

*“Predicción de resistencia a compresión y a tracción de hormigones autocompactantes con áridos reciclados utilizando métodos de Machine Learning y algoritmos de redes neuronales”*



*“To predict the compressive and split tensile strength of self-compacting concrete with recycled aggregates utilizing ensemble machine learning models and algorithms of neural networks”*

# TESIS DOCTORAL

**Autor:**

**Jesús De Prado Gil**  
Ingeniero Industrial

**Directores:**

**Dra. Covadonga Palencia Coto**  
**Dra. Rebeca Martínez García**

Programa de Doctorado en Ciencia y Tecnología  
del Medio Ambiente por la Universidad de León  
Universidad de León



**universidad  
de león**

TESIS DOCTORAL POR COMPENDIO DE PUBLICACIONES

**Predicción de resistencia a compresión y a tracción de hormigones autocompactantes con áridos reciclados utilizando métodos de Machine Learning y algoritmos de redes neuronales**

**Jesús de Prado Gil**

**Programa de Doctorado en Ciencia y Tecnología del Medio Ambiente**

Tutor:

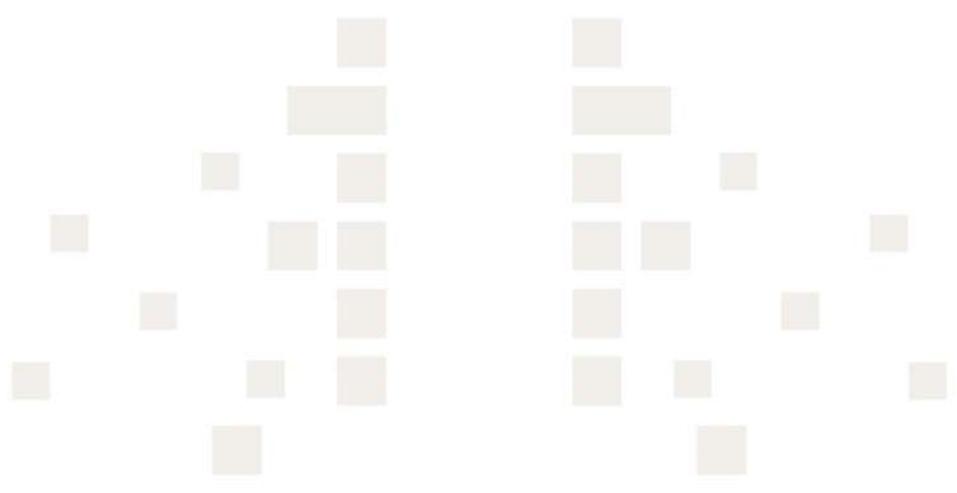
**Dra. Covadonga Palencia Coto**

Directores:

**Dra. Covadonga Palencia Coto**

**Dra. Rebeca Martínez García**

León 2022

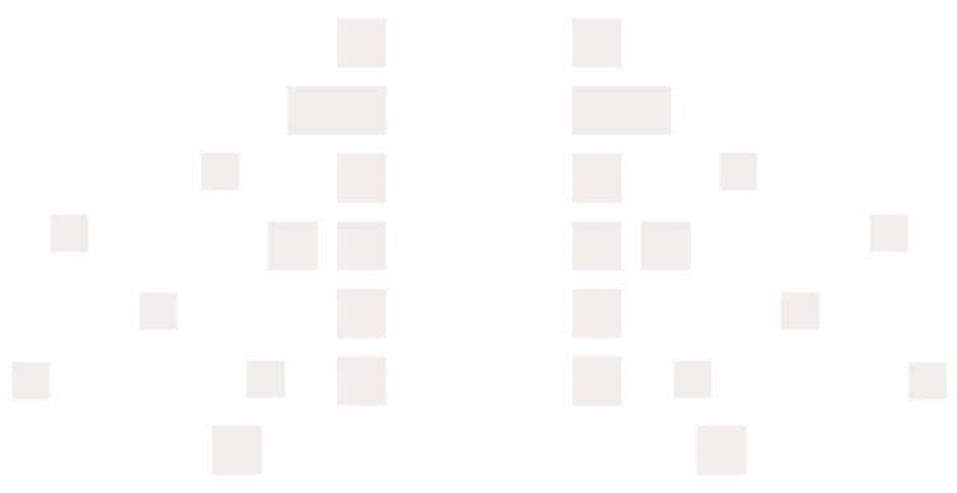


# ***Dedicatoria***

***A mi familia  
A vosotras, Rebeca y Naiara***

“Si sirves a la Naturaleza, ella te servirá a ti”

***Confucio***



# Agradecimientos

---

## Acknowledgements

---

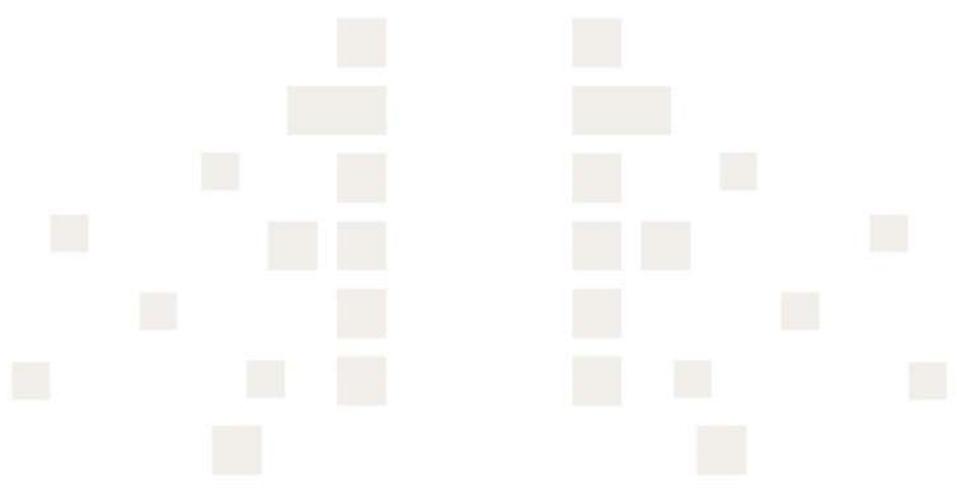
Llegado este momento en el que el final de esta tesis ha llegado, quiero acordarme de todas aquellas personas que de una u otra manera me han ayudado y guiado en el arduo y duro camino de esta investigación.

En primer lugar, quiero agradecer a las directoras de la presente tesis doctoral, las doctoras Covadonga Palencia Coto y Rebeca Martínez García por su abnegada dedicación, buen hacer y encomiable orientación, ayuda y apoyo. Gracias por vuestra paciencia.

Dedicación especial a mi *familia y amigos*, por su apoyo incondicional y estar siempre conmigo. Todo lo que soy es gracias a ellos.

Y finalmente a *Rebeca y Naiara* por ser mi inspiración e ilusión cada día.

*¡Gracias a todos por vuestra generosidad!*



# Tabla de Contenidos

---

## Table of Contents

---

Dedicatoria .....	iv
Agradecimientos.....	vi
Tabla de Contenidos .....	viii
Índice de Figuras.....	xi
Índice de Tablas .....	xiv
Acrónimos y símbolos.....	xvi
<b>CAPÍTULO I Introducción.....</b>	<b>1</b>
<b>1.1 HORMIGÓN AUTOCOMPACTANTE .....</b>	<b>2</b>
1.1.1 Origen y evolución del hormigón autocompactante.....	3
1.1.2 Difusión del concepto de hormigón autocompactante.....	6
1.1.3 Normativas.....	8
1.1.4 Ventajas del uso del hormigón autocompactante.....	9
1.1.5 Aplicaciones del Hormigón autocompactante .....	11
<b>1.2 RESIDUOS DE CONSTRUCCIÓN Y DEMOLICIÓN .....</b>	<b>16</b>
1.2.1 Composición de los residuos de construcción y demolición. ....	22
1.2.2 Generación de los residuos de construcción y demolición.....	24
1.2.3 Problemática medioambiental de los residuos de construcción y demolición 29	
1.2.4 Gestión de los residuos de construcción y demolición.....	33
1.2.5 Áridos reciclados.....	36
1.2.6 Normativa de aplicación para los áridos reciclados .....	37
<b>1.3 HORMIGÓN AUTOCOMPACTANTE CON ÁRIDOS RECICLADOS.....</b>	<b>37</b>
1.3.1 Componentes del hormigón autocompactante con áridos reciclados .....	38
1.3.2 Propiedades mecánicas.....	40
<b>1.4 TÉCNICAS DE APRENDIZAJE AUTOMÁTICO PARA PREDECIR LAS PROPIEDADES MECÁNICAS DEL HORMIGÓN AUTOCOMPACTANTE CON ÁRIDOS RECICLADOS.....</b>	<b>42</b>
1.4.1 Métodos Ensemble .....	44
1.4.2 Redes Neuronales Artificiales.....	49
1.4.3 Métodos de aprendizaje automático en ingeniería.....	53

<b>CAPÍTULO II Objetivos</b> .....	57
<b>2.1 OBJETIVO GENERAL</b> .....	<b>58</b>
2.1.1 Objetivos específicos.....	59
<b>2.2 ESTRUCTURA DE LA PRESENTE TESIS DOCTORAL</b> .....	<b>60</b>
<b>CAPÍTULO III Publicaciones</b> .....	63
<b>3.1 PUBLICACIÓN 1</b> .....	<b>64</b>
<b>3.2 PUBLICACIÓN 2</b> .....	<b>82</b>
<b>3.3 PUBLICACIÓN 3</b> .....	<b>103</b>
<b>3.4 PUBLICACIÓN 4</b> .....	<b>126</b>
<b>CAPÍTULO IV Resumen</b> .....	154
<b>4.1 PREDICCIÓN DE LA RESISTENCIA A LA COMPRESIÓN DEL HORMIGÓN AUTOCOMPACTANTE CON ÁRIDOS RECICLADOS UTILIZANDO MODELOS DE APRENDIZAJE AUTOMÁTICO</b> .....	<b>155</b>
4.1.1 Hormigón autocompactante con áridos reciclados.....	158
4.1.2 Resistencia a la compresión .....	159
4.1.3 Aprendizaje automático .....	160
4.1.4 Materiales y métodos .....	163
4.1.5 Resultados y discusión .....	170
4.1.6 Conclusiones parciales .....	180
<b>4.2 COMPARACIÓN DE HERRAMIENTAS DE APRENDIZAJE AUTOMÁTICO PARA MODELAR LA RESISTENCIA A LA TRACCIÓN DEL HORMIGÓN AUTOCOMPACTANTE CON ÁRIDOS RECICLADOS</b> .....	<b>181</b>
4.2.1 Importancia de la investigación .....	184
4.2.2 Antecedentes de la investigación.....	184
4.2.3 Materiales y métodos .....	189
4.2.4 Resultados y discusión .....	194
4.2.5 Conclusiones parciales .....	200
<b>4.3 PREDICCIÓN DE LA RESISTENCIA A LA TRACCIÓN DEL HORMIGÓN AUTOCOMPACTANTE CON ÁRIDOS RECICLADOS USANDO MÉTODOS DE APRENDIZAJE PROFUNDO</b> .....	<b>201</b>
4.3.1 Literatura de referencia .....	203
4.3.2 Metodología.....	206
4.3.3 Resultados y discusión .....	213

4.3.4	Conclusiones .....	225
<b>4.4</b>	<b>ESTUDIO DE LA PREDICCIÓN DE LA RESISTENCIA A COMPRESIÓN DEL HORMIGÓN AUTOCOMPACTANTE UTILIZANDO NOVEDOSOS ENFOQUES COMPUTACIONALES.....</b>	<b>226</b>
4.4.1	Revisión de literatura .....	229
4.4.2	Materiales y métodos .....	232
4.4.3	Resultados y discusión .....	241
4.4.4	Conclusiones .....	255
	<b>CAPÍTULO V Conclusiones.....</b>	<b>258</b>
<b>5.1</b>	<b>CONCLUSIONES GENERALES.....</b>	<b>259</b>
<b>5.2</b>	<b>LÍNEAS FUTURAS DE INVESTIGACIÓN .....</b>	<b>262</b>
	<b>CAPÍTULO VI Referencias .....</b>	<b>264</b>
<b>6.1</b>	<b>REFERENCIAS .....</b>	<b>265</b>

# Índice de Figuras

---

## Figure index

---

<b>Figura 1.</b> Prueba de flujo en U (U-flow test) .....	5
<b>Figura 2.</b> Puente Shin-kiba Ohashi .....	11
<b>Figura 3.</b> Vista general puente Akashi-Kaikyo .....	122
<b>Figura 4.</b> Tanque de GNL, Osaka Gas CoMPany .....	12
<b>Figura 5.</b> Vista del Puente de la Ronda de la Hispanidad .....	14
<b>Figura 6.</b> Vista panorámica de la fachada del Ayuntamiento de Mollet .....	14
<b>Figura 7.</b> Vista panorámica de la Ciudad de la Justicia de Barcelona .....	15
<b>Figura 8.</b> Vista panorámica del Puente de Tercer milenio .....	15
<b>Figura 9.</b> Vista de la Torre Cristal, en construcción.....	16
<b>Figura 10.</b> Composición porcentual de los RCD en España para el 2014.....	24
<b>Figura 11.</b> Generación de residuos por la totalidad de actividades económicas y hogares en la Unión Europea (EU-28), 2004-2018.....	25
<b>Figura 12.</b> Generación de residuos por actividad económica y hogares en la Unión Europea (UE-28), 2004-2018.....	26
<b>Figura 13.</b> RCD generados por algunos Estados Miembros de la UE-28, 2004-2018.....	27
<b>Figura 14.</b> Generación de residuos por actividad económica y hogares en España para el 2018 .....	28
<b>Figura 15.</b> Evolución de la generación de RCD en España para 2011-2019.....	29
<b>Figura 16.</b> Tasa de reciclaje de los diferentes residuos en la UE para 2018 .....	34
<b>Figura 17.</b> Tasa de recuperación de los RCD en los Estados Miembros de la UE-28 para 2018.....	35
<b>Figura 18.</b> Gestión de los RCD no peligrosos en España para los períodos 2014-2018 .	36
<b>Figura 19.</b> Mapa de calor de los coeficientes de correlación entre las variables de entrada y salida.....	166
<b>Figura 21.</b> Comparación de la predicción de la resistencia a la compresión con los métodos Baggin, a partir del conjunto de datos de prueba.....	173
<b>Figura 22.</b> R2, RMSE, MAE and MAPE de los métodos Boosting.....	175
<b>Figura 23.</b> Comparación de la predicción a la compresión de la resistencia a la compresión con los métodos Boosting, a partir del conjunto de prueba. ....	1757
<b>Figura 24.</b> R <sup>2</sup> , RMSE, MAE and MAPE de los mejores modelos ML.....	17779
<b>Figura 25.</b> Comparación de la predicción de la resistencia a la compresión de los mejores modelos: a partir del conjunto de datos de prueba .....	1780
<b>Figura 26.</b> Contribución de las variables de entrada a la resistencia a la compresión en el modelo RF .....	179
<b>Figura 27.</b> Proceso del aprendizaje automático.....	185
<b>Figura 28.</b> Diagrama esquemático de XGBoost.....	186

<b>Figura 29.</b> Diagrama esquemático de Gradient Boost .....	187
<b>Figura 30.</b> Diagrama esquemático de Extra Trees Regressor .....	188
<b>Figura 31.</b> Distribución de frecuencia con curva Normal de las variables de entrada. ....	191
<b>Figura 32.</b> Matriz de correlación de las características de entrada .....	1924
<b>Figura 33.</b> R2, RMSE, MAE and MAPE de los modelos ML .....	1968
<b>Figura 34.</b> Comparación de la resistencia a la tracción de los modelos, para la data de prueba .....	199
<b>Figura 35.</b> Resistencia a la tracción experimental y predicha para los modelos .....	1991
<b>Figura 36.</b> Contribución de las variables de entrada a la resistencia a la tracción en el modelo XGBoost .....	2002
<b>Figura 37.</b> Características estadísticas de las variables de entrada .....	2080
<b>Figura 38.</b> Características estadísticas de la variable de salida .....	2080
<b>Figura 39.</b> Mapa de calor del coeficiente de correlación entre las variables de entrada y salida.....	2091
<b>Figura 40.</b> Estructura general de ANN .....	2103
<b>Figura 41.</b> Arquitectura de la red neuronal artificial.....	2114
<b>Figura 42.</b> Rendimiento del modelo del algoritmo LM. ....	2146
<b>Figura 43.</b> Histograma de error del modelo del algoritmo LM.....	2147
<b>Figura 44.</b> Gráficos de regresión del algoritmo LM entre la resistencia a la tracción experimental y la predicha .....	21518
<b>Figura 45.</b> Rendimiento del modelo BR .....	21619
<b>Figura 46.</b> Histograma de error del modelo BR.....	21720
<b>Figura 47.</b> Gráficos de regresión de regularización bayesiana entre la resistencia a la tracción experimental y la predicha.....	2181
<b>Figura 48.</b> Rendimiento del modelo SCG .....	2192
<b>Figura 49.</b> Histograma de error del modelo de SCG.....	2203
<b>Figura 50.</b> Gráfico de regresión del algoritmo SCG entre la resistencia a la tracción experimental y predicha .....	2234
<b>Figura 51.</b> Comparación de los valores experimentales y predichos por de los algoritmos ANN: LM, BR, y SCGB .....	2236
<b>Figura 52.</b> R y MSE de los algoritmos LM, BR y SCGB.....	2247
<b>Figura 53.</b> Contribución de las variables de entrada a la resistencia a la tracción por hendidura del HACcon RA en el enfoque BR.....	2258
<b>Figura 54.</b> Valores mínimo, media y máximo de las variables de entrada .....	2347
<b>Figura 55.</b> Valores mínimo, media y máximo de la variable de salida.....	2347
<b>Figura 56.</b> Análisis de frecuencia (histograma) de las variables de entrada.....	23538
<b>Figura 57.</b> Gráfico de multicorrelación entre las variables de entrada y salida. ....	2360
<b>Figura 58.</b> Estructura general de la ANN.....	237
<b>Figura 59.</b> Arquitectura del modelo de RNA .....	2381
<b>Figura 60.</b> Metodología del trabajo de investigación.....	2403
<b>Figura 61.</b> Rendimiento del modelo usando el algoritmo LM .....	2415
<b>Figura 62.</b> Estado de entrenamiento del algoritmo LM.....	2435

<b>Figura 63.</b> Histograma de error del modelo del algoritmo LM.....	2436
<b>Figura 64.</b> Análisis de regresión entre la resistencia a la compresión experimental y predicha mediante el algoritmo LM .....	2437
<b>Figura 65.</b> Rendimiento del modelo utilizando el algoritmo BR.....	24548
<b>Figura 66.</b> Estado de entrenamiento del algoritmo BR. ....	<b>24749</b>
<b>Figura 67.</b> Histograma de errores del modelo del algoritmo BR. ....	2470
<b>Figura 68.</b> Análisis de regresión utilizando el algoritmo BR entre la resistencia a la compresión experimental y predicha. ....	2471
<b>Figura 69.</b> Rendimiento del modelo utilizando el algoritmo SCGB. ....	2492
<b>Figura 70.</b> Estado de entrenamiento del algoritmo SCG .....	250
<b>Figura 71.</b> Histograma de errores del modelo del algoritmo SCG .....	2503
<b>Figura 72.</b> Análisis de regresión mediante el algoritmo SCG entre la resistencia a la compresión experimental y predicha .....	2504
<b>Figura 73.</b> Comparación de los valores experimentales de resistencia a la compresión y los predichos por los diferentes algoritmos empleados en la ANN.....	2506
<b>Figura 74.</b> Valor R (%) y MSE de los algoritmos LM, BR y SCG.....	2547
<b>Figura 75.</b> Contribución de las variables de entrada a la resistencia a la compresión del HAC con RA.....	25558

# Índice de Tablas

---

## Table index

---

<b>Tabla 1.</b> Lista Europea de Residuos, sobre Residuos de Construcción y Demolición. ...	18
<b>Tabla 2.</b> Características de los residuos que permiten clasificarlos como peligrosos ...	20
<b>Tabla 3.</b> Relación de objetivos y publicaciones que integran la tesis .....	60
<b>Tabla 4.</b> Base de datos experimental.....	163
<b>Tabla 5.</b> Valores media, máximo y mínimo de las variables de entrada y salida.....	165
<b>Tabla 6 .</b> Valores media, máximo y mínimo de las variables de entrada ( $\text{kg/m}^3$ ) y salida (MPa) de los conjuntos de datos: entrenamiento, validación y prueba.....	167
<b>Tabla 7.</b> Métricas de rendimiento de los modelos Bagging propuestos. ....	1714
<b>Tabla 8.</b> Métricas de rendimiento de los métodos Boosting propuestos.....	174
<b>Tabla 9.</b> Métricas de rendimiento de los modelos GAM.....	176
<b>Tabla 10.</b> Métricas de rendimiento de los mejores métodos .....	177
<b>Tabla 11.</b> Experimental database .....	1892
<b>Tabla 12.</b> Valores mínimo, máximo, media, desviación estándar, asimetría y kurtosis de las variables de entrada y salida. ....	190
<b>Tabla 13.</b> Mínimo, máximo, media, desviación estándar, asimetría y kurtosis de las variables de entrada y salida, para cada conjunto de datos .....	193
<b>Tabla 14.</b> Criterios estadísticos para $R^2$ .....	194
<b>Tabla 15.</b> Rendimiento de XGBoost, GB, CB y ETR con diferentes parámetros.....	1957
<b>Tabla 16.</b> Base de datos experimental.....	20609
<b>Tabla 17.</b> Valores mínimos, medios y máximos de las variables de entrada y salida	2070
<b>Tabla 18.</b> División de los datos para la prueba del modelo.....	2125
<b>Tabla 19.</b> Resumen de los diferentes parámetros de evaluación del modelo del algoritmo LM. ....	21618
<b>Tabla 20.</b> Resumen de los diferentes parámetros de evaluación del modelo de BR.	2181
<b>Tabla 21.</b> Resumen de los diferentes parámetros de evaluación del modelo del Algoritmo SCGB .....	2214
<b>Tabla 22.</b> Datos experimentales .....	233
<b>Tabla 23.</b> Valores mínimo, media y máximo de las variables de entrada y salida.....	2347
<b>Tabla 24.</b> División de los datos para el entrenamiento, validación y prueba del modelo .....	2392
<b>Tabla 25.</b> Resumen de los parámetros de evaluación del modelo del algoritmo LM. ....	2448

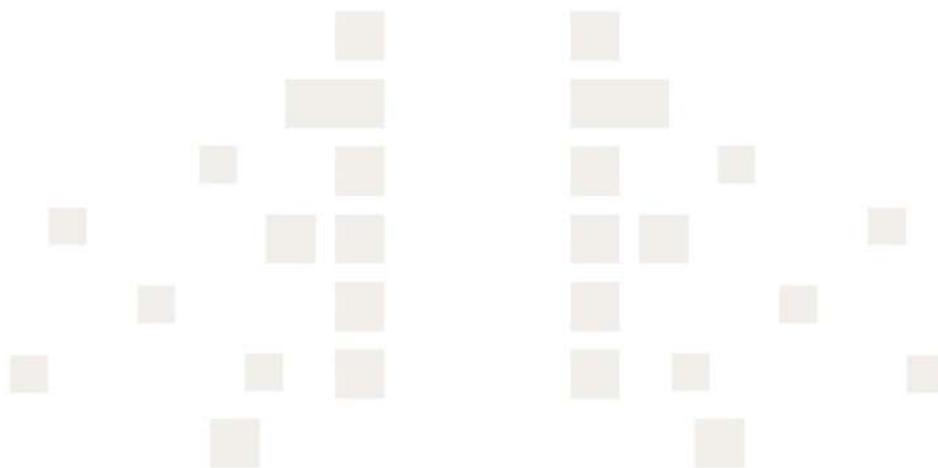
**Tabla 26.** Resumen de los parámetros de evaluación del modelo del algoritmo BR 2471  
**Tabla 27.** Resumen de los parámetros de evaluación del modelo del algoritmo SCGB.  
..... 2525

# Acrónimos y símbolos

## Acronyms and symbols

<b>A/C</b>	Relación agua-cemento	<b>LGBM</b>	Light Gradient Boosting Machine
<b>ACI</b>	American Concrete Institute	<b>LM</b>	Algoritmo de Levenberg-Marquardt
<b>AENOR</b>	Asociación Española de Normalización y Certificación	<b>m<sup>3</sup></b>	Metro cúbico
<b>ANN</b>	Redes neuronales artificiales	<b>MA</b>	Aditivo mineral
<b>As</b>	Coefficiente de Asimetría	<b>MAE</b>	Error absoluto medio
<b>BP-ANN</b>	Descenso de gradiente retropropagado	<b>MAPE</b>	Error porcentual absoluto medio
<b>BR</b>	Regularización Bayesiana	<b>MCMC</b>	Método Monte Carlo basado en cadena de Markov
<b>BRANN</b>	Redes neuronales artificiales regularizadas bayesianas	<b>mix</b>	Mezcla
<b>CA</b>	Árido grueso	<b>ML</b>	Aprendizaje automático, por sus siglas en inglés
<b>CART</b>	Árbol de clasificación y regresión	<b>MLP</b>	Perceptrón multicapa
<b>CB</b>	CatBoosting	<b>MNR</b>	Modelo de regresión multivariante
<b>CFT</b>	Concrete Filled Tubes	<b>MPa</b>	Megapascuales
<b>CG</b>	Gradiente conjugado	<b>NC</b>	Áridos naturales
<b>Cmt</b>	Cemento	<b>OHMS</b>	Técnicas de permutación one_hot_max_size
<b>DL</b>	Aprendizaje profundo	<b>QSAR</b>	Relaciones cuantitativas estructura- actividad
<b>DTR</b>	Decision Tree Regressor Conferencia del Pacífico y	<b>R</b>	Coefficiente de correlación
<b>EASEC</b>	Este de Asia sobre Ingeniería Estructural y Construcción	<b>R<sup>2</sup></b>	Coeficiente de determinación
<b>EHE-08</b>	Instrucción Española del Hormigón Estructural	<b>RA</b>	Árido reciclado
<b>EN</b>	Normas Europeas	<b>RCD</b>	Residuos de construcción y demolición
<b>ETR</b>	Extremely Randomized Trees o Extra-Trees	<b>RF</b>	Random Forest

<b>EUROSTA</b>	Oficina Europea de estadística	<b>RILEM</b>	Reunión Internationale des Laboratoires et Experts des Matér
<b>T</b>		<b>RMSE</b>	Raíz del error medio cuadrático
<b>f<sub>c</sub></b>	Resistencia a la compresión	<b>SCC</b>	Self-compacting concrete
<b>FA</b>	Árido fino	<b>SCGB</b>	Gradiente Conjugado Escalado de Retropropagación
<b>f<sub>ck</sub></b>	Resistencia a la compresión	<b>SD</b>	Desviación estándar
<b>f<sub>st</sub></b>	Resistencia a la tracción	<b>SP</b>	Superplastificante
<b>GA-ANN</b>	Algoritmo genético	<b>SVM</b>	Support vector machine
<b>GAM</b>	Modelo aditivo generalizado	<b>SVR</b>	Support Vector Regressor
<b>GAM1</b>	Modelo aditivo Inverse Gauss	<b>T<sub>n</sub></b>	Toneladas
<b>GAM2</b>	Modelo aditivo Poisson	<b>TS</b>	Resistencia a la tracción
<b>GB</b>	Gradient Boosting	<b>UE</b>	Unión Europea
<b>GEP</b>	Técnicas de programación genética	<b>UE-28</b>	28 estados miembros de la Unión Europea
<b>GLM</b>	Modelos lineales generalizados	<b>UNE</b>	Asociación Española de Normalización
<b>GOSS</b>	Muestreo unilateral basado en gradientes	<b>UNI</b>	Normas italianas
<b>HAC</b>	Hormigón autocompactante	<b>W</b>	Agua
<b>HACR</b>	Hormigón autocompactante con áridos reciclados	<b>X1</b>	Cemento Portland
<b>HC</b>	Hormigón convencional	<b>X2</b>	Materiales cementantes suplementarios
<b>HPC</b>	Hormigón de altas prestaciones	<b>X3</b>	Agua
<b>IA</b>	Inteligencia artificial	<b>X4</b>	Árido fino
<b>INE</b>	Instituto Nacional de Estadística	<b>X5</b>	Árido grueso
<b>K</b>	Coefficiente de Kurtosis	<b>X6</b>	Superplastificante
<b>kg</b>	kilogramo	<b>XGBoost</b>	Extreme Gradient Boosting
<b>KNN</b>	K-Nearest Neighbor	<b>Y</b>	Variable de salida
<b>LASSO</b>	Selección de operadores y Contracción del menor Absoluto		





# **CAPÍTULO I** **Introducción**

CHAPTER I. Introduction

## 1.1 HORMIGÓN AUTOCOMPACTANTE

El hormigón autocompactante (HAC) es un hormigón de alta fluidez que se compacta por acción de la gravedad, sin necesitar medios de vibración mecánica, esto lo hace adecuado para usarlo en regiones del encofrado muy congestionadas y en zonas de difícil acceso (Okamura y Ouchi, 2003a). El Hormigón autocompactante ofrece buena resistencia a la segregación y no crea un efecto de tamizado. De esta forma, la instalación se realiza fácilmente y se puede aplicar en situaciones que no son posibles con el hormigón convencional (HC). En las últimas décadas, el hormigón autocompactante ha sido ampliamente empleado en la industria de la construcción debido a sus propiedades reológicas y de estado fresco, estas facilitan el asentamiento en el encofrado sin vibraciones, reduciendo el coste y la energía asociados al proceso de colada (Patel et al., 2011; W. Tang et al., 2016, 2020).

