla



Fuente: construcción propia

Al revisar por tipo de fibra (ver Figura 30) se observa con claridad que los valores más altos de Y1 y Y2 se dan para las mezclas que contienen únicamente polietileno (X16). Todos los resultados por encima del 5% en alargamiento postfisuración se dan para mezclas con esta fibra sintética. En el caso de la capacidad de absorción de energía los resultados por encima de 500 kJ/m<sup>3</sup> también se dan para las dosificaciones con fibra de polietileno, aunque se observa un dato un poco por encima de 500 kJ/m<sup>3</sup> que corresponde a fibra metálica retorcida.

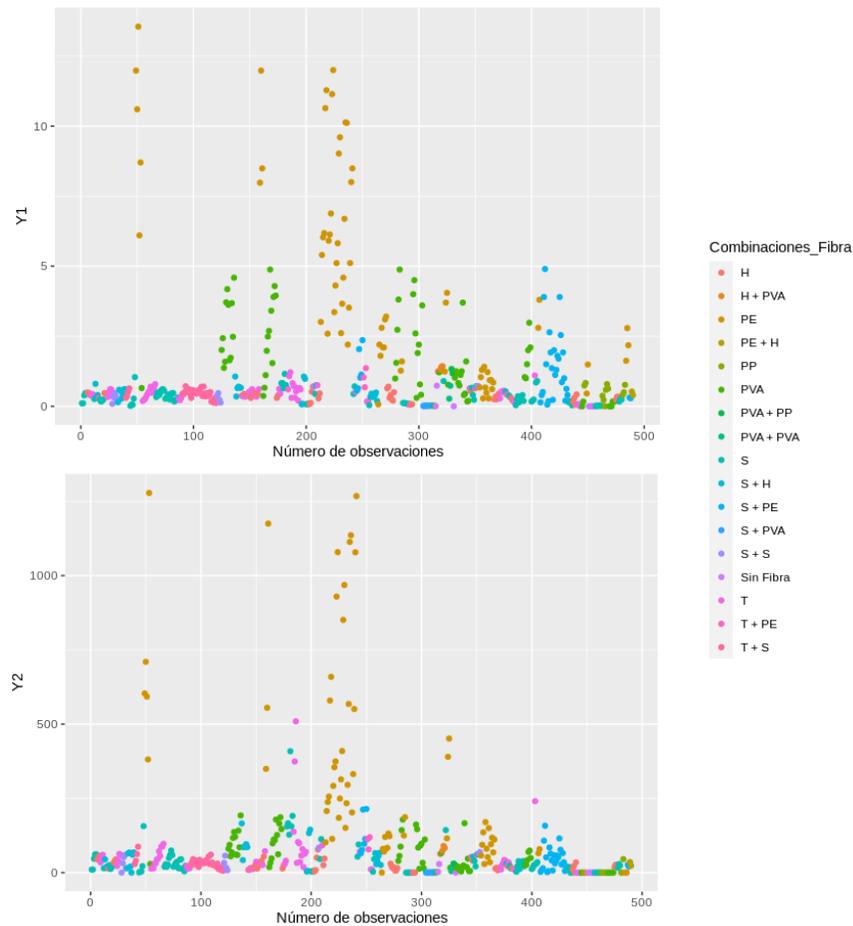
En el caso de las mezclas con dos fibras, la combinación de fibra metálica recta y polietileno (X13+X27 o X16+X24) genera los valores más altos en Y1 (entre 1,5 y 4,9%), aunque no al mismo nivel que alcanza el polietileno individualmente. En el caso de Y2, no se observa una diferencia significativa para algún tipo de las combinaciones de fibra.

La fibra metálica en dosificaciones de una sola fibra presenta resultados relativamente bajos (comparados con la sintética). El mayor valor de Y1 observado alcanza 1,24% para la fibra acabada en gancho, no obstante, no se observa diferencia marcada entre los tres tipos de fibras metálicas. Frente a Y2 tampoco se marcan diferencias resaltables, aunque se marcan tres observaciones con fibra retorcida que están por encima de la agrupación de las demás respuestas en esta variable.

Las mezclas con polipropileno (X17) presentan los valores más bajos de Y1 cuando se trata de fibra sintética, siendo el mayor valor observado de 0.83%. Frente a Y2, esta fibra generalmente tiene 0 kJ/m<sup>3</sup> como respuesta. Es de aclarar que el conjunto de datos solo incluye once observaciones con estas características. Para el polivinilo de alcohol (X18) los resultados para Y1 se

encuentran entre 0 y 4.88%. De 69 observaciones con esta única fibra, 46 están por encima del 1%. Para Y2 las respuestas están entre 0 y 200 kJ/m<sup>3</sup>.

Figura 30: Comportamiento de Y1 y Y2 según las combinaciones de fibra en cada dosificación.



*H: fibra metálica acabada en gancho, PE: Fibra sintética de polietileno, PP: fibra sintética de polipropileno, PVA: fibra sintética de polivinilo de alcohol, S: fibra metálica recta, T: fibra metálica retorcida.*

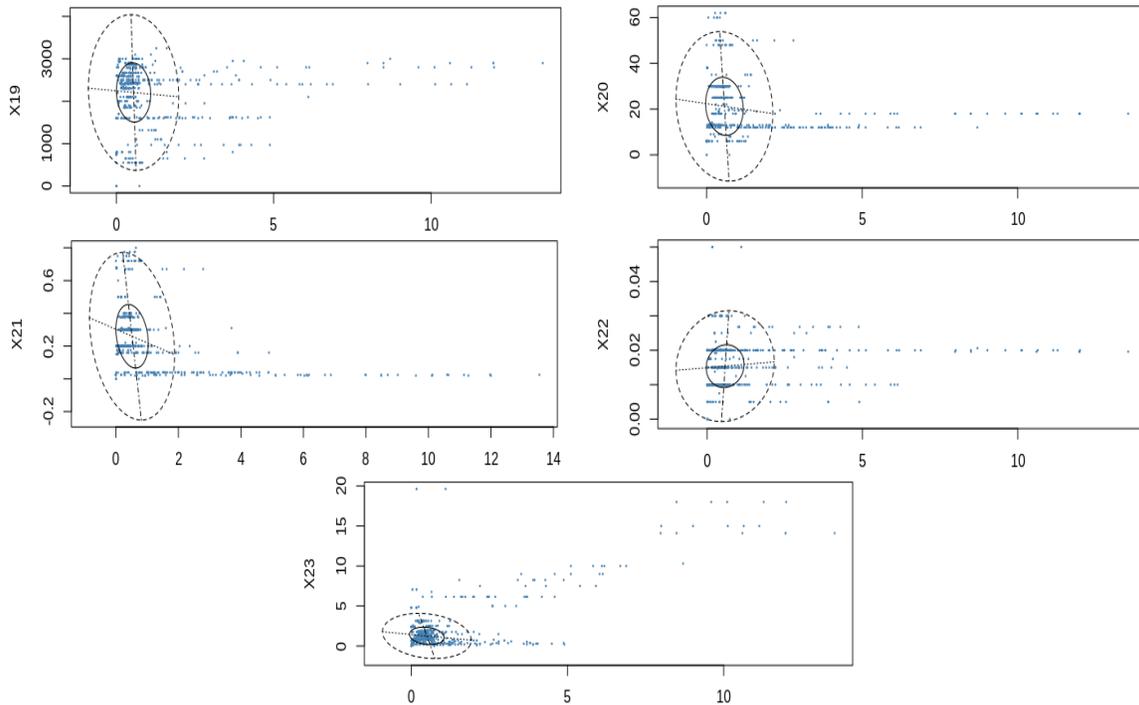
*Fuente: construcción propia*

Los resultados mencionados presentan una idea preliminar del comportamiento de Y1 y Y2 según la clase de fibra que incluye la dosificación, pese a esto, es pertinente tener en cuenta que el volumen de la fibra, así como el factor de la fibra tienen una relación directa con los resultados expuestos.

Adicional a las variables sobre fibras que se acaban de describir, las variables X19 a X23 y X30 a X34, que representan las propiedades de las fibras 1 y 2, se

observan en relación a la respuesta en Y1 en las figuras 31 y 33, y para Y2 en las figuras 32 y 34.

Figura 31: Variables (X19 a X23) de las propiedades de la fibra 1 frente a Y1



Fuente: construcción propia

Resistencia a la tracción fibra 1 (X19): la concentración de valores está alrededor de los 2400 y 2900 MPa, observándose en este mismo rango los valores más altos que toma Y1 y Y2. Los límites en la elipse para X19 son 500 y 4000 MPa, en Y1 el límite superior es de 2% y en Y2 de 180 kJ/m<sup>3</sup>.

Longitud de la fibra 1 (X20): se observa una mayor concentración de valores en 17 mm (aproximadamente). Los valores más elevados de Y1 se registran cuando X20 está alrededor de 20 mm, lo mismo ocurre para Y2. El límite de los datos en la elipse para X20 se observan en 0 y 50 mm, para el caso de Y1 en 0 y 2.5% aproximadamente, en Y2 los límites son 0 y 180 kJ/m<sup>3</sup>.

Diámetro de la fibra 1 (X21): Se observan agrupación de datos para valores de diámetro muy cercanos a 0 (aunque no toman valor de cero a menos que la dosificación no contenga fibra), 0.2, 0.25 y 0.3 mm. Los valores más altos observados en Y1 y Y2 se encuentran en diámetros que tienen medidas cercanas a 0 mm. Los límites del diámetro de fibra están en 0 y 0.69 mm

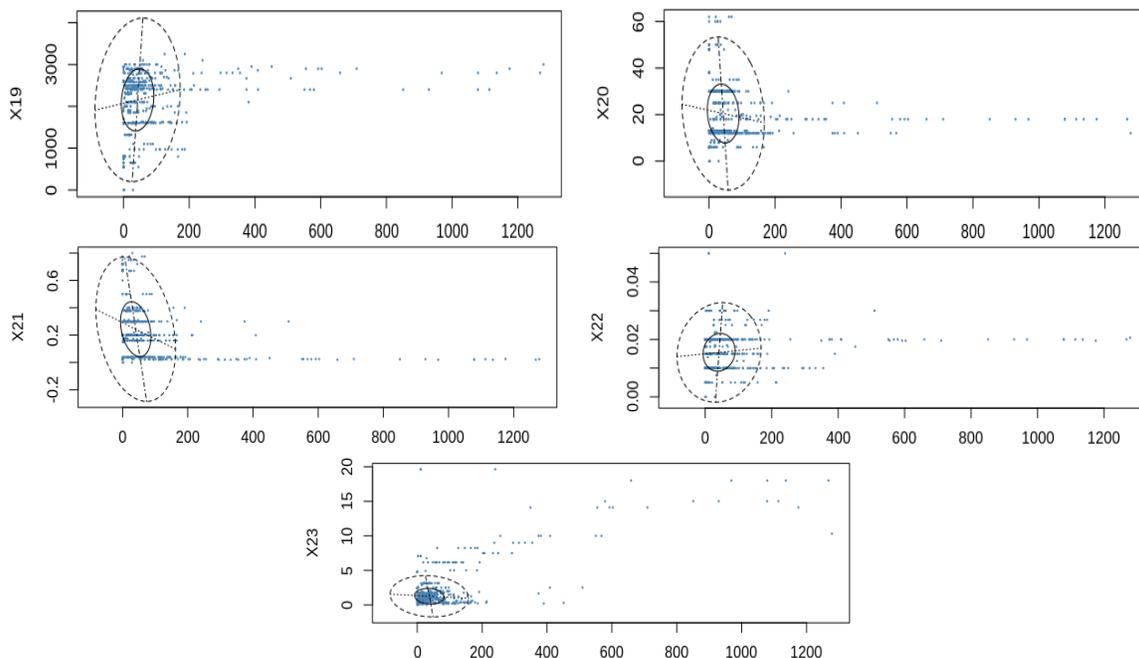
(aproximadamente), en Y1 se marcan en 0 y 2%, para el caso de Y2 se observan en 0 y 180 kJ/m<sup>3</sup>.

Contenido de fibra 1 (X22): El alargamiento postfisuración toma los valores más altos cuando el contenido (en volumen) de fibra 1 es del 1 y el 2%. En el caso de la capacidad de absorción de energía, los valores altos están más inclinados para contenidos de fibra 1 del 2%. Los límites de la elipse son de 0 y 3% en X22, de 0 y 2% para Y1 y 0 y 180 kJ/m<sup>3</sup> para Y2.

Factor de fibra 1 (X23): esta variable se encuentra en función de X20, X21 y X22. La mayoría de los datos están en valores de 0 a 2.5, se observan algunos datos con valores superiores a 5 que se relacionan a los datos más altos tanto en Y1 como en Y2. Los datos de X23 por debajo de 5 alcanzan valores en Y1 que no superan el 5% mientras que en Y2 solo unos pocos superan los 200 kJ/m<sup>3</sup>. Los límites de X23 en la elipse se observan en 0 y 4.5 (aproximadamente), 0 y 1.8% para Y1 y 0 y 180 kJ/m<sup>3</sup> en Y2.

Las variables X30 a X34 presentan una similitud en relación a la mayor cantidad de valores ubicados en 0, esto obedece a la proporción de observaciones que incluyen un solo tipo de fibra. Estos mismos valores de cero, presentan en casi todos los casos, los valores más altos de Y1 y Y2.

Figura 32: Variables (X19 a X23) de las propiedades de la fibra 1 frente a Y2



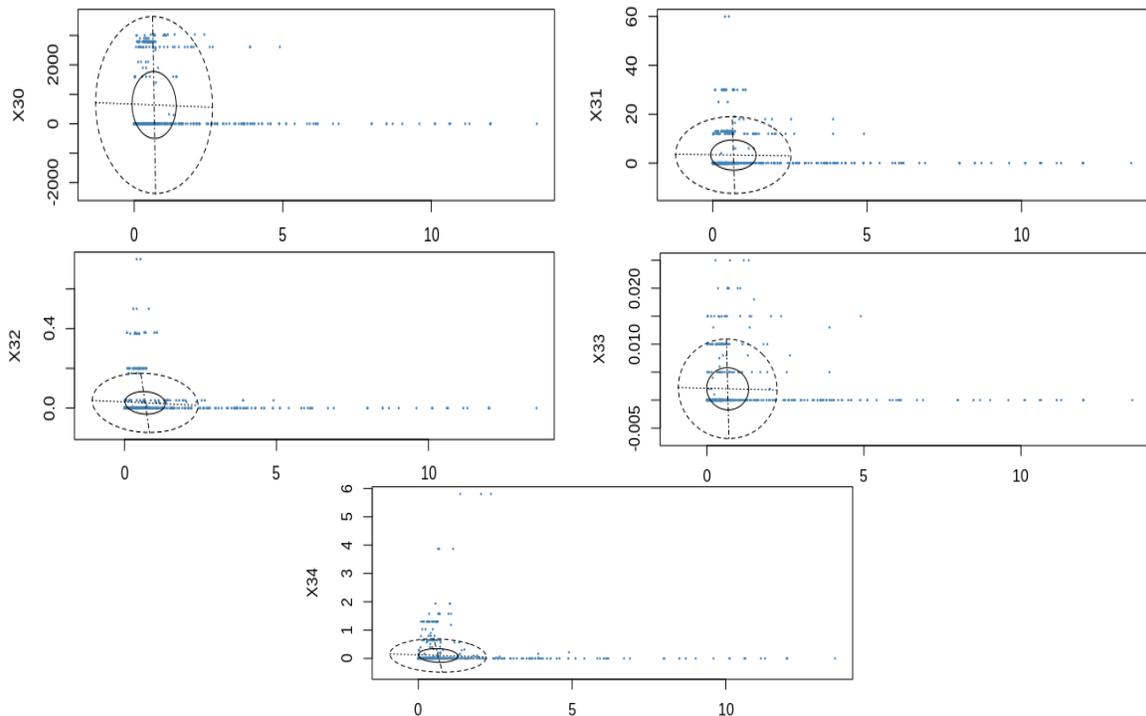
Fuente: construcción propia

Resistencia a la tracción de la fibra 2 (X30): las observaciones con dos tipos de fibras presentan la fibra 2 con resistencias cercanas a los 2500 MPa, respuestas en Y1 de máximo 5% y 200 kJ/m<sup>3</sup> en Y2. Para el caso de los límites de X30 en la elipse se observa que todos los datos están incluidos en la elipse, un 2% se muestra como el límite superior de Y1 y 180 kJ/m<sup>3</sup> para Y2.

Longitud de la fibra 2 (X31): se observa una agrupación de datos cuando los valores de X31 están entre 15 y 20 mm, este último valor presentado como límite (en la elipse). Los datos en esta agrupación alcanzan valores en Y1 por encima de 2% (límite en la elipse para Y1) y 200 kJ/m<sup>3</sup> como valor máximo (y límite de elipse en 180 kJ/m<sup>3</sup>)

Diámetro de la fibra 2 (X32): la mayoría de las fibras 2 toman valores de diámetro muy cercanos a cero, para los cuales también se presentan los valores de Y1 entre el 1 y 2% (unos pocos por encima de estos valores), y entre 0 y 200 kJ/m<sup>3</sup> para Y2. X32 toma valores también por encima de 0.2 mm que se observan fuera del límite de la elipse y que son una cantidad considerable si se tiene en cuenta el número de observaciones con 2 fibras. Y1 tiene límite en 2% y Y2 en 180 kJ/m<sup>3</sup>.

Figura 33: Variables (X30 a X34) de las propiedades de la fibra 2 frente a Y1

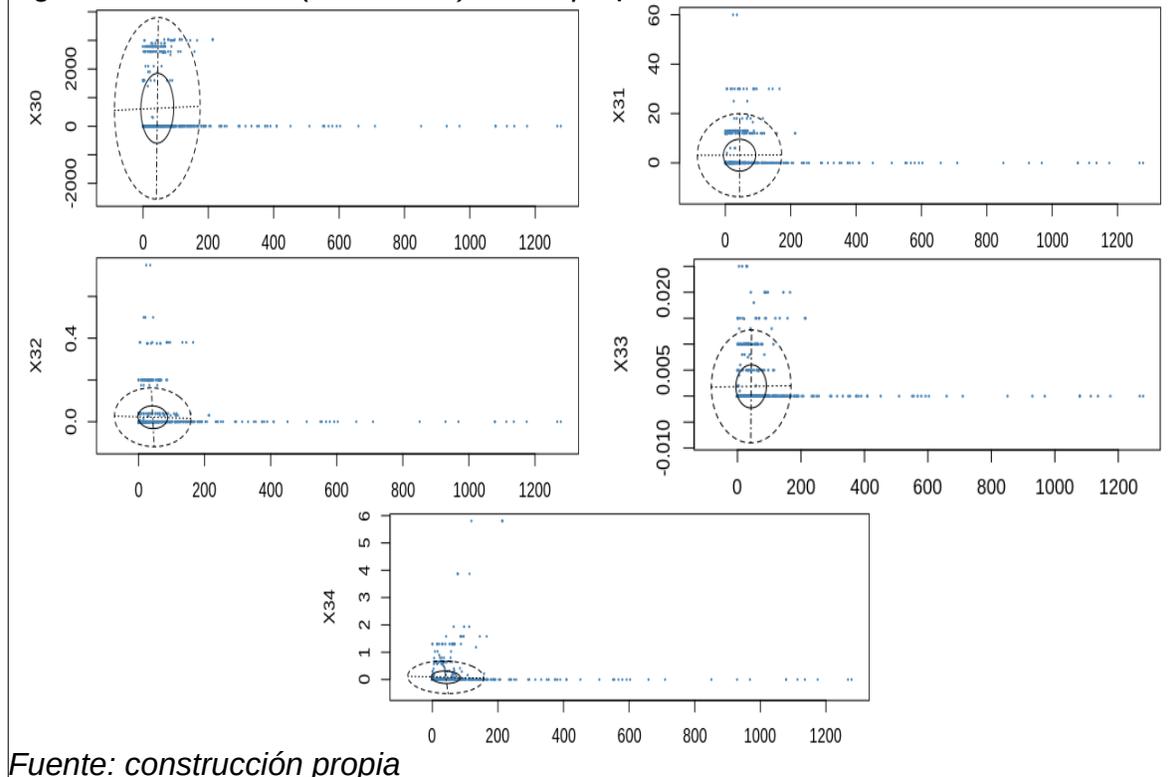


Fuente: construcción propia

Contenido de fibra 2 (X33): la fibra 2 aparece en contenidos del 0.5, 1, 1.5 y 2%, aunque con mayor frecuencia en valores menores al 1%. Son muy pocas las observaciones con contenido de fibra 2 que están entre 0.5 y 1.5% que relacionan valores de Y1 por encima al 2% mientras que en Y2 no se superan los 200 kJ/m<sup>3</sup> (excepto en una observación). El valor más alto para Y1 y Y2 se observa cuando X33 es 1.5%. El límite en la elipse para X33 es de 1%, en Y1 vuelve a ser de 2% y en Y2 de 180 kJ/m<sup>3</sup>.

Factor de fibra 2 (X34): esta variable está en función de X31, X32 y X33. Un valor de 0.8 se observa como límite en X, 2% se presenta como límite para Y1 y 180 kJ/m<sup>3</sup> en Y2. Existe una cantidad relativamente importante de observaciones alrededor de 1.5, pero no alcanza valores altos para Y1 o Y2.

Figura 34: Variables (X30 a X34) de las propiedades de la fibra 2 frente a Y2

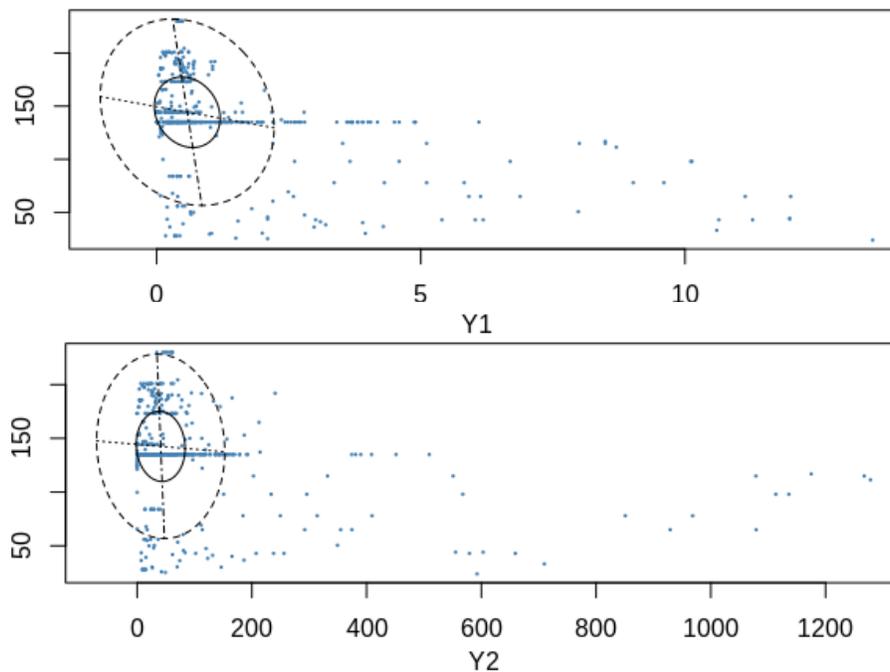


Fuente: construcción propia

Resistencia a la compresión del concreto (X35): la mayor concentración de observaciones en X35, que está entre 130 y 200 MPa, no presenta valores altos en las variables de respuesta, las cuales se observan para resistencias a la compresión menores a 130 MPa. En el caso de Y1, pareciera existir una relación inversamente proporcional, es decir, a mayor resistencia a la compresión, menor alargamiento postfisuración. Para la capacidad de absorción de energía, los

resultados mayores podrían obtenerse para observaciones que presentan datos en X35 mayores a 30Mpa y menores a 130Mpa. Los límites de la elipse en resistencia a la compresión son de 30 a 250 MPa (aproximadamente). Para Y1 los límites serían 0 y 2%, mientras que para Y2 de 0 y 180 kJ/m<sup>3</sup>. La Figura 35 muestra gráficamente esta descripción.