El hormigón autocompactante es un tipo de hormigón con una excelente deformabilidad y resistencia a la segregación. Su fluidez y autocompactabilidad distintiva sin necesidad de vibración durante el proceso de colocación hace de él una construcción silenciosa, así como un rápido ritmo de colocación del hormigón con muy poco tiempo, además de proporcionar un nivel superior de acabado y durabilidad de la estructura (Kovačević et al., 2021; Panda y Bal, 2013). El hormigón autocompactante también consigue las mismas propiedades de ingeniería y durabilidad que el hormigón convencional (HC).

En lo referente a su composición, los materiales para fabricar el hormigón autocompactante son los mismos que el hormigón convencional (HC), es decir, cemento, agua y áridos finos y gruesos, junto con aditivos minerales y químicos en diferentes proporciones. Por lo general, los aditivos químicos (superplastificantes) utilizados son reductores de agua de alto rango y agentes modificadores de la viscosidad, que cambian las propiedades reológicas del hormigón. Mientras que los aditivos minerales se utilizan como material extrafino, además del cemento, y en algunos casos, sustituyen al cemento (Anjaneyulu et al., 2017).

## 1.1.1 Origen y evolución del hormigón autocompactante

En la década de los 80, el problema de la vida útil de las estructuras de hormigón era un tema de investigación de gran interés, debido a que las estructuras de hormigón duraderas requerían una compactación adecuada por parte de trabajadores cualificados (Okamura et al., 2000). Sin embargo, para esta época, en la industria de la construcción de Japón, ocurría una disminución gradual del número de trabajadores cualificados lo que llevó a una reducción similar de la calidad de las obras de construcción (Goodier, 2003; Okamura y Ouchi, 2003). Por lo que, fue tema de gran interés y que hacía necesario hallar una solución para conseguir estructuras de hormigón duraderas, independientemente de la calidad de las obras de construcción.

Dicha solución se podría lograr a través del uso de un hormigón de calidad y durable que fuese capaz de fluir en estructuras congestionadas, por todos los rincones del encofrado, donde el proceso de vibración se hace complicado y que su rendimiento y calidad no dependiese de los operarios, llenando los encofrados por la acción de la gravedad (Nieto Alcolea, 2015). Es así como para 1986, en la Universidad de Tokio, el profesor Hajime Okamura, desarrolló un prototipo de hormigón que podía ser colocado sin ningún medio de compactación y que lograba rellenar el encofrado por la acción de la gravedad sin sufrir segregación ni otros defectos (Okamura y Ouchi, 1998; Ouchi et al., 1997).

Por su parte, Ozawa y Maekawa, de la Universidad de Tokio, realizaron estudios para desarrollar el hormigón autocompactante, utilizando diferentes tipos de superplastificante (SP), cuyo objetivo era estudiar la trabajabilidad y la homogeneidad del hormigón (Maekawa y Ozawa, 1999; Okamura y Ouchi, 2003). Era un hormigón adecuado para la colocación rápida y tenía muy buena permeabilidad.

De acuerdo con Anjaneyulu et al. (2017) y Okamura y Ouchi (2003) el prototipo de hormigón autocompactante lo completó Ozawa y Maekawa en 1988, utilizando materiales que ya existían en el mercado. Este hormigón tuvo un buen comportamiento desde la perspectiva de las propiedades: retracción por secado, calor de hidratación,

densidad tras el endurecimiento, entre otras (Okamura y Ouchi, 1998). En su origen, Okamura denominó este hormigón como “High Performance Concrete” o Hormigón de altas prestaciones, definiéndose, según Okamura y Ouchi (1998) en las tres etapas del hormigón: (1) Fresco: autocompactable; (2) Edad temprana: evitar los defectos iniciales y (3) Tras el endurecimiento: protección contra factores externos. La finalidad era crear un hormigón capaz de compactarse, sin que el factor humano afectara el producto final.

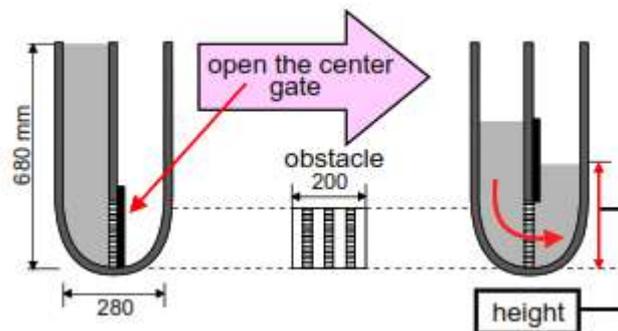
Casi al mismo tiempo, según el profesor Aïtcin y su equipo, de la Universidad de Sherbrooke en Canadá (Gagne y Pigeon, 1990), definieron el hormigón de altas prestaciones (HPC, por sus siglas en inglés) como un hormigón de alta durabilidad por su baja relación agua/cemento. Desde entonces, el término ‘hormigón de altas prestaciones’ se ha empleado en todo el mundo para referirse al hormigón de alta durabilidad. Por ello, Okamura adoptó el término de ‘Hormigón autocompactante de altas prestaciones’ para el hormigón de Japón (Okamura y Ouchi, 1998) .

El hormigón autocompactante (HAC) tiene su origen en las investigaciones sobre el hormigón subacuático antilavado, los pilotes de hormigón *in situ* y el relleno de otras zonas inaccesibles, donde se requiere una cohesión adicional (Anjaneyulu et al., 2017; Goodier, 2003; Okamura et al., 1995). Okamura y su equipo de investigación pretendían desarrollar un hormigón durable, capaz de fluir y consolidarse hasta en las estructuras más complejas, sobre la base de que el hormigón subacuático antilavado se vierte bajo el agua y la segregación se inhibe estrictamente añadiendo una gran cantidad de un agente viscoso (aditivo antilavado), que impide que las partículas de cemento se dispersen en el agua circundante (Anjaneyulu et al., 2017; Ghorpade et al., 2013; Martínez-García, 2021; Okamura y Ouchi, 1999). A pesar de ello, no se pudo emplear el hormigón subacuático antilavado para fabricar el nuevo hormigón para emplearse en las estructuras al aire libre por dos razones: en primer lugar, la alta viscosidad impedía la eliminación de las burbujas de aire; y en segundo lugar, la compactación en las zonas confinadas de las barras de refuerzo era complicada (Anjaneyulu et al., +2017; Martínez-García, 2021).

Al respecto, para evaluar la autocompactabilidad, Okamura y Ozawa (1996) emplearon el ensayo tipo U, por considerarlo satisfactorio, dicha prueba fue desarrollada por el

Centro de Investigación Tecnológica (Technology Research Centre) de la Corporación Taisei en Japón. La prueba mide la capacidad de compactación del HAC (Kumar et al., 2018; Okamura y Ouchi, 2003). En esta prueba, el grado de compactabilidad se puede indicar por la altura que alcanza el hormigón después de fluir a través de un obstáculo.

El aparato (Figura 1) consiste en un recipiente dividido por una pared central en dos compartimentos; entre las dos secciones hay una abertura con una compuerta deslizante, simulando las armaduras de una estructura real. En la compuerta se instalan barras de refuerzo con un diámetro nominal de 200 mm con una separación entre centros de 50 mm. Esto crea un espacio libre de 35 mm entre las barras. Se vierte el hormigón por una de las secciones y luego se levanta la compuerta y el hormigón fluye hacia arriba en la otra sección. Se mide la altura del hormigón en ambas secciones y se evalúa así la fluidez del hormigón. El hormigón con una altura de llenado superior a 300 mm puede considerarse autocompactante (Okamura y Ouchi, 2003b).



**Figura 1.** Prueba de flujo en U (U-flow test), (Okamura y Ouchi, 2003).

La autocompactabilidad puede verse afectada en gran medida por las características de los materiales y la proporción de la mezcla. En este sentido, (Okamura y Ozawa, 1996) propusieron un sistema de proporción de la mezcla donde el contenido de áridos gruesos se fija en el 50% del volumen sólido y el contenido de áridos finos en el 40% del volumen del mortero, de modo que la autocompactabilidad pudiera lograrse fácilmente ajustando únicamente la relación agua-cemento y la dosis de superplastificante (Anjaneyulu et al., 2017; Ghorpade et al., 2013; Okamura y Ouchi, 2003).

La relación agua-cemento (A/C) en volumen se supone entre 0.9 y 1.0 dependiendo de las propiedades del cemento, la dosis de superplastificante y la relación agua-cemento

final se determinaron para asegurar la autocompactabilidad (Okamura y Ouchi, 2003). Por lo tanto, para lograr la capacidad de autocompactación, era indispensable un superplastificante (Ghorpade et al., 2013; Okamura et al., 1995). Con un superplastificante, la pasta puede hacerse más fluida con poca disminución concomitante de la viscosidad, en comparación con el efecto drástico del agua, cuando se debilita la cohesión entre el agregado y la pasta.

## 1.1.2 Difusión del concepto de hormigón autocompactante

Tras el desarrollo del prototipo del hormigón autocompactante en 1988, que demostró ser duradero y económico, considerado uno de los avances más recientes en materia de hormigón de alto rendimiento en la industria de la construcción, hubo un creciente interés por el hormigón autocompactante.

Se han llevado a cabo numerosas investigaciones a nivel internacional, así como la realización de congresos y simposios internacionales para el estudio de este tipo de hormigón. La primera ponencia sobre hormigón autocompactante fue presentada por Ozawa en la Segunda Conferencia del Pacífico y Este de Asia sobre Ingeniería Estructural y Construcción (EASEC-2), por sus siglas en inglés, celebrada en enero de 1989 en Tailandia (Okamura y Ouchi, 1999). Sin embargo, la presentación de Ozawa en la Conferencia Internacional de CANMET y ACI, celebrada en Estambul en mayo de 1992, aceleró la difusión del concepto de hormigón autocompactante en todo el mundo (Okamura et al., 2000).

En noviembre de 1994, el profesor Paul Zia organizó en Bangkok un Taller del American Concrete Institute (ACI) sobre el hormigón de alto rendimiento, este evento hizo que el hormigón autocompactante se convirtiera en un tema de interés común para los investigadores e ingenieros interesados en la vida útil del hormigón y en los sistemas de construcción racionales de todo el mundo (Okamura y Ouchi, 1998).

Para 1996, en la Convención de la ACI, en New Orleans, USA, La conferencia Ferguson: “Concreto autocompactante de altas prestaciones” de Okamura despertó el interés por

el hormigón autocompactante entre los investigadores e ingenieros de Norteamérica (Okamura, 1997)

En 1997, RILEM (Réunion Internationale des Laboratoires et Experts des Matériaux, systèmes de construction et ouvrages) formó el comité: RILEM Technical Committee TC 174 Self-Compacting Concrete, cuyo objetivo consistía en recopilar, analizar y presentar el estado del arte de la tecnología emergente del hormigón autocompactante, así como buscar puntos de vista unificados sobre los ensayos y la evaluación (Skarendahl y Petersson, 2000).

En 1997, se creó el proyecto “Brite Euram BE96-3801 – Rational Production and Improved Working Environment Trough Using Self-Compacting Concrete” dentro del Programa Marco Europeo I+D. Universidades y empresas dieron inicio a dicho proyecto cuyo principal objetivo era desarrollar e introducir la tecnología para la fabricación del hormigón autocompactante en la producción, transporte y ejecución de obras de gran escala (Commission of the European Communities, 1991; Goodier, 2003; Martínez-García, 2021).

En 1998 se celebró un taller internacional sobre hormigón autocompactante en Kochi, Japón (Wallevik y Nielsson, 2003).

El Simposio Internacional RILEM sobre Hormigón Autocompactante lleva hasta 9 ediciones, el primer Simposio celebrado en Estocolmo, Suecia (1999); el segundo Simposio en Tokio, Japón (2001); el tercer Simposio en Reykjavic, Islandia (2003); el cuarto Simposio en Chicago, USA (2005); el quinto en Gante, Bélgica (2007); el Sexto Simposio en Montreal, Canadá (2010); el séptimo Simposio en Paris, Francia (2013); el octavo Simposio en Washington, D.C, USA (2016) y el noveno Simposio en Dresde, Alemania (2019), respectivamente y el 10<sup>th</sup> Simposio (SCC2022) prevista para octubre del 2022 en Changsha, China, fue pospuesto para el 2023 debido a la pandemia de COVID-19 (RILEM, 2022) .

Se han realizado numerosas conferencias y simposios. Por ejemplo:

- Conferencia Norteamericana sobre el Diseño y el Uso del HAC, de la primera a la tercera se celebraron en Chicago en el 2002, 2005, 2008 respectivamente; la

cuarta conferencia se celebró en Montreal en 2010; la quinta conferencia se celebró en Chicago, USA en 2013 y la sexta Conferencia se celebró en Washington, D.C, USA en 2016 (Martínez-García, 2021; Nielsson y Wallevik, 2003; Shi et al., 2014).

- 2ª Conferencia Internacional sobre los Avances en la Tecnología del Hormigón en Oriente Medio: SCC, celebrada en Abu Dabi en 2009 (RILEM Technical Committee, 2008).
- Simposio Internacional sobre Diseño, Rendimiento y Uso del Hormigón Autocompactante, del primero al cuarto simposio se celebraron en China: Changsha (2005), Pekín (2009), Xiamen (2013) y Changsha (2018), respectivamente y el quinto Simposio se celebrará octubre del 2022 en Changsha (Shi et al., 2014).
- Congreso Iberoamericano de Hormigón Autocompactante y Hormigones Especiales, lleva hasta el momento 5 ediciones, el primer congreso celebrado en Valencia, España en 2008; el 2º Congreso se celebró en Guimarães, Portugal en 2010; el 3º Congreso se celebró en Madrid, España en 2012; el 4º Congreso se celebró en Oporto, Portugal en 2015 y el 5º Congreso se celebró en Valencia, España en 2018 (HAC/BAC, s.f.).

Esta cronología de eventos deja en evidencia la importancia que, a nivel mundial, ha adquirido el hormigón autocompactante, llegando a ser, el mayor avance tecnológico de las últimas décadas en términos de hormigón. Esto es debido a la gran receptividad que ha tenido este tipo de hormigón por parte de la industria y los investigadores, debido a que permite reducir tiempo y costos.

### 1.1.3 Normativas

La Asociación Española de Normalización y Certificación (AENOR) que para el año 2017 pasa a ser Asociación Española de Normalización (UNE) , publica cinco normas UNE relativas a ensayos para la caracterización del comportamiento en estado fresco del hormigón autocompactante (UNE, 2021):

- ❖ UNE-EN 12350-8:2020. Ensayos de hormigón fresco. Parte 8: Hormigón autocompactante. Ensayo del escurrimiento. (Esta norma anula la UNE-EN 12350-8:2011, que a su vez anuló UNE 83361:2007).
- ❖ UNE-EN 12350-9:2011. Ensayos de hormigón fresco. Parte 9: Hormigón autocompactante. Ensayo del embudo en V. (Esta norma anula la UNE 83364:2007).
- ❖ UNE-EN 12350-10:2011. Ensayos de hormigón fresco. Parte 10: Hormigón autocompactante. Método de la caja en L. (Esta norma anula la UNE 83363:2007).
- ❖ UNE-EN 12350-12:2011. Ensayos de hormigón fresco. Parte 12: Hormigón autocompactante. Método con el anillo japonés. (Esta norma anula la UNE 83362:2007).
- ❖ UNE-EN 12350-11:2010. Ensayos de hormigón fresco. Parte 11: Hormigón autocompactante. Ensayo de segregación por tamiz.

En este orden de ideas, el 18 de julio de 2008, La Comisión Permanente del Hormigón elabora la Instrucción Española del Hormigón Estructural (EHE-08), la cual se aprueba en el Real Decreto 1247/2008, además, esta instrucción incluye el Anejo 17 relativo a Recomendaciones para la utilización del hormigón autocompactante (Comisión Permanente de Hormigón, 2010). Esta Instrucción fue sustituida por el Código Estructural aprobado según Real Decreto 470/2021 del 29 de junio de 2021 (España, Ministerio de la Presidencia, 2021).

## 1.1.4 Ventajas del uso del hormigón autocompactante

El hormigón autocompactante (HAC) puede clasificarse como un material de construcción avanzado y es considerado como un material respetuoso con el medio ambiente. El HAC garantiza una alta calidad de las estructuras de hormigón en obras in-situ, así como en la industria del prefabricado. La aplicación del HAC también hace posible la automatización de la construcción, lo que conduce a una mayor productividad (Skarendahl y Petersson, 2000). Particularmente, en el contexto español, el uso del HAC,

tal como señala (Martínez-García, 2021) mayoritariamente se emplea en la industria del prefabricado, debido a que facilita su producción y ofrece un rápido retorno de la inversión.

En la actualidad, entre las ventajas que ofrece el hormigón autocompactante se encuentran (Álvarez, 2014; Bermejo Núñez, 2009; Martínez-García, 2021; Okamura et al., 2000; Á. Romero Esquinas, 2018):

- ❖ Mejora de la calidad del hormigón y reducción de las reparaciones en la obra.
- ❖ Tiempos de construcción más rápidos.
- ❖ Reducción de los costes totales.
- ❖ Facilita la introducción de la automatización en la construcción del hormigón.
- ❖ Mejora de la salud y la seguridad gracias a la eliminación de la manipulación de los vibradores.
- ❖ Reducción sustancial de la carga de ruido ambiental en la obra y sus alrededores.
- ❖ Posibilidades de utilización de "áridos", que actualmente son productos de desecho y cuya eliminación es costosa.
- ❖ Una gran estética, con excelentes acabados superficiales, sin defectos ni imperfecciones.
- ❖ Facilidad de colocación.
- ❖ Secciones de hormigón más finas.
- ❖ Mayor libertad de diseño.
- ❖ Mayor durabilidad y fiabilidad de las estructuras de hormigón.
- ❖ La facilidad de colocación se traduce en un ahorro de costes gracias a la reducción de las necesidades de equipos y mano de obra.
- ❖ El HAC hace que el nivel de durabilidad y fiabilidad de la estructura sea independiente de las condiciones existentes en la obra en relación con la calidad de la mano de obra, el vaciado y los sistemas de compactación disponibles.
- ❖ La alta resistencia a la segregación externa y la capacidad de autocompactación de la mezcla permiten eliminar los macrodefectos, las burbujas de aire y los "panales de miel" responsables de penalizar el rendimiento mecánico y la durabilidad de la estructura.

## 1.1.5 Aplicaciones del Hormigón autocompactante

Como resultado del desarrollo del prototipo del HAC en 1998 y las diversas investigaciones que se realizaron a nivel mundial, el hormigón autocompactante empezó a utilizarse en todo tipo de obras in-situ, tales como: columnas de acero rellenas de hormigón, presa (hormigón alrededor de la estructura), muro pantalla, puentes (anclajes, arcos, vigas, torres, juntas), elementos prefabricados, tanques, túneles (Okamura et al., 2000). Así como en la industria del prefabricado, además es utilizado para acortar el período de construcción de la obra.

La primera aplicación del HAC tuvo lugar en Japón en 1991 (Figura 2), utilizándose en las torres de hormigón pretensado del puente colgante Shin-kiba Ohashi (Okamura y Ouchi, 2003).



**Figura 2.** Puente Shin-kiba Ohashi, (Okamura y Ouchi, 2003).

En 1998 en la ciudad de Kobe, Japón, se inaugura el puente Akashi-Kaikyo (Figura 3). Okamura y Ozawa (1996) señalan que “se colocaron unos 433000 m<sup>3</sup> de hormigón autocompactante en los anclajes del puente, siendo para el momento de su culminación, 1997, el puente colgante con la mayor luz del mundo, 1991 m” (p.270). Una de las razones para el uso del HAC fue acortar el tiempo de construcción. Además, se colocaron hasta 1900 m<sup>3</sup> de hormigón en un día. Para mejorar la colocación, se desarrolló y utilizó un hormigón autocompactante con un tamaño máximo de árido grueso de 40 mm (Okamura y Ouchi, 2003; Okamura y Ozawa, 1996; Skarendahl y Petersson, 2000)

Además, en 1998, se empleó el HAC para la pared de un gran tanque de gas licuado de la compañía de Gas de Osaka (Figura 4). El uso del HAC condujo a la reducción de: a) número de vertidos de 14 a 10, ya que se aumentó la altura de cada vertido; b) la cantidad de trabajadores de 150 a 50 y c) el tiempo de construcción de la obra de 22 a 18 meses (Okamura et al., 2000).



**Figura 3.** Vista general puente Akashi-Kaikyo, (GME, s.f.).



**Figura 4.** Tanque de GNL, Osaka Gas Company, (NBM&CW, 2019).

En lo que respecta al uso del HAC en la construcción de edificios de gran altura, los japoneses fueron los pioneros, desarrollando una tecnología denominada “Concrete Filled Tubes (CFT)”. Esta consiste en rellenar grandes tubos de acero con HAC, y unidos mediante diafragmas, eliminando así el encofrado y la armadura y reduciendo el plazo de ejecución de la obra. Con esta tecnología construyeron, en Yokohama, Japón, los pilares de las 9 primeras plantas del edificio Landmark Tower (Martínez-García, 2021b; Vilanova, 2009).

Por otra parte, a mediados de los noventa, en países como Canadá, Suecia, Holanda, Tailandia, Taiwán, Austria, Estados Unidos, Francia, Austria, Reino Unido, Islandia y Korea desarrollan y profundizan en las investigaciones del HAC, comenzando a aplicar en sus construcciones el HAC (Okamura et al., 2000).

A finales de los 90, en Europa, se comenzó a emplear el HAC en las obras, siendo Francia y Suecia los primeros países en emplear el HAC para la construcción de edificios y puentes. Entre las aplicaciones del HAC se encuentra (Bermejo Núñez, 2009; Martínez-García, 2021; Nieto Alcolea, 2015; Skarendahl y Petersson, 2000; Vilanova, 2009):

- ❖ Suecia: para finales de los noventa se habían construido 19 puentes cuyos requisitos de durabilidad eran altos, varios edificios. En Slona, en el marco del programa Startboxen se construyó un edificio comercial. En Malmo, se empleó el HAC para la construcción de un puente
- ❖ Francia: en Meudon se empleó en la construcción del Centro de Arte, específicamente en las zapatas, muros y soleras. En Chamarande, se empleó el HAC para construir muros altamente reforzados. En Vierzon, se utilizó el HAC en la construcción de dos vigas en forma H de dimensiones 38.50 m de longitud, 80 cm de altura y 30 cm de espesor.

Particularmente, en España, se empleó el HAC para diversas obras, entre las que se mencionan:

- ❖ La primera obra fue en Zaragoza, en el 2000, el arco mixto del puente de la Ronda de la Hispanidad sobre el río Ebro (Figura 5).
- ❖ Nuevo edificio del Ayuntamiento en Mollet de Vallés, Barcelona, en el 2002, Fue la primera estructura postensada donde se empleó el HAC (Figura 6).



**Figura 5.** *Puente de la Ronda de la Hispanidad, (Vilanova, 2009).*



**Figura 6.** *Vista panorámica de la fachada del Ayuntamiento de Mollet, (Martínez-García, 2021).*

- ❖ Fabricación de 312 vigas de cajón con 17500 m<sup>3</sup> de HAC pretensado para los viaductos en la autopista Scut do Norte Litoral, en Portugal en el 2003.
- ❖ Reparación de los túneles de Montblanc y Lilla de la línea AVE Madrid-Zaragoza-Valencia, para el 2004.
- ❖ Ciudad de la Justicia, compuesta por 8 edificios para los que se empleó el HAC visto coloreado de 7 colores: rojo, amarillo, verde, naranja, marrón, negro y blanco, en Barcelona en el 2005 (Figura 7).



**Figura 7.** Vista panorámica de la Ciudad de la Justicia de Barcelona, (Hernández, 2010).

- ❖ Puente del Milenio de la Expo 2008, realizado con HAC de color blanco de altas prestaciones y resistencias, en Zaragoza en el 2008 (Figura 8).



**Figura 8.** Vista panorámica del Puente de Tercer milenio, (edu1975, 2012).

- ❖ La Torre de Cristal (Figura 9), en Madrid, es un rascacielos de 249 metros y 50 plantas, su construcción comenzó en 2004 y se culminó en 2009. Forma parte del complejo Cuatro Torres Business Area: La Torre de Cepsa, proyecto del arquitecto Norman Foster, la Torre PwC (anteriormente denominada Torre Sacyr) proyecto de los arquitectos Carlos Rubio y Enrique Álvarez-Salas, la Torre de Cristal de César Pelli y la Torre Emperador Castellana (originalmente Torre Espacio) de Henry Cobb.



**Figura 9.** Vista de la Torre Cristal, en construcción, (edu1975, 2012).

## 1.2 RESIDUOS DE CONSTRUCCIÓN Y DEMOLICIÓN

Los Residuos de construcción y demolición (RCD) son esos residuos sólidos, básicamente inertes, que resultan de alguna actividad del sector de construcción, como consecuencia de la construcción de nuevas edificaciones así como modificaciones, restauración, renovación, demolición y cualquier tipo de mejora o cambio total o parcial que sufra alguna construcción (El Hagggar, 2007; Iacoboaea et al., 2019; Mejía et al., 2013).

En este orden de ideas, en 2018 la Unión Europea (UE) pone en vigencia la Directiva (UE) 2018/851 del Parlamento Europeo y del Consejo de 30 de mayo de 2018 por la que se modifica la Directiva 2008/68/CE sobre residuos, en la cual define residuos de construcción y demolición (RCD) como “los residuos resultantes de las actividades de construcción y demolición en general, comprende también los residuos procedentes de pequeñas actividades personales de construcción y demolición realizadas en hogares” (Parlamento Europeo y El Consejo de la Unión Europea, 2018).

Al respecto, a través del Real Decreto 105/2008, de 1 de febrero por el que se regula la producción y gestión de los residuos de construcción y demolición, en su artículo 2, literal a), define residuos de construcción y demolición (RCD) como cualquier sustancia u objeto que se genere en una obra de construcción y demolición (España, Ministerio de la Presidencia, 2008).

A su vez, el Real Decreto 105/2008, en su artículo 2, literal c), considera que una obra de construcción y demolición:

“Es la actividad consistente en: la construcción, rehabilitación, reparación, reforma o demolición de un bien inmueble, tal como, un edificio, carretera, puerto, aeropuerto, ferrocarril, canal, presa, instalación deportiva o de ocio, así como cualquier otro análogo de ingeniería civil; además de la realización de trabajos que modifiquen la forma o sustancia del terreno o del subsuelo, tales como excavaciones, inyecciones, urbanizaciones u otros análogos, con exclusión de aquellas actividades provenientes de industrias extractivas” (España, Ministerio de la Presidencia, 2008).

Sin embargo, quedan excluidas las tierras y piedras no contaminadas por sustancias peligrosas, los residuos generados en las obras de construcción y demolición regulados por una legislación específica y residuos regulados por la Directiva 2006/21/CE del Parlamento Europeo y del Consejo de 15 de marzo de 2006, sobre la gestión de los residuos de industrias extractivas (Parlamento Europeo y El Consejo de la Unión Europea, 2006).

Por otra parte, el Real Decreto 105/2008, considera “parte integrante de una obra de construcción y demolición toda instalación que dé servicio exclusivo a la misma, y en la medida que su montaje y desmontaje se dé lugar durante la ejecución de la obra o al final de la misma, tales como: plantas de machaqueo, plantas de fabricación de hormigón, grava-cemento o suelo-cemento, plantas de prefabricados de hormigón, plantas de fabricación de mezclas bituminosas, talleres de fabricación de encofrados, talleres de elaboración de ferralla, almacenes de materiales y almacenes de residuos de la propia obra y planta de tratamiento de los residuos de construcción y demolición de la obra” (España, Ministerio de la Presidencia, 2008).

Entre los RCD procesados y reciclados se incluyen una variedad de materiales como productos cerámicos, residuos de hormigón, material asfáltico y en menor medida componente como madera, vidrio y plásticos (Aldaaja, 2019; Jiménez et al., 2011; Martínez-García, 2021; Servigon Ruiz, 2021). Dada la variedad de RCD, el Real Decreto 15/2008 estipula que los mismos deben estar codificados de acuerdo a la lista europea

de residuos publicada por Orden MAM/304/2002, de 8 de febrero, o normas que la sustituya (España, Ministerio de la Presidencia, 2008), de acuerdo con esto esta orden es derogada por la Ley 7/2022, de 8 de abril, de residuos y suelos contaminados para una economía circular, la cual establece en su artículo 6 que la identificación y clasificación de residuos se hará de conformidad con la lista establecida en la Decisión de la Comisión 2014/955/UE (España, Jefatura del Estado, 2022).

Al respecto, en la Decisión de la Comisión 2014/955/UE, se establece la lista de los diferentes tipos de residuos de construcción y demolición, definidos mediante códigos de seis cifras, específicamente en el capítulo 17 se establecen la lista y sus códigos, (incluida la tierra excavada de zonas contaminadas) (Comisión Europea, 2014), la misma se presenta en la Tabla 1.

**Tabla 1.** *Lista Europea de Residuos, sobre Residuos de Construcción y Demolición.*

<b>17</b>	<b>RESIDUOS DE LA CONSTRUCCIÓN Y DEMOLICIÓN (INCLUIDA LA TIERRA EXCAVADA DE ZONAS CONTAMINADAS)</b>
<b>17 01</b>	<b>Hormigón, ladrillos, tejas y materiales cerámicos</b>
17 01 01	Hormigón
17 01 02	Ladrillos
17 01 03	Tejas y materiales cerámicos
17 01 06*	Mezclas o fracciones separadas, de hormigón, ladrillos, tejas y materiales cerámicos que contienen sustancias peligrosas
17 01 07	Mezclas de hormigón, ladrillos, tejas y materiales cerámicos, distintas de las específicas en el código 17 01 06
<b>17 02</b>	<b>Madera, vidrio y plástico</b>
17 02 01	Madera
17 02 02	Vidrio
17 02 03	Plástico
17 02 04*	Vidrio, plástico y madera que contienen sustancias peligrosas o están contaminados por ellas
<b>17 03</b>	<b>Mezclas bituminosas, alquitrán de hulla y otros productos alquitranados</b>
17 03 01*	Mezclas bituminosas que contienen alquitrán de hulla
17 03 02	Mezclas distintas de las específicas en el código 17 03 01
17 03 03*	Alquitrán de hulla y productos alquitranados
<b>17 04</b>	<b>Metales (incluidas sus aleaciones)</b>
17 04 01	Cobre, bronce, latón
17 04 02	Aluminio
17 04 03	Plomo
17 04 04	Zinc

17 04 05	Hierro y acero
17 04 06	Estaño
17 04 07	Metales mezclados
17 04 09*	Residuos metálicos contaminados con sustancias peligrosas
17 04 10*	Cables que contienen hidrocarburos, alquitrán de hulla y otras sustancias peligrosas
17 04 11	Cables distintos de los específicos en el código 17 04 10
<b>17 05</b>	<b>Tierra (incluida la tierra excavada de zonas contaminadas), piedras y lodos de drenaje</b>
17 05 03*	Tierra y piedras que contienen sustancias peligrosas
17 05 04	Tierra y piedras distintas de las específicas en el código 17 05 03
17 05 05*	Lodos de drenaje que contienen sustancias peligrosas
17 05 06	Lodos de drenaje distintos del especificado en el código 17 05 05
17 05 07*	Balasto de vías férreas que contienen sustancias peligrosas
17 05 08	Balasto de vías férreas distinto del especificado en el código 17 05 07
<b>17 06</b>	<b>Materiales de aislamiento y materiales de construcción que contienen amianto</b>
17 06 01*	Materiales de aislamiento que contienen amianto
17 06 03*	Otros materiales de aislamiento que consisten en sustancias peligrosas o contienen dichas sustancias
17 06 04	Materiales de aislamiento distintos de los especificados en los códigos 17 06 01 y 17 06 03
17 06 05*	Materiales de construcción que contienen amianto
<b>17 08</b>	<b>Materiales de construcción a base de yeso</b>
17 08 01*	Materiales de construcción a base de yeso contaminados con sustancias peligrosas
17 08 02	Materiales de construcción a base de yeso distintos de los especificados en el código 17 08 01
<b>17 09</b>	<b>Otros residuos de construcción y demolición</b>
17 09 01*	Residuos de construcción y demolición que contienen mercurio
17 09 02*	Residuos de construcción y demolición que contienen PCB (por ejemplo, sellantes que contienen PCB, revestimientos de suelo a base de resinas que contienen PCB, acristalamientos dobles que contienen PCB, condensadores que contienen PCB)
17 09 03*	Otros residuos de construcción y demolición (incluidos los residuos mezclados) que contienen sustancias peligrosas
17 09 04	Residuos mezclados de construcción y demolición distintos de los especificados en los códigos 17 09 01, 17 09 02 y 17 09 03

*Nota.* Los códigos con (\*) asterisco hacen referencia a los residuos de aleaciones considerados residuos peligrosos.

Esta tabla ha sido adaptada de: "Decisión de la Comisión 2014/955/UE de 18 de diciembre de 2014 por la que se modifica la Decisión 2000/532/CE, sobre la lista de residuos, de conformidad con la Directiva 2008/98/CE del Parlamento Europeo y del Consejo", por Comisión Europea, 2014, *Diario Oficial de la Unión Europea*, p. 78-79.

Estos diferentes residuos son clasificados de acuerdo a la naturaleza en: peligroso, no peligrosos o inertes. En lo referido a los residuos peligrosos de construcción y demolición, la Directiva 2008/98/CE del Parlamento Europeo y del Consejo de 19 de noviembre de 2008, sobre los residuos, los define como los residuos que tienen una o varias de las características peligrosas que pueden ser perjudiciales para el medio ambiente o la salud humana (Parlamento Europeo y Consejo de la Union Europea, 2008). Estas características están descritas en el Reglamento (UE) 1357/2014 de la Comisión, el cual sustituye al Anexo III, de la Directiva 2008/98/CE del Parlamento Europeo y del Consejo de 19 de noviembre de 2008, sobre los residuos, (La Comisión Europea, 2014) las mismas se presentan en la Tabla 2.

**Tabla 2.** Características de los residuos que permiten clasificarlos como peligrosos.

Código	Característica	Descripción
HP 1	Explosivo	Corresponde a los residuos que, por reacción química, pueden desprender gases a una temperatura, presión y velocidad tales que pueden ocasionar daños a su entorno. Se incluyen los residuos pirotécnicos, los residuos de peróxidos orgánicos explosivos y los residuos autorreactivos explosivos
HP 2	Comburente	Corresponde a los residuos que, generalmente liberando oxígeno, pueden provocar o facilitar la combustión de otras sustancias. carburantes diésel y aceites ligeros para calefacción usados con un punto de inflamación entre $> 55\text{ }^{\circ}\text{C}$ y $\leq 75\text{ }^{\circ}\text{C}$ ;
HP 3	Inflamable	Residuos líquidos o sólidos pirofóricos inflamables: residuos líquidos o sólidos que, aun en pequeñas cantidades, pueden inflamarse al cabo de cinco minutos de entrar en contacto con el aire; Residuos sólidos inflamables: residuos sólidos que se inflaman con facilidad o que pueden provocar fuego o contribuir a provocar fuego por fricción; Residuos gaseosos inflamables: residuos gaseosos que se inflaman con el aire a $20\text{ }^{\circ}\text{C}$ y a una presión de referencia de 101,3 kPa; Residuos que reaccionan en contacto con el agua: residuos que, en contacto con el agua, desprenden gases inflamables en cantidades peligrosas;

		Otros residuos inflamables: aerosoles inflamables, residuos que experimentan calentamiento espontáneo inflamable, residuos de peróxidos orgánicos inflamables y residuos autorreactivos inflamables.
HP 4	Irritante – irritación cutánea y lesiones oculares	Corresponde a los residuos que, cuando se aplican, pueden provocar irritaciones o lesiones oculares
HP 5	Toxicidad específica en determinados órganos (STOT en su sigla inglesa) /Toxicidad por aspiración	Corresponde a los residuos que pueden provocar una toxicidad específica en determinados órganos, bien por una exposición única bien por exposiciones repetidas, o que pueden provocar efectos tóxicos agudos por aspiración.
HP 6	Toxicidad aguda	Corresponde a los residuos que pueden provocar efectos tóxicos agudos tras la administración por vía oral o cutánea o como consecuencia de una exposición por inhalación.
HP 7	Carcinógeno	Corresponde a los residuos que inducen cáncer o aumentan su incidencia.
HP 8	Corrosivo	Corresponde a los residuos que, cuando se aplican, pueden provocar corrosión cutánea.
HP 9	Infecioso	Corresponde a los residuos que contienen microorganismos viables, o sus toxinas, de los que se sabe o existen razones fundadas para creer que causan enfermedades en el ser humano o en otros organismos vivos.
HP 10	Tóxico para la reproducción	Corresponde a los residuos que tienen efectos adversos sobre la función sexual y la fertilidad de hombres y mujeres adultos, así como sobre el desarrollo de los descendientes.
HP 11	Mutágeno	Corresponde a los residuos que pueden provocar una mutación, es decir, un cambio permanente en la cantidad o en la estructura del material genético de una célula.
HP 12	Liberación de un gas de toxicidad aguda	Corresponde a los residuos que emiten gases de toxicidad aguda (Acute Tox. 1, 2 o 3) en contacto con agua o con un ácido.
HP 13	Sensibilizante	Corresponde a los residuos que contienen una o varias sustancias que se sabe tienen efectos sensibilizantes para la piel o los órganos respiratorios.
HP 14	Ecotóxico	Corresponde a los residuos que presentan o pueden presentar riesgos inmediatos o diferidos para uno o más compartimentos del medio ambiente.

HP 15	Residuos que pueden presentar una de las características de peligrosidad antes mencionadas que el residuo original no presentaba directamente	Residuos susceptibles, después de su eliminación, de dar lugar a otra sustancia por un medio cualquiera, por ejemplo, un lixiviado que posee alguna de las características antes enumeradas.
-------	---	--

*Nota.* Esta tabla ha sido adaptada de: “REGLAMENTO (UE) No 1357/2014 DE LA COMISION, de 18 de diciembre de 2014, por el que sustituye el anexo III de la Directiva 2008/98/CE del Parlamento Europeo y del Consejo, sobre los residuos y por la que se derogan determinadas Directivas” por La Comisión Europea, 2014, *Diario Oficial de la Unión Europea*, p. 91-96.

En lo referido a los residuos no peligrosos o inertes, se considera como tal a aquellos residuos que no contaminan el medio ambiente y tampoco representan riesgo para la salud. Según, el Real Decreto 105/2008, en su artículo 2, literal b) define residuo inerte como: “aquel residuo no peligroso que no experimenta transformaciones físicas, químicas o biológicas significativas, no es soluble ni combustible, ni reacciona física ni químicamente ni de ninguna otra manera, no es biodegradable, no afecta negativamente a otras materias con las cuales entra en contacto de forma que pueda dar lugar a contaminación del medio ambiente o perjudicar a la salud humana” (España, Ministerio de la Presidencia, 2008). Por otra parte, la calidad de las aguas superficiales o subterráneas no debe ser alterada por la lixiviabilidad total, la cantidad de contaminantes del RCD y los tóxicos que actúan en el ambiente producto del lixiviado deberán ser insignificantes.

## 1.2.1 Composición de los residuos de construcción y demolición

La procedencia de los residuos de construcción y demolición (RCD) generalmente resulta de la construcción, renovación y demolición de edificios, carreteras puentes y otras estructuras. Según Wu et al. (2014) la composición de los RCD es muy variada, depende del tipo de obra o edificación o demolición involucrada y refleja en gran medida el tipo y distribución porcentual de las materias primas utilizadas en el sector de construcción.

Pueden variar de un país a otro dependiendo de la disponibilidad de los mismos y costumbres de construcción en cada país (EUROSTAT, 2022c).

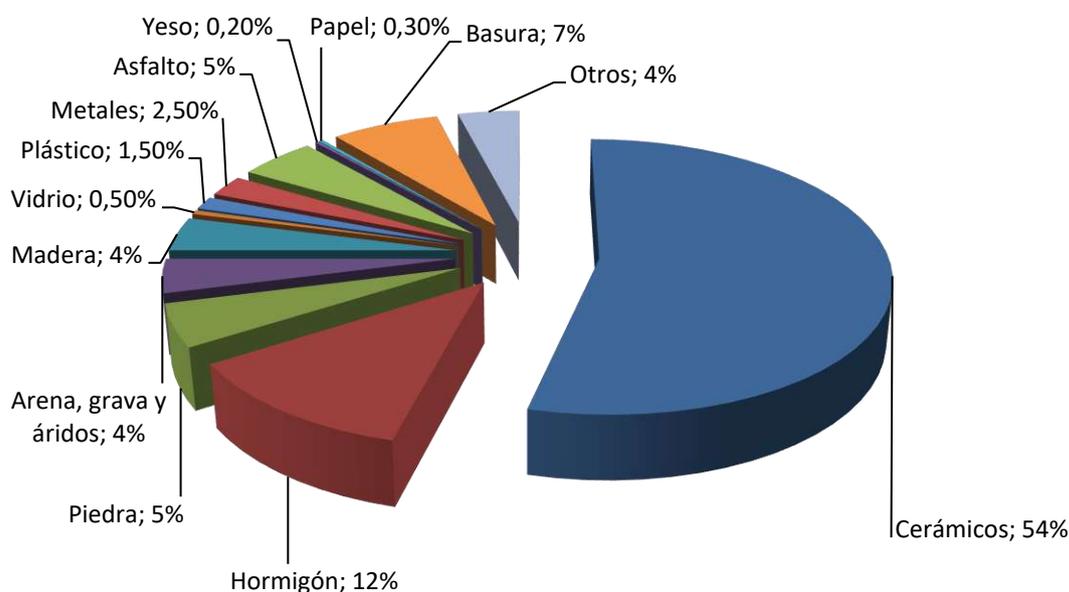
Generalmente, los residuos producto de las actividades de construcción y demolición, se conforman en su mayor parte de hormigón, productos cerámicos, material asfáltico y tierras de excavación; además puede contener otros materiales como amianto (localizado en aislamientos, techos y baldosas y sellado resistente al fuego), pinturas a base de plomo (en techos, tejas y cables eléctricos), yeso, maderas, plásticos, acero, papel y cartón, considerados como impurezas (Pacheco Bustos et al., 2017; Sánchez Roldán, 2019; Srour et al., 2013; Villoria Sáez, 2014). Los mismos pueden ser considerados como peligrosos de acuerdo con el Reglamento (UE) No 1357/2014 de la comisión, de 18 de diciembre de 2014, por el que se sustituye el anexo III de la Directiva 2008/98/CE del Parlamento Europeo y del Consejo, sobre los residuos y por la que se derogan determinadas Directivas (La Comisión Europea, 2014).

La mayor parte de los RCD se pueden considerar como inertes, es decir que en su estado original su poder contaminante es relativamente bajo. Los RCD inertes en general se consideran que son poco perjudiciales para el medioambiente (Sánchez Roldán, 2019; Wu et al., 2014). Sin embargo, estos residuos pueden volverse peligrosos para el medioambiente y para la salud, debido a que pueden contener una variedad de sustancias que pueden ser biodegradables convirtiéndose así en sustancias contaminantes, de diferentes maneras: gaseosa, que va al aire; lixiviados, que van a las aguas superficiales y subterráneas, o en forma de sedimentos para los suelos (Aldaaja, 2019; Mejía et al., 2013; Sánchez Roldán, 2019).

Para el 2018, Unión Europea, EU-28, generó aproximadamente un 3% de residuos construcción y demolición clasificados como peligrosos, mayoritariamente materiales minerales, representado los RCD no peligrosos la mayor proporción (97%) (EUROSTAT, 2022c).

En España, para el 2019, el porcentaje de RCD generado clasificados como no peligrosos es superior al 99%, cuyo componente principal son residuos minerales, mientras que la generación de RCD peligrosos es inferior al 1% (INE, 2022). Los RCD, en España, según el Centro de Estudios y Experimentación de Obras Públicas del Ministerio de Fomento

están compuestos por: cerámicos, hormigón, piedra, arena, grava y áridos, madera, vidrio, plásticos, metales, asfalto, yeso, papel, basura y otros (CEDEX, 2014). En la Figura 10 se presenta la composición porcentual de los RCD en España para el 2014 (CEDEX, 2014).



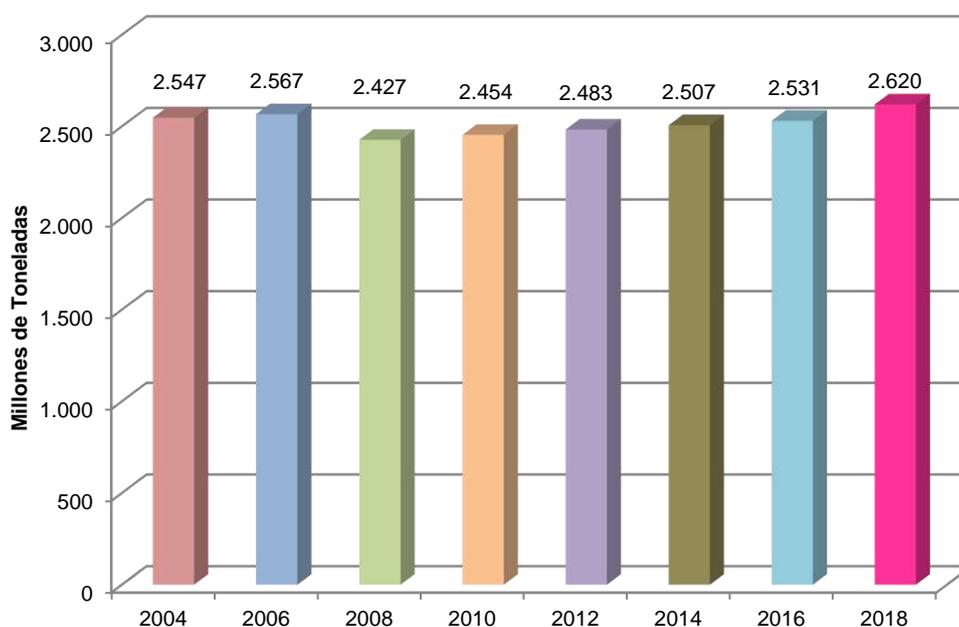
**Figura 10.** Composición porcentual de los RCD en España para el 2014, (CEDEX, 2014).

En la Figura 10, se puede apreciar que los materiales cerámicos (54%) representan un porcentaje significativo en la composición de los RCD. Mientras que del 46% restante, el hormigón (12%) presenta un porcentaje significativo, los demás compuestos: basura, asfalto, piedra, madera, arena, grava y áridos, metales, plástico, vidrio, papel, yeso y otros, hacen referencia a proporciones como máximo del 7%.

## 1.2.2 Generación de los residuos de construcción y demolición

En el 2018, el total de residuos generados en la Unión Europea EU-28 por todas las actividades económicas y hogares superó los 2620 miles de millones de toneladas (EUROSTAT, 2022b). Al respecto en la Figura 11 se aprecia como la generación total de

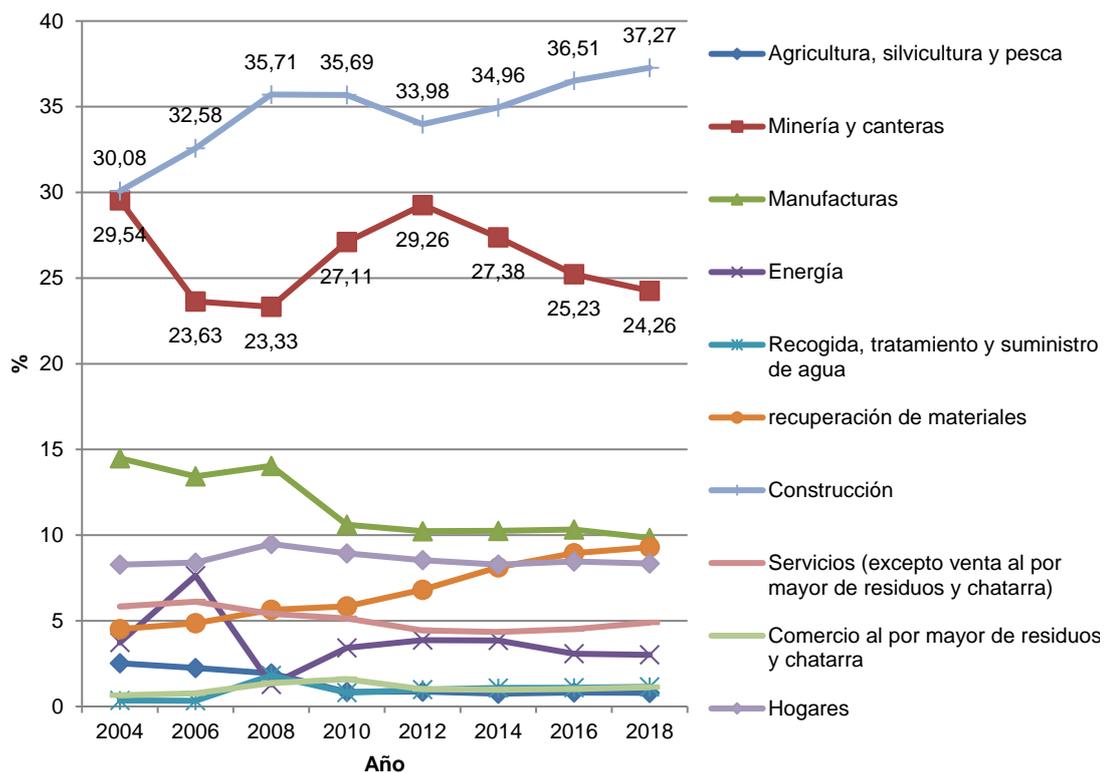
residuos presenta una tendencia a aumentar, para los períodos 2008-2018, con un incremento promedio del 1.5% entre 2008 y 2016, mientras que para años 2016 a 2018 se duplica este incremento, al superar el 3% (+89 millones de toneladas), y en comparación con lo generado en el 2008 el incremento fue del 8% (+193 millones de toneladas). Este incremento de los residuos se debe al crecimiento poblacional y urbanístico.



**Figura 11.** Generación de residuos por la totalidad de actividades económicas y hogares en la Unión Europea (EU-28), 2004-2018, (EUROSTAT, 2022c).