Figura 35: Resistencia a la compresión del concreto (X35) frente a Y1 y Y2



Fuente: construcción propia

Las dosificaciones recolectadas evidencian un buen comportamiento, en la respuesta de alargamiento postfisuración y capacidad de absorción de energía, cuando contienen un solo tipo de fibra, no obstante, es de tener en cuenta que la proporción de observaciones con dos tipos de fibras es mucho menor a las de una sola fibra. Esto podría limitar el análisis que se realice para observaciones con dos fibras.

De igual forma ocurre con las observaciones que incluyen fibras sintéticas, se limita su análisis, aunque con los datos disponibles se alcanza a observar un mejor desempeño, en las propiedades mecánicas del concreto, cuando incluye fibras sintéticas.

Dadas las características de los datos disponibles, el análisis realizado parece identificar observaciones con respuestas en Y1 superiores a 2% y en Y2 superiores a 180 kJ/m<sup>3</sup> como posibles datos atípicos. Esta no es una conclusión

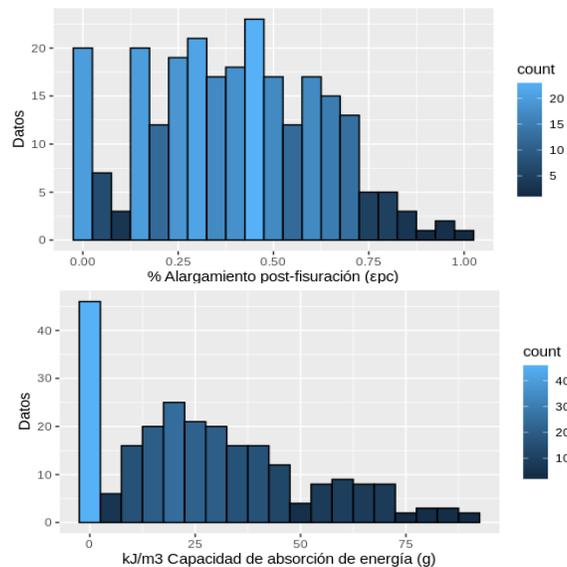
que pueda tomarse como definitiva, la literatura científica presenta resultados con alargamiento postfisuración superiores al 2% y capacidad de absorción de energía superior a 180 kJ/m<sup>3</sup>.

El comportamiento observado en el conjunto de datos presenta estas características porque en las observaciones existe una mayor proporción de dosificaciones que mencionan fibras metálicas y no sintéticas, esto porque las primeras son más comunes en la literatura científica.

### 5.1.2. Limpieza del conjunto de datos y consolidación de observaciones definitivas.

Haciendo uso de R, con la librería Mixtools, se identifican los datos anómalos en cada variable X de manera independiente para cada variable de respuesta, es decir, se obtiene un conjunto de datos para Y1 y otro para Y2. Para la variable Y1 el conjunto de datos definitivo tiene un total de 251 observaciones. Esta variable de respuesta toma valores entre 0 y 1,02%. Los datos iniciales variaban entre 0 y 13.55%. Mientras que en la variable Y2 el conjunto de datos final tiene 245 observaciones, el valor mínimo y máximo en esta variable es de 0 y 91.93 kJ/m<sup>3</sup>, respectivamente. Los datos iniciales variaban entre 0 y 278.13 kJ/m<sup>3</sup>. La distribución de los conjuntos de datos definitivos se muestra en los histogramas de la Figura 36.

Figura 36: Distribución de las variables Y1 y Y2 posterior a la limpieza de datos.



Fuente: construcción propia

### **5.1.2.1 Conjuntos de datos definitivos para alargamiento post-fisuración (Y1) y capacidad de absorción de energía (Y2)**

Frente a la distribución de los datos sin limpieza se observa notoriamente una reducción de la dispersión de los datos, iniciando por el valor mínimo y máximo de cada variable X hasta los límites definidos en la elipse dibujada.

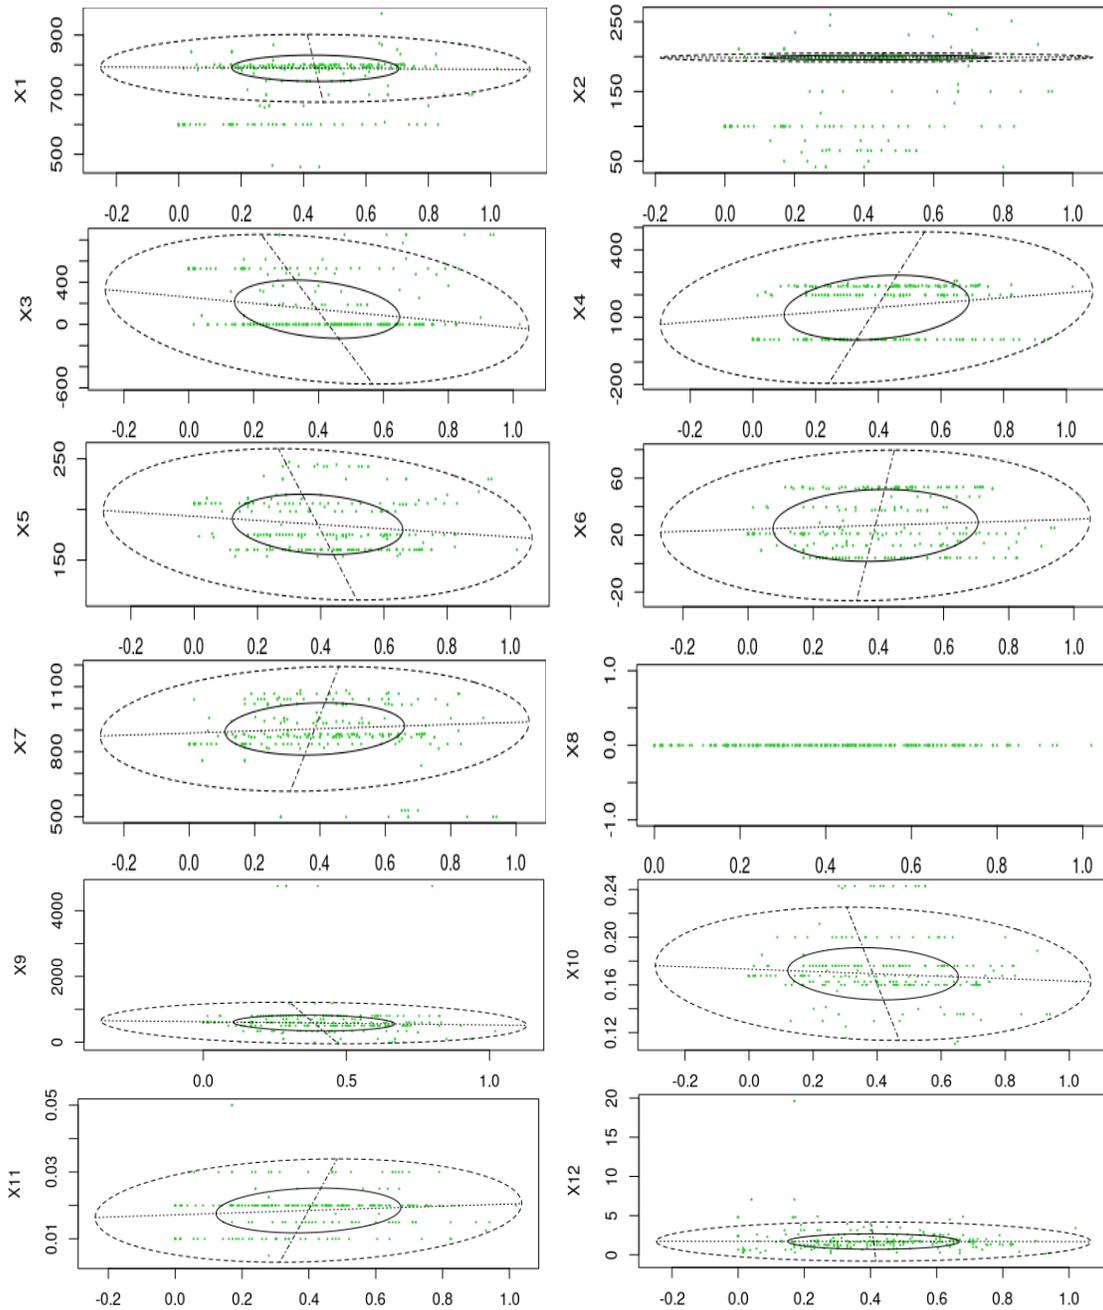
En la mayoría de los casos, las observaciones se encuentran dentro de la elipse o, al menos, un número muy reducido de datos están fuera de ellas. Es posible continuar con la limpieza de datos y mejorar los resultados en cada variable. No obstante, esto implica seguir reduciendo la cantidad de observaciones disponibles para entrenamiento y prueba de los modelos de redes neuronales, lo cual, es contraproducente para los intereses del presente estudio.

Se resalta que la variable X8 presenta todas sus observaciones en cero, por lo que la misma se excluye del conjunto de datos, lo que significa que se pasa de un *dataset* de 35 a 34 variables independientes.

La Figura 37 deja ver el comportamiento de las primeras doce variables frente a Y1, que presentan los componentes de la matriz de concreto y el total de fibra que se le incluye. X1 y X2 son las variables que presentan mayor cantidad de observaciones por fuera de los límites que establece la elipse. Las variables X3, X7, X10 y X12 presentan una menor cantidad de observaciones fuera de la elipse.

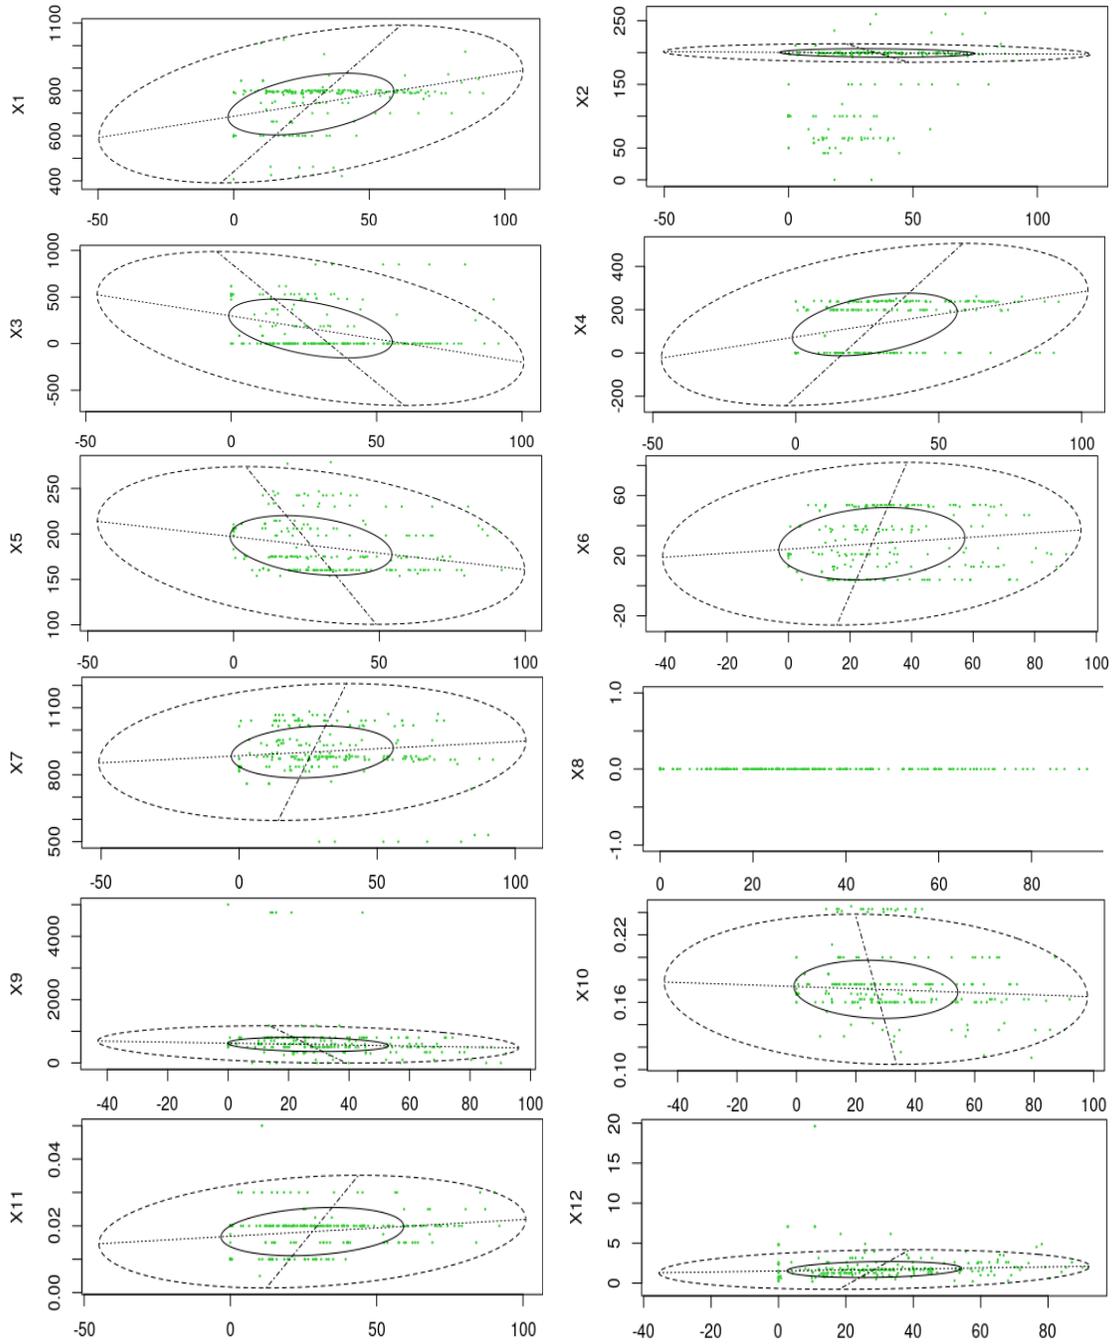
Con respecto a Y2, la Figura 38 presenta el comportamiento de estas doce variables (X1 a X12). En X2 se marca una mayor cantidad de observaciones por fuera de los límites de la elipse. Para X8 se presenta con todas las observaciones en cero y variables como X3, X7, X9, X10 y X12 evidencian algunos datos por fuera de los límites de la elipse.

Figura 37: Variables X de la matriz de concreto frente a Y1 posterior a la limpieza de datos



Fuente: construcción propia

Figura 38: Variables X de la matriz de concreto frente a Y2 posterior a la limpieza de datos

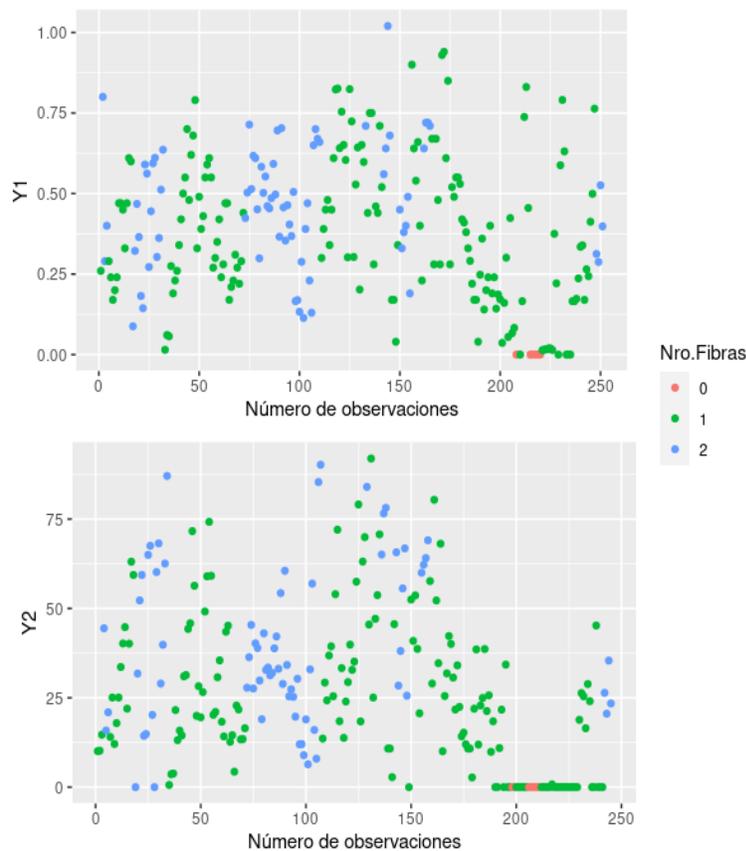


Fuente: construcción propia

Al revisar los conjuntos de datos frente a la cantidad de observaciones por el número de fibras, se encuentra que ambos conjuntos contienen 8 observaciones sin fibra, Y1 tiene 167 observaciones con una fibra, mientras que Y2 tiene 164. Para el caso de observaciones con dos fibras, Y1 reúne 76 con esta característica, mientras que Y2 presenta 73.

Los resultados de la Figura 39 comparados con los exhibidos en la Figura 29 permiten ver con mayor claridad el resultado de la limpieza de datos realizada. Ambas variables de respuesta reducen considerablemente el rango de valores que puede tomar. La reducción de la cantidad de observaciones que incluye cada conjunto de datos también deja ver con claridad una menor dispersión y “homogeneidad” entre los resultados de observaciones según la cantidad de fibras en cada dosificación.

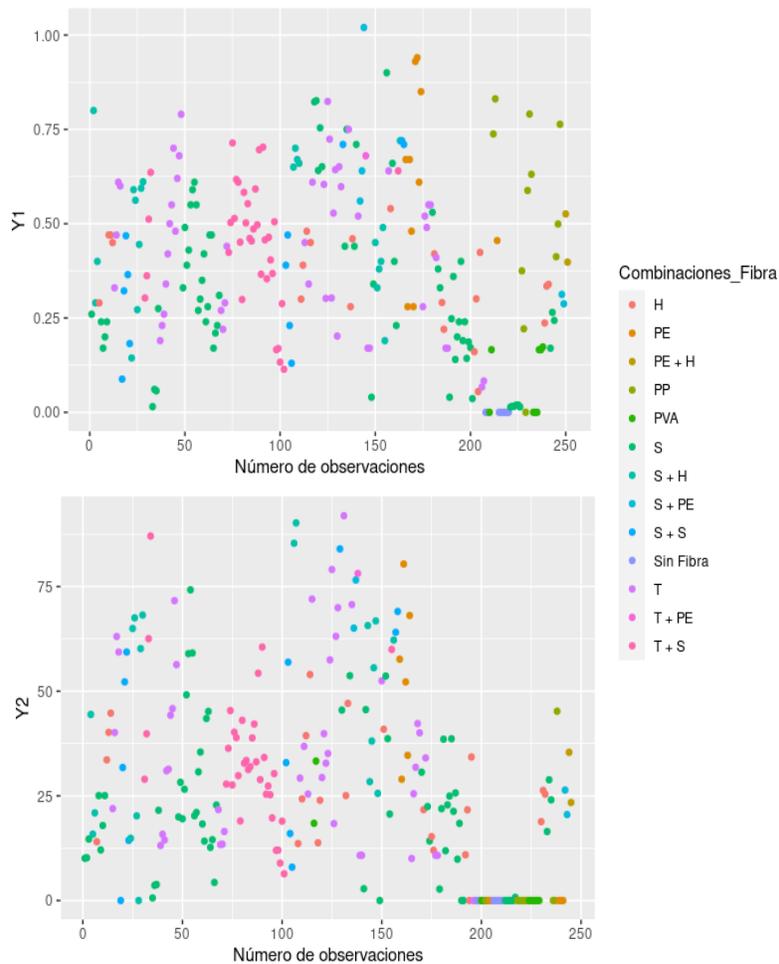
*Figura 39: Comportamiento de Y1 y Y2 según cantidad de fibras posterior a la limpieza de datos*



*Fuente: construcción propia*

Así, el comportamiento frente a las combinaciones de fibra es ligeramente diferente en los conjuntos de datos obtenidos posterior a la limpieza. La Figura 40 presenta los detalles de las dosificaciones de los conjuntos de datos definitivos. Al compararlos con los descritos en la Figura 30 dejan ver que la limpieza suprimió las dosificaciones en los que la fibra de polietileno resaltaba con los valores de respuesta más altos tanto en Y1 como en Y2.