Ahora bien, en la Figura 12 se presenta la proporción de residuos generados por cada actividad económica y hogares para los períodos 2004-2018 de la Unión Europea, donde puede apreciarse que las actividades los sectores construcción y minería y canteras son las que más contribuyen en la generación de residuos (EUROSTAT, 2022b).

La actividad del sector construcción es la que más contribuye en la generación total de residuos de la UE, ya que más de un tercio del total de residuos de la UE los genera esta actividad (Figura 12). A pesar que para el 2012 presentó una ligera disminución, en términos generales es una actividad que se caracteriza por ir incrementando anualmente sus residuos, presentando en el 2018 su valor más alto de 37,27% del total de residuos de la UE (EUROSTAT, 2022b).

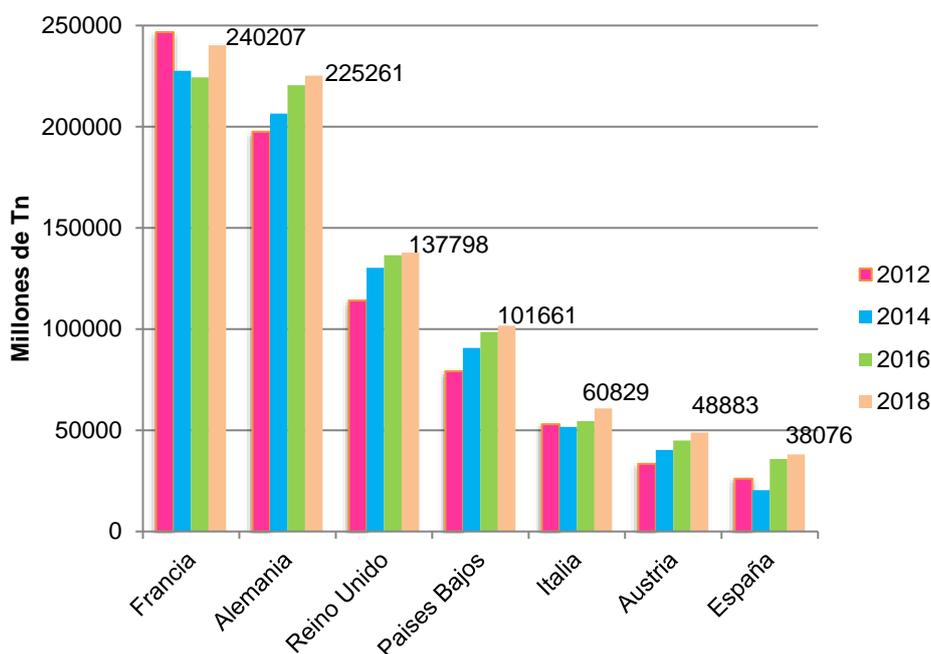


**Figura 12.** Generación de residuos por actividad económica y hogares en la Unión Europea (UE-28), 2004-2018, (EUROSTAT, 2022b).

Por otra parte, en la Unión Europea, la segunda actividad que genera más residuos es la minería y canteras. En términos generales a lo largo de los períodos 2004-2018 generó, en promedio, un aproximado de 26.22% del total de residuos de la UE (EUROSTAT, 2022b). Sin embargo, su contribución en la generación de residuos va disminuyendo, aun cuando para los períodos 2008-2012 presentó un ligero aumento porcentual su tendencia es a la disminución de su contribución en la generación de residuos de la UE.

La participación del resto de las actividades económicas (agricultura, silvicultura y pesca, manufacturas, energía, recogida, tratamiento y suministro de agua, servicios, comercio al por mayor de residuos y chatarra y hogares) en la generación de residuos de la UE, se encuentra por debajo del 10% (Figura 12), mostrando toda una tendencia a disminuir su contribución de residuo. Excepto la actividad recuperación de materiales que claramente presenta una tendencia a incrementar su contribución en la generación de residuos de la UE, a pesar que su aporte se encuentra por debajo del 10%.

Específicamente, los Estados Miembros de la UE-28 para el 2018 generaron 977 millones de toneladas de RCD (EUROSTAT, 2022b). En la Figura 13 se representan los RCD generados por los siete Estados Miembros de la UE-28 que más generan RCD, para los períodos 2012-2018. Particularmente, se aprecia Francia (240 millones de Tn), Alemania (225 millones de Tn) son los que más RCD generan (EUROSTAT, 2022b). En general estos Estados Miembros de la UE-28 presentan una tendencia ascendente en la generación de RCD, tal como se refleja en la Figura 13.



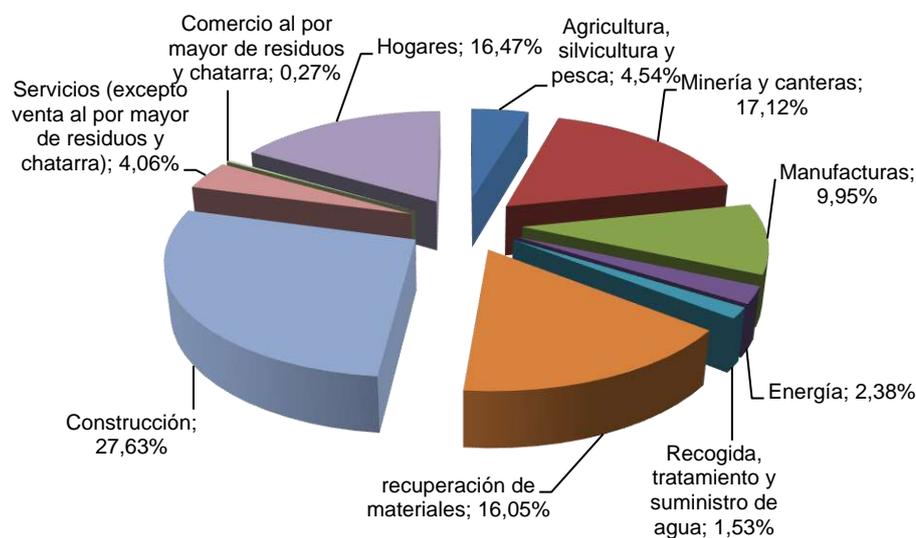
Nota. Datos tomados de: "Generation of waste by economic activity", por EUROSTAT, 2022, <https://ec.europa.eu/eurostat/databrowser/view/ten00106/default/table?lang=en>.

**Figura 13.** RCD generados por algunos Estados Miembros de la UE-28, 2004-2018, (EUROSTAT, 2022b).

Particularmente, España, generó más de 38 millones de toneladas de RCD (Figura 13) para el 2018 (EUROSTAT, 2022b), lo que equivale al 4% de los residuos totales de RCD generados por los Estados Miembros de la UE-28.

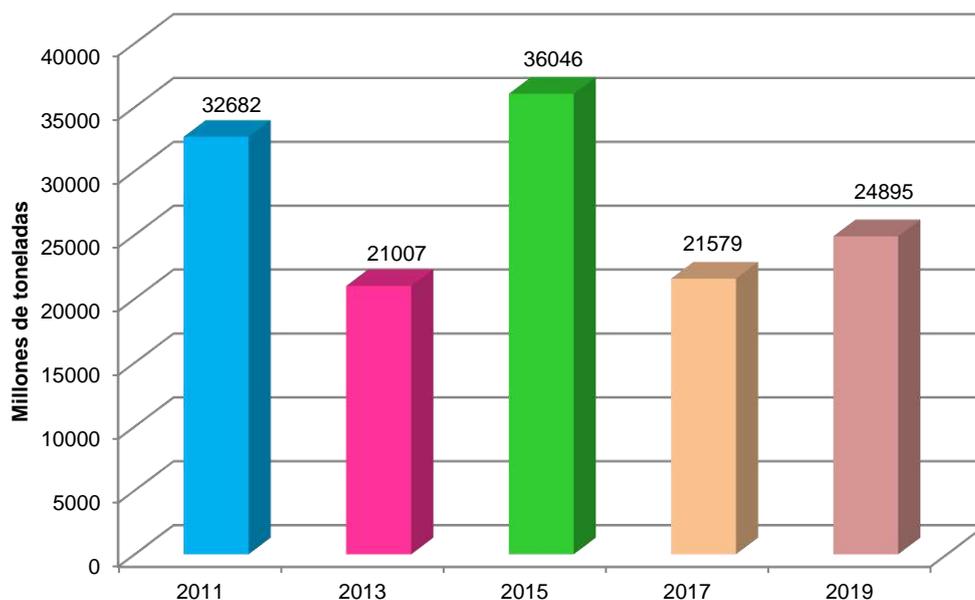
En la Figura 14 se presenta la distribución de estos residuos generados por actividad económica y hogares en España para el año 2018, donde se puede observar que la actividad económica que genera más residuos es la construcción con un contribución de 27.63% de los residuos totales generados en España, seguido por minería y canteras y

recuperación de materiales con un 17.12% y un 16.05% respectivamente (EUROSTAT, 2022b). Vemos que este comportamiento es similar al que presenta la generación total de residuos de la UE-28 donde también estas actividades son las que más generan residuos.



**Figura 14.** Generación de residuos por actividad económica y hogares en España para el 2018, (EUROSTAT, 2022b).

La Figura 15 muestra la evolución de la generación de RCD en España para los períodos 2011-2019, cifras emanadas por Instituto Nacional de Estadística (INE) de España (INE, 2022a). En el año 2015 se aprecia el nivel más alto de generación de RCD, 36046 miles de toneladas. En general, la evolución de la generación de RCD siguió diferentes patrones a lo largo del tiempo entre 2011 y 2019. En el año 2013, en España, se generó, en comparación con 2011, un 36% menos de RCD, lo que supone una disminución de 15675 miles de toneladas. Esto es como consecuencia de la crisis económica española, iniciada en el 2008 y concluida en el 2014, que produjo una profunda recesión en el sector construcción (Consejería del Medio Ambiente y Ordenación del Territorio, 2018; Martínez-García, 2021; Sánchez Roldán, 2019)



**Figura 15.** Evolución de la generación de RCD en España para 2011-2019, (INE, 2022c).

### 1.2.3 Problemática medioambiental de los residuos de construcción y demolición

La actividad humana origina importantes impactos sobre el medio ambiente, el crecimiento exponencial de la población conlleva a un crecimiento urbanístico descontrolado, así como el de grandes obras de construcción que inciden directamente en el deterioro del medio ambiente. Esto lleva a que el sector de la construcción presente un crecimiento exponencial, particularmente, en el territorio de la Unión Europea que trae como consecuencia el aumento desmedido de los RCD (Martínez-García, 2021). Este crecimiento del sector de la construcción implica actividades como la restauración, demolición, mejoras de infraestructuras que son generadoras de residuos de construcción y demolición que impactan en el medio ambiente.

Esto se evidenció en la Figura 12, donde se aprecia que el sector de construcción genera más de la tercera parte del total de los residuos generados en la UE (EUROSTAT, 2022b), específicamente genera entre un 30% y un 40% de RCD, a lo largo de los períodos 2004-2018. Estos niveles elevados de generación de RCD son considerados por la UE como un importante flujo de residuos (García-González, 2016)

Particularmente, para el 2019, en España, se generaron 24894552 millones de toneladas de RCD (INE, 2022b), lo que representa más del 27% del total residuos generados en España. La existencia de investigaciones sobre esta temática refleja la creciente preocupación por la cantidad de RCD que se generan y su impacto medioambiental.

Esto hace al sector de la construcción uno de los sectores responsables del impacto ambiental, por ser: (1) el principal consumidor de áridos naturales, necesarios para fabricar el hormigón, (2) el principal generador de residuos. Generalmente, este impacto ambiental se presenta en todos sus procesos, desde la extracción de recursos naturales, la fabricación de materiales, así como las actividades realizadas en la construcción de las obras. Esto provoca el agotamiento de los áridos naturales, así como la contaminación de suelos, agua y aire y daños para la salud humana (Pacheco Bustos et al., 2017)

Para el 2020, en Europa (42 países) consumieron 3930 millones de toneladas de áridos naturales para construcción (Fueyo Editores, 2022b). Siendo el sector de la construcción el principal consumidor de áridos, que es la materia prima por excelencia para producir el hormigón y después del agua, es la segunda más consumida por el hombre (ANEFA, 2018; Fueyo Editores, 2022a). Para el 2021 España presentó un consumo de áridos naturales para construcción superior a 136 millones de toneladas (Fueyo Editores, 2022a).

El consumo y explotación de los áridos naturales se caracteriza por un consumo elevado de energía, erosión de suelos, contribuyen al deterioro del impacto visual del paisaje, generación de polvo, alteración del hábitat natural, emisiones de CO<sub>2</sub>, así como la generación de una gran cantidad de residuos de construcción y demolición (Bizcocho Tocón, 2014; Martínez-García, 2021; Suárez Silgado, 2016).

Sin embargo, el impacto medioambiental del sector de construcción no queda solo en el entorno del consumo de áridos naturales, sino también en la gestión inadecuada de los residuos de construcción y demolición.

En particular, el abandono o la gestión inadecuada de los RCD pueden generar impactos medioambientales negativos tales como, la degradación y erosión de suelos, el agotamiento de vertederos, consumo de recursos energéticos, el agotamiento de los

recursos naturales, contaminación del agua, contaminación acústica, contribuir al cambio climático y afectar la salud humana y a los ecosistemas (Barrientos, 2016; K. Chen et al., 2020; García-González, 2016; Suárez Silgado, 2016).

En primer lugar, la degradación y erosión del suelo es producto del vertido incontrolado de RCD que significativamente ocupa espacio en la tierra (K. Chen et al., 2020; Yuan, 2013). El creciente desarrollo urbanístico y de construcción a gran escala necesitan recursos y provocan el agotamiento de los limitados vertederos (Vitale et al., 2017; Yuan, 2013). Por otra parte, debido a la presencia de lixiviados de RCD, los vertidos ilegales pueden suponer un potencial riesgo para las aguas subterráneas y superficiales (Vitale et al., 2017).

En este orden de ideas, Nasrullah et al. (2014); Servigon Ruiz (2021); Vitale et al. (2017) y Ye et al. (2012) señalan que uno de los posibles problemas medioambientales que provocan los RCD se refiere a un tratamiento inadecuado (como la contaminación de suelo y los recursos hídricos por el vertido ilegal y/o incontrolado), una utilización ilegal de sus grandes volúmenes para ocultar residuos peligrosos, la pérdida de recursos relacionada con la eliminación sin recuperación de materiales así como la disposición de los residuos en zonas verdes deteriora la capa vegetal, lo que puede causar la destrucción de hábitats naturales de flora y fauna y genera impactos en el paisaje urbano.

La práctica de arrojar los RCD en vertederos puede tener un impacto significativamente negativo en el medio ambiente:

- ❖ Los vertederos emiten metano que contamina el aire y exagera el efecto invernadero.
- ❖ El vertido de materiales inflamables y tóxicos como pintura, barnices y otros productos químicos en los vertederos también provoca la filtración de materiales nocivos en el suelo. Esta filtración puede llegar a las reservas acuíferas subterráneas y contaminar las vías fluviales, destruyendo los ecosistemas conectados a los suministros de agua dulce.

Con la finalidad de reducir este impacto medioambiental ante el aumento desmedido de los RCD, y contribuir a la sostenibilidad de la actividad de construcción, en el 2008 entran en vigencia dos legislaciones que tratan sobre la valorización, reutilización y reciclado de RCD, como lo son, en primer lugar, en España, el REAL DECRETO 105/2008, de 1 de febrero, por el que se regula la producción y gestión de los residuos de construcción y demolición, en sus articulados 8 y 9, regula la valorización de residuos de construcción y demolición y en su articulado 13, regula la utilización de residuos inertes en obras de restauración, acondicionamiento o relleno. (España, Ministerio de la Presidencia, 2008)

En segundo lugar, en la comunidad económica europea, promulga la Directiva 2008/98/CE del Parlamento Europeo y del Consejo de 19 de noviembre de 2008, sobre los residuos, en la que establece en su artículo 10 sobre la valorización de los residuos y en su articulado 11, numeral 2, literal b) sobre la preparación para la reutilización y reciclado de residuos, específicamente en el literal b establece:

antes de 2020, deberá aumentarse hasta un mínimo del 70% de su peso la preparación para la reutilización, el reciclado, y otra valorización de materiales, incluidas las actividades de relleno que utilicen residuos como sucedáneos de otros materiales, de los residuos no peligrosos procedentes de la construcción y de las demoliciones, con exclusión de los materiales presentes de modo natural definidos en la categoría 17 05 04 de la lista de residuos (Parlamento Europeo y El Consejo de la Unión Europea, 2008).

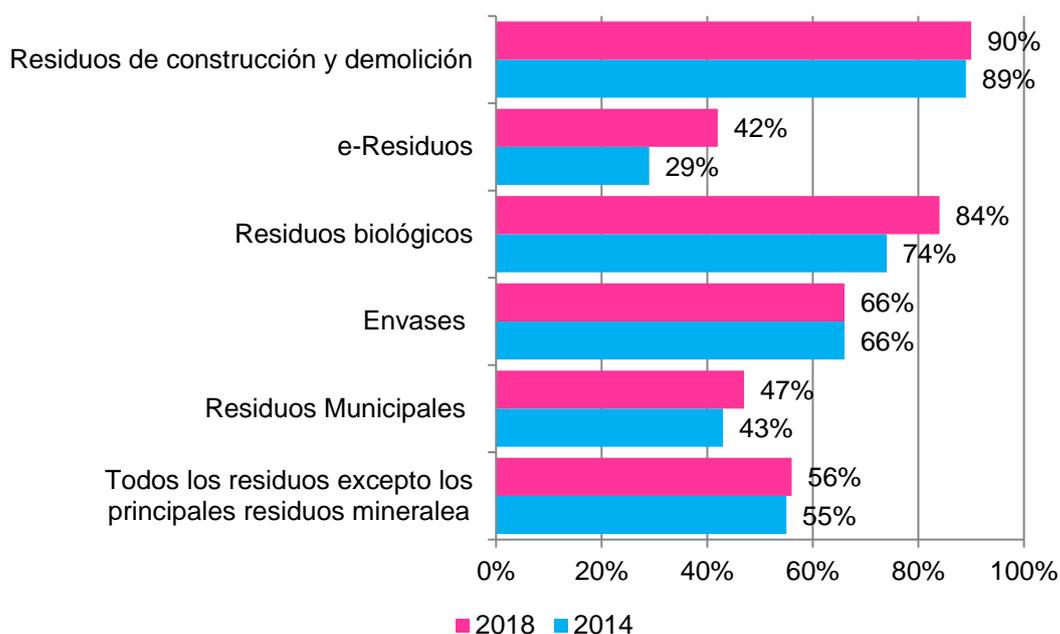
Por ende, una adecuada valorización y gestión de los residuos de construcción y demolición puede incidir positivamente en la reducción de los impactos negativos que acarrear la generación de los RCD, tal como señalan González-Fonteboa (2002) y Pacheco Bustos et al. (2017) la gestión eficaz de los residuos y su uso como materiales secundarios que puedan ser incorporados a la actividad constructiva.

## 1.2.4 Gestión de los residuos de construcción y demolición

Según la Directiva (UE) 2018/851 del Parlamento Europeo y del Consejo, de 30 de mayo de 2018, por la que modifica la Directiva 2008/98/CE sobre los residuos, establece que la gestión de residuos es “la recogida, el transporte, la valorización (incluida la clasificación) y la eliminación de los residuos, incluida la vigilancia de estas operaciones, así como el mantenimiento posterior al cierre de los vertederos, incluidas las actuaciones realizadas en calidad de negociante o agente” (Jefatura de Estado, 2011; Parlamento Europeo y El Consejo de la Unión Europea, 2008, 2018).

Existen diferentes maneras de gestionar los residuos, al respecto, Yuan y Shen (2011) señalan que por medio de las estrategias de: reducción de residuos, reutilización, reciclaje y disposición se logra la minimización de RCD.

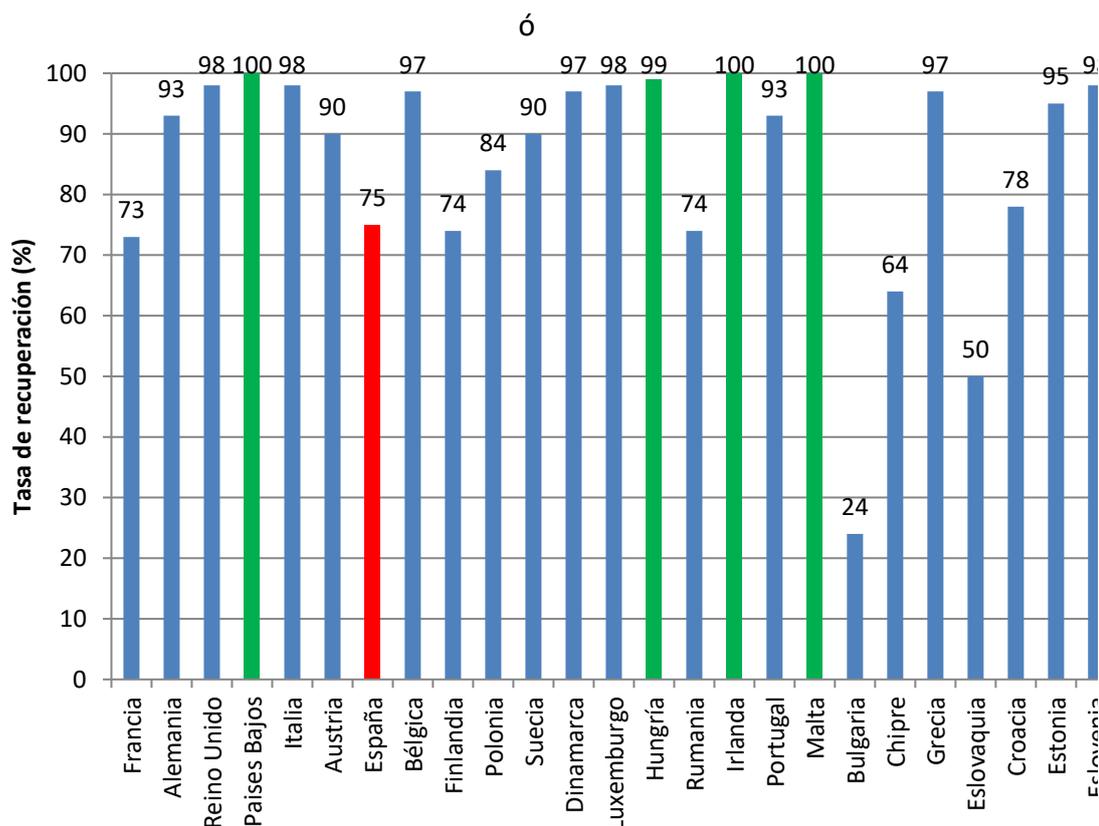
Al respecto, para el 2018 en la Unión Europea, la tasa de reciclaje de residuos alcanzó el 56% del total de residuos tratados –sin considerar los principales residuos minerales-, la cual superó en 1 punto la tasa del 2014 (EUROSTAT, 2022d). En la Figura 16 se muestran las tasas de reciclaje de los diferentes residuos en la Unión Europea para el año 2018 (EUROSTAT, 2022a), donde se puede apreciar que los RCD fueron el flujo de residuos más recuperados, con una tasa del 90% la cual superó en 1 punto la tasa del 2014, seguido de los residuos biológicos cuya tasa de reciclaje es del 84% superando la del 2014 en 10 puntos, de igual manera se destaca el reciclaje de los e-residuos al ver que la tasa del 2018 (42%) superó en 13 puntos a la del 2014, esto refleja que las tasas de reciclaje y/o recuperación de los residuos sigue creciendo, con lo cual se minimiza el impacto ambiental.



**Figura 16.** Tasa de reciclaje de los diferentes residuos en la UE para 2018, (EUROSTAT, 2022a).

En la Figura 17, se puede apreciar como los Estados Miembros presentan diferencias significativas en la tasa de recuperación de los RCD para el 2018. Se observa que estados como Bulgaria, Chipre y Eslovaquia no logran alcanzar por lo menos el umbral del 70% establecido por la UE en la Directiva 2008/98/CE para el 2020 en su artículo 11, numeral 2, literal b, por lo que se hace necesario que mejoren las estrategias de recuperación de los RCD en sus sistemas de gestión de residuos para así lograr por lo menos alcanzar esta tasa exigida por la UE. Mientras que el resto de los países, incluyendo España, para el 2018, ya han sobrepasado el umbral requerido por la UE para el 2020 (EUROSTAT, 2022a; Parlamento Europeo y El Consejo de la Unión Europea, 2008, p. 98).

En el caso particular de España, aun cuando para el 2018 ya sobrepasó el umbral establecido por la UE, al presentar una tasa del 75%, sin embargo, presentó una disminución de 5 puntos con respecto al 2016, esto lleva a la reflexión de que debe revisar sus sistemas de gestión de recuperación de los RCD, para por lo menos mantener esta tasa y lograr incrementarla. En la medida que esto suceda se lograría minimizar el impacto medioambiental que generan los RCD.



**Figura 17.** Tasa de recuperación de los RCD en los Estados Miembros de la UE-28 para 2018, (EUROSTAT, 2022a)

En general estas cifras reflejan la preocupación por los Estados Miembros en el impacto medioambiental que genera los residuos de construcción y demolición.

Particularmente, en la Figura 18 se presenta la evolución de gestión de los RCD en España, para los períodos 2014-2018, donde puede observarse que a partir del 2017 España sobrepasa el umbral del 70% establecido por la UE en la Directiva 2008/98/CE para el 2020 (EUROSTAT, 2022a; Secretaría del Estado de Medio Ambiente, 2022), manteniéndose para estos dos períodos con un comportamiento lineal, lo cual indica que aun cuando está por encima del umbral se debe revisar el sistema de gestión de residuos para lograr superar esta cifra y así buscar la sostenibilidad de la actividad de construcción, minimizando el impacto medioambiental que producen los RCD.

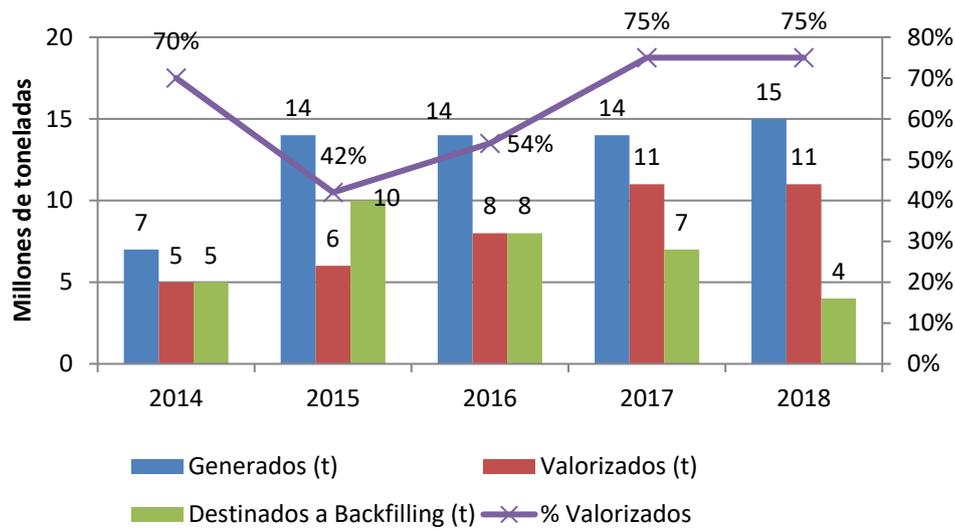


Figura 18. Gestión de los RCD no peligrosos en España para los períodos 2014-2018, (Secretaría del Estado de Medio Ambiente, 2022).

## 1.2.5 Áridos reciclados

El árido reciclado (RA), según la norma UNE-EN 12620:2003+A1:2009, es el “árido resultante del tratamiento del material inorgánico previamente utilizado en construcción” (UNE Normalización Española, 2009), resultando de la molienda y machacado de residuos inorgánicos e inertes procedentes de la construcción y/o demolición.

Según el origen de los residuos pueden distinguirse (RCD, 2018):

- ❖ áridos reciclados procedentes del hormigón: son los provenientes de residuos de hormigón por machaqueo, cribado y procesado, con más de un 90% de hormigón triturado y piedra natural sin mortero.
- ❖ áridos reciclados procedentes de residuos cerámicos (ladrillos, tejas, azulejos cerámicos y porcelánicos).
- ❖ áridos reciclados mixtos: provenientes de RCD con mezclas de materiales de naturaleza cerámica y de hormigón triturado, piedra sin mortero y otros materiales.

Específicamente, en el Código Estructural se establece que la sustitución de áridos gruesos no debe superar el 20% en peso sobre el contenido total de árido grueso. (España, Ministerio de la Presidencia, 2021).

## 1.2.6 Normativa de aplicación para los áridos reciclados

El Ministerio de la Presidencia de España publica dos decretos que establecen regulaciones para los áridos reciclados (España, Ministerio de la Presidencia, 2008, 2021):

- ❖ Real decreto 15/2008, de 1 de febrero por el que regula la producción y gestión de los residuos de construcción y demolición.
- ❖ Código Estructural, aprobado en el Real Decreto 470/2021, de 29 de junio.

Por su parte, la Asociación Española de Normalización publica unas normas UNE relativas a los áridos reciclados (UNE, 2021):

- ❖ UNE-EN 146901:2018. Áridos y designación.
- ❖ UNE-EN 12620:2003+A1:2009. Árido para hormigón.

## 1.3 HORMIGÓN AUTOCOMPACTANTE CON ÁRIDOS RECICLADOS

El hormigón autocompactante con áridos reciclado (HACR) es un hormigón que utiliza áridos parciales o totalmente reciclados como áridos gruesos o finos. Debido a la escasez crítica de áridos naturales y el daño al medioambiente, la disponibilidad de hormigón demolido para su uso como áridos reciclados está aumentando. De acuerdo el Código Estructural en su artículo 30, numeral 30.8.1 recomienda “limitar el contenido de árido grueso reciclado al 20% del peso sobre el contenido total de árido grueso” (España, Ministerio de la Presidencia, 2021). Esta limitación no afecta las propiedades del HAC con RA en comparación a las del hormigón convencional. Sin embargo la norma establece la necesidad de realizar estudios específicos y experimentación

complementaria, para porcentajes superiores, estos estudios deberán ser aprobados por la Dirección Facultativa (España, Ministerio de la Presidencia, 2021).

## 1.3.1 Componentes del hormigón autocompactante con áridos reciclados

El hormigón es una mezcla de cemento, agua, árido fino y árido grueso, conforme a la UNE-EN 206:2013+A2:2021 relativa a las especificaciones, prestaciones producción y conformidad del hormigón (UNE Normalización Española, 2021), donde el cemento actúa como material aglutinante. El hormigón autocompactante tiene los mismos materiales que el hormigón convencional (HC), sin embargo, sus proporciones relativas difieren y deben ser elegidas con precisión.

### 1.3.1.1 Cemento

El cemento como material conglomerante en el hormigón, de acuerdo al Código Estructural su dosificación debe oscilar entre los 250 kg/m<sup>3</sup> y 500 kg/m<sup>3</sup>, este límite, según la norma, podrá superarse previa justificación experimental y autorización expresa de la Dirección Facultativa (España, Ministerio de la Presidencia, 2021). De acuerdo a esta norma para la fabricación del hormigón puede emplearse cementos portland tipo I o tipo II, que sean de clases resistentes 32,5R, 42,5R, 52,5N y 52,5R.

### 1.3.1.2 Áridos

Las características de los áridos deben permitir alcanzar la adecuada resistencia y durabilidad del HAC, así como cualquier otra exigencia que establece el Código Estructural (España, Ministerio de la Presidencia, 2021). Esta misma norma establece que como áridos pueden emplearse áridos gruesos (gravas) y áridos finos (arenas) de acuerdo con la UNE-EN 12620:2003+A1:2009. Se pueden emplear los mismos áridos que se emplean para el hormigón convencional, debido a que no se requiere de ninguna exigencia específica.

Al respecto Nieto Alcolea (2015) señala que la granulometría y la forma de los áridos, específicamente la de los áridos gruesos, tienen una incidencia directa en la capacidad de paso y fluidez de las mezclas del HAC. Mientras más esféricos sean los áridos es menor el roce entre ellos y como consecuencia, habrá mayor fluidez y menos bloqueos. El Código Estructural indica que los tamaños máximo y mínimo de los áridos están establecidos en la norma UNE-EN 12620 (España, Ministerio de la Presidencia, 2021).

### 1.3.1.3 Adiciones

Las adiciones (aditivos minerales) son materiales que aportan finos al HAC. El Código Estructural, establece que las adiciones son “aquellos materiales inorgánicos, puzolánicos o con hidraulicidad latente que, finamente divididos, pueden ser añadidos al hormigón con el fin de mejorar alguna de sus propiedades o conferirle características especiales” (España, Ministerio de la Presidencia, 2021, p. 77). Estos aditivos clasificados por la norma como:

- ❖ Inorgánicos: filler mineral (piedra caliza, dolomía, entre otros) y pigmentos.
- ❖ Puzolánicos: cenizas volantes y humo de sílice
- ❖ Hidraulicidad latente: escorias granuladas molidas de alto horno.

Según lo establecido en el Código Estructural, se debe conseguir una cantidad adecuada de aditivos, cuyas partículas pasan por el tamiz 0,125 mm, que permite alcanzar la autocompactabilidad del hormigón (España, Ministerio de la Presidencia, 2021; Vilanova Fernández, 2009). Estos distintos tipos de aditivos empleados en el HAC tienen como finalidad aportar la adecuada cohesión y aumentar el volumen de la pasta, que permitan mejorar las propiedades en estado fresco y endurecido, así como la trabajabilidad necesaria del hormigón en estado fresco para evitar la segregación de los áridos gruesos y la exudación del agua durante su colocación (Gomes, 2002; Pinedo, 2009).

### 1.3.1.4 Aditivos

Los aditivos son aquellos productos químicos, que, según el Código Estructural, que:

“Incorporados al hormigón antes del amasado (o durante el mismo o en el transcurso de un amasado suplementario) en una proporción no superior al 5% del peso de cemento, producen la modificación deseada, en estado fresco o endurecido, de alguna de sus características, propiedades o de su comportamiento”. (España, Ministerio de la Presidencia, 2021)

El uso de los aditivos permite obtener la autocompactabilidad del HAC, ya que es la única manera de compensar la demanda de agua de las adiciones y del árido fino sin aumentar la relación agua/cemento. Estos aditivos pueden ser: superplastificantes o reductores de agua de alta actividad, moduladores de viscosidad o cohesionantes y otros aditivos químicos tales como: retenedores de agua, inclusores de aire, aceleradores, retardantes, hidrófugos o reductores de retracción (Nieto Alcolea, 2015; A. Romero Esquinas, 2018).

### 1.3.1.5 Agua

En términos generales, según el Código Estructural, pueden emplearse todas las aguas consideradas como aceptables por la práctica, que no contengan ingredientes perjudiciales en cantidades tales que afecten las propiedades del hormigón (España, Ministerio de la Presidencia, 2021).

Debido al uso de aditivos superplastificantes, la relación agua/cemento necesario para la mezcla será menor en el HAC que en el hormigón convencional. Esta debe asegurar, el aporte mínimo de agua que garantice, la hidratación del cemento y la fabricación de la superficie de los áridos para un adecuado comportamiento en estado fresco (Sainz-Aja Guerra, 2019).

## 1.3.2 Propiedades mecánicas

### 1.3.2.1 Resistencia a compresión

De acuerdo con el Código Estructural la resistencia a compresión es una referencia imprescindible (España, Ministerio de la Presidencia, 2021). Además, la resistencia a la compresión suele considerarse un indicador de la calidad del HAC porque está

directamente relacionada con la estructura de la pasta (García Ballester, 2016; Toirac Corral, 2009; Vu et al., 2020).

Para una misma relación agua/cemento (A/C) la resistencia a compresión del hormigón autocompactante es ligeramente mayor a la del hormigón convencional (Nieto Alcolea, 2015; Peláez Carretero, 2014; Vilanova, 2009), esto es debido a la incorporación de superplastificantes así como la falta de vibración da una mayor interfase pasta-árido (Fernández Gómez y Burón Maestro, 2005; Peláez Carretero, 2014).

Por otra parte, al incorporarle al HAC el árido reciclado (AR) para la fabricación del HACR y manteniendo la misma relación agua/cemento, la resistencia a la compresión disminuye con el aumento de los porcentajes de sustitución de RA (Butler et al., 2011; Grdic et al., 2010b; Nieto Alcolea, 2015; Poongodi, Muthi, et al., 2021; Sasanipour y Aslani, 2020a).

### 1.3.2.2 Resistencia a tracción

La resistencia a la tracción tiene una relación directa con la resistencia a compresión, de forma tal que al aumentar la resistencia a compresión también aumentará la resistencia a la tracción. Es por ello que, el HAC debe ser suministrado con una resistencia a compresión especificada (Nieto Alcolea, 2015).

La incorporación de áridos reciclados impacta de forma negativa sobre la resistencia a tracción, a mayor proporción de áridos reciclados se obtiene una disminución de la resistencia a tracción (Chakradhara Rao et al., 2011; García-González, 2016; Kathirvel et al., 2022; Martínez-García, 2021). Sin embargo, diferentes investigadores señalan que el comportamiento de la resistencia a la tracción depende del árido reciclado a emplear (Dawood, 2020; Y. Wang et al., 2019).

### 1.3.2.3 Módulo de elasticidad

El módulo de deformación, es un parámetro mecánico que indica la relación entre la tensión y la deformación longitudinal unitaria, y es empleado para analizar la rigidez del material. Esta propiedad se ve influenciada por el volumen, la naturaleza y tamaño del

árido reciclado así como por el volumen de la pasta y la cantidad de los finos utilizados (Nieto Alcolea, 2015; Romero Esquinas, 2018).

### 1.3.2.4 Durabilidad

La durabilidad dependerá de las condiciones ambientales y de la permeabilidad del HAC, esto limita la entrada de sustancias que conlleva a acciones degradantes del HAC (Comisión Permanente de Hormigón, 2010; Nieto Alcolea, 2015; Peláez Carretero, 2014; Romero Esquinas, 2018). Además, de acuerdo con Peláez Carretero (2014) “la durabilidad del HAC se verá influenciada por la composición del hormigón, por el material seleccionado, así como el grado de supervisión durante la colocación, compactación, acabado y curado” (p.43).

## 1.4 TÉCNICAS DE APRENDIZAJE AUTOMÁTICO PARA PREDECIR LAS PROPIEDADES MECÁNICAS DEL HORMIGÓN AUTOCOMPACTANTE CON ÁRIDOS RECICLADOS

El rápido desarrollo de nuevos tipos de hormigón, estimulado por los requisitos cada vez exigentes en la industria de la construcción, ha motivado una mayor investigación para desarrollar nuevos modelos de predicción que puedan estimar las propiedades del hormigón. La predicción de las propiedades mecánicas del hormigón ha sido una importante tarea de investigación que podría satisfacer mejor los requisitos de diversos códigos y normas de diseño.

Actualmente, en el campo de la ingeniería Civil, los métodos de ML han mejorado la seguridad, la productividad, la calidad y el mantenimiento de la construcción (Ahmad, Farooq, et al., 2021; X. Zhang et al., 2021) y se han utilizado para modelar y predecir las propiedades mecánicas del HACR (Bai et al., 2019; Sharafati et al., 2021; Y. Song et al., 2022) . Es así como, la predicción de estas propiedades mediante el ML ahorra: tiempo de laboratorio, desperdicio de componentes de hormigón, energía, y coste (Bai et al.,

2019; Kaloop et al., 2020; Koya, 2021; K. T. Nguyen et al., 2020; Nguyen-Sy et al., 2020; Y. Song et al., 2022). Además, permite manejar grandes volúmenes de datos y predecir las propiedades de los HACR con alta precisión (Ahmad, Ostrowski, et al., 2021a; Koya, 2021; K. T. Nguyen et al., 2020).

La relación entre las propiedades mecánicas del hormigón y sus parámetros de diseño de la mezcla no puede expresarse a través de una única fórmula matemática, por lo que se necesita modelos de optimización más avanzados para ello. Es aquí donde se destaca la importancia de explorar los beneficios que ofrece el Aprendizaje Automático (Machine Learning) (ML por sus siglas en inglés) al integrarlo a los enfoques de optimización.

El aprendizaje Automático suele ser parte de la inteligencia artificial que se utiliza para analizar grandes volúmenes de datos, predecir comportamientos de las variables y tomar decisiones inteligentes. Es un método de realización de Inteligencia Artificial (IA) que tiene la capacidad de aprender y predecir datos (Huang et al., 2021). Adoptando el aprendizaje automático es posible predecir las propiedades mecánicas del hormigón autocompactante (HAC) con áridos reciclados (RA) que presentan diferentes composiciones. El uso de estas herramientas de predicción permite ahorrar lotes de prueba costosos y que requieren de mucho tiempo, así como el trabajo experimental asociado necesario para lograr la resistencia deseada del hormigón (Chaabene et al., 2020; Yaseen et al., 2018).

El aprendizaje automático puede desarrollarse mediante una variedad de algoritmos que suelen clasificarse en tres tipos de aprendizaje diferentes según su estilo de aprendizaje: supervisado, no supervisado y de refuerzo (Goodfellow et al., 2016; Huang et al., 2021). Particularmente en este trabajo se utilizarán algunas técnicas de aprendizaje supervisado.

El aprendizaje supervisado es adecuado para datos que tienen características y etiquetas. Es decir, se proporcionan datos para predecir las etiquetas. En el diseño de ingeniería, los métodos asistidos por ordenador, como el aprendizaje automático y la estadística de datos, se han utilizado de forma eficaz y proporcionan potentes beneficios (Goharzay et al., 2020), especialmente cuando se trata de materiales con variables

complejas y una gran incertidumbre, como los materiales compuestos (Chaabene et al., 2020). Varios estudios han demostrado que los modelos de aprendizaje automático se han aplicado ampliamente y se han utilizado como herramientas valiosas para la predicción de las propiedades mecánicas del hormigón (A. Ahmad, Ostrowski, et al., 2021; Behnood y Golafshani, 2018; Dantas et al., 2013; de-Prado-Gil, Zaid, et al., 2022; Erdal et al., 2013; Kovačević et al. , 2021; Song et al., 2022).

Particularmente, el aprendizaje supervisado se clasifica en dos tipos: de Regresión y de Clasificación. En este trabajo nos centraremos en las técnicas de Clasificación, entre ellas se encuentran los árboles de decisión, los métodos ensemble y los vecinos más cercanos. Más específicamente, para predecir las propiedades mecánicas: resistencia a compresión y resistencia a tracción del HACR se aplicarán los métodos ensemble: Boosting (Gradiente Boosting, Light Gradient Boosting Machine, Extreme Gradient Boosting, Category Boosting) y bagging (Random Forest, K-Nearest Neighbor, Extremely Randomized Trees).

## 1.4.1 Métodos Ensemble

Los métodos de Ensemble son algoritmos de aprendizaje que construyen un conjunto de clasificadores y luego clasifican nuevos puntos de datos mediante un voto ponderado de sus predicciones (Van Assche y Blockeel, 2007). Combina las predicciones de varios modelos para obtener una predicción que sea más estable y generalice mejor. La idea es promediar los errores individuales de los distintos modelos para reducir el riesgo de sobreajuste y mantener un buen rendimiento de predicción.

En la regresión, la predicción global suele ser la media de las predicciones de los árboles individuales, mientras que, en la clasificación, la predicción global se basa en un voto ponderado con probabilidades promediadas entre todos los árboles, y la clase con la mayor probabilidad es la clase final predicha.

### 1.4.1.1 Métodos Bagging

Bagging es el acrónimo de 'Bootstrap Aggregation'. Los métodos bagging reducen la varianza de un clasificador de árbol de decisión y ayudan a reducir el sobreajuste debido a que cada submuestra aporta diferentes propiedades al predictor (Alpaydin, 2010; Polikar, 2012). En este caso, el objetivo es crear varios subconjuntos de datos a partir de una muestra de entrenamiento elegida al azar con reemplazo. Cada colección de subconjuntos de datos se utiliza para entrenar sus árboles de decisión. Como resultado, se obtiene un conjunto de modelos diferentes. Se utiliza la media de todas las predicciones de los diferentes árboles, lo que resulta más robusto que un único clasificador de árboles de decisión (Alpaydin, 2010; Berthold et al., 2010; Recarey Fernández, 2021).

Entre los métodos Bagging, en este trabajo nos centraremos en los métodos: Random Forest (RF), K-Nearest Neighbor (KNN), Extremely Randomized Trees o Extra-Trees (ETR).

#### 1.4.1.1.1 Random Forest

Random Forest (RF) es un método de conjunto basado en árboles y se desarrolló para solucionar las deficiencias del método tradicional de árbol de clasificación y regresión (CART). Random Forest (RF) tiene como objetivo mejorar la reducción de varianza a través de la construcción de árboles de clasificación menos correlacionados entre ellos (Recarey Fernández, 2021). El RF consiste en un gran número de aprendices de árboles de decisión débiles, que crecen en paralelo para reducir el sesgo y la varianza del modelo al mismo tiempo (Breiman, 2001). Para entrenar Random Forest, se extraen N conjuntos de muestras bootstrap del conjunto de datos original. Cada muestra de bootstrap se utiliza para hacer crecer un árbol de regresión (o clasificación) sin podar. En lugar de utilizar todos los predictores disponibles en este paso, sólo se selecciona un número pequeño y fijo de K predictores muestreados aleatoriamente como candidatos a la división. Estos dos pasos se repiten hasta que crecen C árboles de este tipo, y los nuevos datos se predicen agregando la predicción de los C árboles (M. W. Ahmad, Reynolds, et al., 2018). La RF utiliza el bagging para aumentar la diversidad de los árboles al

cultivarlos a partir de diferentes conjuntos de datos de entrenamiento y, por tanto, reducir la varianza global del modelo (Cutler et al., 2012; Rodríguez-Galiano et al., 2015).

#### 1.4.1.1.2 Extremely Randomized Trees

Extremely Randomized Trees (ETR) (Geurts et al., 2006a) es una técnica de aprendizaje automático que fue desarrollada como una extensión del algoritmo de Random Forest, y es menos probable que sobreajuste un conjunto de datos. Extremely Randomized Trees emplea el mismo principio que Random Forest y utiliza un subconjunto aleatorio de características para entrenar cada estimador base (John et al., 2016). Sin embargo, selecciona aleatoriamente la mejor característica junto con el valor correspondiente para dividir el nodo (John et al., 2016). ETR utiliza todo el conjunto de datos de entrenamiento para entrenar cada árbol de regresión. Por otro lado, RF utiliza una réplica bootstrap para entrenar el modelo (Cutler et al., 2012; John et al., 2016).

#### 1.4.1.1.3 K-Nearest Neighbor

El algoritmo K-Nearest Neighbour (KNN) es un método de aprendizaje automático no paramétrico que utiliza la función de similitud o distancia  $d$  para predecir resultados basados en los  $k$  ejemplos de entrenamiento más cercanos en el espacio de características (Olu-Ajayi et al., 2022; Ortiz-Bejar et al., 2018). KNN forman una clase simple e intuitiva de métodos no paramétricos en el reconocimiento de patrones. El algoritmo KNN es una de las funciones de distancia más comunes que funciona eficazmente en datos numéricos (N. Ali et al., 2019). El concepto principal de KNN depende del cálculo de las distancias entre las muestras de datos probadas y las de entrenamiento para identificar a sus vecinos más cercanos. La muestra analizada se asigna simplemente a la clase de su vecino más cercano (Larose, 2015; Rimanic et al., 2020). En KNN, el valor  $k$  representa el número de vecinos más cercanos. Este valor es el factor decisivo para este clasificador, ya que el valor  $k$  decide cuántos vecinos influyen en la clasificación. Cuando  $k = 1$ , el nuevo objeto de datos se asigna simplemente a la clase de su vecino más cercano. Los vecinos se toman de un conjunto de datos de entrenamiento para los que ya se conoce la clasificación correcta. La distancia euclidiana

es la función de distancia más utilizada con KNN (Cover y Hart, 1967; Larose y Larose, 2014; Olu-Ajayi et al., 2022).

### 1.4.1.2 Métodos Boosting

Los métodos Boosting son una familia de algoritmos que tienen como objetivo crear un clasificador con un error de entrenamiento arbitrariamente pequeño partiendo de un conjunto de clasificadores base (Dietterich, 2000; Recarey Fernández, 2021). Los métodos Boosting utilizados en este trabajo son: Gradient Boosting (GB), Light Gradient Boosting Machine (LGBM), Extreme Gradient Boosting (XGBoost), CatBoost.

#### 1.4.1.2.1 Gradient Boosting

El algoritmo Gradient Boosting (GB) es un método de aprendizaje automático que puede utilizarse tanto para problemas de regresión como de clasificación. Esta técnica algoritmo construye el modelo en etapas como otros sistemas de boosting pero generaliza estos mediante la mejora de una función de pérdida diferenciable arbitraria (Dietterich, 2000; Flores y Keith, 2019; Olu-Ajayi et al., 2022). GB utiliza un conjunto de modelos débiles que colectivamente forman un modelo más fuerte. Este método construye el modelo por etapas mediante el descenso de gradiente en el espacio de funciones pero además los generaliza optimizando una función de pérdida diferenciable arbitraria (Berk, 2006; Flores y Keith, 2019; Friedman, 200a; C.-X. Zhang y Zhang, 2009).

#### 1.4.1.2.2 Light Gradient Boosting Machine

Light Gradient Boosting Machine (LGBM) es un algoritmo de elevación de gradiente rápido, distribuido y de alto rendimiento que se basa en un popular algoritmo de aprendizaje automático: el árbol de decisión (Ke et al., 2017). Puede utilizarse en tareas de clasificación, regresión y muchas otras tareas de aprendizaje automático. LGBM fue desarrollado para conseguir una mayor velocidad de entrenamiento y un menor uso de memoria, manteniendo al mismo tiempo una alta precisión. LGBM hace crecer el árbol por hojas dividiendo el nodo de la hoja mediante un algoritmo basado en el histograma, lo que supone grandes ventajas tanto en eficiencia como en consumo de memoria

(Rathakrishnan et al., 2022). Como el crecimiento del árbol por hojas conlleva una mayor complejidad del modelo, LGBM puede dar lugar a una mayor ganancia de precisión en cada iteración. Sin embargo, también implica un alto riesgo de sobreajuste, que se aborda mediante términos de regularización. También se implementan dos técnicas, a saber, el muestreo unilateral basado en el gradiente (GOSS) y la agrupación exclusiva de características (EFB), para hacer del LGBM un algoritmo EML rápido, eficiente y estable. Durante el proceso de entrenamiento, dado que las muestras de datos con alto gradiente contribuirán más a la ganancia de información, GOSS selecciona las muestras con alto gradiente y descarta las de bajo gradiente. Por otro lado, EFB agrupa características exclusivas en un espacio de características disperso, reduciendo así la dimensionalidad y mejorando la eficiencia.

#### 1.4.1.2.3 Extreme Gradient Boosting

Extreme Gradient Boosting (XGBoost) es un algoritmo avanzado que se ha utilizado recientemente en el proceso de selección de características. Se desarrolló como una extensión y mejora del gradient boosting (Shi et al., 2019; Wan et al., 2021). La estructura principal del algoritmo depende de la construcción eficiente de árboles boosted (Torres-Barrán et al., 2019). En el problema de selección de características, el objetivo principal de XGBoost es construir árboles boosted para lograr la importancia de las características de las variables de entrada que se utilizan para el proceso de entrenamiento (Naganna et al., 2020). Los árboles boost se clasifican en árboles de clasificación y de regresión. La importancia de las características se extrae utilizando tres métodos: ganancia, frecuencia y cobertura (Hastie et al., 2009). El método de ganancia calcula la importancia de las características, la frecuencia calcula el número de árboles en los árboles boosted, y la cobertura calcula el valor relativo de la observación (Falah et al., 2022; Naganna et al., 2020).

#### 1.4.1.2.4 CatBoost

Catboost, propuesto por la empresa Yandex, en 2017, es un novedoso algoritmo de refuerzo de gradiente (Kang et al., 2019; Prokhorenkova et al., 2018), que introduce muchas mejoras para superar el sobreajuste del modelo y hacer frente al paralelismo.

Es eficiente en la predicción de características categóricas (Ibrahim et al., 2020; Prokhorenkova et al., 2018). Catboost es un algoritmo de refuerzo ordenado (Niu et al., 2021), es una implementación de gradient boosting, que utiliza árboles de decisión binarios como predictores base (FeroV y Modrý, 2016; Ibrahim et al., 2020; Prokhorenkova et al., 2018). Así, el diseño puede completarse en menos tiempo. Por lo general, el punto clave es la alta precisión de la predicción; sin embargo, también hay que hacer hincapié en la buena estabilidad y la menor carga de trabajo computacional cuando se emplean modelos de aprendizaje automático/profundo (Kang et al., 2019).

## 1.4.2 Redes Neuronales Artificiales

Las redes neuronales artificiales (a veces llamadas simplemente redes neuronales o modelos conexionistas) (ANN, por sus siglas en inglés) proporcionan un medio para tratar problemas complejos orientados a patrones, tanto de categorización como de series temporales (análisis de tendencias) (Walczak y Cerpa, 2003). La naturaleza no paramétrica de las redes neuronales permite desarrollar modelos sin tener ningún conocimiento previo de la distribución de la población de datos o de los posibles efectos de interacción entre las variables, como exigen los métodos estadísticos paramétricos habitualmente utilizados (Kononenko y Kukar, 2007).