*Figura 40: Comportamiento de Y1 y Y2 según combinaciones de fibra posterior a la limpieza de datos.*



*H: fibra metálica acabada en gancho, PE: Fibra sintética de polietileno, PP: fibra sintética de polipropileno, PVA: fibra sintética de polivinilo de alcohol, S: fibra metálica recta, T: fibra metálica retorcida.*

*Fuente: construcción propia*

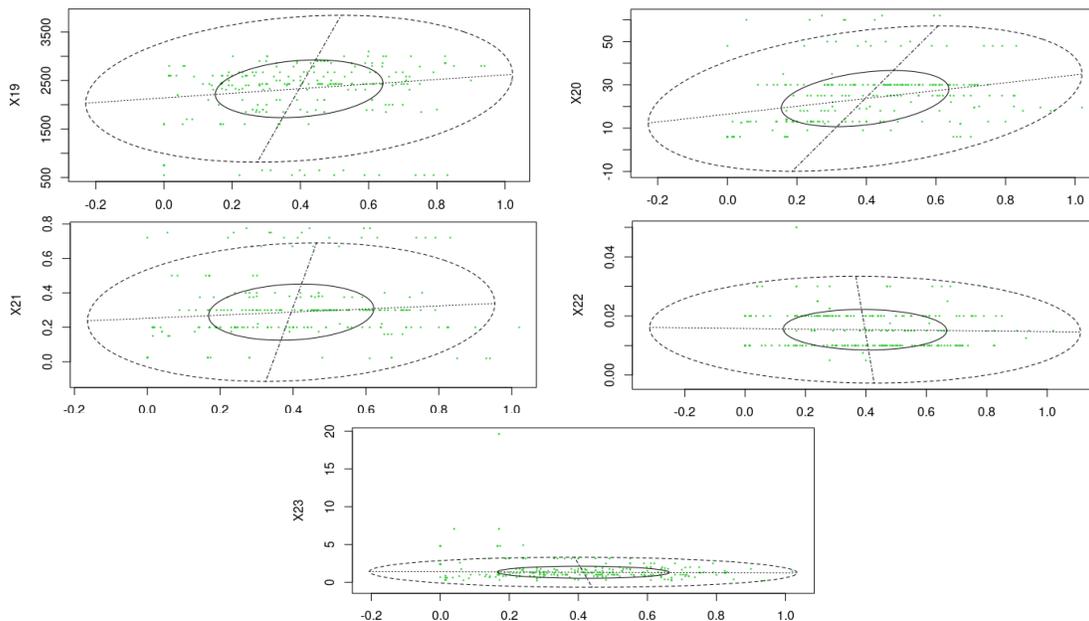
En general, se podría decir que las fibras sintéticas pierden “protagonismo” en función de las respuestas en Y1 y Y2. En el alargamiento postfisuración se observa una leve participación en los valores más altos (superiores a 0.75%) de dosificaciones con polipropileno y polietileno, aunque es mayor el número de observaciones con fibra metálica.

En la capacidad de absorción de energía, en los valores de respuesta más altos (mayores a 75 kJ/m<sup>3</sup>) solo una de las dosificaciones incluye polietileno. Las demás dosificaciones observadas se relacionan a fibras metálicas.

Aunque los límites definidos como objetivos, para cada variable de respuesta en el presente estudio, son inferiores a los mencionados en el anterior análisis, el resultado observado podría orientar los resultados de los modelos de RNA a dosificaciones que incluyan fibras metálicas. Sin embargo, es de aclarar que esta conclusión obedece a una percepción visual que ofrecen las graficas presentadas.

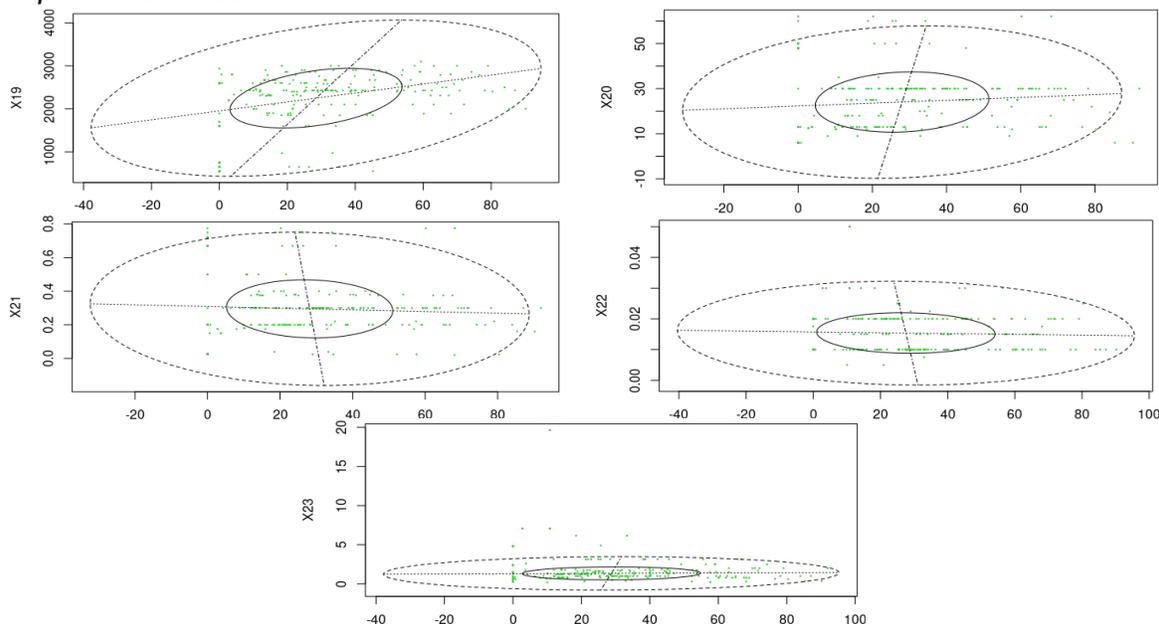
Por otra parte, frente a las variables independientes X19 a X23, que describen las propiedades de la fibra 1 en cada dosificación, el detalle de los datos frente a las variables de respuesta Y1 y Y2, se observan en las figuras 41 y 42, respectivamente.

*Figura 41: Variables (X19 a X23) propiedades fibra 1 frente a Y1 posterior a limpieza de datos*



*Fuente: construcción propia*

Figura 42: Variables (X19 a X23) propiedades fibra 1 frente a Y2 posterior a limpieza de datos



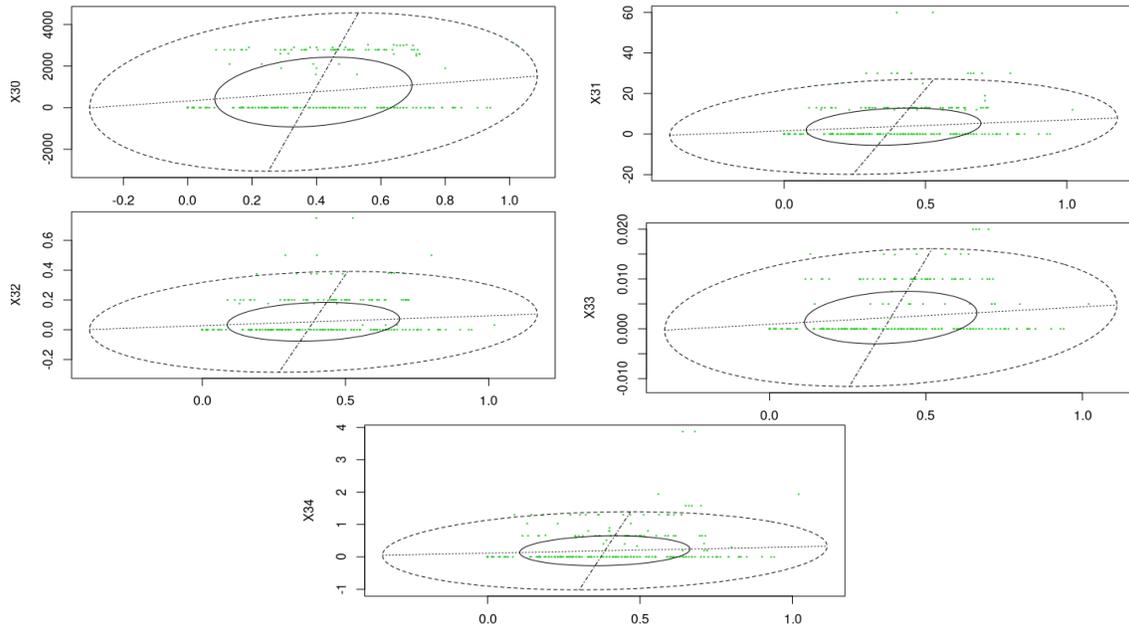
Fuente: construcción propia

En el caso de X21 si se observa una diferencia entre Y1 y Y2, presentando para Y1 una mayor cantidad de datos por fuera de elipse. En todo caso, es evidente la reducción en la dispersión de los datos si se compara con el comportamiento de los datos iniciales.

Las propiedades de la fibra 2, que se presentan en las variables X30 a X34, también presentan similitud al cruzar con los resultados de respuesta en Y1 y Y2. Tal como se mencionó, para las variables X19 a X23, en este caso también se observa un comportamiento similar en ambas variables de respuesta. X30 presenta prácticamente todos sus datos dentro de la elipse. Las demás variables (X31 a X34) presentan una pequeña cantidad de datos por fuera de los límites que marcan las elipses. Las figuras 43 y 44 presentan gráficamente los resultados descritos para Y1 y Y2, respectivamente.

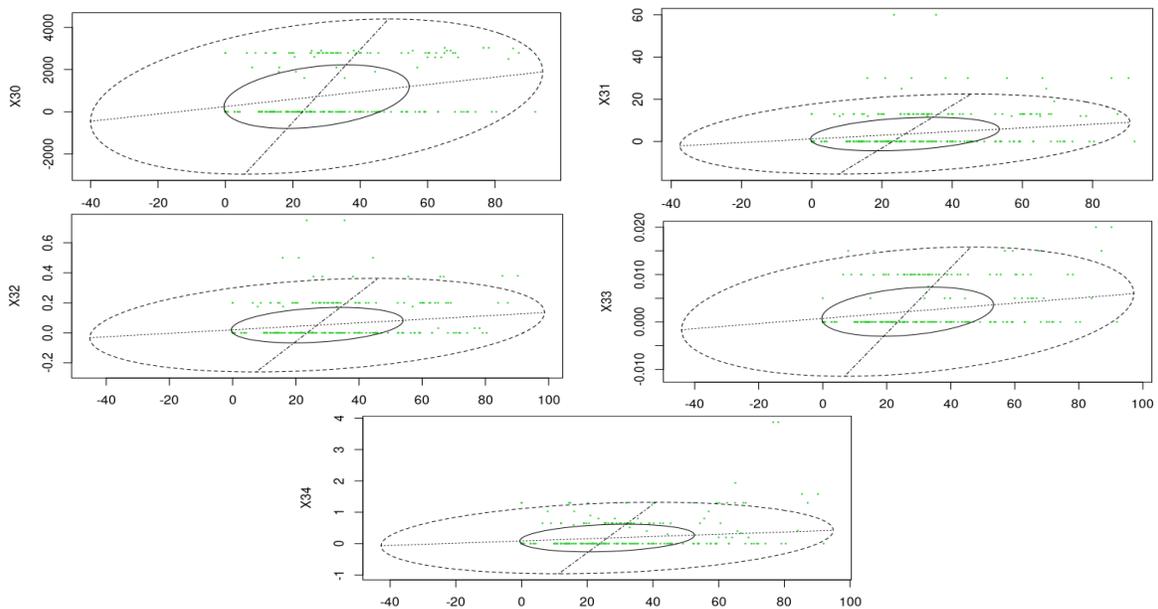
El detalle de los datos se observa similar tanto para Y1 como para Y2. Los datos se encuentran dentro de las elipses que demarcan los límites de posibles datos anómalos con algunas pocas excepciones.

Figura 43: Variables (X30 a X34) propiedades fibra 2 frente a Y1 posterior a limpieza de datos



Fuente: construcción propia

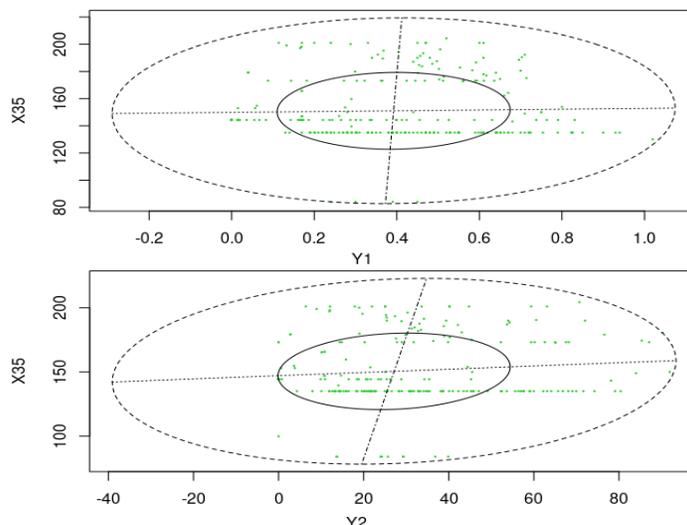
Figura 44: Variables (X30 a X34). Propiedades fibra 2 frente a Y2 posterior a la limpieza de datos



Fuente: construcción propia

Frente a la última variable independiente, la resistencia a la compresión (X35), no se observan datos por fuera de las elipses que limitan los posibles datos anómalos tanto en Y1 como en Y2. La Figura 45 muestra gráficamente estos resultados.

*Figura 45: Resistencia a la compresión concreto (X35) frente Y1 y Y2 posterior a limpieza de datos*



*Fuente: construcción propia*

En concordancia, la limpieza de los datos reduce la varianza de estos y el sesgo respecto a las respuesta que se puedan obtener frente a la predicción de los modelos de RNA. No obstante, el costo de la limpieza es considerable si se tiene en cuenta que para Y1 se suprimen un total de 239 dosificaciones, mientras que para Y2 el valor de observaciones que se suprimen fue mayor, alcanzando 245 dosificaciones, esto es un 50% del total de datos iniciales.

Estos resultados evidencian deficiencias en la recolección de datos, además de la poca disponibilidad de datos en publicaciones científicas relacionados al endurecimiento por deformación y la capacidad de absorción de energía del HPFRCC y UHPFRC, especialmente en el uso de fibras sintéticas. Esta situación se describe como una limitación en el presente estudio. Esta situación se describe como una limitación en el presente estudio. Adicionalmente, no fue posible tener disponibles el total de datos experimentales que se esperaban del Laboratorio de Materiales debido a la suspensión de ensayos dada la situación de salud pública anteriormente mencionada.

A fin de garantizar la independencia de las variables que representan las fibras (1 y 2) y restar posibles efectos matemáticos de la ordenación de estas en las

mezclas, la base de datos considerada se duplica, permutando la ordenación de la fibra. Por lo tanto, el número total de observaciones que conforman el conjunto de datos es de 502 para la variable Y1 y 490 para Y2. Con esto se busca eliminar situaciones de suboptimización al no “mencionar” en los datos que los resultados son independientes del orden de las fibras en el arreglo de observaciones.

Por último, todas las variables de entrada son normalizadas a escala lineal con mínimo 0 y máximo 1, siguiendo la ecuación 5. Las variables de salida no se normalizaron a fin de facilitar la interpretación de los resultados del entrenamiento de las RNA. Adicionalmente, la limpieza de datos reduce considerablemente la dispersión de las variables de respuesta, situación que hace posible hacer uso de estos datos sin normalizar.

### **5.1.3 Modelos de RNA para predicción del alargamiento post-fisuración y la capacidad de absorción de energía del HPFRCC**

Los modelos de RNA fueron programados en R (4.0) usando las librerías Tensorflow (2.0) y Keras (2.3). En los script elaborados para entrenamiento de las RNA se mantienen todas las opciones por defecto en aquellos hiperparámetros que permiten su modificación.

Los conjuntos de datos con 502 observaciones para Y1 y 490 observaciones para Y2 se dividen en dos subconjuntos: *train* y *test*. La cantidad de observaciones para Y1 del *train* es de 401 y el *test* es de 101. Para Y2 la cantidad de observaciones para *train* es de 392 y en el *test* de 98.

La primera parte de los modelos se realiza con entrenamiento y validación tipo K-fold, en todas las arquitecturas se mantienen parámetros en común:

- 1) Validación tipo K-fold con K=5
- 2) 100 epoch por cada K
- 3) 100 valores para aleatoriedad de pesos iniciales (de 1 a 100)
- 4) RMSPROP como algoritmo de aprendizaje
- 5) MSE como función de pérdida (loss function)
- 6) Función de activación la lineal rectificada (ReLU)
- 7) El conjunto de datos usado es el *train*

En el caso de los modelos de una capa oculta se realiza el entrenamiento para 70 arquitecturas. El número de neuronas en la capa oculta que varía de 1 a 70.

Asimismo, para el modelo de dos capas ocultas se realiza entrenamiento para 70 arquitecturas. El número de neuronas en la primera capa oculta se deja fijo en aquel con el error mínimo de la arquitectura de una capa oculta y se varía de 1 a 70 el número de neuronas de la segunda capa oculta.

De la misma forma, en el modelo de tres capas ocultas se realiza el entrenamiento para 70 arquitecturas. En la primera y segunda capa se fijan el número de neuronas de acuerdo al menor error encontrados en estas y se varía de 1 a 70 el número de neuronas en la tercera capa oculta.

Para cada arquitectura de RNA evaluada se probaron 100 asignaciones de pesos iniciales y para todas ellas se entrenó la red pasando los datos de entrenamiento hasta 100 veces (100 epochs). Los resultados mostrados se obtienen mediante la validación cruzada tipo K-fold con K=5.

Con los resultados de la primera parte del entrenamiento se realiza un segundo entrenamiento solo para las arquitecturas seleccionadas (según los resultados del anterior proceso), esto con el fin de determinar cual es el número de veces que deben pasar los datos por el modelo. Los parámetros para esta segunda parte son:

- 1) 100 valores para aleatoriedad de pesos iniciales (de 1 a 100)
- 2) 2000 epoch por cada valor de aleatoriedad
- 3) RMSPROP como algoritmo de aprendizaje
- 4) MSE como función de pérdida (loss function)
- 5) Función de activación la lineal rectificada (ReLU)
- 6) Se usa los conjuntos de datos *train* para el entrenamiento y *test* para la validación

Para esto, se entrenan seis arquitecturas de RNA. Cada variable de respuesta tiene 3 modelos de RNA: de una, dos y tres capas ocultas. Se establecen 100 asignaciones de pesos iniciales, pasando los datos de entrenamiento hasta 2000 veces (2000 epochs). Los resultados mostrados se obtienen mediante validación con el conjunto de datos *test*.

### **5.1.3.1 Modelos de RNA para el alargamiento post-fisuración (Y1)**

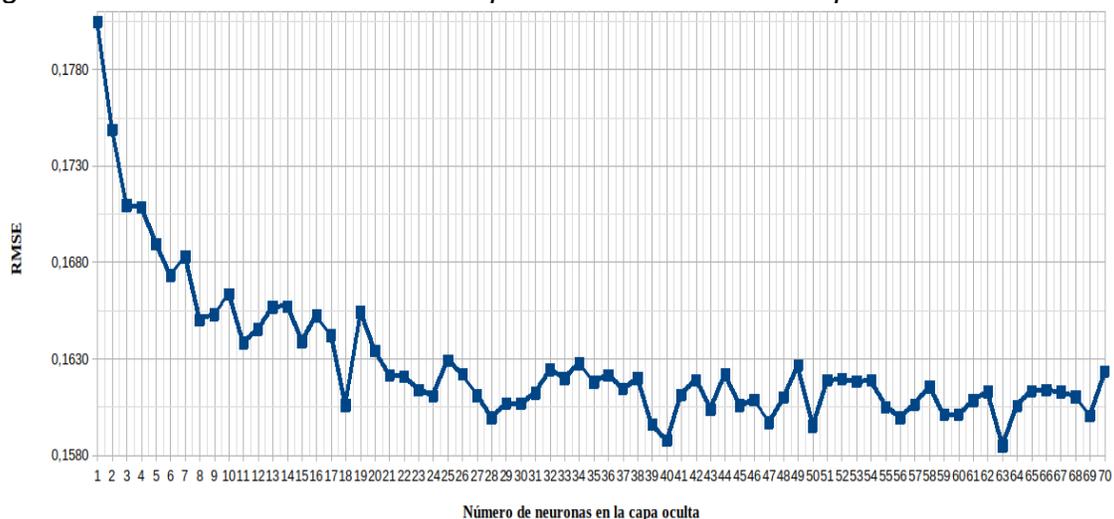
#### **5.1.3.1.1 Modelo de una capa oculta para Y1**

Para el modelo de una capa oculta en el alargamiento postfisuración se observan valores de RMSE entre un máximo de 0.1804 y un mínimo 0.1584 puntos

porcentuales. El rango de variación es de 0.0219. El valor mínimo se observó en la arquitectura de 63 neuronas en la capa oculta. El segundo valor más bajo en el error se observó para 40 neuronas en la capa oculta, esto es, 0.1588 puntos porcentuales.

La Figura 46 muestra los resultados de los errores para en entrenamiento de 70 arquitecturas de RNA con una capa oculta. El error más alto se observa para el modelo de una neurona.

Figura 46: Validación cruzada k-fold para Y1 en RNA de 1 capa oculta



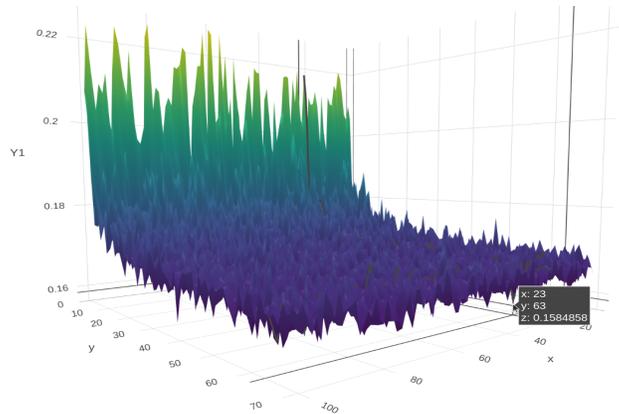
Fuente: construcción propia

A partir de los modelos de 21 neuronas en adelante, el rango de variación del error se reduce considerablemente y tiende a mantenerse estable. Después del error mínimo (de la arquitectura de 63 neuronas), la tendencia parece mantenerse estable, aunque por encima del valor mínimo observado. Estos resultados se consideran relativamente altos si se tiene que el objetivo del presente estudio es que la variable alcance al menos un valor de 0.3.

Este modelo podría predecir un valor para Y1 que puede estar 0.1584 puntos porcentuales por encima o por debajo del valor real del alargamiento postfisuración de una mezcla de HPFRCC. Si se tuviese una mezcla de concreto con un valor real de alargamiento postfisuración de 0.3, el valor que estimaría el modelo podría estar en promedio entre 0.1416 y 0.4584 puntos porcentuales. Lo anterior, para un rango de variación de 0.3168, valor que en sí mismo es superior al mínimo deseado.

En la Figura 47 se observan los resultados del entrenamiento de las 70 arquitecturas para cada uno de números aleatorios de pesos iniciales. El menor RMSE se observa entonces para 63 (y) neuronas en la capa oculta y con 23 (x) como número aleatorio para pesos iniciales de la RNA.

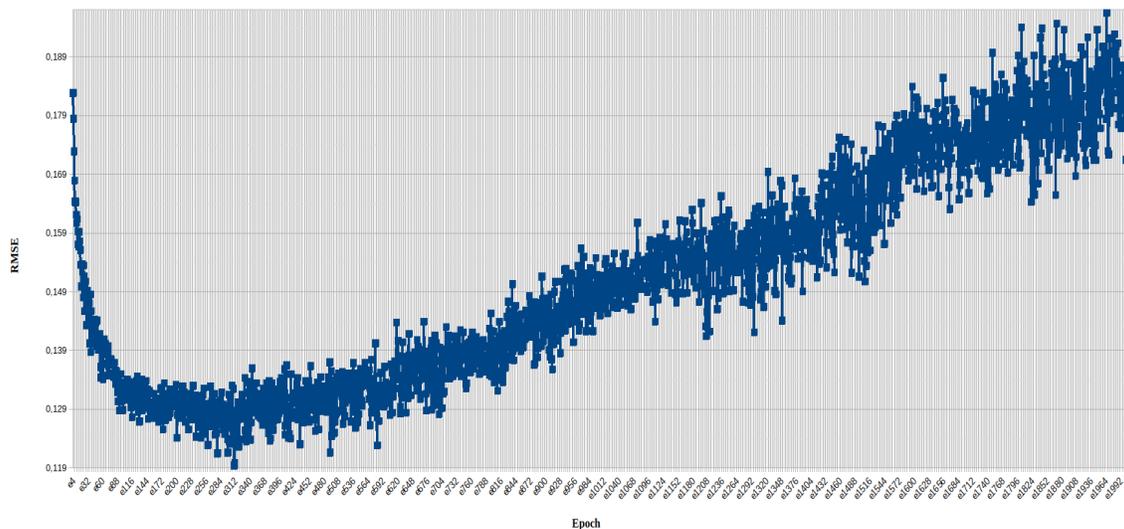
Figura 47: Validación cruzada k-fold para Y1 en RNA de 1 capa oculta 3D



$x$  = aleatorio de pesos iniciales,  $y$  = número de neuronas en la capa oculta  
Fuente: construcción propia

El modelo de RNA con una capa oculta con 63 neuronas se entrena nuevamente a fin de determinar la cantidad de veces que se deben pasar los datos ( epoch) para obtener el mínimo error. La Figura 48 permite observar los resultados de esta actividad.

Figura 48: Validación de RNA de 1 capa oculta con 63 neuronas para Y1

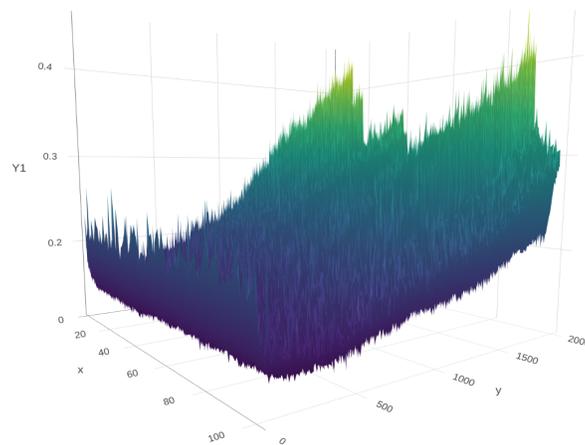


Fuente: construcción propia

El modelo entrenado arroja un error de 0.1194 puntos porcentuales para un epoch de 307 y un número de aleatoriedad de asignación de pesos iniciales de 55. El resultado obtenido presenta una diferencia significativa con respecto a lo evidenciado en la validación cruzada. El resultado implica una reducción del error en 0.039 puntos porcentuales.

Los resultados del error del modelo RNA con 63 neuronas en la primera capa oculta presentan menor variabilidad (entre epoch) para la aleatoriedad de pesos iniciales que se asignan entre 20 y 60, resultados que se observan en la Figura 49.

*Figura 49: Validación de RNA de 1 capa oculta con 63 neuronas para Y1 3D*



*x = número aleatorio de pesos iniciales, y = número de epoch*

*Fuente: construcción propia*

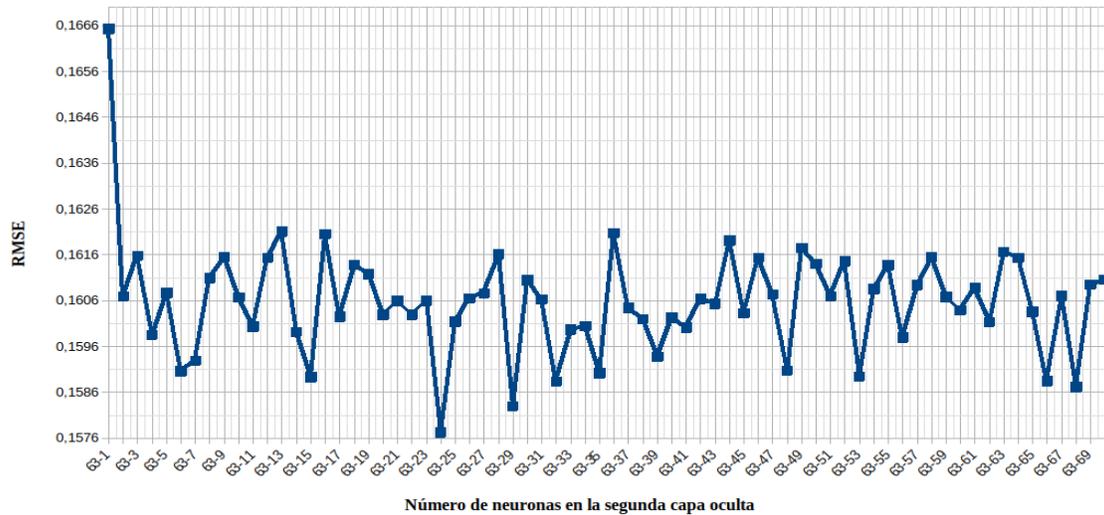
### **5.1.3.1.2 Modelo de dos capas ocultas para Y1**

El modelo de dos capas ocultas inicia con un número fijo de neuronas en la primera capa oculta de 63. El RMSE varía entre un valor máximo de 0.1665 y un mínimo de 0.1577 puntos porcentuales. El rango de variación que se observa en las 70 arquitecturas evaluadas con dos capas ocultas es de 0.0088. Este rango de variación es considerablemente bajo frente al observado en las RNA de una capa oculta. El RMSE mínimo mencionado se observa para la arquitectura 63-24. El segundo valor más bajo en RMSE se observa en la arquitectura 63-29 con un valor de 0.1582 puntos porcentuales.

La Figura 50 permite observar de manera gráfica los resultados del entrenamiento que se realiza para los modelos de dos capas ocultas de Y1. Frente a los resultados de la primera capa oculta se observa que el mínimo RMSE es menor

0,0007 puntos porcentuales. Sin embargo, no es una variación que presente una gran diferencia respecto al objetivo de este estudio para Y1. El rango de variación mencionado para el error es amplio dado el resultado de la arquitectura 63-1, sin contar este resultado el rango de variación sería de 0.0029 puntos porcentuales.

Figura 50: Validación cruzada k-fold para Y1 en RNA de 2 capas ocultas

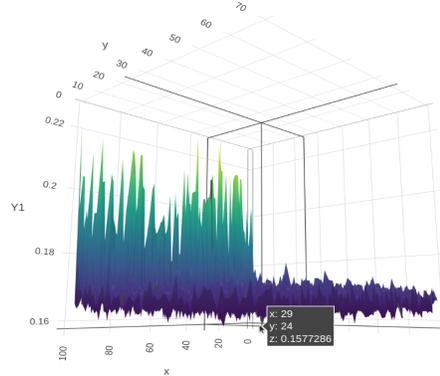


Fuente: construcción propia

Los resultados implican que el modelo de RNA de dos capas ocultas, con el error mínimo, podría predecir un valor para Y1 que variaría 0.1577 puntos porcentuales por encima o por debajo del valor real del alargamiento postfisuración de una mezcla de HPRCC. En una mezcla de concreto con un valor real de alargamiento postfisuración de 0.3, el valor que estimaría el modelo podría estar en promedio entre 0.1423 y 0.4577 puntos porcentuales. Esto refleja un rango de variación de 0.3154.

La Figura 51 muestra los resultados del entrenamiento de las 70 arquitecturas de dos capas ocultas para cada uno de números aleatorios de pesos iniciales. El menor RMSE se observa entonces para 24 (y) neuronas en la segunda capa oculta y con 23 (x) como número aleatorio para pesos iniciales de la RNA.

Figura 51: Validación cruzada k-fold para Y1 en RNA de 2 capas ocultas 3D

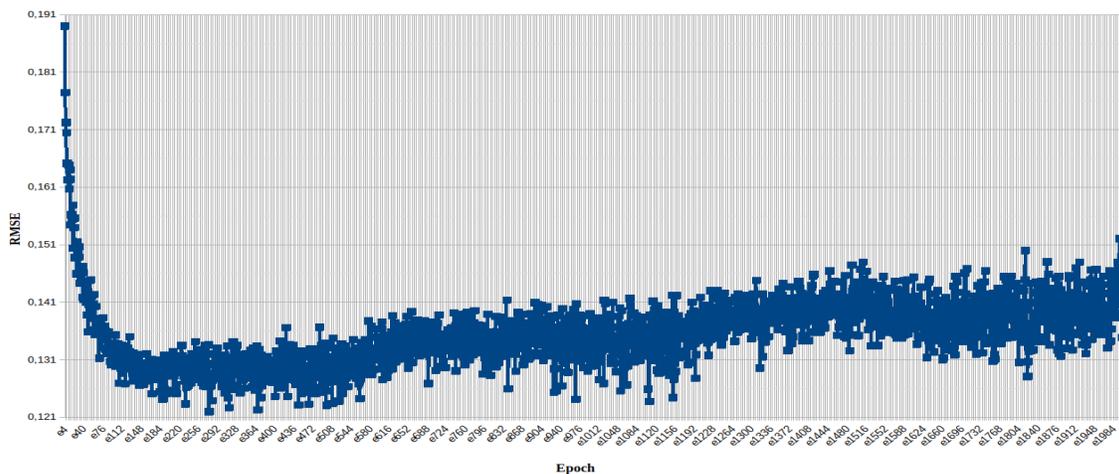


$x$  = aleatorio de pesos iniciales,  $y$  = número de neuronas en la 2da capa oculta  
Fuente: construcción propia

El modelo de RNA con 63 neuronas en la primera capa oculta y 24 neuronas en la segunda capa oculta se entrena nuevamente para determinar la cantidad de veces que se deben pasar los datos (epoch) para el mínimo error.

La Figura 52 presenta estos resultados con un error de 0.1219 puntos porcentuales y un número de epoch de 273. El resultado en cuanto a la aleatoriedad de asignación de pesos iniciales es de 38. El error obtenido en este entrenamiento es considerablemente menor respecto al mejor resultado en los modelos con la validación tipo k-fold, siendo la diferencia de 0.0358. Sin embargo, al comparar este error con el obtenido para el entrenamiento y validación del modelo de una capa oculta (con 2000 epoch), se observa que el error es mayor en 0,0025 puntos porcentuales.

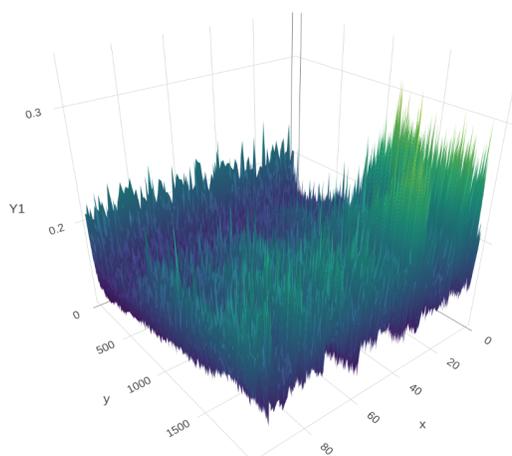
Figura 52: Validación de RNA de 2 capas ocultas con 63 y 24 neuronas para Y1



Fuente: construcción propia

Los resultados del error del modelo RNA con 63 neuronas en la primera capa oculta y 24 neuronas en la segunda capa oculta presentan una mayor variabilidad para la aleatoriedad de pesos iniciales que se asignan entre 1 y 40, aunque en alrededor de 35, la variación es menor que en los demás resultados para el mismo rango y similar a los resultados obtenidos para aleatoriedad de pesos iniciales por encima de 41. Lo mencionado se observan en la Figura 53.

*Figura 53: Validación RNA de 2 capas ocultas con 63 y 24 neuronas para Y1 3D*



*x = aleatorio de pesos iniciales, y = número de epoch*

*Fuente: construcción propia*

### **5.1.3.1.3 Modelo de tres capas oculta para Y1**

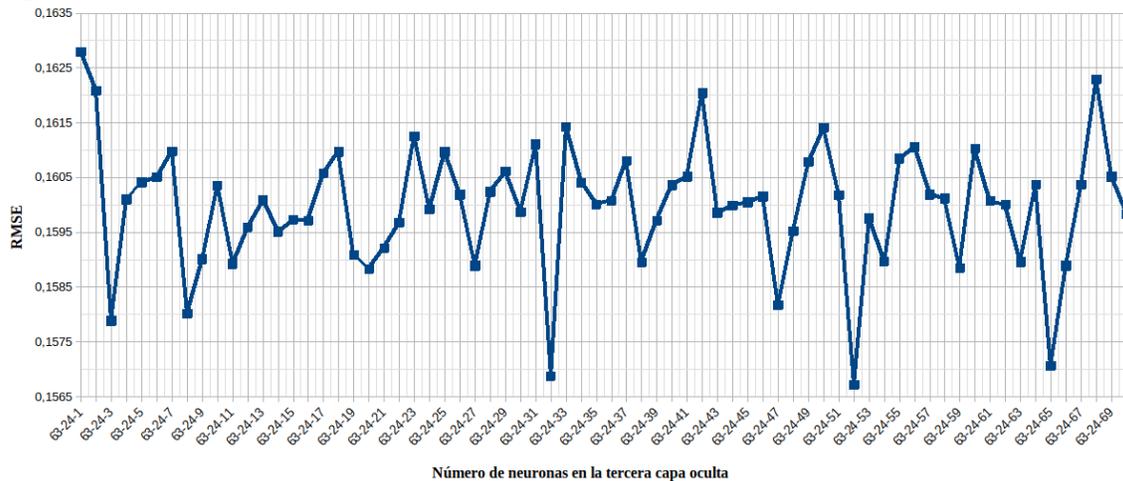
Para el modelo de tres capas ocultas se tiene un número fijo de 63 y 24 neuronas en la primera y segunda capa oculta, respectivamente. Se observan resultados de RMSE que se ubican entre un máximo de 0.1651 y un mínimo de 0.1567 puntos porcentuales, esto es, un rango de 0.0084.

Frente a la variabilidad en el error de las arquitecturas de una capa oculta es considerable la diferencia, no es así al compararlos con los resultados de las arquitecturas de la segunda capa oculta. El mínimo observado se encontró para la arquitectura 63-24-52. El segundo menor valor de RMSE se ubicó en el arreglo 63-24-32 con 0.1568 puntos porcentuales.

La Figura 54 detalla los resultados del entrenamiento de RNA de tres capas ocultas para el alargamiento postfisuración. En este caso, a medida que se aumentan el número de capas (y se fijan el número de neuronas de las capas

anteriores), el rango de variación del error tiende a reducirse. Asimismo, el error de la arquitectura con una neurona en una de las capas ocultas tiende a acercarse más al error mínimo de las anteriores arquitecturas entrenadas (aunque sigue siendo el más alto de las 70 arquitecturas).

Figura 54: Validación cruzada k-fold para Y1 en RNA de 3 capas ocultas



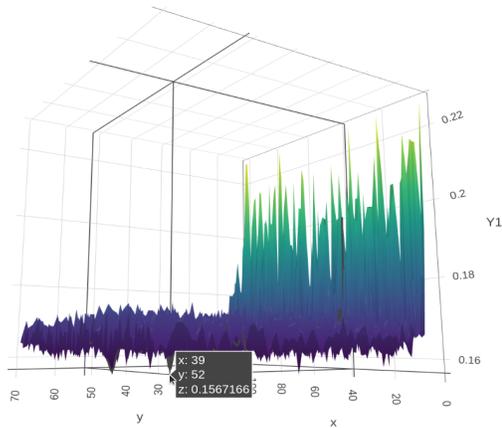
Fuente: construcción propia

Para tres capas ocultas no existe mucha diferencia en relación a la estimación de resultados posibles, mencionados para dos capas ocultas, es decir, en el rango de variación del resultado respuesta.

La Figura 55 permite observar los resultados del entrenamiento de las 70 arquitecturas de tres capas ocultas para cada uno de números aleatorios de pesos iniciales. El menor RMSE se encuentra en 52 (y) neuronas en la tercera capa oculta y con 39 (x) como número aleatorio para pesos iniciales de la RNA.

El modelo de RNA con 63 neuronas en la primera capa oculta, 24 neuronas en la segunda capa oculta y 52 neuronas en la tercera capa oculta, se entrena para encontrar la cantidad de veces que se deben pasar los datos (epoch) para obtener el mínimo error.

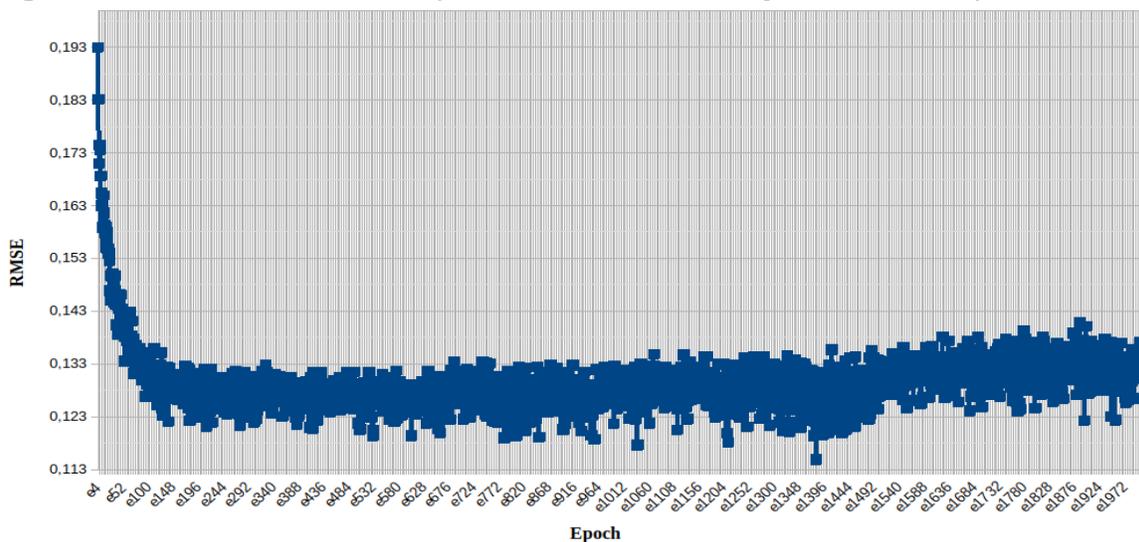
Figura 55: Validación cruzada k-fold para Y1 en RNA de 3 capas ocultas 3D



$x$  = aleatorio de pesos iniciales,  $y$  = número de neuronas en la 3ra capa oculta  
Fuente: construcción propia

La Figura 56 presenta un error de 0.1148 puntos porcentuales y un número de epoch de 1378. El resultado en cuanto a la aleatoriedad de asignación de pesos iniciales es de 57. El error obtenido en este entrenamiento es menor frente a los modelos de una y dos capas. En cuanto a la estimación del alargamiento postfisuración, implica que en promedio el rango de variación sería de 0.2296 puntos porcentuales, resultado que se presenta por debajo del objetivo de 0.3%.

Figura 56: Validación RNA 3 capas ocultas con 63, 24 y 52 neuronas para Y1



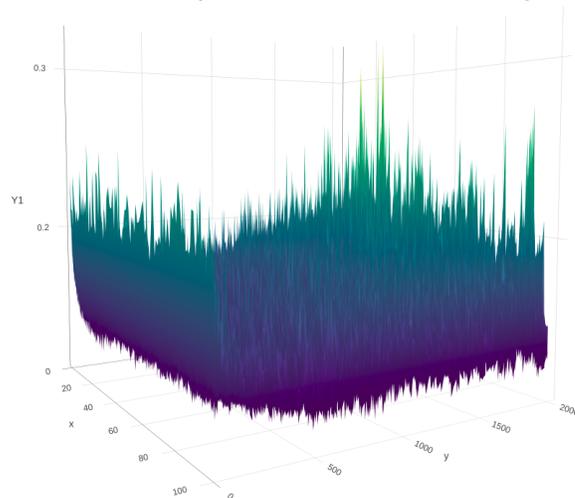
Fuente: construcción propia

Con los datos disponibles de entrenamiento de las arquitecturas de RNA para la variable Y1 se puede concluir que el modelo de tres capas ocultas presenta los mejores resultados.

Pese a que la diferencia del error en contraposición al obtenido en el modelo de una capa es de 0.0046 puntos porcentuales (que representa un 1,5% frente al objetivo de la variable de respuesta en cuestión), la misma puede ser determinante si se calcula el error medio absoluto del modelo, pues se espera que este último sea menor que el error cuadrático medio utilizado como función de pérdida en los entrenamientos de modelos RNA realizados.

Los resultados del error del modelo RNA con 63 neuronas en la primera capa oculta, 24 neuronas en la segunda capa oculta y 52 neuronas en la tercera capa oculta presentan una mayor variabilidad para la aleatoriedad de pesos iniciales que se asignan entre 1 y 20 y para aquellos mayores a 80. Los resultados mencionados se observan en la Figura 57.

*Figura 57: Validación RNA 3 capas ocultas con 63, 24 y 52 neuronas para Y1 3D*



*x = número aleatorio de pesos iniciales, y = número de epoch*  
*Fuente: construcción propia*

### 5.1.3.2 Modelos de RNA para la capacidad de absorción de energía (Y2)

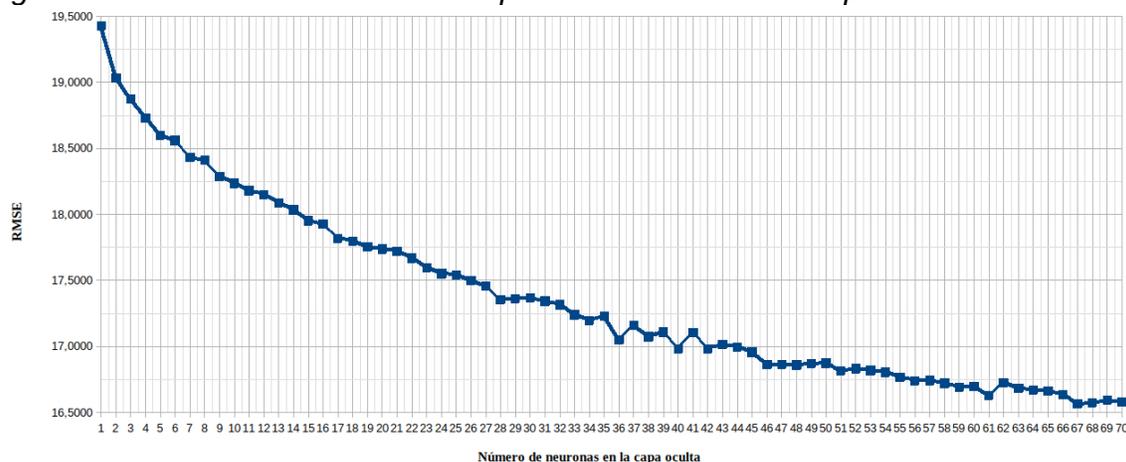
#### 5.1.3.2.1 Modelo de una capa oculta para Y2

El modelo de una capa oculta para la capacidad de absorción de energía muestra valores de RMSE entre un máximo de 19.4270 y un mínimo 16.5659. El rango de variación es de 2.8611.