Las ANN se basan en la analogía que existe en el comportamiento y función del cerebro humano y el sistema nervioso. Estas redes emulan una red neuronal biológica, pero utilizan un conjunto reducido de conceptos de los sistemas neuronales biológicos (Walczak y Cerpa, 2003; Zador, 2019). En concreto, los modelos de ANN simulan la actividad eléctrica del cerebro y del sistema nervioso. Las ANN al tratar de emular el comportamiento del cerebro humano, se caracterizan por el aprendizaje a través de la experiencia y de la extracción del conocimiento a partir de los datos.

Las redes neuronales aprenden a partir de ejemplos paralelos de pares de entrada y salida y realizan generalizaciones (Abdon Dantas et al., 2013; Abu Yaman et al., 2017), es decir, identifican la causalidad entre la entrada y la salida a través de un entrenamiento iterativo y lo utilizan para realizar pronósticos (Bingöl et al., 2013). La capacidad de dar respuestas correctas o casi correctas a tareas incompletas y a datos

ruidosos o pobres convierte a las ANN en una potente herramienta para resolver muchos problemas de ingeniería civil (Khademi et al., 2016; Saridemir, 2009). Otras ventajas son el número ilimitado de entradas y salidas (Abdon Dantas et al., 2013; Chou et al., 2011), la rapidez de implementación (Lai y Serra, 1997) y la facilidad de uso. Las desventajas son la sensibilidad al conjunto de datos, el proceso iterativo para determinar la estructura óptima y la dependencia del hardware (Lai y Serra, 1997). Las ANN se utilizan en el diseño de mezclas de hormigón para predecir las proporciones o propiedades óptimas de la mezcla, como la resistencia a la compresión y a la tracción (Azimi-Pour y Eskandari-Naddaf, 2018; Bui et al., 2018b; Gayatri Vineela et al., 2018; Getahun et al., 2018; Onyari y Ikotun, 2018), el módulo de elasticidad (Topçu y Saridemir, 2007), el asentamiento (Chandwani et al., 2015; Cihan, 2020; Öztaş et al., 2006), la contracción por secado (Bal y Buyle-Bodin, 2013).

Particularmente, esta investigación, se centrará en la aplicación de ANN, a través de los algoritmos:

- ❖ Algoritmo de Levenberg-Marquardt (LM).
- ❖ Las redes neuronales artificiales regularizadas bayesianas (BRANN).
- ❖ Gradiente Conjugado Escalado de Retropropagación (SCGB).

### 1.4.2.1 Algoritmo de Levenberg-Marquardt

El algoritmo de Levenberg-Marquardt (LM) se desarrolló a principios de los años 60 para resolver problemas de mínimos cuadrados no lineales. Es un algoritmo de solución iterativo que da respuesta al problema de mínimos cuadrados cuando la función de ajuste no es lineal en sus parámetros (Gavin, 2020). El algoritmo de Levenberg-Marquardt combina dos algoritmos de minimización numérica: el método de descenso del gradiente y el método de Gauss-Newton. En el método de descenso de gradiente, la suma de los errores al cuadrado se reduce actualizando los parámetros en la dirección de ascenso más pronunciado. Mientras que en el método de Gauss-Newton, la suma de cuadrados se reduce asumiendo que la función de mínimos cuadrados es localmente cuadrática en los parámetros, y encontrando el mínimo de esta cuadrática. El algoritmo LM actúa más como un método de ascenso gradiente cuando los parámetros están lejos

de su valor óptimo, y actúa más como el método de Gauss-Newton cuando los parámetros están cerca de su valor óptimo.

### 1.4.2.2 Regularización Bayesiana

Las redes neuronales artificiales regularizadas bayesianas (BRANN) son más robustas (Ceballos et al., 2011; Gouravaraju et al., 2021) que las redes de retropropagación estándar y pueden reducir o eliminar la necesidad de una larga validación cruzada. La regularización bayesiana es un proceso matemático que convierte una regresión no lineal en un problema estadístico "bien planteado" a la manera de una regresión de cresta, incorporando el teorema de Bayes al esquema de regularización (Burden y Winkler, 2008). Estas redes proporcionan soluciones a una serie de problemas que surgen en el modelado QSAR, como la elección del modelo, la robustez del modelo, la elección del conjunto de validación, el tamaño del esfuerzo de validación y la optimización de la arquitectura de la red (Ticknor, 2013; L. Ye et al., 2021). Las BRANN evitan el sobreajuste porque la regularización empuja los pesos innecesarios hacia cero, eliminándolos de forma efectiva. Son difíciles de sobreentrenar, ya que los procedimientos de evidencia proporcionan un criterio bayesiano objetivo para detener el entrenamiento (Ceballos et al., 2011). También son difíciles de sobreentrenar, porque BRANN calcula y entrena sobre un número de parámetros o pesos efectivos de la red, desactivando efectivamente los que no son relevantes (Burden y Winkler, 2008; Sariev y Germano, 2020; Ye et al., 2021). Este número efectivo suele ser considerablemente menor que el número de pesos de una red neuronal de retropropagación estándar totalmente conectada (Burden y Winkler, 2008).

### 1.4.2.3 Gradiente conjugado escalado de retropropagación

En el aprendizaje profundo, la técnica de retropropagación es el mecanismo central para que las redes neuronales aprendan sobre cualquier error en la predicción de datos. La propagación, por otro lado, se refiere a la transmisión de datos en una dirección determinada a través de un canal dedicado.

El algoritmo básico de retropropagación ajusta los pesos en la dirección de descenso más pronunciada, es decir, gradiente negativo más alto. Esta es la dirección en la que la función de rendimiento disminuye más rápidamente. Resulta que, aunque la función disminuye más rápidamente a lo largo del gradiente negativo, esto no produce necesariamente la convergencia más rápida (Baghirli, 2015; Hagan et al., 2002).

En los algoritmos de gradiente conjugado (CG, por sus siglas en inglés) se realiza una búsqueda a lo largo de dicha dirección que produce generalmente una convergencia más rápida que la dirección de descenso más pronunciado, preservando al mismo tiempo la minimización del error conseguida en todos los pasos anteriores (Kişi y Uncuoğlu, 2005). Esta dirección se denomina dirección conjugada. En la mayoría de los algoritmos CG, el tamaño del paso se ajusta en cada iteración. Se realiza una búsqueda a lo largo de la dirección del gradiente conjugado para determinar el tamaño del paso, que minimizará la función de rendimiento a lo largo de esa línea (Baghirli, 2015).

Todos los algoritmos CG comienzan buscando en la dirección de descenso más pronunciado en la primera iteración. Con frecuencia, los algoritmos CG se utilizan con la búsqueda de líneas. Esto significa que el tamaño del paso se aproxima con una técnica de búsqueda lineal, evitando el cálculo de la matriz hessiana para determinar la distancia óptima para moverse a lo largo de la dirección de búsqueda actual. Luego, se determina la siguiente dirección de búsqueda de forma que sea conjugada con la dirección de búsqueda anterior. Este procedimiento denominado Scaled Conjugate Gradient Backpropagation (SCGB) fue desarrollado por Møller (Møller, 1993), se basa en algoritmos CG, sin embargo evita la búsqueda de líneas en cada iteración, a diferencia de otros algoritmos de CG que requieren una búsqueda en cada iteración, utiliza un enfoque Levenberg-Marquardt para escalar el tamaño del paso (MHagan et al., 1996; Møller, 1993) .

### 1.4.3 Métodos de aprendizaje automático en ingeniería

Particularmente, en la ingeniería civil, para el diseño de las estructuras de HACR se necesita predecir el comportamiento de las propiedades mecánicas del HACR, más específicamente la resistencia a compresión y la resistencia a la tracción son propiedades vitales en el diseño de las estructuras de hormigón. Las propiedades mecánicas dependen en gran medida del diseño de la mezcla y de la proporción de los materiales constitutivos (Arun Kumar et al., 2020). La predicción de estas propiedades se vuelve más crucial cuando se toman en cuenta para el análisis coste-beneficio y el tiempo (Ahmad, Farooq, et al., 2021).

Dado que el HACR es un material compuesto, el diseño de la mezcla puede afectar significativamente sus propiedades. Para obtener el diseño de un objetivo, se hace necesario la fabricación de varias mezclas mediante métodos experimentales que requieren de una mano de obra calificada, desperdicio de material, consumo de tiempo y dinero, generación de residuos ( Ahmad, Farooq, et al., 2021; Carrasco, 2020; Naseri et al., 2020). Además, con estos métodos de laboratorio donde se realizan mezclas de pruebas finitas, el diseño de la mezcla óptima parece ser inviable (Naseri et al., 2020) .

El empleo de métodos tradicionales en la dosificación de mezclas de HACR no logra optimizar al máximo la proporción de cada material que compone la mezcla con mayor resistencia (Carrasco, 2020). Normalmente, se han utilizado métodos estadísticos para modelar las propiedades mecánicas del hormigón, como la resistencia a compresión, el módulo de elasticidad, la resistencia a tracción y a flexión, etc. (Abdon Dantas et al., 2013). Sin embargo, con la llegada de las mezclas complejas para cumplir con los exigentes requisitos del creciente desarrollo de la construcción, tales procedimientos estadísticos han demostrado poca precisión para determinar las propiedades mecánicas de los hormigones (Khademi et al., 2016; Nguyen-Sy et al., 2020).

La inclusión de más componentes en las mezclas de HACR ha llevado a relaciones altamente no lineales entre los componentes de la mezcla y las propiedades mecánicas

del HACR. Así, los procedimientos estadísticos tradicionales no han podido captar hasta qué punto estos componentes afectan a las propiedades reológicas y mecánicas del HACR. En consecuencia, es necesario el uso de modelos más robustos que permitan captar los efectos de la composición de la mezcla en las propiedades del hormigón (Kovačević et al., 2022; X. Pan et al., 2022; H. Song et al., 2021; Uysal y Tanyildizi, 2011) y que permitan optimizar al máximo la mezcla que más se ajuste a las características de la estructura a construir. (M.-C. Kang et al., 2021; Naseri et al., 2020)

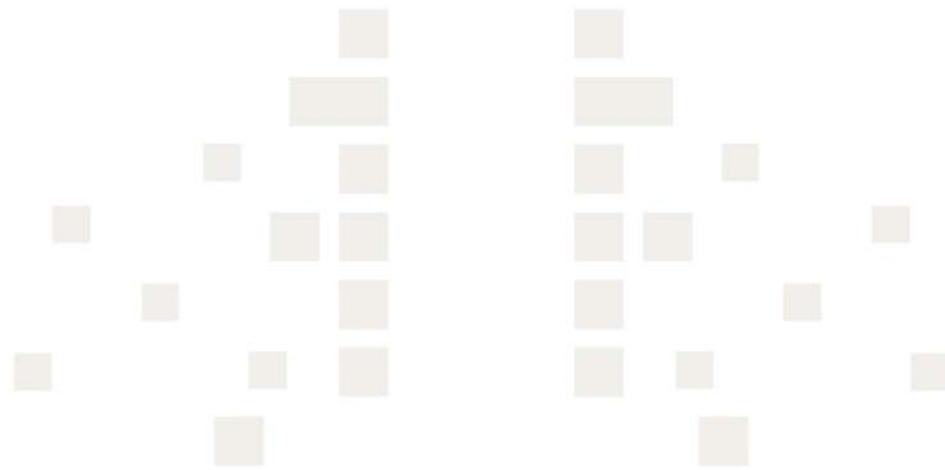
En este sentido, las técnicas de aprendizaje automático (ML) han ganado mucha atención en las últimas décadas, particularmente, en el campo de la ingeniería civil, debido a su notable capacidad de análisis, manejo de gran volumen de datos y procesamiento de datos (Kovačević et al. 2021; Y. Song et al., 2022). El empleo de las técnicas de aprendizaje automático puede proveer soluciones en el establecimiento de modelos para predecir las propiedades mecánicas del hormigón, tales como la resistencia a compresión y la resistencia a tracción por división. El uso de estas técnicas se ha convertido en un área importante de investigación en este campo, tal como lo demuestran investigadores como Ahmad et al. (2021); Awoyera et al. (2020); Chaabene et al. (2020); de-Prado-Gil et al. (2022); Song et al. (2021) y Zalapa (2021) entre otros.

En lo que respecta a trabajar con aprendizaje automático, hay una diversidad de investigaciones que han aplicado los métodos de ensemble (Ahmad, Ostrowski, et al., 2021a; de-Prado-Gil, Palencia, Silva-Monteiro, et al., 2022; D.-C. Feng et al., 2020; Kovačević et al., 2021; Nguyen-Sy et al., 2020; Shang et al., 2022a; Sharafati et al., 2021; Zhang y Zhang, 2009) para predecir la resistencia a compresión. En cuanto a la resistencia a la tracción, diversos investigadores (de-Prado-Gil et al., 2022; Guo et al., 2021; Koya et al., 2021; Lyngdoh et al., 2022; Yan et al., 2013) utilizaron métodos ensemble para modelar y predecir esta propiedad a través de grandes volúmenes de datos tomados de investigaciones previas.

Por otra parte, investigadores como Ahmad et al. (2021); Azizifar y Babajanzadeh (2018); de-Prado-Gil et al. (2022); Farooq et al. (2021); Kovačević et al. (2022); Liu (2009); Nguyen et al. (2020); Silva et al. (2020); Song et al. (2022); Xu et al. (2019) y Xu et al. (2021), realizaron estudios aplicando las redes neuronales artificiales (ANN) para

predecir el comportamiento de la resistencia a la compresión del hormigón. De igual manera, investigaciones como las de Behnood et al. (2015); Bui et al. (2018); de-Prado-Gil et al. (2022); Guo et al. (2021); Nagarajan et al. (2020) y Ray et al. (2021), entre otros aplicaron redes neuronales para predecir la resistencia a tracción por división del hormigón.

Estos trabajos reflejan la necesidad de seguir realizando investigaciones y aplicando el aprendizaje automático con bases de datos y que a su vez estas sean cada vez más numerosas (Zalapa, 2021), donde se emplean registros de datos de experimentos de laboratorio sin la necesidad de realizar pruebas destructivas que consumen tiempo y dinero, además de causar impacto en el medioambiente al generar residuos.





**CAPÍTULO II**  
**Objetivos**

CHAPTER II. Objectives

## 2.1 OBJETIVO GENERAL

La industria de la construcción, para producir el hormigón autocompactante, consume muchos áridos naturales, así como la generación de muchos residuos de construcción y demolición (RCD) que impactan en el medio ambiente, es por ello que respetando las normativas de la UE y el marco regulador español se trata de minimizar el impacto medioambiental con el reciclaje de los RCD a través del uso de los áridos reciclados para producir el HACR.

Se hace necesario diseñar una mezcla óptima de HACR que tenga las propiedades mecánicas que garanticen la resistencia deseada para la infraestructura a construir y su adecuado desempeño en el tiempo. Para el diseño de esta mezcla óptima y la predicción de las propiedades mecánicas, tradicionalmente se emplean métodos experimentales que manejan muestras limitadas, consumen tiempo, generan costes y además importante generación de residuos que causan un gran impacto medio ambiental. Es por ello que, para satisfacer las exigencias de la industria de la construcción, actualmente, se emplean las técnicas de aprendizaje automático (ML) para modelar la mezcla óptima y predecir las propiedades mecánicas del HACR. Estas técnicas permiten reducir la degradación del medio ambiente, así como reducir la relación coste-tiempo.

Esto conduce al interés del investigador de aplicar estas técnicas novedosas para predecir la resistencia a compresión y resistencia a tracción del HACR, por lo tanto el objetivo general de este trabajo es predecir las propiedades mecánicas del hormigón autocompactante con áridos reciclados (HACR) a través de la aplicación de las técnicas de Aprendizaje Automático (ML) y Redes Neuronales Artificiales (ANN) utilizando las mezclas provenientes de artículos de investigación publicados en revistas científicas.

De esta manera se busca contribuir en la minimización del impacto medioambiental que produce la fabricación de las mezclas de HACR para la búsqueda de la mezcla óptima y el comportamiento de sus propiedades mecánicas.

## 2.1.1 Objetivos específicos

Para dar respuesta al objetivo general planteado, la investigación se centra en los siguientes objetivos específicos:

1. Realizar una revisión bibliográfica del estado del arte de los aspectos necesarios para desarrollar la investigación, tales como:
  - ❖ Hormigón autocompactante, origen, normativas, difusión, propiedades y aplicación.
  - ❖ Residuos de construcción y demolición, composición, clasificación, normativa, impacto medioambiental.
  - ❖ Hormigón autocompactante con áridos reciclados, componentes, propiedades, normativas.
  - ❖ Aplicación de las técnicas de aprendizaje automática y redes neuronales en la predicción de la resistencia a compresión y resistencia a tracción por división del HACR.
2. Predecir la resistencia a compresión a 28 días del hormigón autocompactante con áridos reciclados (HACR) a través de la aplicación de modos Ensemble de aprendizaje automático (ML).
3. Comparar cuatro métodos de aprendizaje automático (ML): Extreme Gradient Boosting (XGBoost), Gradient Boosting, CatBoost y Extremely Randomized Trees (ETR) para predecir la resistencia a la tracción a 28 días del hormigón autocompactante con áridos reciclados (HACR).
4. Predecir la resistencia a la tracción a los 28 días del hormigón autocompactante con áridos reciclados (HACR) utilizando la técnica de redes neuronales artificiales, comparando los siguientes algoritmos: Levenberg-Marquardt (LM), Regularización Bayesiana (BR) y Gradiente Conjugado Escalado de Retropropagación (SCGB).
5. Utilizar redes neuronales artificiales (ANN) para validar y pronosticar la resistencia a compresión del hormigón autocompactante con áridos reciclados (HACR), desarrollando y comparando diferentes técnicas, como la de Levenberg-

Marquardt (LM), Regularización Bayesiana (BR) y Gradiente Conjugado Escalado de Retropropagación (SCGB).

La Tabla 3 muestra la relación entre las publicaciones de la presente investigación y los objetivos específicos.

**Tabla 3.** *Relación de objetivos y publicaciones que integran la tesis.*

Objetivos	Artículos
2	To predict the compressive strength of self-compacting concrete with recycled aggregates utilizing ensemble machine learning methods
3	A Comparison of Machine Learning Tools that Model the Splitting Tensile Strength of Self-Compacting Recycled Aggregate Concrete
4	Prediction of Splitting Tensile Strength of Self-Compacting Recycled Aggregate Concrete Using Novel Deep Learning Methods
5	A Study on the Prediction of Compressive Strength of Self-Compacting Recycled Aggregate Concrete Utilizing Novel Computational Approaches

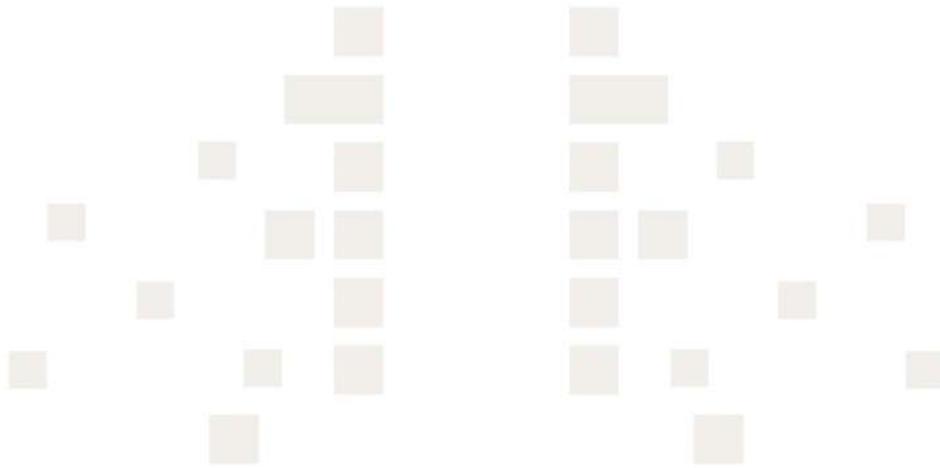
## 2.2 ESTRUCTURA DE LA PRESENTE TESIS DOCTORAL

Esta tesis doctoral se presenta bajo la modalidad de compendio de publicaciones.

Capítulo I, Introducción, donde se ha presentado una revisión bibliográfica acerca de: HAC, su origen y evolución, difusión, componentes, propiedades, los residuos de construcción y demolición (RCD), su clasificación, composición y la problemática a nivel mundial de los RCD, sobre el hormigón autocompactante con áridos reciclados, la normativa de aplicación y por último sobre aprendizaje automático. El Capítulo II, referido a los objetivos a alcanzar en esta tesis y estructura de la misma.

Capítulo III, Publicaciones, en este capítulo se recogen los cuatro artículos publicados en revistas internacionales indexadas en el “Incite Journal Citation Report”. Publicación 1: *To predict the compressive strength of self compacting concrete with recycled aggregate utilizing ensemble machine learning models*, publicado en el 2022, en la revista “Case Studies in Construction Materials”, una revista cuyo factor de impacto es 4.934 (para el año 2021), además se sitúa en el primer cuartil (Q1) de la categoría Ingeniería Civil (posición 27/138) del índice JCR. Publicación 2, *A Comparison of Machine Learning Tools that Model the Splitting Tensile Strength of Self-Compacting Recycled Aggregate Concrete*, se publicó en la revista Materials, en 2022. El factor de impacto de esta revista es 3.748 para el 2021, y se sitúa el pimer cuartil (Q1) de la categoría Metalurgia e Ingeniería Metalúrgica (posición 18/79) del índice JCR. Publicación 3: *Prediction of Splitting Tensile Strength of Self-Compacting Recycled Aggregate Concrete Using Novel Deep Learning Methods*, publicada en Mathematics, 2022. Esta revista tuvo un factor de impacto 2.592 para el 2021 y está ubicada en el primer cuartil (Q1), primer decil, de la categoría Matemáticas Generales (posición 21/332). Publicación 4: *A Study on the Prediction of Compressive Strength of Self-Compacting Recycled Aggregate Concrete Utilizing Computational Approaches*, publicada Materials, 2022. El factor de impacto de esta revista es 3.748 para el 2021, y se sitúa el pimer cuartil (Q1) de la categoría Metalurgia e Ingeniería Metalúrgica (posición 18/79) del índice JCR.

Capítulo IV, Resumen, se presenta el resumen de la presente tesis. El Capítulo V, Conclusiones, se presentan las conclusiones más relevantes obtenidos en esta investigación, así como las futuras líneas de investigación motivadas por la presente tesis. Y, por último, el Capítulo VI, Referencias, donde se plasman todas las referencias que sustentan esta tesis.





# **CAPÍTULO III** **Publicaciones**

CHAPTER III. Publications

## 3.1 PUBLICACIÓN 1

*To predict the compressive strength of self-compacting concrete with recycled aggregate utilizing ensemble machine learning models*

Jesús de-Prado-Gil, Covadonga Palencia, Neemías Silva-Monteiro, Rebeca Martínez-García

Case Studies in Construction Materials 2022, 16, e01046  
DOI: 10.1016/j.cscm.2022.e01046

Current Impact Factor: 4.934 (Year 2021)  
JCR category rank: 27/138 (Q1) 'Engineering Civil'

Este estudio tiene como objetivo aplicar métodos de aprendizaje automático para predecir la resistencia a compresión del hormigón autocompactante con áridos reciclados. Para ello, se aplicaron los métodos ensemble: Random Forest (RF), K-Nearest Neighbor (KNN), Extremely Randomized Trees (ERT), Gradiente Boosting (GB), Light Gradient Boosting Machine (LGBM), Extreme Gradient Boosting (XGBoost), Category Boosting (CB) y los modelos aditivos generalizados: Inverse Gauss (GAM1) y Poisson (GAM2). Para el desarrollo de los modelos se recopilaron 515 muestras de artículos de investigación, que fueron divididas en tres subconjuntos: entrenamiento (360), validación (77) y prueba (78). Las variables de entrada son: cemento, agua, componente mineral, áridos finos, áridos gruesos y componente química (superplastificantes) y la resistencia a compresión como variable de salida. Para evaluar la capacidad de los modelos para predecir la resistencia a la compresión se emplearon las métricas:  $R^2$ , RMSE, MAE y MAPE. Los resultados indican los modelos RF ( $R^2 = 0.7128$ , RMSE = 0.0807, MAE = 0.06) y GB ( $R^2 = 0.6948$ , RMSE = 0.0832, MAE = 0.0569) presentan el mayor rendimiento para predecir la resistencia a compresión del HAC con áridos reciclados. Siendo RF el modelo más robusto. El análisis de sensibilidad del modelo RF indica que el cemento y el agua son las variables que presentan mayor incidencia en la predicción de la resistencia a compresión, así como el árido grueso es la de menor incidencia.

Predicción de resistencia a compresión y a tracción de hormigones autocompactantes con áridos reciclados utilizando métodos de Machine Learning y algoritmos de redes neuronales

## 3.2 PUBLICACIÓN 2

### *A Comparison of Machine Learning Tools that Model the Splitting Tensile Strength of Self-Compacting Recycled Aggregate Concrete*

Jesús de-Prado-Gil, Covadonga Palencia, P. Jagadesh and Rebeca Martínez-García

Materials 2022, 15, 4164

DOI: 10.3390/ma15124164

Current Impact Factor: 3.748 (Year 2021)

JCR category rank: 18/79 (Q1) in 'Metallurgy and Metallurgical Engineering'

Actualmente diversas investigaciones emplean técnicas de Machine Learning para predecir las propiedades mecánicas del Hormigón. Este estudio compara cuatro métodos de ML: eXtreme Gradient Boosting (XGBoost), Gradient Boosting (GB), Cat Boosting (CB) y Extra Trees Regressor (ETR) para predecir la resistencia a tracción por división a los 28 días del HAC con RA. Se utilizó una base de datos de 381 muestras de la literatura publicada en revistas científicas. Las mismas se dividieron aleatoriamente en 3 conjuntos: entrenamiento (70%), validación (15%) y prueba (15%), cada uno con 267, 57 y 57 muestras respectivamente. Para evaluar los modelos se emplearon las métricas  $R^2$ , RMSE y MAE. Para el conjunto de datos de entrenamiento los resultados mostraron que los cuatro modelos son capaces de predecir la resistencia a la tracción del HAC con RA, esto debido a que los valores de  $R^2$  para cada modelo fueron superiores a 0.75. XGBoost es el modelo que presenta el mejor rendimiento, mostrando el valor de  $R^2 = 0.8423$  más alto, así como los valores más bajos de RMSE = 0.0581 y MAE = 0.0443, en comparación con los modelos GB, CB y ETR. Por tanto, XGBoost se considera el mejor modelo para predecir la resistencia a la tracción a los 28 días del HAC con RA. El análisis de sensibilidad revela que la variable que más contribuye a la predicción de la resistencia a tracción por división de este material después de 28 días fue el cemento.