El error mínimo observado se da para la arquitectura de 67 neuronas en la capa oculta. A medida que el número de neuronas se aumenta, el error en términos generales va en descenso. Es posible que después de la arquitectura de 70 neuronas se observe un error menor al observado, sin embargo, el coste computacional que implica el entrenamiento de las RNA frente a una, poco probable, reducción significativa del error, no hacen atractiva esta alternativa.

La Figura 58 permite observar la tendencia del comportamiento de los errores a medida que se aumenta el número de neuronas en la capa oculta. A partir de la arquitectura con 46 neuronas el error reduce su variación, se alcanzan a observar rachas en las que el error parece ser el mismo en diferentes arquitecturas, dada la baja variación de este. Es por esta razón que se concluye que posiblemente no haya una reducción significativa en el error de entrenamiento de RNA para un número superior a 70 neuronas en la capa oculta.

Figura 58: Validación cruzada k-fold para Y2 en RNA de 1 capa oculta



Fuente: construcción propia

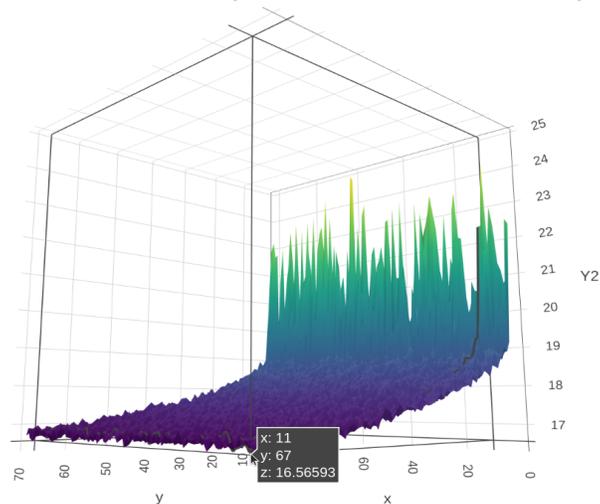
El modelo de una capa oculta para Y2 estimaría un valor que podría diferir en 16.5659 kJ/m<sup>3</sup> del valor real de la capacidad de absorción de energía de una

mezcla de HPFRCC. Una mezcla de concreto con un valor real de absorción de energía de  $50 \text{ kJ/m}^3$  tendría valores estimados que oscilarían entre un mínimo de  $33.4341 \text{ kJ/m}^3$  y máximo de  $69.5659 \text{ kJ/m}^3$ , en promedio. Este es un resultado a resaltar si se considera que el objetivo de este estudio para la variable Y2 es de mínimo  $50 \text{ kJ/m}^3$ .

En la Figura 59 se detallan los resultados del entrenamiento de las 70 arquitecturas de una capa oculta para cada uno de números aleatorios de pesos iniciales. El mínimo RMSE se encuentra en 67 (y) neuronas en la primera capa oculta y con 11 (x) como número aleatorio para pesos iniciales de la RNA. La reducción del error en cada valor aleatorio de pesos iniciales es constante como se observó en la Figura 58.

En el modelo de RNA con una capa oculta de 67 neuronas, se validan los resultados con el conjunto de datos test para conocer la cantidad de veces que se deben pasar los datos (epoch) para obtener el mínimo error.

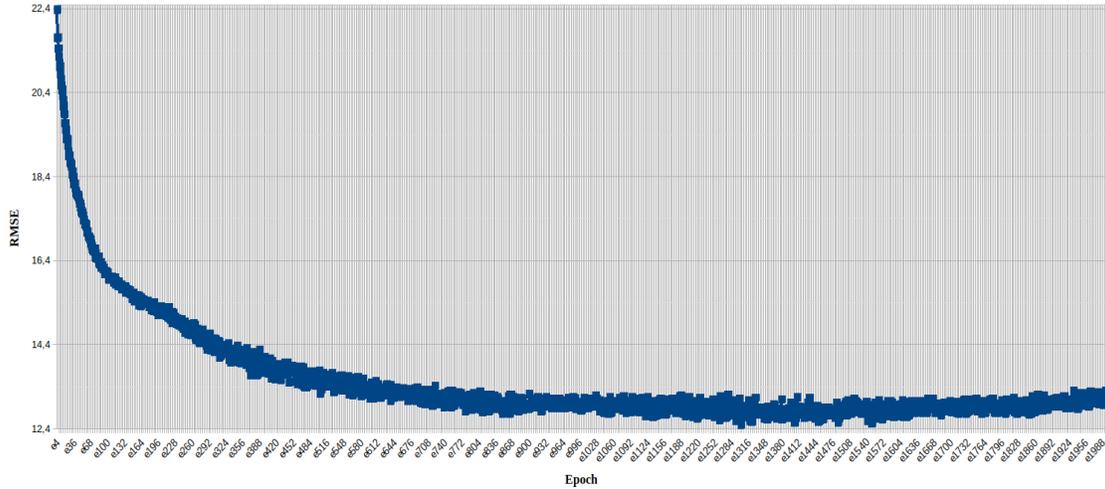
*Figura 59: Validación cruzada k-fold para Y2 en RNA de 1 capa oculta 3D*



*x = aleatorio de pesos iniciales, y = número de neuronas en la 1ra capa oculta*  
*Fuente: construcción propia*

La Figura 60 registra los resultados del entrenamiento del modelo RNA de 67 neuronas. El error se observa en  $12.4933 \text{ kJ/m}^3$  para 1299 epoch y un número de aleatoriedad de asignación de pesos iniciales de 91. El resultado se reduce en  $4 \text{ kJ/m}^3$  respecto a los obtenidos en la validación cruzada. Al presentar una estimación para la capacidad de absorción de energía, el modelo generaría resultados, que, en promedio, estarían en un rango de variación de  $24.9866 \text{ kJ/m}^3$ , valor que es menor al 50% del objetivo establecido para Y2

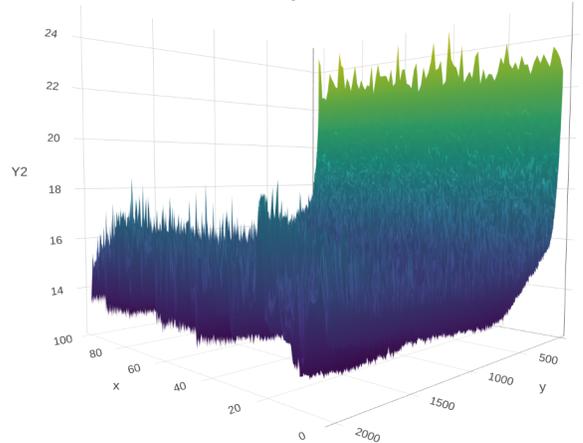
Figura 60: Validación de RNA de 1 capa oculta con 67 neuronas para Y2



Fuente: construcción propia

Los resultados del error del modelo RNA, con 67 neuronas en la primera capa oculta, registran mayor variabilidad cuando la aleatoriedad de pesos iniciales está entre 20 y 40. Esto se evidencia en los resultados que se observan en la Figura 61.

Figura 61: Validación de RNA de 1 capa oculta con 67 neuronas para Y2 3D



x = aleatorio de pesos iniciales, y = número de epoch

Fuente: construcción propia

### 5.1.3.2.2 Modelo de dos capas ocultas para Y2

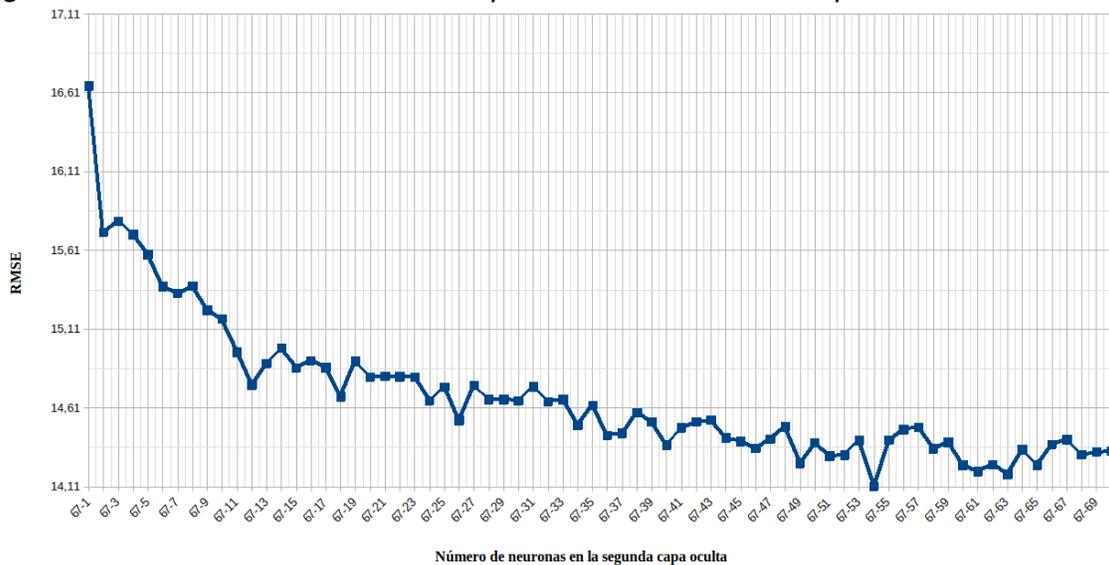
En el modelo de dos capas ocultas, con un número fijo de neuronas en la primera capa oculta de 67, el RMSE varía entre un máximo de 16.6534 y un mínimo de 14.1120 kJ/m<sup>3</sup>. Es decir, un rango de 2.5413 kJ/m<sup>3</sup>.

Aunque el rango no presenta gran diferencia frente al modelo de una capa oculta, el valor máximo y mínimo sí se encuentra evidentemente por debajo. El valor mínimo del primer modelo es muy cercano al valor máximo en el modelo de dos capas ocultas. El RMSE mínimo en dos capas ocultas se observa para la arquitectura 67-54.

La Figura 62 muestra los resultados del entrenamiento en dos capas ocultas para Y2. Frente a los resultados de la primera capa oculta se observa que la diferencia entre los mínimos RMSE es menor 2,4539 kJ/m<sup>3</sup>, valor que es muy similar al rango de variación tanto en una como en dos capas ocultas.

Los resultados llevan a que sea posible que el modelo de RNA, de dos capas ocultas, estime un resultado de capacidad de absorción de energía, mayor o menor al valor real en 14.1120 kJ/m<sup>3</sup>.

Figura 62: Validación cruzada k-fold para Y2 en RNA de 2 capas ocultas



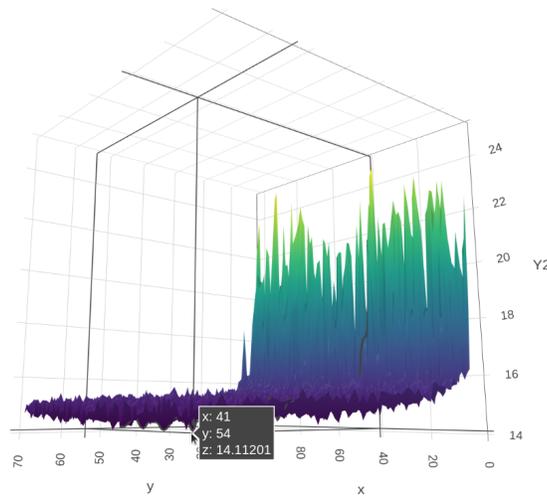
Fuente: construcción propia

En una mezcla de concreto con un valor real de absorción de energía de 50 kJ/m<sup>3</sup>, el valor estimado, en promedio, tomaría valores entre 35.888 y 64,112, lo que

significa un rango de variación de  $28.224 \text{ kJ/m}^3$ . Las diferencias entre los resultados del modelo de una capa y el de dos capas ocultas son evidentes en los valores mayor y menor de RMSE, lo cual impacta la variación promedio que podría darse en la estimación de respuestas de la variable en estudio.

En la Figura 63 se observan los resultados del entrenamiento de 70 arquitecturas de dos capas ocultas para cada uno de los números aleatorios de pesos iniciales. El mínimo RMSE se encuentra en 54 (y) neuronas en la segunda capa oculta y con 41 (x) como número aleatorio para pesos iniciales de la RNA.

*Figura 63: Validación cruzada k-fold para Y2 en RNA de 2 capas ocultas 3D*



*x = aleatorio de pesos iniciales, y = número de neuronas en la 2da capa oculta*  
*Fuente: construcción propia*

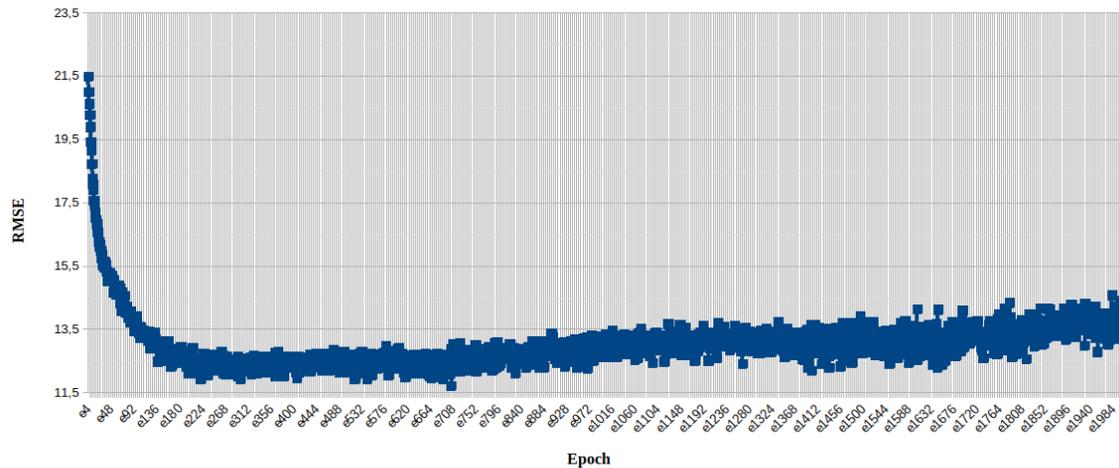
El modelo de RNA con 67 y 54 neuronas en la primera y segunda capa oculta, respectivamente, se entrena buscando establecer el número de veces que se deben pasar los datos (epoch) por el modelo para alcanzar el error mínimo.

La Figura 64 permite observar los resultados de dicho entrenamiento. El error mínimo registrado es de  $11.7113 \text{ kJ/m}^3$  para un número de epoch de 702. El valor de la aleatoriedad de asignación de pesos iniciales asociado a este error es de 67.

El error obtenido en este entrenamiento es menor respecto al resultado del mismo modelo con la validación tipo k-fold, presentando una reducción de  $2.4 \text{ kJ/m}^3$ . Adicionalmente, el error también resulta menor si se compara con el obtenido para el entrenamiento y validación del modelo de una capa oculta (con 2000 epoch) dado que la diferencia es de  $0.782 \text{ kJ/m}^3$ .

El modelo RNA para Y2 de dos capas ocultas con 67 y 57 neuronas en la primera y segunda capa, respectivamente, reflejan variabilidad para la aleatoriedad de pesos iniciales que se asignan entre 40 y 60, así como los valores cercanos a 100.

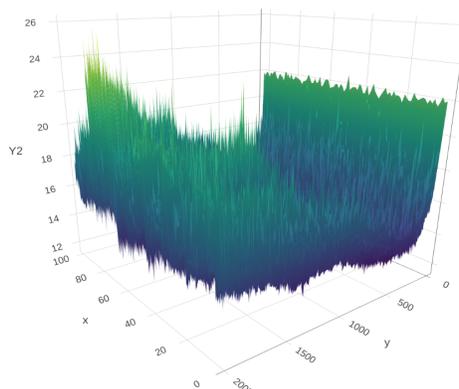
Figura 64: Validación de RNA de 2 capas ocultas con 67 y 54 neuronas para Y2.



Fuente: construcción propia

Los resultados presentados en la Figura 65 podrían verse diferentes a los que refleja la Figura 64, no obstante es importante resaltar que esta última presenta, en promedio por valores de aleatoriedad, los resultados del error de cada epoch. Aunque se observan valores de error considerablemente altos, también se encuentran valores del mismo error mucho menores en el mismo modelo.

Figura 65: Validación RNA de 2 capas ocultas con 67 y 54 neuronas para Y2 3D



$x$  = aleatorio de pesos iniciales,  $y$  = número de epoch.

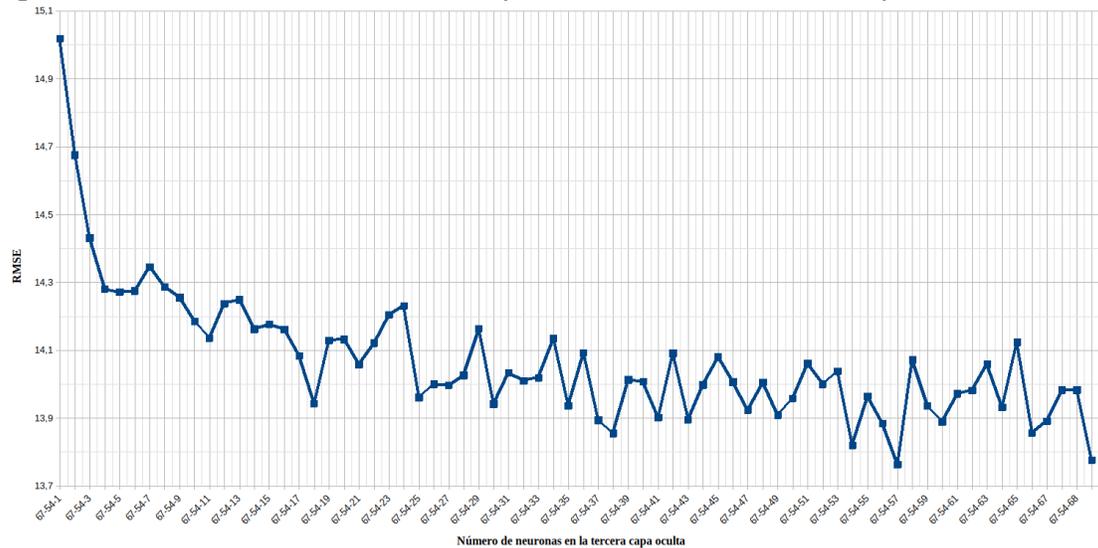
Fuente: construcción propia

### 5.1.3.2.3 Modelo de tres capas ocultas para Y2

Por último, el modelo de tres capas ocultas de Y2 inicia con un número fijo de 67 y 54 neuronas en la primera y segunda capa oculta, respectivamente. Los resultados de RMSE se ubican entre un máximo de 14.6708 y un mínimo de 13.7623 kJ/m<sup>3</sup>, esto es, un rango de 0.9085 kJ/m<sup>3</sup>. El resultado de error mínimo mencionado se observa para la arquitectura 67-54-57. Frente a la variación de las arquitecturas anteriores, los resultados son considerablemente menores en cuanto a los valores máximos y mínimos del RMSE.

En la Figura 66 En la figura 67 se observan los resultados del entrenamiento de RNA de tres capas ocultas para la capacidad de absorción de energía. Pese a que el rango de variación es bajo, si se excluyeran los dos primeros valores, la diferencia en el rango sería significativa. De este resultado se podría decir que para Y2 el aumentar la cantidad de capas ocultas y neuronas no tendría un impacto significativo en el mejoramiento de los resultados.

Figura 66: Validación cruzada k-fold para Y2 en RNA de tres capas ocultas



Fuente: construcción propia

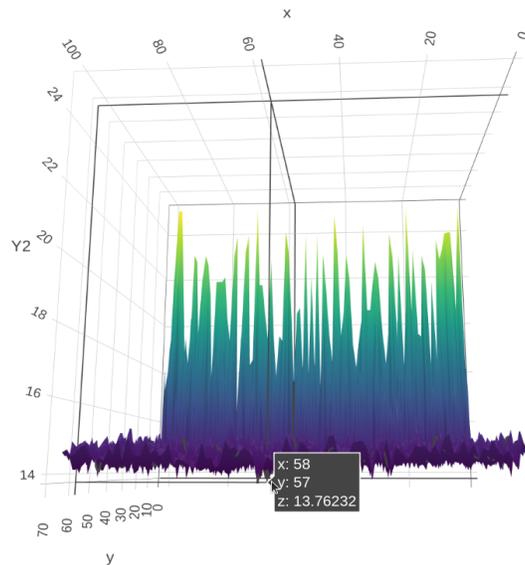
Un modelo de RNA de tres capas ocultas, con 67-54-57 neuronas en cada capa, podría estimar valores de capacidad de absorción de energía que en promedio variarían en 13.7623 kJ/m<sup>3</sup> del valor real, ya sea por encima o por debajo.

En una mezcla de concreto con un valor real de absorción de energía de 50 kJ/m<sup>3</sup>, el valor estimado, en promedio, tomaría valores entre 36.2377 y 63.7623. Lo que significa un rango de variación de 27,5246 kJ/m<sup>3</sup>. Si bien es cierto, son resultados

considerablemente mejores a los de los modelos de una y dos capas ocultas, los mismos no son concluyentes.

La Figura 67 presenta los resultados del entrenamiento de 70 arquitecturas de tres capas ocultas para cada uno de números aleatorios de pesos iniciales. El mínimo RMSE se encuentra en 57 (y) neuronas en la tercera capa oculta y con 58 (x) como número aleatorio para pesos iniciales de la RNA.

*Figura 67: Validación cruzada k-fold para Y2 en RNA de 3 capas ocultas 3D*



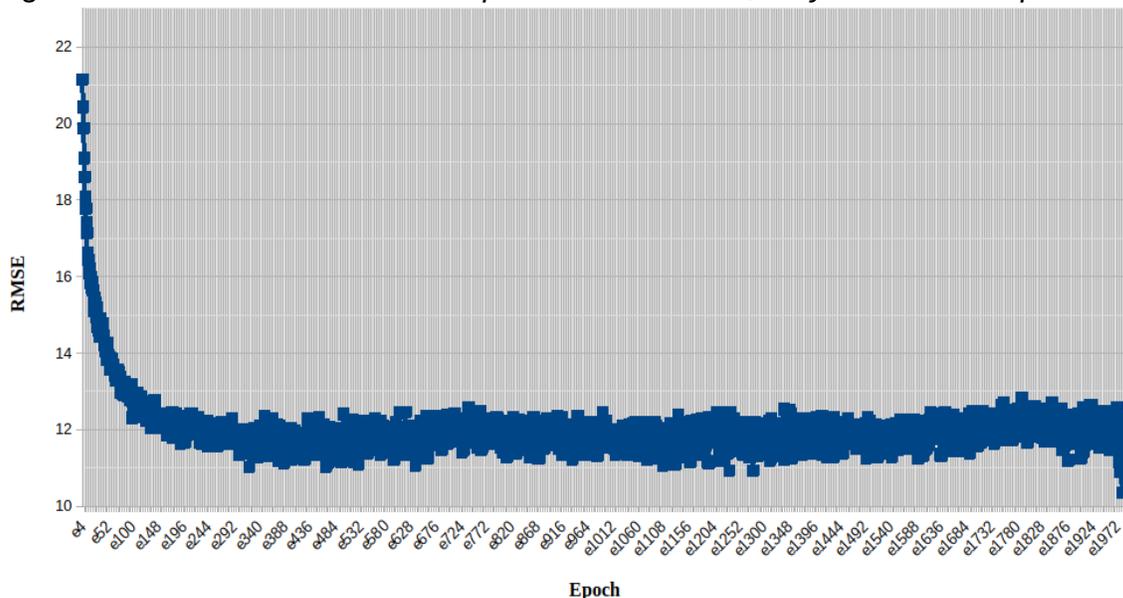
*x = aleatorio de pesos iniciales, y = número de neuronas en la 3ra capa oculta*

*Fuente: construcción propia*

El modelo de RNA tres capas ocultas con 67, 54 y 57 neuronas en la primera, segunda y tercera capa, respectivamente, se entrena a fin de observar cantidad de veces que deben pasar los datos por el modelo (epoch) hasta observar el error mínimo.

La Figura 68 presenta los resultados del entrenamiento mencionado. El error mínimo alcanzado es de 10.3449 kJ/m<sup>3</sup>, para un epoch de 1978 y un valor de aleatoriedad de asignación de pesos iniciales de 75.

Figura 68: Validación RNA de 3 capas ocultas con 67, 54 y 57 neuronas para Y2



Fuente: construcción propia

El error en este modelo es menor que los modelos de una y dos capas ocultas. En relación a la estimación de la capacidad de absorción de energía para una mezcla de HPFRCC, el rango de variación del resultado, en promedio, sería de 20,6898  $\text{kJ/m}^3$ . Este se presenta como un buen resultado según los objetivos del presente estudio.

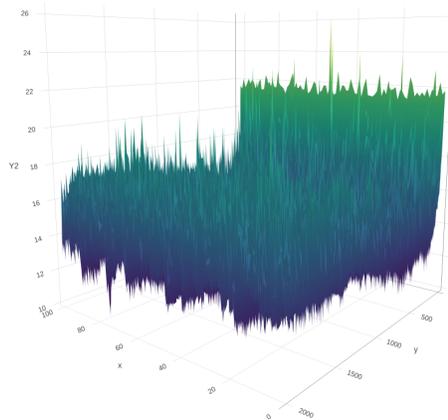
Los resultados del entrenamiento de las arquitecturas de RNA planteadas para la variable Y2 permiten observar que el modelo de tres capas ocultas presenta el error mínimo. Para este caso, se evidencia que a medida que se aumenta el número de capas el error disminuye. Así, del modelo de una a dos capas ocultas el error disminuyó en 0,782  $\text{kJ/m}^3$ . También, del modelo de dos al de tres capas ocultas el error se redujo en 1,3664 (equivalente a un 2,73% frente al objetivo en la capacidad de absorción de energía).

Al igual que se mencionó para Y1, se espera que, si se realiza la evaluación con el error absoluto medio, los valores serán menores que el error cuadrático medio utilizado como función de pérdida en los entrenamientos de los modelos RNA.

Los resultados del error del modelo RNA con 67, 54 y 57 neuronas en la primera, segunda y tercera capa oculta, respectivamente, presentan una mayor variabilidad constante en los valores aleatoriedad de pesos iniciales en todo el intervalo de valores de asignación (entre 1 y 100). La Figura 69 permite observar que los

valores de error en el entrenamiento del modelo varían entre 26 kJ/m<sup>3</sup> (aproximadamente) y el mínimo ya mencionado.

Figura 69: Validación RNA 3 capas ocultas con 67, 54 y 57 neuronas para Y2 3D



$x$  = aleatorio de pesos iniciales,  $y$  = número de epoch.

Fuente: construcción propia

### 5.1.3.3 Selección de los mejores modelos para cada variable

Para las dos variables en evaluación, los modelos de tres capas ocultas presentan el menor error, tanto en la validación tipo k-fold como con el conjunto de datos *test*. Las Tablas 4 y 5 muestran el resumen de los resultados de cada arquitectura y un porcentaje de reducción del error de una arquitectura a otra.

En el caso de la variable Y1, la arquitectura seleccionada para la predicción del alargamiento postfisuración para las dosificaciones de HPFRCC es de 63, 24 y 52 neuronas en la primera, segunda y tercera capa oculta respectivamente, con un valor de asignación de pesos iniciales de 57 y epoch de 1378.

Para la variable Y2, la arquitectura seleccionada para la predicción de la capacidad de absorción de energía para las dosificaciones de HPFRCC es de 67, 54 y 57 neuronas en la primera, segunda y tercera capa oculta respectivamente, con una valor de asignación de pesos iniciales de 75 y epoch de 1978.

Tabla 4: Resumen de resultados de entrenamiento de RNA para Y1

<b>Validación</b>
-------------------

		K-fold	Test	Reducción del error test
<b>1 capa oculta</b>	RMSE	0,1584	0,1194	NA
	Asignación pesos aleatorios	NA	55	
	Epoch	NA	307	
	Arquitectura	NA	63	
<b>2 capas ocultas</b>	RMSE	0,1577	0,1219	<b>-2,09%</b>
	Asignación pesos aleatorios	NA	38	
	Epoch	NA	273	
	Arquitectura	NA	63-24	
<b>3 capas ocultas</b>	RMSE	0,1567	0,1148	<b>5,82%</b>
	Asignación pesos aleatorios	NA	57	
	Epoch	NA	1378	
	Arquitectura	NA	63-24-52	

Fuente: construcción propia

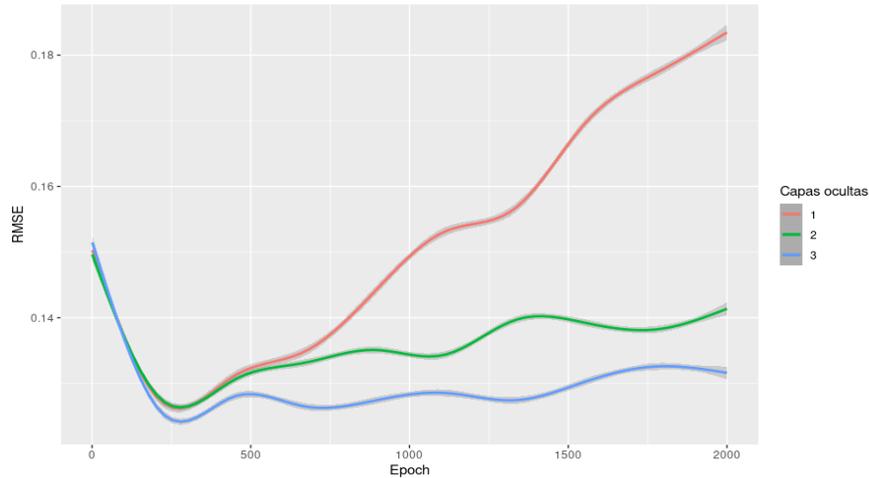
Tabla 5: Resumen de resultados de entrenamiento de RNA para Y2

		Validación		Reducción del error test
		K-fold	test	
<b>1 capa oculta</b>	RMSE	16,5659	12,4933	NA
	Asignación pesos aleatorios	NA	91	
	Epoch	NA	1299	
	Arquitectura	NA	67	
<b>2 capas ocultas</b>	RMSE	14,112	11,7113	<b>6,26%</b>
	Asignación pesos aleatorios	NA	67	
	Epoch	NA	702	
	Arquitectura	NA	67-54	
<b>3 capas ocultas</b>	RMSE	13,7623	10,3449	<b>11,67%</b>
	Asignación pesos aleatorios	NA	75	
	Epoch	NA	1978	
	Arquitectura	NA	67-54-57	

Fuente: construcción propia

Las gráficas suavizadas de la Figura 70 permiten observar de manera general la diferencia entre las tres arquitecturas en el error de validación Test para Y1. Los tres modelos inician con un comportamiento similar, pero después de los 250 epoch los modelos de RNA empiezan a aumentar el error.

Figura 70: Curvas suavizadas para RMSE de los modelos de RNA para Y1



Fuente: construcción propia

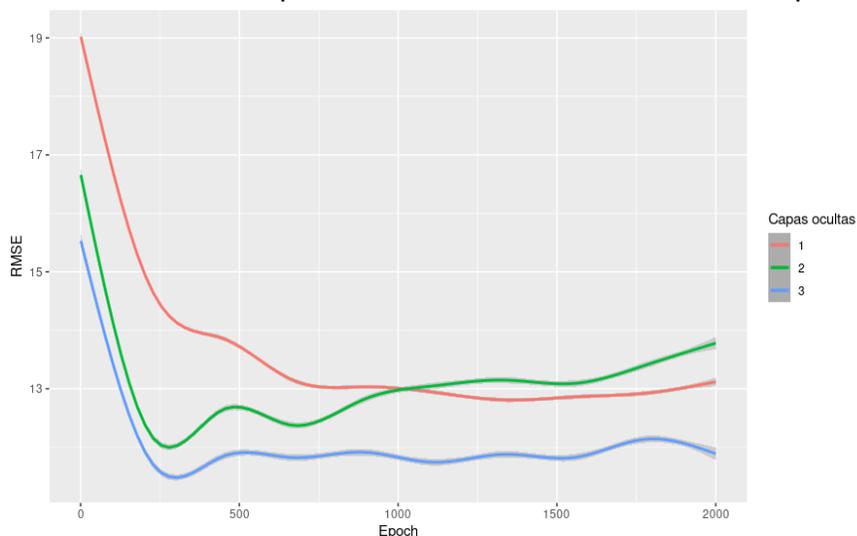
En los modelos entrenados para estimación del alargamiento postfisuración, aquellos de dos y tres capas ocultas no tienen el mismo aumento en el error que el observado para una sola capa oculta. Pese a esto, el error en el modelo de tres capas ocultas se mantiene siempre por debajo. Al finalizar las gráficas (en 2000 epoch), el modelo de dos capas ocultas presenta un posible aumento del error mientras que el modelo de tres capas ocultas presenta cierta tendencia a reducir el error nuevamente.

La Figura 71 presenta la diferencia existente entre las tres arquitecturas en el error de validación *test* para la capacidad de absorción de energía. En la primera parte de los resultados (antes del epoch 250), el modelo de una capa oculta presenta un error evidentemente mayor que los otros dos modelos, que, a su vez, reflejan cierta similitud en su comportamiento, aunque el modelo de tres capas ocultas se mantiene siempre con un error menor.

Después del epoch 750, el RMSE en el modelo de tres capas ocultas tiende a mantenerse constante, mientras que el de dos capas ocultas empieza a aumentar hasta superar el error del modelo de una capa oculta. El modelo de una capa oculta se mantiene sin una variación pronunciada después de los 750 epoch.

Al igual que el resultado visto para la variable Y1, el modelo de tres capas ocultas en Y2 presenta un RMSE menor que los otros dos modelos, esta vez desde el principio hasta el fin del entrenamiento a 2000 epoch.

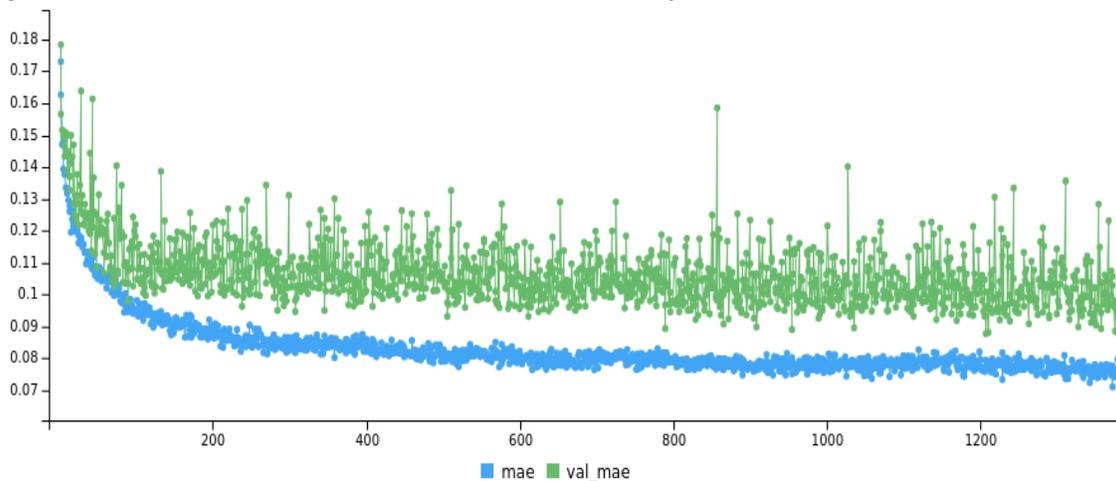
Figura 71: Curvas suavizadas para RMSE de los modelos de RNA para Y2



Fuente: construcción propia

Una vez obtenidos los parámetros definitivos de cada modelo se hace el entrenamiento para Y1 y Y2 fijando los parámetros ya descritos (número de neuronas en cada capa oculta, asignación de pesos iniciales y epoch) a fin de obtener el modelo de RNA definitivo. Los resultados para cada variable se observan en las figuras 72 y 73. En este caso se utiliza el MAE para evaluar los modelos.

Figura 72: Evaluación de entrenamiento de RNA para Y1 con MAE

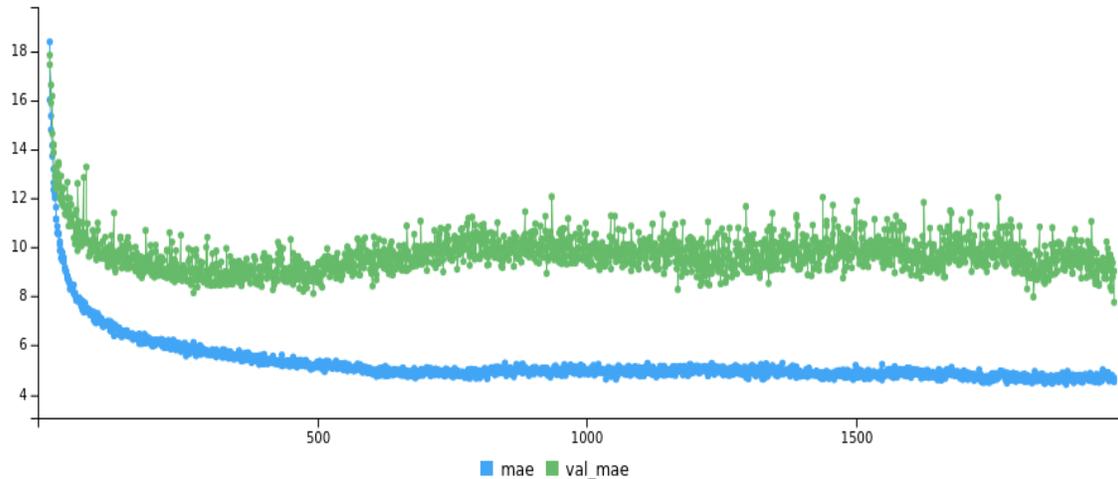


mae: entrenamiento, val\_mae: validación

Fuente: construcción propia

Para Y1, el MAE mínimo que se observa es de 0.08768 puntos porcentuales, lo que significa una diferencia de 0.02712 frente al resultado de RMSE. Es de resaltar que en este caso los mínimos resultan en un epoch diferente. Para el MAE, el epoch 1207 presenta el valor mínimo.

Figura 73: Evaluación de entrenamiento de RNA para Y2 con MAE



mae: entrenamiento, val\_mae: validación  
Fuente: construcción propia

En cuanto a Y2 el modelo presenta un valor mínimo de 7.7614 kJ/m<sup>3</sup> al ser evaluado con el MAE, el cual es 2.5835 kJ/m<sup>3</sup>, menor al resultado obtenido con RMSE. A diferencia de lo ocurrido con la variable Y1, en Y2 ambos mínimos se encuentran en el epoch 1978.

#### 5.1.3.4 Construcción del conjunto de datos de combinaciones

Las opciones de mezclas de HPFRCC dependen, principalmente, de la disponibilidad de fibras en el mercado colombiano. La Tabla 6 presenta el detalle de las fibras a tener en cuenta en las combinaciones y el coste de las mismas.

Tabla 6: Fibras en las dosificaciones de combinaciones de HPFRCC y Coste

Fibra	Resistencia a la tracción (MPa)	Longitud de la fibra (mm)	Diámetro de la fibra (mm)	Coste (COP*/Kg)
Metálica recta (S)	2650	13	0,2	11.000
Metálica acabada en gancho (H 1600)	1600	60	0,75	4.855

Fibra	Resistencia a la tracción (MPa)	Longitud de la fibra (mm)	Diámetro de la fibra (mm)	Coste (COP*/Kg)
Metálica acabada en gancho (H 2000)	2000	35	0,5	9.000
Metálica retorcida (T)	1700	13	0,5	7.500
Sintética polietileno-polipropileno (PE-PP)	650	50	0,67	27.000
Sintética polipropileno (PP)	550	48	0,72	30.000
Sintética Polivinilo de alcohol (PVA)	1600	6	0,025	35.000

Fuente: construcción propia. \*COP: Pesos colombianos

Se define un solo tipo de matriz de cemento con 8 componentes. Se incluye también la resistencia a la compresión de dicha matriz. La Tabla 7 lista los componentes de dicha matriz y sus respectivas cantidades.

Tabla 7: Matriz de cemento definida para el listado de combinaciones de HPFRCC

Componente	Valor
Cemento (Kg/m <sup>3</sup> )	600
Humo de sílice (Kg/m <sup>3</sup> )	100
Materiales cementantes (Kg/m <sup>3</sup> )	528,5
Agua (Kg/m <sup>3</sup> )	206
Superplastificante (Kg/m <sup>3</sup> )	21
Arena (Kg/m <sup>3</sup> )	836
Tamaño del agregado (µm)	600
Relación Agua/binder	0,167684168
Resistencia a la compresión (MPa)	155,6

Fuente: construcción propia

El volumen de la fibra que se contempla en las dosificaciones de HPFRCC varía entre el 1 y el 5%. Las dosificaciones pueden incluir uno o dos tipos de fibras. Para el caso de las dosificaciones que contemplan un solo tipo de fibra se incluyen 41 opciones de volumen por cada fibra,

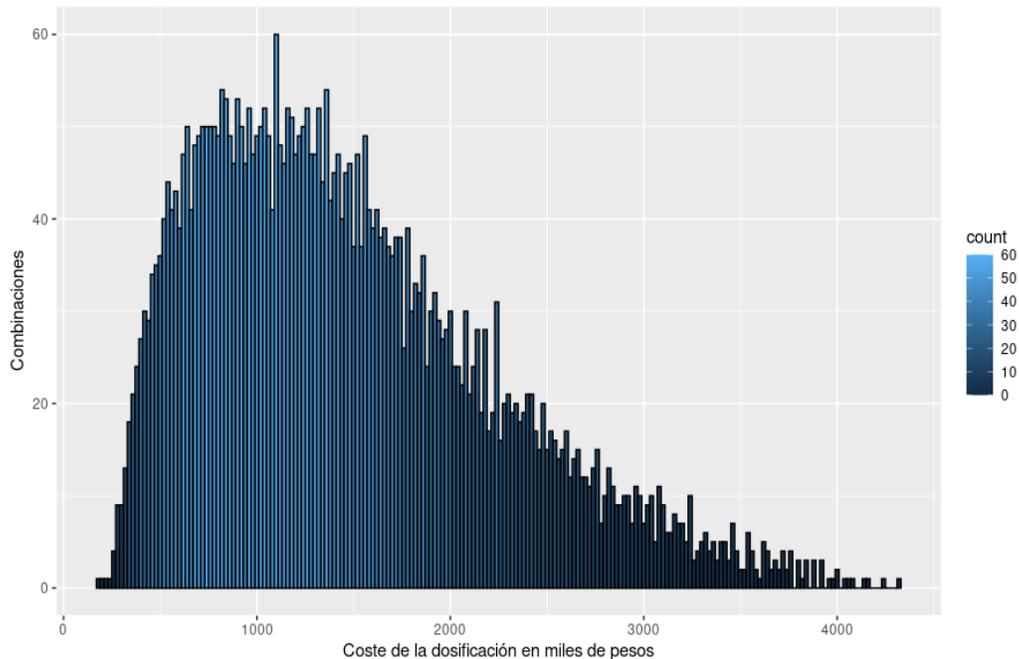
Las dosificaciones de 2 fibras tienen 205 mezclas posibles, cada una de las 41 opciones anteriormente mencionadas se combina con el volumen de la fibra 2 que tiene 5 posibles opciones.

Con los anteriores datos, se generan un total de 4592 dosificaciones de las cuales 287 contemplan un solo tipo de fibra y las 4305 restantes dos tipos de fibras.

En la Figura 74 se presentan los costos de las fibras en las dosificaciones en miles de pesos por volumen, esta muestra el detalle de la distribución de los costes de las combinaciones de HPFRCC. Estos varían entre 189 y 4318 y el promedio del coste es de 1475, aunque el 75% de estas tiene un valor inferior a 1935.

El conjunto de datos elaborado con el fin de estimar los valores de alargamiento postfisuración y la capacidad de absorción de energía en cada una, se pasa por los modelos de RNA seleccionados. Los resultados se analizan para identificar cuáles dosificaciones tienen alargamiento postfisuración superior al 0.3% y capacidad de absorción de energía superior a 50 kJ/m<sup>3</sup> (máximos), valores que funcionan como límites para identificar las combinaciones de HPFRCC de interés en este estudio.