### 3.3 PUBLICACIÓN 3

*Prediction of Splitting Tensile Strength of Self-Compacting Recycled Aggregate Concrete Using Novel Deep Learning Methods*

Jesús de-Prado-Gil, Osama Zaid, Covadonga Palencia and Rebeca Martínez-García

Mathematics 2022, 10, 2245

DOI: 10.3390/math10132245

Current Impact Factor: 2.592 (Year 2021)

JCR category rank: 21/332 (Q1) in "General Mathematics"

El hormigón autocompactante (HAC) contiene un 60-70% de áridos gruesos y finos, que se sustituyen por residuos de la construcción, como los áridos reciclados (RA). En la actualidad, muchos investigadores están estudiando la predicción de las propiedades del hormigón mediante técnicas de soft computing, que acabarán reduciendo la degradación del medio ambiente y otros residuos de materiales. El objetivo de este trabajo es predecir la resistencia a la tracción a los 28 días del HAC con RA utilizando la técnica de redes neuronales artificiales, comparando los algoritmos: Levenberg-Marquardt (LM), regularización bayesiana (BR) y gradiente conjugado escalado de retropropagación (SCGB). Se recogieron un total de 381 muestras de varias revistas publicadas. Las variables de entrada fueron el cemento, el aditivo, el agua, los áridos finos y gruesos y el superplastificante; los datos se dividieron aleatoriamente en tres conjuntos -entrenamiento (60%), validación (10%) y prueba (30%)- con 10 neuronas en la capa oculta. Los modelos se evaluaron a través del MSE y R. Los resultados indicaron que los tres modelos tienen una precisión óptima; aun así, BR dio el mejor rendimiento ( $R = 0,91$  y  $MSE = 0,2087$ ) en comparación con LM y SCGB, por lo tanto, BR es el mejor modelo para predecir la TS. El análisis de sensibilidad indicó que el cemento (30,07%) fue la variable que más contribuyó a la predicción de la TS a 28 días para el HAC con RA, y el agua (2,39%) fue la que menos contribuyó.

## 3.4 PUBLICACIÓN 4

### *A Study on the Prediction of Compressive Strength of Self-Compacting Recycled Aggregate Concrete Utilizing Novel Computational Approaches*

Jesús de-Prado-Gil, Covadonga Palencia, P. Jagadesh and Rebeca Martínez-García

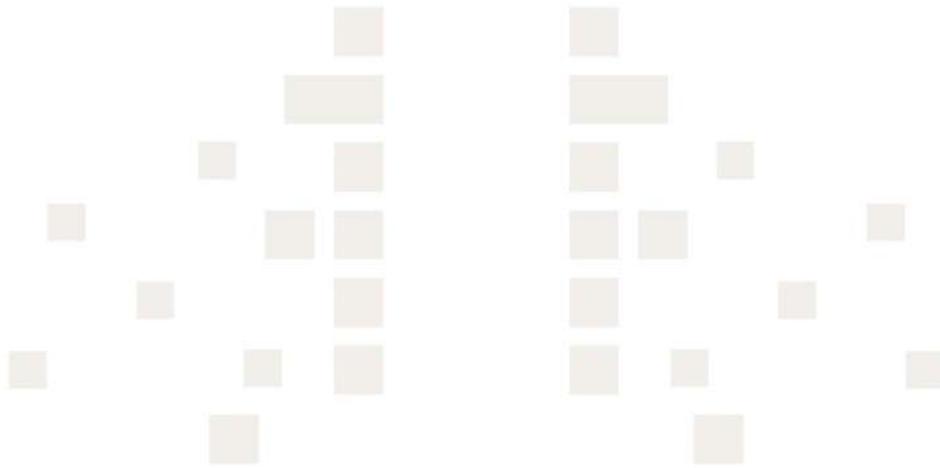
Materials 2022, 15, 4164

DOI:10.3390/ma15124164

Current Impact Factor: 3.748 (Year 2021)

JCR category rank: 18/79 (Q1) in 'Metallurgy and Metallurgical Engineering'

Cada año se produce una cantidad considerable de materiales de construcción desechados en todo el mundo, lo que provoca la degradación del ecosistema. El hormigón autocompactante (HAC) tiene un 60-70% de áridos gruesos y finos en su composición, por lo que la sustitución de estos áridos por otro de desecho, como el árido reciclado (RA), reduce el coste del HAC. Este estudio compara novedosas técnicas de algoritmos de redes neuronales artificiales Levenberg Marquardt (LM), regularización bayesiana (BR) y gradiente conjugado escalado de retropropagación (SCGB) para estimar la resistencia a la compresión a 28 días ( $f'_c$ ) del HAC con RA. Se recogieron un total de 515 muestras de varios artículos publicados, divididas aleatoriamente en entrenamiento (70%), validación (10%) y prueba (20%). Los estadísticos, el coeficiente de correlación (R) y el error medio cuadrático (MSE) se emplearon para evaluar los modelos; cuanto mayor sea el R y menor el MSE, más preciso será el algoritmo. El mejor resultado lo obtiene BR ( $R = 0,91$  y  $MSE = 43,755$ ), mientras que la precisión de LM es casi la misma ( $R = 0,90$  y  $MSE = 48,14$ ). LM procesa la red en un tiempo mucho menor que BR. Como resultado, LM y BR son los mejores modelos en la predicción de la  $f'_c$  de 28 días de HAC con RA. El análisis de sensibilidad mostró que el cemento (28,39%) y el agua (23,47%) son las variables más críticas para predecir la  $f'_c$  a 28 días del HAC con RA, mientras que el árido grueso es la que menos contribuye (9,23%).





**CAPÍTULO IV**  
**Resumen**

CHAPTER IV. Abstract

## 4.1 PREDICCIÓN DE LA RESISTENCIA A LA COMPRESIÓN DEL HORMIGÓN AUTOCOMPACTANTE CON ÁRIDOS RECICLADOS UTILIZANDO MODELOS DE APRENDIZAJE AUTOMÁTICO

A nivel mundial, el rápido desarrollo de la industria de la construcción a lo largo de los años ha conducido a un consumo excesivo de recursos naturales, la acumulación de una gran cantidad de residuos de construcción y demolición (RCD) y desechar los áridos reciclados (RA) en los vertederos puede ocasionar daños ambientales (B K A et al., 2021; K. Liu et al., 2021a; Señas et al., 2016a; Xie et al., 2018). Particularmente en las últimas décadas, en la Unión Europea, la industria de la construcción ha tenido un crecimiento exponencial, y como consecuencia de este crecimiento, la producción de RCD ha ido aumentando (Martínez-García, 2021b; Martínez-García et al., 2020). Con este gran desarrollo de la industria de la construcción, la tasa de demolición aumenta día a día, lo que hace necesario reutilizar eficazmente los RCD (Jagadesh et al., 2021; Padmini et al., 2009). En general, la composición de estos residuos contiene hormigón, mampostería, madera, asfalto metálico, materiales cerámicos, entre otros (B K A et al., 2021; Jagadesh et al., 2021).

Este desarrollo de la industria de la construcción hace que el hormigón sea uno de los productos más utilizados en todo el mundo (Azizifar y Babajanzadeh, 2018; B K A et al., 2021; Farooq et al., 2021a), debido a sus diversas ventajas sobre otros materiales, por ejemplo, integridad, durabilidad, modularidad, economía (D.-C. Feng et al., 2020a). El hormigón se compone principalmente de áridos finos (arena) y áridos gruesos (piedra), estos áridos representan aproximadamente el 75% del total de hormigón (B K A et al., 2021; Sims et al., 2019).

Dado que el hormigón es el material de construcción más utilizado a nivel mundial y con la intención de aprovechar estos residuos de construcción para minimizar el impacto

medioambiental, la industria de la construcción ha desarrollado técnicas avanzadas para el diseño del hormigón (A. Ahmad, Ostrowski, et al., 2021a; Azizifar y Babajanzadeh, 2018; Jagadesh et al., 2021) logrando así diferentes tipos de hormigón con diferentes aditivos minerales. Recientemente, la industria de la construcción está aplicando ampliamente una variedad de hormigones especiales, incluyendo el hormigón autocompactante (HAC) y el hormigón de altas prestaciones (HPC) (Azizifar y Babajanzadeh, 2018). La introducción del HAC brinda un potencial aceptable y atrae el interés por explotar materiales sustitutos, residuos, subproductos y materiales secundarios como los aditivos minerales.

El hormigón autocompactante es un hormigón fluido que se caracteriza por una mayor capacidad de flujo, una buena resistencia a la segregación y un asentamiento bajo su propio peso. Por ello, este tipo de hormigón permite rellenar el encofrado sin necesidad de vibración mecánica, por lo que puede utilizarse fácilmente en encofrados complicados, elementos estructurales reforzados y zonas de difícil acceso. Así, evita el sangrado y la segregación y mantiene la estabilidad al mismo tiempo (Alyamaç y Ince, 2009; Dinakar et al., 2013). En este sentido, se utiliza en la construcción de obras civiles en todo el mundo, aprovechando su capacidad de compactación por la acción de la gravedad (Alyamaç y Ince, 2009; Nair y Jayaraj, 2020; Nalanth et al., 2014; Señas et al., 2016a).

La calidad del HAC se establece generalmente en función de su resistencia a la compresión, la cual da una referencia general de la calidad del hormigón, ya que está directamente relacionada con la estructura de la mezcla endurecida (García Ballester, 2016). Generalmente, la forma de obtener la resistencia a la compresión del HAC es por medio de experimentos físicos, los cuales son costosos y consumen mucho tiempo para obtener resultados, por lo que la eficiencia de trabajo será muy baja (D.-C. Feng et al., 2020a). Por ello, los avances tecnológicos permiten resolver problemas de ingeniería a un menor coste mediante otros métodos, como la regresión empírica, la simulación numérica y el uso de métodos de aprendizaje automático (D.-C. Feng et al., 2020a; P. F. S. Silva et al., 2020). Estos métodos permiten predecir la resistencia a la compresión del

HAC con la proporción de la mezcla diseñada de diferentes componentes (cemento, aditivo, agua, áridos gruesos, áridos finos y superplastificantes).

En este sentido, hay una tendencia a utilizar la inteligencia artificial a través de técnicas de aprendizaje automático (ML) para predecir la resistencia a la compresión del HAC (W. Ahmad, Ahmad, et al., 2021; B K A et al., 2021; Farooq et al., 2021a; Xie et al., 2020; J. J. Xu et al., 2021), estas técnicas pueden ser utilizadas para diversos fines, tales como la regresión, la clasificación, la correlación, la agrupación. Por lo tanto, con el desarrollo de las técnicas de ML, se hace más fácil predecir la resistencia a la compresión del HAC (P. F. S. Silva et al., 2020), así como otras propiedades mecánicas del hormigón (J. Xu, Zhao, et al., 2019). En este sentido, para evaluar las propiedades mecánicas del hormigón con áridos reciclados Xu et al. (2019) utilizaron la regresión no lineal múltiple y las redes neuronales; Xu et al. (2021) emplearon un método de calibración probabilística basado en la teoría bayesiana y el método Monte Carlo basado en cadena de Markov (MCMC), así como Xu et al. (2019) desarrollaron tres tipos diferentes de modelos: el modelo de regresión multivariante (MNR) y las dos redes neuronales (es decir, BP-ANN y GA-ANN) para predecir el comportamiento del HAC bajo carga triaxial.

Específicamente, la predicción de la resistencia a la compresión del hormigón autocompactante es una aplicación de la función de regresión ML, mediante la aplicación de ciertos métodos que pueden aprender de los datos de entrada y proporcionar resultados muy precisos. En la actualidad, se emplean diversos métodos de ML para predecir la resistencia a la compresión del hormigón autocompactante, entre los que se encuentran los métodos de ensemble (W. Ahmad, Ahmad, et al., 2021; DeRousseau et al., 2019b), las redes neuronales artificiales (J. Xu, Chen, et al., 2019; J. Xu, Zhao, et al., 2019), los modelos de regresión (Azizifar y Babajanzadeh, 2018; DeRousseau et al., 2019b; J. Xu, Chen, et al., 2019) y los modelos aditivos generalizados (GAM) (DeRousseau et al., 2019b; Mendes et al., 2017).

Por lo tanto, el objetivo de investigación de este apartado es aplicar métodos de aprendizaje automático para predecir la resistencia a la compresión del hormigón autocompactante con áridos reciclados.

## 4.1.1 Hormigón autocompactante con áridos reciclados

El hormigón autocompactante es definido como un tipo de hormigón especial capaz de compactarse por la acción de su propio peso, que puede asentarse en las secciones muy reforzadas y profundas, llenando los encofrados y discurre entre estructuras de difícil acceso o moldes complejos, sin necesidad de vibrado ni de cualquier otro método de compactación (Bermejo Núñez, 2009; Burón Maestro et al., 2006; Comisión Permanente de Hormigón, 2010). Este tipo de hormigón, desarrollado en Japón en los años 80 con los avances en las tecnologías del hormigón, una vez endurecido es denso, homogéneo y tiene las mismas propiedades de ingeniería y durabilidad que el hormigón de vibrado tradicional (Bermejo Núñez, 2009; Kushwaha et al., 2013; Nair y Jayaraj, 2020; Neto et al., 2010), esto debido a una dosificación estudiada y del empleo de aditivos superplastificantes específicos (Bermejo Núñez, 2009; Burón Maestro et al., 2006; Comisión Permanente de Hormigón, 2010). Presenta la característica de ser homogéneo así como mantener su cohesión, durante su puesta en obra, sin presentar segregación o sangrado, bloqueo de áridos gruesos, ni exudación de la lechada (Alyamaç y Ince, 2009; Comisión Permanente de Hormigón, 2010; Kovačević et al., 2021; Nair y Jayaraj, 2020).

Para la elaboración de la mezcla del HAC, se emplean los mismos componentes que los que se usan para el hormigón convencional: cemento, áridos finos, áridos gruesos, conglomerante y agua (Brouwers y Radix, 2005; Comisión Permanente de Hormigón, 2010; Gołaszewski y Cygan, 2017; Martínez-García, 2021; Singh et al., 2018), en proporciones correctas que permitan obtener una mezcla homogénea. Además de estos materiales, en la elaboración del HAC se incluyen aditivos como los superplastificantes y aditivos modulares de viscosidad (aditivos químicos), en diferentes proporciones, que ayudan a reducir la segregación y exudación durante el vaciado en obra así como la sensibilidad a la variación de otros elementos de la mezcla (Bermejo Núñez, 2009; Gołaszewski y Cygan, 2017; Martínez-García, 2021).

El rápido desarrollo de la industria de la construcción ha generado una gran demanda de hormigón, trayendo como consecuencia un uso desmedido de los recursos naturales,

como es el caso de los áridos naturales, material empleado en la elaboración del hormigón, así como el aumento de los residuos de construcción y demolición. Por tal razón, la industria de la construcción se ha visto en la necesidad de explotar menos los recursos naturales, disminuir el impacto ambiental y aprovechar los residuos de construcción y demolición, esto se ha logrado gracias al uso de los áridos reciclados provenientes de los residuos del hormigón (Katar et al., 2021; Liu et al., 2021; Nair y Jayaraj, 2020; Nieto Alcolea, 2015; Señas et al., 201a).

El reciclaje de los RCD para la preparación de áridos reciclados, para sustituir a los áridos naturales, permite la elaboración del HAC con áridos reciclados (Burón Maestro et al., 2006; Carro-López et al., 2018; Martínez-García, 2021; Pérez-Benedicto et al., 2012), el cual ha sido reconocido como una manera para reducir los residuos de construcción y conservar el medio ambiente, además de una disminución en el coste de las obras de construcción (Katar et al., 2021; Nair y Jayaraj, 2020).

Las propiedades mecánicas del HAC con áridos reciclados, tales como la resistencia a la compresión, resistencia a la tracción, elasticidad, resistencia a la flexión, apenas se ven afectadas con respecto a las del hormigón convencional (Carro-López et al., 2018; Martínez-García, 2021; Pérez-Benedicto et al., 2012). Martínez-García (2021) señala que una sustitución del 20% de áridos reciclados tiene poca incidencia en las propiedades y características del hormigón con áridos reciclados en comparación con las del hormigón convencional. EHE-8 (Comisión Permanente de Hormigón, 2010) recomienda la proporción de peso del 20% de áridos reciclados como el límite máximo de peso permitido del uso de áridos reciclados en la mezcla de hormigón.

## 4.1.2 Resistencia a la compresión

La resistencia a la compresión es una de las características mecánicas principales que presenta el hormigón. La resistencia a la compresión se calcula mediante la carga de rotura dividida por el área de la sección transversal que resiste la carga y se expresa en megapascales (MPa) (Bradú et al., 2016). Es considerado un valor convencional establecido a través de un ensayo normalizado y referido a la tensión para la que se alcanza el agotamiento. La resistencia a la compresión del hormigón está sujeta a la

proporción de áridos reciclados incorporados en la mezcla (García Ballester, 2016; Nieto Alcolea, 2015; Robas, 2009) por lo que su dosificación adecuada influye de forma significativa en la resistencia a la compresión.

### 4.1.3 Aprendizaje automático

El aprendizaje automático (ML) es uno de los enfoques principales de la inteligencia artificial (IA). El aprendizaje automático se utiliza actualmente en varios campos de investigación. Se caracteriza por la capacidad de mejorar el comportamiento, denominada aprendizaje, a partir de experiencias anteriores. Esta mejora consiste en establecer reglas lógicas que lleven a un determinado sistema a tomar decisiones más asertivas para un contexto determinado. El aprendizaje automático se ocupa de los sistemas que se entrenan a partir de los datos en lugar de ser programados explícitamente, utiliza algoritmos para aprender de los patrones de datos (Rouhiainen, 2008; Song et al., 2021; Zhang y Ma, 2012). Los métodos de aprendizaje automático permiten el análisis de grandes cantidades de datos, siendo extremadamente eficientes en términos de tiempo de cálculo y procesamiento (K. Liu et al., 2021a; Nafees et al., 2021a), proporcionando resultados más rápidos y precisos, reduciendo así las tasas de error a niveles insignificantes. Los métodos de aprendizaje automático pueden dividirse en 3 categorías: aprendizaje supervisado; aprendizaje no supervisado (Algoritmos clustering, Análisis de componentes principales, entre otros) y aprendizaje por refuerzo (Rouhiainen, 2008; Yang y Cao, 2018). Los métodos de aprendizaje supervisado están expuestos a grandes cantidades de datos etiquetados, incluyendo las variables de entrada y de salida. El algoritmo encuentra patrones entre los datos, aprende de las observaciones y genera predicciones hasta que el error se haya minimizado lo suficiente. El aprendizaje supervisado se divide en dos tipos: Clasificación y regresión (Murphy, 2012). La Clasificación utiliza algoritmos para reconocer patrones específicos dentro del conjunto de datos para definir las predicciones. Entre los algoritmos de clasificación más comunes se encuentran: métodos de ensemble, Árboles de decisión, los vecinos más cercanos. La Regresión se emplea para entender la relación entre las variables dependientes e independientes, suele emplearse para hacer proyecciones. Entre los

algoritmos de regresión se encuentra: modelos lineales generalizados (GLM), modelos aditivos generalizados (GAM), regresión logística, entre otros. Los Métodos de aprendizaje no supervisados emplean conjuntos de datos que no están clasificados con la finalidad de encontrar patrones en fragmentos de datos reconociendo similitudes y agrupando los datos por categorías (Murphy, 2012).

Los Métodos de refuerzo son un aprendizaje de ensayo y error. El sistema interactúa con su entorno produciendo acciones que descubren errores, los algoritmos determinan automáticamente el comportamiento ideal dentro de un contexto específico buscando maximizar su rendimiento (Murphy, 2012). Particularmente en este artículo, para predecir la resistencia a la compresión del hormigón autocompactante con áridos reciclados, se utilizan métodos de aprendizaje supervisados, específicamente nueve métodos ensemble: Random Forest (RF), K-Nearest Neighbor (KNN), Extremely Randomized Trees (ERT), Gradiente Boosting (GB), Light Gradient Boosting Machine (LGBM), Extreme Gradient Boosting (XGB), Category Boosting (CB) y los modelos aditivos generalizados: Inverse Gauss (GAM1) y Poisson (GAM2)

### 4.1.3.1 Métodos ensemble

Los métodos de ensemble son algoritmos de aprendizaje que combinan múltiples modelos de aprendizaje automático diferencial para mejorar el rendimiento de la predicción (Al Daoud, 2019; Li et al., 2018; Liu et al., 2017). El resultado es un modelo final que rinde más que los modelos individuales. Entre los métodos de ensemble se encuentran: Boosting y Bagging.

Bagging (bootstrap aggregating), busca mejorar la clasificación combinando los resultados de predicción de los modelos entrenados independientemente en conjuntos de entrenamiento generados aleatoriamente. En los métodos Bagging, la idea es construir varios estimadores independientes y calcular la media de las predicciones. Esto da como resultado un estimador con una varianza mínima en comparación con los estimadores independientes. Entre los métodos Bagging propuestos se encuentran: K-Neighbor Regressor (KNN), Random Forest (RF) y Extratrees Regressor (ETR) (DeRousseau et al., 2019b; Jabeur et al., 2021; Marani y Nehdi, 2020; Olu-Ajayi et al.,

2022a; Silva et al., 2020; Yang y Cao, 2018). K-Neighbor Regressor (KNN) busca encontrar un grupo de muestras de entrenamiento cercanas a un nuevo punto de consulta y predecir su valor (Altman, 1992). Random Forest (RF) es un método que tiene en cuenta varios árboles de decisión aleatorios y los ajusta basándose en varias submuestras de los datos de entrenamiento, utilizando el promedio de los árboles de decisión para predecir mejor y controlar el sobreajuste (Breiman, 2001). Extretrees Regressor (ETR) es similar a la RF, diferenciándose únicamente en la forma en que se realizan las divisiones aleatorias en los árboles (Geurts et al., 2006).

Boosting es un meta-algoritmo ensemble que combina un conjunto de clasificadores débiles para crear un clasificador fuerte. Construye un ensemble de forma incremental mediante el entrenamiento iterativo de un nuevo modelo para enfatizar las muestras de entrenamiento mal clasificadas de los modelos anteriores. Los estimadores se construyen secuencialmente mientras se busca reducir el sesgo del estimador final combinado. Entre los métodos empleados se encuentran: Gradiente Boosting (GB), Light Gradient Boosting Machine (LGBM), Extreme Gradient Boosting (XGB) y Category Boosting (CB) (Al Daoud, 2019; Jabeur et al., 2021; Marani y Nehdi, 2020). GB construye progresivamente un modelo utilizando la optimización de funciones de pérdida diferenciables (Friedman, 2001). En cada paso, se ajusta un árbol de regresión siguiendo el gradiente negativo de la función de pérdida. LGBM es una variación de GB que utiliza árboles basados en algoritmos de aprendizaje. Como resultado, el LGBM tiene un valor de velocidad en la etapa de entrenamiento, garantizando una mayor eficiencia (Ke et al., 2017). XGB es una variación de GB y tiene un algoritmo de optimización para dividir los árboles integrado con un componente de regularización (para evitar el sobreajuste) (Chen y Guestrin, 2016). CB es también una variación del GB, que: utiliza árboles simétricos para proporcionar una ejecución más rápida, permite el uso de procesamiento paralelo, y utiliza boosting ordenado para evitar el sobreajuste (Prokhorenkova et al., 2018).

### 4.1.3.2 Modelos aditivos generalizados

Los modelos aditivos generalizados (GAM) son una extensión de los modelos lineales generalizados. El GAM es un modelo lineal generalizado, en el que la variable de salida viene dada por una combinación lineal de funciones suaves desconocidas de algunas variables predictoras. Los modelos GAM no restringen la relación entre la variable respuesta y la explicativa a la forma lineal, permite que esta relación tenga forma desconocida, empleando distribuciones de la Familia Exponencial para la variable respuesta. En este artículo se utilizan las distribuciones exponenciales Gaussiana Inversa (GAM1) y Poisson (GAM2) para construir el modelo GAM (Murphy, 2012; Servén et al., 2018; Wood, 2017)

### 4.1.4 Materiales y métodos

#### 4.1.4.1 Base de datos experimental

Los datos recogidos mediante la búsqueda en artículos de investigación contienen los resultados de 515 muestras de HAC endurecido con áridos reciclados. La Tabla 4 resume la base de datos incluyendo la cantidad de datos (no.) aportados por cada artículo, así como su proporción (porcentaje) en los datos.

**Tabla 4.** Base de datos experimental.

No	Reference	no.	porcenta je	No	Reference	no.	percent aje
1	Ali y Al-Tersawy (201)	18	3.49	29	Nili et al. (2019)	10	1.94
2	Aslani et al. (2018)	15	2.91	30	Pan et al. (2019)	6	1.17
3	Babalola et al. (2020)	14	2.72	31	Pereira-De-Oliveira et al. (2014)	4	0.78
4	Bahrami et al. (2020)	10	1.94	32	Poongodi et al. (2021)	9	1.75
5	Barroqueiro et al. (2020)	6	1.17	33	Revathi et al. (2013)	5	0.97
6	Behera et al. (2019)	6	1.17	34	Revilla-Cuesta et al. (2020)	5	0.97

7	Bidabadi et al. (2020)	11	2.13	35	Sadeghi-Nik et al. (2019)	12	2.33
8	Chakkamalayath et al. (2020)	6	1.17	36	Salesa et al. (2017)	4	0.78
9	Duan et al. (2020)	10	1.94	37	Sasanipour y Aslani (2019)	5	0.97
10	Fiol, et al. (2018)	12	2.33	38	Sasanipour y Aslani (2020)	5	0.97
11	Gesoglu et al. (2015)	24	4.66	39	Señas et al. (2016)	6	1.17
12	Grdic et al. (2010)	3	0.58	40	Sharifi et al. (2013)	6	1.17
13	Güneyisi et al. (2014)	5	0.97	41	Silva y de Brito (2017)	5	0.97
14	Guo et al. (2020)	27	5.24	42	Singh y Jain (2015)	10	1.94
15	Kapoor et al. (2016)	8	1.55	43	Singh et al. (2019)	12	2.33
16	Katar et al. (2021)	4	0.78	44	Sua-lam y Makul (2013)	20	3.88
17	Khafaga (2014)	10	2.91	45	Sun et al. (2020)	10	1.94
18	Khodair y Luqman (2017)	20	3.88	46	Surendar et al. (2021)	7	1.36
19	Kou y Poon (2009)	13	2.52	47	Tang et al. (2016)	5	0.97
20	Krishna et al. (2018)	5	0.97	48	TThomas et al. (2016)	4	0.78
21	Kumar et al. (2017)	4	0.78	49	Tuyan et al. (2014)	12	2.33
22	Li et al. (2019)	4	0.78	50	Uygunoğlu et al. (2014)	8	1.55
23	Long et al., (2016)	4	0.78	51	Wang et al. (2020)	5	0.97
24	Mahakavi y Chithra (2020)	25	4.85	52	Yu et al. (2014)	3	0.58
25	Manzi et al.(2017)	4	0.78	53	Yu et al. (2020)	6	1.17
26	Martínez-García et al., 2020)	4	0.78	54	Yu et al. (2021)	21	4.07
27	Mo et al. (2021)	5	0.97	55	Zhou et al. (2013)	6	1.17
28	Nieto et al. (2019)	22	4.27			51	100
						5	

A partir de estos artículos publicados sobre la resistencia a la compresión del HAC con RA, la Tabla 5 muestra los valores media, mínimos y máximos de las variables de entrada (cemento, admixture (componente mineral), agua, árido fino, árido grueso, superplastificante) y de salida (resistencia a la compresión) empleadas para la modelización de la resistencia a la compresión del hormigón autocompactante con áridos reciclados, mediante el uso de técnicas de Aprendizaje Automático.