Figura 74: Distribución de costes de mezclas de las combinaciones



Fuente: construcción propia

## 5.2 Resultados y contribución

### 5.2.1 Predicción del alargamiento post-fisuración

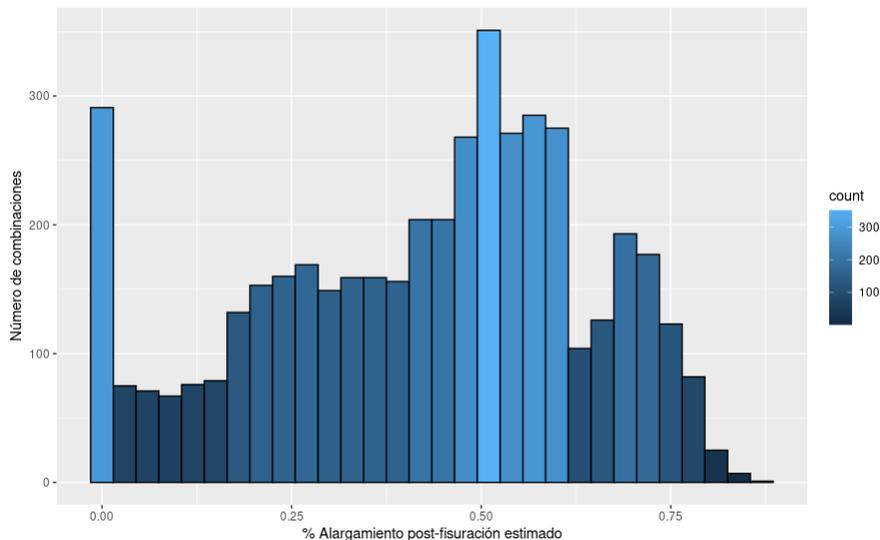
El conjunto de datos de 4592 dosificaciones se pasa por el modelo RNA de tres capas ocultas de 63, 24 y 52 neuronas en cada una, con una asignación de pesos iniciales de 57 y 1378 epoch, a fin de estimar los resultados de la variable Y1.

Una vez obtenidas las predicciones de Y1 se evidencia una dispersión en dicha variable entre un mínimo de 0 y un máximo de 0.85%. El 70.58% de las combinaciones (3241) presenta un alargamiento postfisuración superior al 0,3%. La Figura 75 detalla la cantidad de observaciones por intervalos de respuesta.

Frente a la fibra que contiene cada dosificación, las mezclas que incluyen un solo tipo de fibra (siete opciones) se observan así (ver Figura 76):

- 1) Aquellas que incluyen únicamente fibra S o PVA presentan un resultado menor a 0.3%, esto quiere decir que, independientemente del coste, se descartan.
- 2) Todas las mezclas o dosificaciones que incluyen PP o PE-PP presentan respuestas superiores al mínimo aceptado para la variable.
- 3) La fibra H es la de mejores resultados dentro de las metálicas. Este tipo de fibra de 1600 MPa tiene 34 dosificaciones con valores de Y1 superiores al límite, en la de 2000 MPa, el número de dosificaciones con respuesta adecuada es de 32.

Figura 75: Histograma de estimación del alargamiento post-fisuración

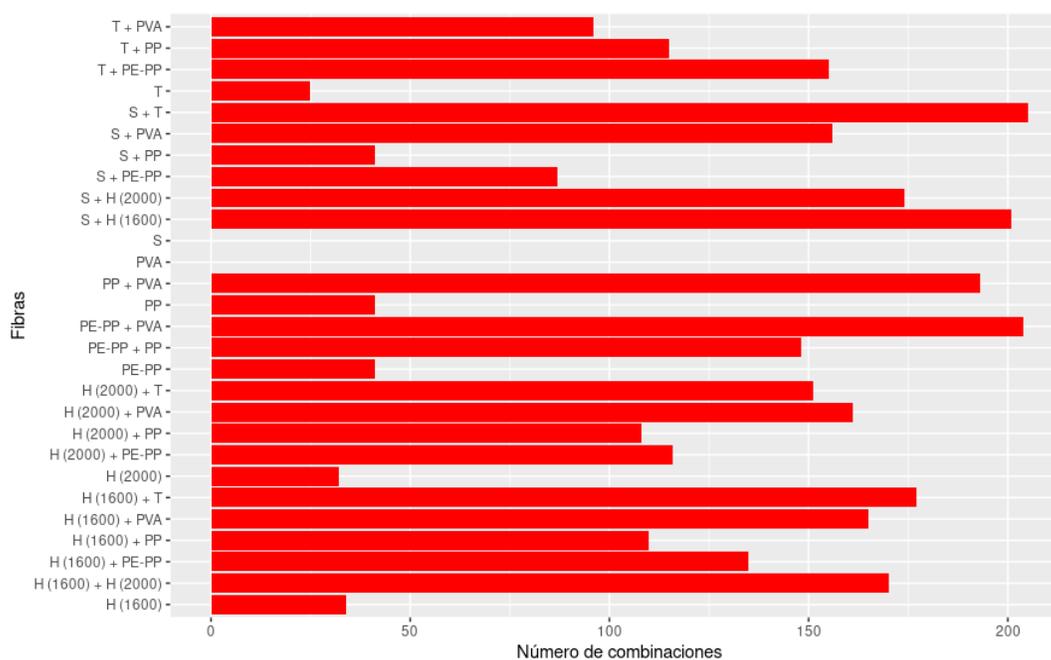


Fuente: construcción propia

La Figura 76 también detalla las dosificaciones que combinan dos tipos de fibra (21 opciones), frente a estas se podría resaltar:

- 1) Las dosificaciones que incluyen S y PP tienen los resultados más bajos, solo el 20% de las dosificaciones de este tipo superan el mínimo esperado.
- 2) Todas las dosificaciones que incluyen como componente fibras T y S tienen resultados en Y1 superior al esperado. Las mezclas que presentan PE-PP y PVA tienen 204 resultados por encima del límite (una sola dosificación no supera).
- 3) Cinco de las nueve combinaciones de fibras con los resultados superiores a 0.3% en el alargamiento postfisuración incluyen algún tipo de fibra H contempladas en las combinaciones.

Figura 76: Combinaciones de fibra frente a la respuesta estimada en Y1



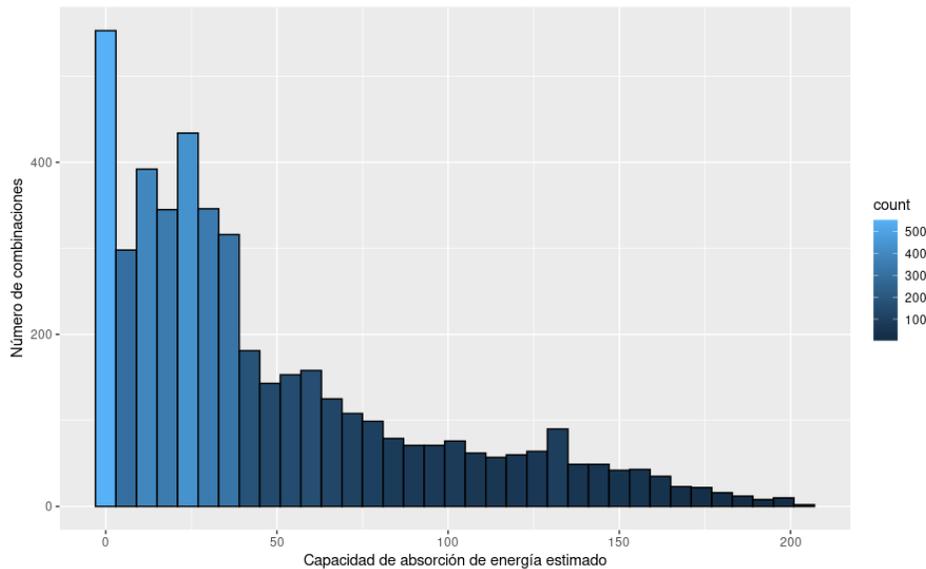
Fuente: construcción propia

### 5.2.2 Predicción de la capacidad de absorción de energía

Para la variable Y2, el conjunto de dosificaciones se pasa por el modelo de RNA de tres capas ocultas con 67, 54 y 57 neuronas y con asignación de pesos iniciales de 75 y 1978 epoch para predecir la capacidad de absorción de energía. Los resultados de las estimaciones presentan un rango de variación de 0 a 202.63

$\text{kJ/m}^3$ . Se observa que el 35.1% de las combinaciones tienen una respuesta por encima de  $50 \text{ kJ/m}^3$ . Los detalles de dichos resultados se reflejan en la Figura 77, presentados por intervalos.

Figura 77: Histograma de estimación de la capacidad de absorción de energía

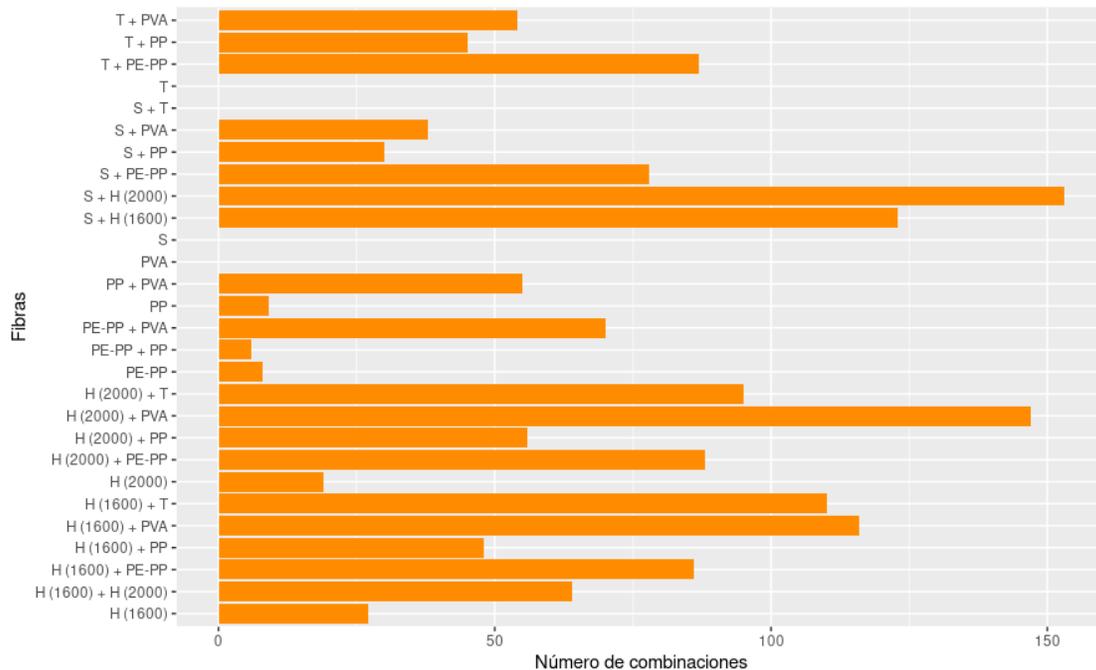


Fuente: construcción propia

En las dosificaciones con un solo tipo de fibra, los resultados permiten destacar las siguientes características (ver Figura 78):

- 1) Las mezclas que contienen únicamente fibra T, S o PVA, no presentan capacidad de absorción de energía superior al límite esperado.
- 2) Las dosificaciones que contienen fibra H, tanto de 1600 como de 2000 MPa, presenta los mejores resultados. Para el caso de la fibra de 1600 MPa, 27 de las 41 dosificaciones presentan resultados adecuados y 19 de las 41 dosificaciones con 2000MPa, superan este mínimo esperado.
- 3) Alrededor del 20% de las mezclas que contienen fibra sintética PP o PP-PE tiene resultados de capacidad de absorción de energía que superar en límite que establece el objetivo.

Figura 78: Combinaciones de fibra frente a la respuesta estimada en Y2



Fuente: construcción propia

En la Figura 78 se incluye el detalle de las dosificaciones con dos tipos de fibras, se observan mejores resultados en capacidad de absorción de energía cuando las mismas incluyen fibra metálica H. Al respecto se detalla que:

- 1) Ninguna de las dosificaciones con fibra S y T tienen una capacidad de absorción de energía superiores a  $50 \text{ kJ/m}^3$ .
- 2) Las dosificaciones que incluyen dos tipos de fibras sintéticas, en general, presentan un bajo desempeño para la variable Y2. En los resultados de la combinación de fibra PE-PP y PVA el 35% de las mezclas superan el mínimo esperado.
- 3) Alrededor del 50% de las combinaciones, con dos tipos de fibras, que cumplen el objetivo frente a la capacidad de absorción de energía, incluyen alguna de las dos opciones de fibra H disponibles, siendo entre estas las combinaciones S y H (2000), H (2000) y PVA, y S y H (1600) la de mayor cantidad de dosificaciones que superan el límite esperado.

Los resultados descritos detallan el cumplimiento del límite de las variables de manera individual, no obstante, es necesario conocer los resultados de las dosificaciones que cumplen las condiciones de ambas variables, conforme al objetivo de este estudio. Según los resultados evidenciados, de manera individual

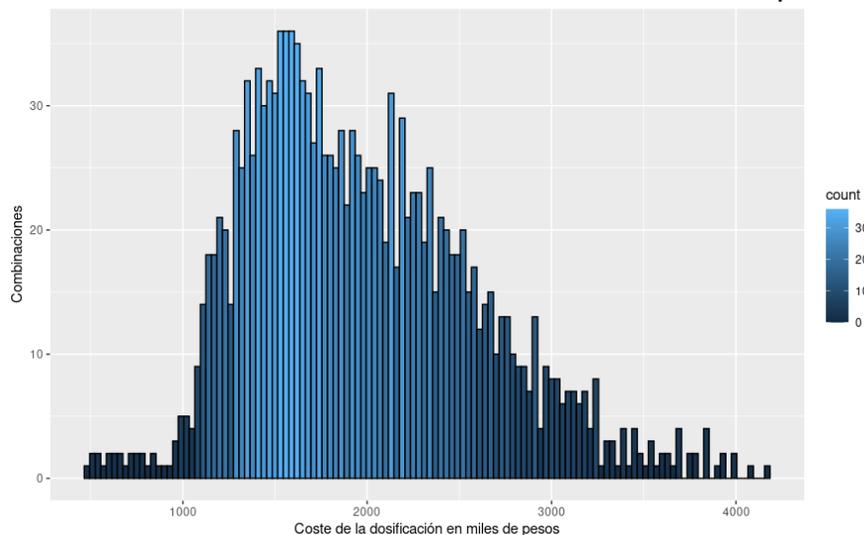
para Y1 y Y2, se podría esperar que las combinaciones que incluyen fibra H sean las que cumplen el objetivo. Adicionalmente, teniendo en cuenta los resultados visto hasta el momento, no es muy probable que las combinaciones que incluyen fibra sintética aparezcan entre aquellas que cumplen ambas condiciones, pese a esto, entre las fibras sintéticas la de PE-PP presenta el mejor desempeño en las propiedades estimadas.

### 5.2.3 Identificación de las mezclas optimas HPFRCC – máximos y mínimos.

Al revisar los resultados de las combinaciones teniendo en cuenta ambas variables, es decir, aquellas combinaciones que en el alcanzan o superan el límite tanto de Y1 como de Y2, se observa que 1535 de estas cumplen dichas condiciones, esto es, el 33.43% de las combinaciones.

Para Y1 estos resultados toman valores entre 0.3 y 0.81% mientras que para el caso de Y2 los resultados van desde 50.01 y 202.64 kJ/m<sup>3</sup>. Los costos de la fibra en estas combinaciones va desde un mínimo (en miles de pesos por volumen) 483.56 hasta 4160.5. El coste promedio de las fibras es de 1972.5 y el 75% de las combinaciones presentan un coste menor a 2370. Frente a los resultados de coste inicialmente analizados, se observa un aumento en estos valores de referencia, es decir, que las combinaciones que se excluyen del estudio dado que no cumplen las características de las propiedades mecánicas deseadas, son en promedio, las de las fibras de menor coste. Los resultados mencionados se observan en la Figura 79.

Figura 79: Distribución costes mezclas de combinaciones con respuesta Y1 y Y2



Fuente: construcción propia

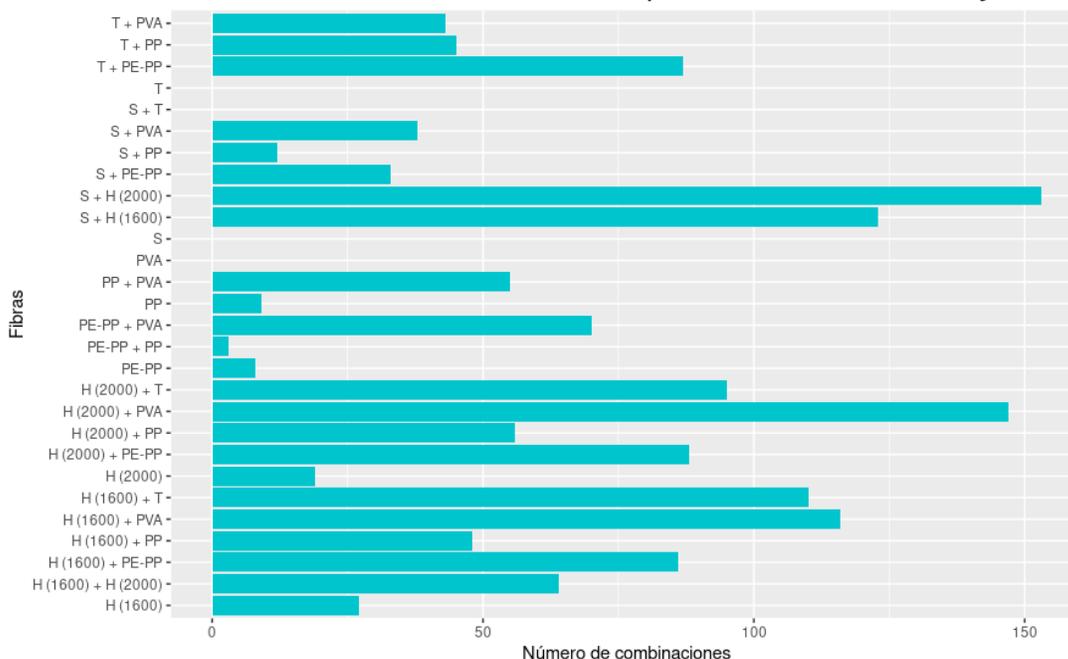
Los resultados en relación al tipo de fibras que se encuentra que aquellas dosificaciones que tienen un tipo de fibra como PVA, S, T y combinación de S y T no presentan el alargamiento post-fisuración y la capacidad de absorción de energía buscadas.

Con relación a las fibras sintéticas, aquellas dosificaciones que incluyen PE-PP o PP únicamente, solo 8 y 9 de estas, respectivamente, reflejan los resultados esperados. La mayor cantidad de dosificaciones con alargamiento post-fisuración superior a 0,3% y capacidad de absorción de energía superior a 50kJ/m<sup>3</sup> se da en combinación de dos tipos de fibras, y en estas, aparece una de las dos fibras H disponibles. Los resultados descritos se observa en la Figura 80.

Se podría plantear inicialmente que los tres tipos de mezcla con mayor probabilidad de éxito son aquellas que contienen combinaciones de fibra S y H (1600), S y H (2000), y H (2000) y PVA, no obstante esta última es poco viable dado el coste elevado de la fibra de PVA.

En la identificación de máximos y mínimos se buscan aquellas dosificaciones en las que se maximiza el resultado en Y1 y Y2 y minimiza el coste, para un total de 1535 mezclas, se presentan los siguientes resultados:

*Figura 80: Combinaciones de fibra frente a la respuesta estimada en Y1 y Y2*



*Fuente: construcción propia*

Los resultados de de identificación de máximos y mínimos, muestran las combinaciones esperadas según el análisis realizado para las variables Y1 y Y2. Las combinaciones con mayor probabilidad de éxito son aquellas que contienen dos tipos de fibra metálica y cuando una de estas es de tipo H bien sea de 1600 o 2000 MPa. El coste de las fibras seleccionadas están por debajo del promedio calculado para aquellas dosificaciones que superan los límites establecidos como objetivo en Y1 y Y2. Las fibras con mayor probabilidad de éxito para un alargamiento post-fisuración superior a 0.3% y una capacidad de absorción de energía superior a 50 kJ/m<sup>3</sup> se encontraría entre los COP\$ 811.909 y COP\$ 1.005.820, para volúmenes de fibra de 1.5 y 2.1%. La Tabla 8 presenta el detalle de los resultados definitivos.

*Tabla 8: Resultados optimización multiobjetivo*

Fibra 1		Fibra 2		Vol total (%)	Resultado		
Tipo	Vol (%)	Tipo	Vol (%)		Y1 (%)	Y2 (kJ/m <sup>3</sup> )	Coste (miles)
S	0,34	H (1600)	1.36	1.70	0.3137	51.4476	811,91
S	0,36	H (1600)	1.44	1.80	0.3174	53.4265	859,67
S	0,38	H (1600)	1.52	1.90	0.3210	55.5911	907,43
S	0,64	H (1600)	0.96	1.60	0.3567	51.5186	918,51
S	0,75	H (1600)	0.75	1.50	0.3902	50.7820	933,46
S	0,40	H (1600)	1.60	2.00	0.3264	57.7557	955,19
S	0,68	H (1600)	1.02	1.70	0.3415	53.2636	975,92
S	0,80	H (1600)	0.80	1.60	0.3707	52.5943	995,69
S	0,42	H (1600)	1.68	2.10	0.3349	59.9753	1002,95
S	0,90	H (1600)	0.60	1.50	0.4090	51.3500	1005,82

*Fuente: construcción propia*

## **6. Conclusiones y recomendaciones**

Las RNA son una herramienta adecuada para analizar, entender e interpretar datos y de esta manera aportar en la toma de decisiones. En el caso de estudio esta herramienta resulta adecuada para orientar la toma de decisiones en cuanto al diseño de las mezclas de concreto de HPFRCC que optimice los resultados tanto de sus propiedades mecánicas como económicos de tal forma que sea viable a nivel comercial.

Adicionalmente, las RNA son una herramienta que nos permite “extraer” el conocimiento de la información de un conjunto de datos, esto se presenta como una herramienta útil para facilitar el entendimiento de una situación o problemática de interés, representada por un conjunto de datos. Aunque inicialmente este conocimiento puede quedar en una “caja negra”, esto es, que no se puede visualizar, un desarrollo complementario en los modelos de RNA podría permitir el acceso a ese conocimiento.

La calidad y confiabilidad de los datos es relevante para obtener resultados útiles cuando se hace uso de RNA. No es recomendable el uso de este tipo de modelos cuando la cantidad de datos disponibles no es suficientemente grande o cuando los mismos no resultan confiables. Una cantidad de datos considerable es necesaria para tener un conocimiento amplio y acertado del problema en estudio. Tener a disposición datos confiables es pertinente para que los modelos de RNA otorguen resultados que orienten de manera adecuada la toma de decisiones.

En este estudios, mediante uso de RNA se hizo posible identificar las dosificaciones HPFRCC que incluyen fibras accesibles en el mercado colombiano de mayor probabilidad de éxito bajo criterios de alargamiento post-fisuración superior a 0.3%, capacidad de absorción de energía superior a 50 kJ/m<sup>3</sup> y menor coste posible, orientando una adecuada toma de decisiones en las pruebas de laboratorio que se pueden desarrollar, logrando de esta manera una futura optimización de recursos.

### **6.1 Trabajo Futuro**

Los resultados del presente estudio podrían orientarse a resultados más robustos con un conjunto de datos inicial mucho más amplio y que incluya mayor información de la aplicación de Fibras Sintéticas en los Concretos Reforzados con

Fibra. Por ende, es posible que este estudio pueda mejorarse con un dataset inicial mucho mayor y explorando otros tipos de arquitecturas de RNA.

El estudio presentado no incluye un análisis de influencia o sensibilidad de las variables de entrada, esto es, una manera de visualizar el conocimiento que ofrece el modelo. Por esto, se abre un espacio para desarrollar un modelo, que complemente lo desarrollado, que permita iluminar la caja negra y obtener detalles del comportamiento de las variables estudiadas. Esta opción existe para otro tipo de librerías o herramientas de R, no obstante, para el caso de Keras no fue posible tener acceso a una herramienta que permita este resultado.

En el desarrollo de este estudio se utilizó la herramienta R con las librerías Keras y Tensorflow para el entrenamiento de los modelos de RNA. No obstante, no fue posible modificar algunos hiperparámetros en los modelos propios del único algoritmo de aprendizaje utilizado debido a las limitaciones de tiempo. Para futuros trabajos se podría explorar el comportamiento de los modelos modificando los hiperparámetros del algoritmo de aprendizaje. Adicionalmente, puede ser de gran beneficio estudiar las diferencias que se pueden presentar al hacer uso de otros algoritmos de aprendizaje u otras funciones de activación en modelos de RNA de regresión. Por último, cabe mencionar que la literatura disponible de RNA, en las que se usa Keras y Tensorflow, está más enfocada a problemas de clasificación y no de regresión, situación que se presenta como una limitante si se tiene en cuenta que estas dos librerías son las de mayor uso en Deep Learning a nivel mundial, y es muy poca la información que se tiene para darle este tipo de aplicación.

## Referencias

- Abdollahzadeh, A., Masoudnia, R., & Aghababaei, S. (2011). Predict strength of rubberized concrete using artificial neural network. *WSEAS Transactions on Computers*, 10(2), 31–40.
- Abellán-García, J. (2020). Four-layer perceptron approach for strength prediction of UHPC. *Construction and Building Materials*, 256, 119465. <https://doi.org/10.1016/j.conbuildmat.2020.119465>
- Abellán García, J., Fernández Gómez, J., & Torres Castellanos, N. (2020). Properties prediction of environmentally friendly ultra-high-performance concrete using artificial neural networks. *European Journal of Environmental and Civil Engineering*, 0(0), 1–25. <https://doi.org/10.1080/19648189.2020.1762749>
- Abellán, J. (2020). Comparison of Artificial Intelligence and Multivariate Regression in modeling the flexural behavior of UHPFRC. *DYNA*. <http://doi.org/10.15446/dyna.v87n214.86172>
- Abellán, J., Fernández, J., Torres, N., & Núñez, A. (2020a). Development of cost-efficient UHPC with local materials in Colombia. *Proceedings of Hipermat 2020 - 5th International Symposium on UHPC and Nanotechnology for Construction Materials*, March, 97–98.
- Abellán, J., Fernández, J., Torres, N., & Núñez, A. (2020b). Ultra-High-Performance Concrete With Local High Unburned Carbon Flyash. *American Concrete Institute*, 1, 1–37.
- Abellán, J., Torres, N., & Núñez, A. (2018). CONCRETOS DE MUY ALTAS PRESTACIONES REFORZADOS CON FIBRAS: ESTADO DEL ARTE, APLICACIONES Y POSIBILIDADES EN EL MERCADO LATINOAMERICANO. *XXXVIII Jornadas Suramericanas de Ingeniería Estructural Lima 2018*.
- Abellán, J., Torres, N., Núñez, A., & Fernández, J. (2018). INFLUENCIA DEL EXPONENTE DE FULLER, LA RELACION AGUA CONGLOMERANTE Y EL CONTENIDO EN POLICARBOXILATO EN LAS PROPIEDADES DE CONCRETOS DE MUY ALTAS PRESTACIONES. *19 Convencion Científica de Ingeniería y Arquitectura La Habana Cuba*.

- Abounia Omran, B., Chen, Q., & Jin, R. (2014). Prediction of Compressive Strength of “Green” Concrete Using Artificial Neural Networks. *50th ASC Annual International Conference Proceedings*, 1–9.
- Adeli, H. (2001). Neural networks in civil engineering: 1989-2000. *Computer-Aided Civil and Infrastructure Engineering*, *16*(2), 126–142.  
<https://doi.org/10.1111/0885-9507.00219>
- Bal, L., & Buyle-Bodin, F. (2013). Artificial neural network for predicting drying shrinkage of concrete. *Construction and Building Materials*, *38*, 248–254.  
<https://doi.org/10.1016/j.conbuildmat.2012.08.043>
- Basheer, I. A., & Hajmeer, M. (2000). Artificial neural networks: Fundamentals, computing, design, and application. *Journal of Microbiological Methods*, *43*(1), 3–31. [https://doi.org/10.1016/S0167-7012\(00\)00201-3](https://doi.org/10.1016/S0167-7012(00)00201-3)
- Beck, M. W. (2018). NeuralNetTools : Visualization and Analysis Tools for Neural Networks. *Journal of Statistical Software*, *85*(11).  
<https://doi.org/10.18637/jss.v085.i11>
- Bharathi, S. D., Manju, R., & Premalatha, J. (2017). Prediction of Compressive Strength for Self- Compacting Concrete ( SCC ) using Artificial Intelligence and Regression Analysis. *International Journal of ChemTech Research*, *10*(8), 263–275.
- Bishop, C. M. (2006). Pattern Recognition and Machine Learning. In M. Jordan, J. Kleinberg, & B. Schölkopf (Eds.), *Oxidation Communications* (Vol. 27, Issue 1). Springer Singapore. <https://www.springer.com/gp/book/9780387310732>
- Chandwani, V., Agrawal, V., & Nagar, R. (2015). Modeling slump of ready mix concrete using genetic algorithms assisted training of Artificial Neural Networks. *Expert Systems with Applications*, *42*(2), 885–893.  
<https://doi.org/10.1016/j.eswa.2014.08.048>
- Chao, S.-H., Kaka, V., Palacios, G., Kim, J., Choi, Y.-J., Aghdasi, P., Nojavan, A., & Schultz, A. (2016). Seismic Behavior of Ultra-High-Performance Fiber-Reinforced Concrete Moment Frame Members. *Proceedings of the First International Interactive Symposium on UHPC*, 1–10. <https://doi.org/10.21838/uhpc.2016.44>
- Chollet, F., & Allaire, J. J. (2017). Deep Learning with R. In *Book* (Issue 1). Manning Publications. <https://doi.org/citeulike-article-id:10054678>
- Cruz, R. M. S., Peixoto, H. M., & Magalhães, R. M. (2011). Artificial Neural Networks and Efficient Optimization Techniques for Applications in

- Engineering. In K. Suzuki (Ed.), *Artificial Neural Networks - Methodological Advances and Biomedical Applications* (pp. 45–68). InTech.
- D. N. Moriasi, J. G. Arnold, M. W. Van Liew, R. L. Bingner, R. D. Harmel, & T. L. Veith. (2007). Model Evaluation Guidelines for Systematic Quantification of Accuracy in Watershed Simulations. *Transactions of the ASABE*, 50(3), 885–900. <https://doi.org/10.13031/2013.23153>
- de Larrard, F., & Sedran, T. (2002). Mixture-proportioning of high-performance concrete. *Cement and Concrete Research*, 32(11), 1699–1704. [https://doi.org/10.1016/S0008-8846\(02\)00861-X](https://doi.org/10.1016/S0008-8846(02)00861-X)
- De Larrard, F., & Sedran, T. (1994). Optimization of ultra-high-performance concrete by the use of a packing model. *Cement and Concrete Research*, 24(6), 997–1009. [https://doi.org/10.1016/0008-8846\(94\)90022-1](https://doi.org/10.1016/0008-8846(94)90022-1)
- Demir, F. (2008). Prediction of elastic modulus of normal and high strength concrete by artificial neural networks. *Construction and Building Materials*, 22(7), 1428–1435. <https://doi.org/10.1016/j.conbuildmat.2007.04.004>
- Deperlioglu, O., & Kose, U. (2011). An educational tool for artificial neural networks. *Computers and Electrical Engineering*, 37(3), 392–402. <https://doi.org/10.1016/j.compeleceng.2011.03.010>
- Everitt, B., & Hothorn, T. (2011). *An Introduction to Applied Multivariate Analysis with R*. Springer New York. <https://doi.org/10.1007/978-1-4419-9650-3>
- Funk, J. E., & Dinger, D. R. (1994). Predictive Process Control of Crowded Particulate Suspensions. In *Predictive Process Control of Crowded Particulate Suspensions*. <https://doi.org/10.1007/978-1-4615-3118-0>
- Getahun, M. A., Shitote, S. M., & Abiero Gariy, Z. C. (2018). Artificial neural network based modelling approach for strength prediction of concrete incorporating agricultural and construction wastes. *Construction and Building Materials*, 190, 517–525. <https://doi.org/10.1016/j.conbuildmat.2018.09.097>
- Ghafari, E., Bandarabadi, M., Costa, H., & Júlio, E. (2012). Design of UHPC using artificial neural networks. In *Brittle Matrix Composites 10* (Issue July, pp. 61–69). Elsevier. <https://doi.org/10.1533/9780857099891.61>
- Ghafari, E., Bandarabadi, M., Costa, H., & Júlio, E. (2015). 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(11), 04015017. [https://doi.org/10.1061/\(ASCE\)MT.1943-5533.0001270](https://doi.org/10.1061/(ASCE)MT.1943-5533.0001270)

- Ghatak, A. (2019). Deep Learning with R. In *Deep Learning with R*. Springer Singapore. <https://doi.org/10.1007/978-981-13-5850-0>
- González-salcedo, L. O. (2012). Aplicación de la Inteligencia Artificial en el diseño de mezclas de concreto . Estado del Arte. *Cuaderno ACTIVA*, 4, 55–65.
- González-Salcedo, L. O., Guerrero Zúñiga, A. P., Delvasto-arjona, S., & Luis Adrián, W. E. (2017). Redes neuronales artificiales para estimar propiedades en estado fresco y endurecido , para hormigones reforzados con fibras metálicas. *Cuaderno Activa*, 2016, 95–107.  
<http://ojs.tdea.edu.co/index.php/cuadernoactiva/article/download/423/495/>.
- González, L., Guerrero, A., Delvastro, S., & Will, A. (2012). Red neuronal artificial para estimar la resistencia a compresión, en concretos fibro-reforzados con polipropileno. *Ventana Informativa*, 26, 11–28.  
<http://revistasum.umanizales.edu.co/ojs/index.php/ventanainformatica/article/viewFile/217/267>
- González Salcedo, L., Guerrero Zúñiga, A., Delvasto Arjona, S., & Ernesto Will, A. (2012). Exploración con Redes Neuronales Artificiales para Estimar la Resistencia a la Compresión, en Concretos Fibroreforzados con Acero. *CIENCIA E INGENIERÍA NEOGRANADINA*, 22–1, 19–41.  
<https://dialnet.unirioja.es/servlet/articulo?codigo=5065718>
- Gupta, S. (2013). Using Artificial Neural Network to Predict the Compressive Strength of Concrete containing Nano-silica. *Civil Engineering and Architecture*, 1(3), 96–102. <https://doi.org/10.13189/cea.2013.010306>
- Hakim, S. J. S., Noorzaei, J., Jaafar, M. S., Jameel, M., & Mohammadhassani, M. (2011). Application of artificial neural networks to predict compressive strength of high strength concrete. *International Journal of Physical Sciences*, 6(5), 975–981. <https://doi.org/10.5897/IJPS11.023>
- Harsh, K., Bharath, N., Siddesh, C. S., & Kuldeep, S. (2016). AN INTRODUCTION TO ARTIFICIAL NEURAL NETWORK. *International Journal Of Advance Research And Innovative Ideas In Education*, 1(5), 27–30.
- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2017). An Introduction to Statistical Learning. In *Synthesis Lectures on Mathematics and Statistics* (Issue 8). Springer New York. <https://doi.org/10.1007/978-1-4614-7138-7>
- Jammal, Peshawa, M. A., & Rezhna Hassan, F. (2014). Data Normalization and Standardization. *Machine Learning Technical Reports*, 1, 1–6.  
<https://doi.org/10.13140/RG.2.2.28948.04489>

- Khan, M. I., Al-Osta, M. A., Ahmad, S., & Rahman, M. K. (2018). Seismic behavior of beam-column joints strengthened with ultra-high performance fiber reinforced concrete. *Composite Structures*, *200*, 103–119. <https://doi.org/10.1016/j.compstruct.2018.05.080>
- Khosravani, M. R., Nasiri, S., Anders, D., & Weinberg, K. (2019). Prediction of dynamic properties of ultra-high performance concrete by an artificial intelligence approach. *Advances in Engineering Software*, *127*(September 2018), 51–58. <https://doi.org/10.1016/j.advengsoft.2018.10.002>
- Kim, D. J., Wille, K., Naaman, A. E., & El-Tawil, S. (2012). Strength Dependent Tensile Behavior of Strain Hardening Fiber Reinforced Concrete. In *RILEM* (pp. 3–10). [https://doi.org/10.1007/978-94-007-2436-5\\_1](https://doi.org/10.1007/978-94-007-2436-5_1)
- Krenker, A., Bešter, J., & Kos, A. (2011). Introduction to the Artificial Neural Networks. In K. Suzuki (Ed.), *Artificial Neural Networks - Methodological Advances and Biomedical Applications* (pp. 3–18). InTech.
- Lazarevska, M., Knezevic, M., Cvetkovska, M., & Trombeva-Gavriloska, A. (2014). APPLICATION OF ARTIFICIAL NEURAL NETWORKS IN CIVIL ENGINEERING. *Tehnički Vjesnik*, *21*(6), 1353–1359. <https://hrcak.srce.hr/131329?lang=en>
- Li, L., Cai, Z., Yu, K., Zhang, Y. X., & Ding, Y. (2019). Performance-based design of all-grade strain hardening cementitious composites with compressive strengths from 40 MPa to 120 MPa. *Cement and Concrete Composites*, *97*(January 2018), 202–217. <https://doi.org/10.1016/j.cemconcomp.2019.01.001>
- Manaswi, N. K. (2018). Deep Learning with Applications Using Python. In *Deep Learning with Applications Using Python*. Apress. <https://doi.org/10.1007/978-1-4842-3516-4>
- Massicotte, B., Dagenais, M.-A., & Lagier, F. (2013). Performance of UHPFRC jackets for the seismic strengthening of bridge piers. *RILEM-Fib-AFGC International Symposium on Ultra-High Performance Fibre-Reinforced*, *1*, 89–98. <https://www.afgc.asso.fr/app/uploads/2014/01/pp-89-98-Massicotte.pdf>
- Montaño, J. J. (2002). Redes Neuronales Artificiales aplicadas al Análisis de Datos. *Network*, 275.
- Mushgil, H. M., Alani, H. A., & George, L. E. (2015). Comparison between Resilient and Standard Back Propagation Algorithms Efficiency in Pattern Recognition. *International Journal of Scientific & Engineering Research*, *6*(3), 773–778.

- Naderpour, H., Kheyroddin, A., & Amiri, G. G. (2010). Prediction of FRP-confined compressive strength of concrete using artificial neural networks. *Composite Structures*, 92(12), 2817–2829.  
<https://doi.org/10.1016/j.compstruct.2010.04.008>
- Parichatprecha, R., & Nimityongskul, P. (2009). Analysis of durability of high performance concrete using artificial neural networks. *Construction and Building Materials*, 23(2), 910–917.  
<https://doi.org/10.1016/j.conbuildmat.2008.04.015>
- Park, S. H., Kim, D. J., Ryu, G. S., & Koh, K. T. (2012). Tensile behavior of ultra high performance hybrid fiber reinforced concrete. *Cement and Concrete Composites*, 34(2), 172–184.  
<https://doi.org/10.1016/j.cemconcomp.2011.09.009>
- Patterson, D. W. (1990). *Introduction to Artificial Intelligence and Expert Systems*. Prentice-Hall of India.  
<http://182.160.97.198:8080/xmlui/handle/123456789/914>
- Plant, R. (1994, January 10). An introduction to artificial intelligence. *32nd Aerospace Sciences Meeting and Exhibit*. <https://doi.org/10.2514/6.1994-294>
- Prasad, N., Singh, R., & Lal, S. P. (2013). Comparison of back propagation and resilient propagation algorithm for spam classification. *Proceedings of International Conference on Computational Intelligence, Modelling and Simulation*, 29–34. <https://doi.org/10.1109/CIMSim.2013.14>
- Saini, L. M. (2008). Peak load forecasting using Bayesian regularization, Resilient and adaptive backpropagation learning based artificial neural networks. *Electric Power Systems Research*, 78(7), 1302–1310.  
<https://doi.org/10.1016/j.epsr.2007.11.003>
- Serna Ros, P., López Martínez, J. Á., & Camacho Torregrosa, E. (2012). UHPFRC : De los componentes a la estructura. *I Simposio Latino Americano Sobre Concreto Autoadensavel*.
- Shanker, M., Hu, M. Y., & Hung, M. S. (1996). Effect of data standardization on neural network training. *Omega*, 24(4), 385–397. [https://doi.org/10.1016/0305-0483\(96\)00010-2](https://doi.org/10.1016/0305-0483(96)00010-2)
- Shi, L., Lin, S., Lu, Y., & Bai, Y. (2017). *Prediction of mechanical properties of engineered cementitious composites using artificial neural network*.

- SRIDHAR, R., & PRASAD, R. (2019). STUDY ON MECHANICAL PROPERTIES OF HYBRID FIBER REINFORCED ENGINEERED CEMENTITIOUS COMPOSITES. *Romanian Journal of Materials*, 49, 424–433.
- Srinivasulu, S., & Jain, A. (2006). A comparative analysis of training methods for artificial neural network rainfall-runoff models. *Applied Soft Computing Journal*, 6(3), 295–306. <https://doi.org/10.1016/j.asoc.2005.02.002>
- Tayeh, B. A., Aadi, A. S., Hilal, N. N., Bakar, B. H. A., Al-Tayeb, M. M., & Mansour, W. N. (2019). Properties of ultra-high-performance fiber-reinforced concrete (UHPFRC)—a review paper. *AIP Conference Proceedings*, 2157(September), 020040. <https://doi.org/10.1063/1.5126575>
- Torres, J. (2018). *Deep learning. Introducción práctica con Keras* (Vol. 1). Watch This Space. <https://torres.ai/deep-learning-inteligencia-artificial-keras>
- Treadgold, N., & Gedeon, T. (1996). The SARPROP algorithm: a simulated annealing enhancement to resilient back propagation. ... *International Panel Conference on Soft and ...*, February 1997. <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.47.8197&rep=rep1&type=pdf>
- Uysal, M., & Tanyildizi, H. (2012). Estimation of compressive strength of self compacting concrete containing polypropylene fiber and mineral additives exposed to high temperature using artificial neural network. *Construction and Building Materials*, 27(1), 404–414. <https://doi.org/10.1016/j.conbuildmat.2011.07.028>
- Wang, S., & Li, V. C. (2007). Engineered cementitious composites with high-volume fly ash. *ACI Materials Journal*, 104(3), 233–241. <https://doi.org/10.14359/18668>
- Wille, K., El-Tawil, S., & Naaman, A. E. (2014). Properties of strain hardening ultra high performance fiber reinforced concrete (UHP-FRC) under direct tensile loading. *Cement and Concrete Composites*, 48, 53–66. <https://doi.org/10.1016/j.cemconcomp.2013.12.015>
- Wille, K., Kim, D. J., & Naaman, A. E. (2011). Strain-hardening UHP-FRC with low fiber contents. *Materials and Structures*, 44(3), 583–598. <https://doi.org/10.1617/s11527-010-9650-4>
- Yoo, D.-Y., & Kim, M.-J. (2019). High energy absorbent ultra-high-performance concrete with hybrid steel and polyethylene fibers. *Construction and Building Materials*, 209, 354–363. <https://doi.org/10.1016/j.conbuildmat.2019.03.096>

## Abreviaturas

ADADelta	Tasa de aprendizaje adaptativa (Adaptive learning rate)
ADAM	Estimación adaptativa de momento (Adaptive Moment Estimation por sus siglas en inglés)
AE	Error promedio (Average Error por sus siglas en inglés)
BP	Algoritmo de propagación hacia atrás (Back Propagation algorithm por sus siglas en inglés)
COP	Pesos Colombianos
DFF	Deep Feed Forward
FF	Feed Forward
FRC	Fiber reinforced concrete – Concreto reforzado con fibra
HPFRCC	High-performance fiber-reinforced cementitious composites - Concreto reforzado con fibras con alto comportamiento de endurecimiento por deformación
HSC	High strength concrete – Concreto de alta resistencia
IA	Inteligencia Artificial
LMA	Algoritmo de Levenberg-Maquardt (Levenberg-Maquardt Algorithm por sus siglas en inglés)
LVDT	Transformador diferencial de variación lineal (sensor)
MAE	Media de los errores absolutos (MAE Mean Absolute Error por sus siglas en inglés)
MAPE	Media del porcentaje de error absoluto ( Mean Absolute Percentage Error por sus siglas en inglés)
MLP	Multilayer perceptron (Perceptrones multi capa)
MSE	Media de errores cuadrados (Mean Square Error por sus siglas en inglés)
NMBE	Media del error de sesgo normalizado (Normalized Mean Bias Error por sus siglas en inglés)
R <sup>2</sup>	Coefficiente de correlación
RMSE	Raíz cuadrada de la media de errores cuadrados (Root Mean Square Error por sus siglas en inglés)

RMSProp	Propagación por Raiz cuadrada de la Media del gradiente (Root Mean Square gradient Propagation por sus siglas en inglés)
RNA	Redes Neuronales Artificiales (ANN en inglés)
RNN	Recurrent Neural Network
Rprop	Algoritmo resiliente de propagación hacia atrás (Resilient Backpropagation Algorithm por sus siglas en ingles)
RSR	Relación del RMSE y la desviación estándar de los datos (Ratio of the root mean square error to the standard deviation of measured data)
SGD	Gradiente descendiente estocástico (Stochastic Gradient Descent por sus siglas en ingles)
UHPFRC	Ultra-high-performance fiber-feinforced cement composites
UHSC	Ultra high strenght concrete – Concreto de ultra alta resistencia
$\epsilon_{cc}$	Alargamiento en la primera fisuración
$\epsilon_{pc}$	Alargamiento en la máxima tensión de endurecimiento por deformación
$\sigma_{cc}$	Fuerza de tensión en la primera fisuración
$\sigma_{pc}$	Máxima tensión de endurecimiento por deformación