**Tabla 5.** Valores media, máximo y mínimo de las variables de entrada y salida.

Variables	Abreviatura	Media	Mínimo	Máximo	
Entrada	Cemento (kg/m <sup>3</sup> )	C	375.84	78.00	635.00
	Admixture (kg/m <sup>3</sup> )	A	135.17	0.00	515.00
	Agua (kg/m <sup>3</sup> )	W	176.87	45.50	277.00
	Árido fino (kg/m <sup>3</sup> )	FA	845.10	532.20	1200.00
	Árido grueso (kg/m <sup>3</sup> )	CA	784.91	328.00	1170.00
	Superplastificante (kg/m <sup>3</sup> )	SP	4.50	0.00	16.00
Salida	Resistencia a compresión (MPa)	FCK	44.94	7.17	87.00

#### 4.1.4.2 Análisis exploratorio de datos

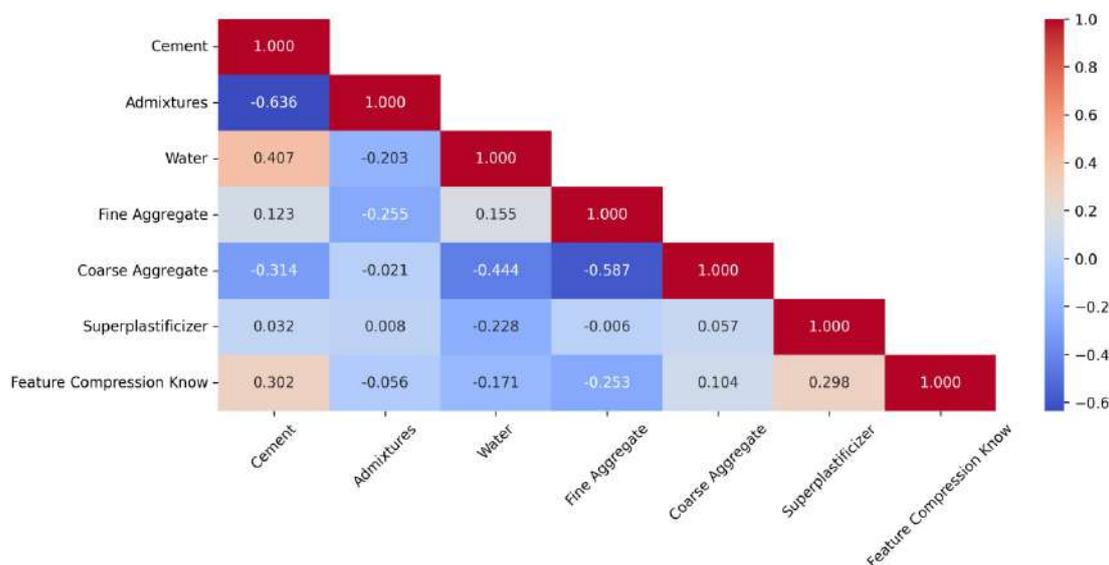
El coeficiente de correlación ( $r$ ) entre las variables de entrada: cemento, admixture, agua, árido fino, árido grueso y superplastificante y la variable de salida resistencia a la compresión (fck) se calculó para evaluar la dependencia de las variables entre sí. Un valor absoluto elevado de  $r$  entre las variables estaría indicando que existe correlación entre ellas, en consecuencia, solo se tendría en cuenta una de ellas y las demás se excluirían. Para el cálculo de  $r$  se empleó la ecuación 1:

$$r = \frac{\sum[(x_i - \bar{x})(y_i - \bar{y})]}{\sqrt{\sum(x_i - \bar{x})^2 * \sum(y_i - \bar{y})^2}} \quad (1)$$

donde,  $x_i$  = variable de entrada,  $\bar{x}_i$  = media de la variable de entrada,  $y_i$  = fck variable de salida,  $\bar{y}_i$  = media fck experimental,  $i = 1, \dots, n$  y  $n$  = número total de datos.

Una correlación ( $|r| > 0.8$ ) entre variables de entrada podría señalar presencia de multicolinealidad entre las variables (Hassan y El-Hag, 2020), lo que afectaría a los resultados de la modelización, provocando un sesgo en el modelo.

El mapa de calor de los coeficientes de correlación se muestra en la Figura 19. Se puede observar que no existe ninguna correlación significativa entre las variables de entrada y que ninguna correlación es superior a 0.8, lo cual indica que no existe multicolinealidad entre las variables de entrada.



**Figura 19.** Mapa de calor de los coeficientes de correlación entre las variables de entrada y salida.

### 4.1.4.3 División del conjunto de datos

Los métodos de aprendizaje automático requieren que los conjuntos de datos se dividan en subconjuntos de entrenamiento, validación y prueba, para su evaluación comparativa (DeRousseau et al., 2019; Farooq et al., 2021; K. Liu et al., 2021; Marani y Nehdi, 2020). Durante el proceso de entrenamiento, se evalúa el rendimiento del modelo con el conjunto de datos de validación para optimizar los hiperparámetros del modelo. Por último, para mostrar la precisión del modelo en la predicción de la resistencia a la compresión se utiliza el conjunto de datos de prueba.

Para la modelización de la resistencia a la compresión del hormigón autocompactante con áridos reciclado, un total de 515 muestras fueron divididas aleatoriamente en: 360 muestras (70%) para el proceso de entrenamiento, 77 muestras (15%) para el proceso de validación y 78 muestras (15%) para el proceso de prueba. La Tabla 6 muestra los valores media, mínimo y máximo de las variables de entrada (cemento, admixture, agua,

áridos fino, árido grueso, superplastificante) y de salida (resistencia a compresión) para los conjuntos de datos de entrenamiento, validación y prueba.

**Tabla 6 . Valores media, máximo y mínimo de las variables de entrada (kg/m<sup>3</sup>) y salida (MPa) de los conjuntos de datos: entrenamiento, validación y prueba.**

Conjunto	Variables	Media	Mínimo	Máximo	
Entrenamiento	Entrada	Cemento (kg/m <sup>3</sup> )	377.78	94.00	635.00
		Admixture (kg/m <sup>3</sup> )	131.42	0.00	390.00
		Agua (kg/m <sup>3</sup> )	176.15	45.50	277.00
		Árido fino (kg/m <sup>3</sup> )	847.52	532.20	1200.00
		Árido grueso (kg/m <sup>3</sup> )	786.41	328.00	1170.00
		Superplastificante (kg/m <sup>3</sup> )	4.61	0.00	16.00
		Salida	Resistencia a compresión (MPa)	45.01	7.17
Validación	Entrada	Cemento (kg/m <sup>3</sup> )	391.35	130.00	635.00
		Admixture (kg/m <sup>3</sup> )	130.65	0.00	390.00
		Agua (kg/m <sup>3</sup> )	179.51	45.50	277.00
		Árido fino (kg/m <sup>3</sup> )	846.37	532.20	1200.00
		Árido grueso (kg/m <sup>3</sup> )	769.58	328.00	1170.00
		Superplastificante (kg/m <sup>3</sup> )	4.14	0.00	16.00
		Salida	Resistencia a compresión (MPa)	45.21	21.00
Prueba	Entrada	Cemento (kg/m <sup>3</sup> )	351.56	78.00	635.00
		Admixture (kg/m <sup>3</sup> )	156.98	0.00	515.00
		Agua (kg/m <sup>3</sup> )	177.59	45.50	277.00
		Árido fino (kg/m <sup>3</sup> )	832.68	581.00	1200.00
		Árido grueso (kg/m <sup>3</sup> )	793.12	502.10	1170.00
		Superplastificante (kg/m <sup>3</sup> )	4.36	0.00	14.00
		Salida	Resistencia a compresión (MPa)	44.34	12.07

#### 4.1.4.4 Desarrollo de modelos

En este estudio, se desarrollaron nueve métodos ML, descritos en la sección 4.1.3.1 (KNN, RF, ETR, GB, LGBM, XGB, CB, GAM1, GAM2), para proyectar la resistencia a la compresión del hormigón autocompactante con áridos reciclados. Tras la preparación de los datos, las variables de entrada se introducen en los métodos de aprendizaje. El conjunto de entrenamiento se empleó para desarrollar un modelo de predicción para cada método, mientras que el conjunto de validación datos se utilizó para el ajuste de

los hiperparámetros. Cabe señalar que, en los siguientes apartados, el mejor hiperparámetro obtenido para los datos de validación se destaca en negrita.

#### 4.1.4.4.1 Métodos Bagging

KNN, los hiperparámetros que se ajustaron para este algoritmo fueron número de vecinos a utilizar para la consulta, 'n\_neighbors' = [1, 2, **3**, 4, 5, 10, 20, 50]; pesos de los puntos de consulta, que pueden ser uniformes (los mismos para todos los puntos) y proporcionales a la inversa de la distancia al punto de consulta, pesos = ['uniform', '**distance**']; algoritmo utilizado para calcular los vecinos más cercanos, algoritmo = ['auto', 'ball\_tree', 'kd\_tree', '**brute**'].

RF se desarrolló con los siguientes hiperparámetros: el número de árboles, n\_estimators = [2, 3, 5, 10, 20, **50**, 100, 150, 200]; la profundidad máxima de cada árbol, max\_depth = [2, 3, 5, 10, 20, **50**, 100, 150, 200]; función para medir la calidad de la división de un árbol, criterion = ['squared\_error', '**absolute\_error**', 'poisson'].

ERT se desarrolló con los mismos hiperparámetros que se utilizaron en RF: el número de árboles, n\_estimators = [2, 3, 5, 10, 20, 50, 100, 150, **200**]; la profundidad máxima de cada árbol, max\_depth = [2, 3, 5, 10, 20, **50**, 100, 150, 200]; función para medir la calidad de la división de un árbol, criterion = ['**squared\_error**', 'absolute\_error', 'poisson'].

#### 4.1.4.4.2 Métodos Boosting

GB se desarrolló utilizando los hiperparámetros: número de etapas de boosting, n\_estimators = [2, 3, 5, 10, 20, 50, 100, 150, 200, **500**]; profundidad máxima para limitar el número de nodos del árbol, max\_depth = [2, 3, **5**, 10, 20, 50, 100, 150, 200]; la tasa de aprendizaje, learning\_rate = [0.01, **0.1**, 0.5, 0.6, 0.65, 0.7, 1].

LGBM, los hiperparámetros que se ajustaron para este algoritmo fueron: número de etapas de boosting, n\_estimators = [5,10,20,50,90,120,200,300,**400**,500]; número de hojas del árbol, n\_leaves = [5, 10, **20**, 50, 100, 150, 200]; la tasa de aprendizaje, learning\_rate = [0.01,0.1,**0.25**,0.5,0.75,1].

XGB se desarrolló utilizando los hiperparámetros: número de etapas de boosting, estimators = [2, 3, 5, 10, 20, **50**, 100, 150, 200]; la profundidad máxima, max\_depth = [2, 3, 5, **10**, 20, 50, 100, 150, 200]; la tasa de aprendizaje, learning\_rate = [0.01, 0.1, **0.5**, 0.6, 0.65, 0.7, 1].

CB se desarrolló utilizando los hiperparámetros: número de iteraciones del algoritmo, iterations = [**50**]; profundidad máxima del árbol, depth = [2, 3, 5, **10**, 12, 16]; la tasa de aprendizaje, learning\_rate = [0.01,0.1,0.25,0.5,0.75,**1**].

#### 4.1.4.4.3 Modelos GAM

Modelos GAMs, el hiperparámetro utilizado para ajustar los GAMs fue el número de funciones suaves, spline. Para el GAM1 tenemos n\_spline = [5, 10, 20, 50, 100, 150, 200, 300, **500**], y para el GAM2 tenemos n\_spline = [5, 10, 20, 50, 100, 150, 200, 300, **500**].

#### 4.1.4.5 Métricas para evaluar el rendimiento de los métodos de aprendizaje automático

Se emplearon cuatro métricas estadísticas de rendimiento para determinar la eficacia y la precisión de las predicciones de todos los métodos de aprendizaje automático empleados para predecir la resistencia a la compresión del hormigón autocompactante con áridos reciclados: Coeficiente de Determinación ( $R^2$ ) (Ecuación 2), la Raíz cuadrada del Error Medio Cuadrático (RMSE) (Ecuación 3), Error Porcentual Absoluto Medio (MAPE) (Ecuación 4) y Error Absoluto Medio (MAE) (Ecuación 5) (Ahmad, Ostrowski, et al., 2021b; Babajanzadeh y Azizifar, 2018; DeRousseau et al., 2019; Marani y Nehdi, 2020).

$$R^2 = 1 - \frac{\sum(y_i - \hat{y}_i)^2}{\sum(y_i - \bar{y})^2} \quad (2)$$

$$RMSE = \sqrt{\frac{1}{n} \sum (y_i - \hat{y}_i)^2} \quad (3)$$

$$MAE = \frac{1}{n} \sum |y_i - \hat{y}_i| \quad (4)$$

$$MAPE = \frac{100}{n} \sum \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (5)$$

donde,  $y_i$  = fck (variable de salida),  $\hat{y}_i$  = fck estimado,  $\bar{y}_i$  = media fck experimental y  $n$  = Número de muestras

Particularmente RMSE y MAE tienen las mismas unidades (MPa) que la resistencia a la compresión (FCK), mientras que  $R^2$  y MAPE se expresan porcentualmente. Los valores más bajos de RMSE, MAE y MAPE, así como los valores más altos de  $R^2$  indican una buena precisión del resultado de la predicción de la resistencia a la compresión del HAC con RA utilizando los modelos ML (Farooq et al., 2021; Feng et al., 2020; Kovačević et al., 2021; Li et al., 2019).

## 4.1.5 Resultados y discusión

La capacidad de los métodos Bagging (KNN, RF, ETR), Boosting (GB, LGBM, XGB, CB) y GAM (GAM1, GAM2) para predecir la resistencia a la compresión del HAC con RA para el entrenamiento, la validación y el conjunto de datos de prueba se evaluó exhaustivamente mediante las métricas: coeficiente de determinación ( $R^2$ ), raíz cuadrada del error medio cuadrático (RMSE), error porcentual absoluto (MAPE) y error absoluto medio (MAE). Sin embargo, el valor  $R^2$  también conocido como coeficiente de determinación, se considera el mejor de ellos para la evaluación de modelos (Nafees et al., 2021b). Los valores de  $R^2$  entre 0.60 y 0.75 indican resultados satisfactorios, valores entre 0.75 y 0.95 indican una buena predicción del modelo y valores superiores a 0.95 indican excelente predicción, mientras que los valores inferiores a 0.60 indican resultados insatisfactorios (Ahmad et al., 2021; Ahmad, Ostrowski, et al., 2021b; Marani y Nehdi, 2020). Además, también se llevó a cabo el análisis de sensibilidad. Los resultados de estos análisis se presentan en detalle en las siguientes secciones.

### 4.1.5.1 Rendimiento predictivo de los modelos de aprendizaje automático

#### 4.1.5.1.1 Rendimiento predictivo de los modelos Bagging

La Tabla 7 muestra los resultados de  $R^2$ , RMSE, MAE y MAPE para los valores del conjunto de datos de entrenamiento, validación y de prueba de los modelos Bagging: K-

Neighbor Regressor (KNN), Random Forest (RF), Extretrees Regressor (ETR), para la resistencia a la compresión del HAC con RA. En general, los errores en el conjunto de datos de entrenamiento presentan la adecuación del modelo desarrollado, mientras que los errores en los datos de prueba presentan la capacidad de generalización del modelo desarrollado. Se puede observar que todos los modelos: KNN, RF y ERT, muestran una buena concordancia con los datos de entrenamiento dado que los coeficientes de determinación  $R^2$  son todos superiores al 90%, demostrando que estos modelos son capaces de predecir la resistencia a la compresión del HAC con RA cerca de los valores determinados experimentalmente.

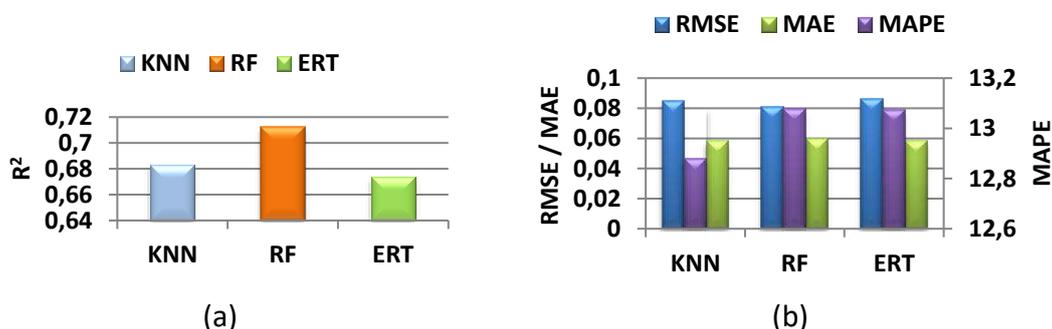
Comparando las métricas de los métodos KNN, RF y ETR para los datos de prueba, en la Tabla 7, se puede observar que Random Forest (RF) supera a los modelos KNN y ERT en términos de su capacidad para predecir y generalizar, al observar un valor satisfactorio de  $R^2 = 0.7128$ , así como bajos valores de MAE =0.060 y MAPE =13.0784, estos se consideran resultados satisfactorios para seleccionar a RF como un buen modelo. A pesar de que las métricas estadísticas de los modelos KNN, RF y ETR en los datos de prueba no difieren mucho, la Figura 20a muestra que el modelo RF supera a los otros modelos. En lo que respecta al rendimiento, los valores de RMSE y MAE inferiores a 0.10 indican un buen ajuste (Figura 20b) en las predicciones de la resistencia a la compresión (Ahmad et al., 2021; Montaña Moreno et al., 2013; Nafees et al., 2021; Vivas et al., 2020).

**Tabla 7.** Métricas de rendimiento de los modelos Bagging propuestos.

Conjunto	Métricas	Métodos		
		KNN	RF	ETR
Entrenamiento	$R^2$	0.9633	0.9388	0.9653
	RMSE	0.0322	0.0415	0.0313
	MAE	0.0130	0.0285	0.0121
	MAPE	2.9935	6.8785	3.0697
Validación	$R^2$	0.4155	0.5766	0.5066
	RMSE	0.1248	0.1062	0.1147
	MAE	0.0810	0.0739	0.0770
	MAPE	19.6506	17.6191	18.2424
Prueba	$R^2$	0.6832	0.7128	0.6739
	RMSE	0.0848	0.0807	0.0860

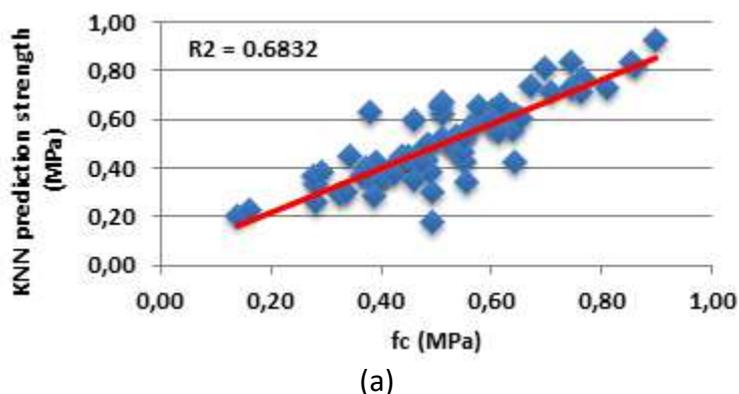
MAE	0.0582	0.0600	0.0586
MAPE	12.8782	13.0784	13.0738

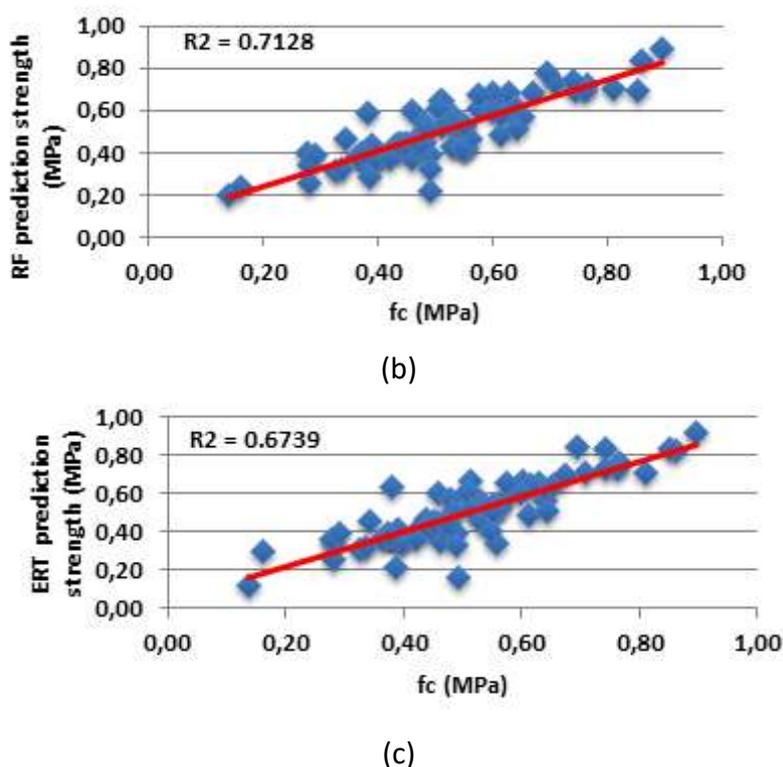
En la Figura 21, se puede apreciar que los métodos: KNN, RF y ERT parecen predecir bien las mediciones reales. Sin embargo, puede apreciarse que para el modelo realizado con RF los valores predictivos fueron bastante similares a los datos medidos, esto se refleja en la gráfica de predicción donde los valores se agrupan a lo largo de la recta de predicción y presentan menos dispersión en comparación con los modelos KNN y ERT. Estos resultados indican que RF tienen una gran capacidad para aprender de los datos de entrenamiento. En general, puede decirse que Random Forest (RF) puede predecir la resistencia a la compresión, generando resultados fiables con un alto grado de adecuación en comparación con los valores reales, lo que es similar a los hallazgos de estudios anteriores (Kang et al., 2021; Liu et al., 2021). El rendimiento superior del modelo de RF puede atribuirse a su estructura (Liu et al., 2021).



Nota. Métricas: a)  $R^2$ , (b) RMSE, MAE y MAPE.

**Figura 20.**  $R^2$ , RMSE, MAE y MAPE de los métodos Bagging.





Nota. Métodos Bagging: (a) KNN, (b) RF and (c) ERT.

**Figura 21.** Comparación de la predicción de la resistencia a la compresión con los métodos Bagging, a partir del conjunto de datos de prueba.

#### 4.1.5.1.2 Rendimiento predictivo de los modelos Boosting

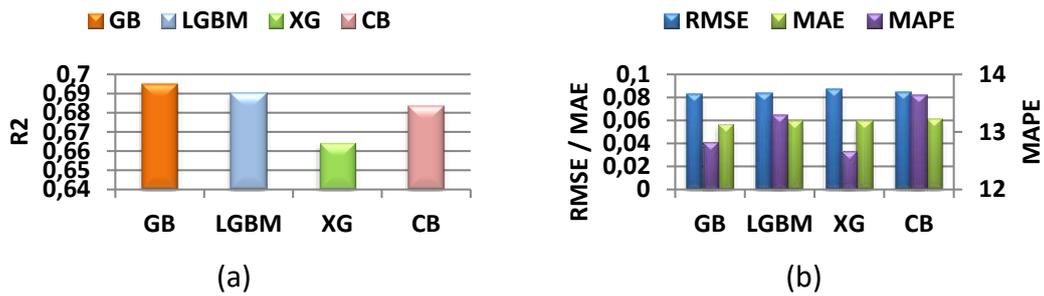
La tabla 8 presenta un resumen de las métricas de precisión de los modelos Boosting: Gradiente Boosting (GB), Light Gradient Boosting Machine (LGBM), Extreme Gradient Boosting (XGB), Category Boosting (CB), de los conjuntos de datos de entrenamiento, validación y prueba. Se puede observar que, en el conjunto de datos de entrenamiento, los valores de  $R^2$  para todos los modelos fueron superiores a 0.95, por lo que todos los modelos muestran una buena concordancia con los datos de entrenamiento. Esto indica que estos modelos pueden realizar una excelente predicción (Ahmad et al., 2021; Ahmad, Ostrowski, et al., 2021b; Marani y Nehdi, 2020) de la resistencia a la compresión del HAC con RA.

**Tabla 8.** Métricas de rendimiento de los métodos Boosting propuestos.

conjuntos	Métricas	Métodos			
		GB	LGBM	XGB	CB
Entrenamiento	R <sup>2</sup>	0.9653	0.9530	0.9648	0.9644
	RMSE	0.0313	0.0364	0.0315	0.0317
	MAE	0.0134	0.0205	0.0148	0.0164
	MAPE	3.1342	4.4857	3.5297	3.8346
Validación	R <sup>2</sup>	0.5257	0.5455	0.4783	0.4551
	RMSE	0.1124	0.1100	0.1179	0.1205
	MAE	0.0771	0.0788	0.0791	0.0833
	MAPE	18.2233	18.2537	18.7161	19.7652
Prueba	R <sup>2</sup>	0.6948	0.6905	0.6643	0.6837
	RMSE	0.0832	0.0838	0.0873	0.0847
	MAE	0.0569	0.0592	0.0595	0.0614
	MAPE	12.8259	13.2913	12.6654	13.6472

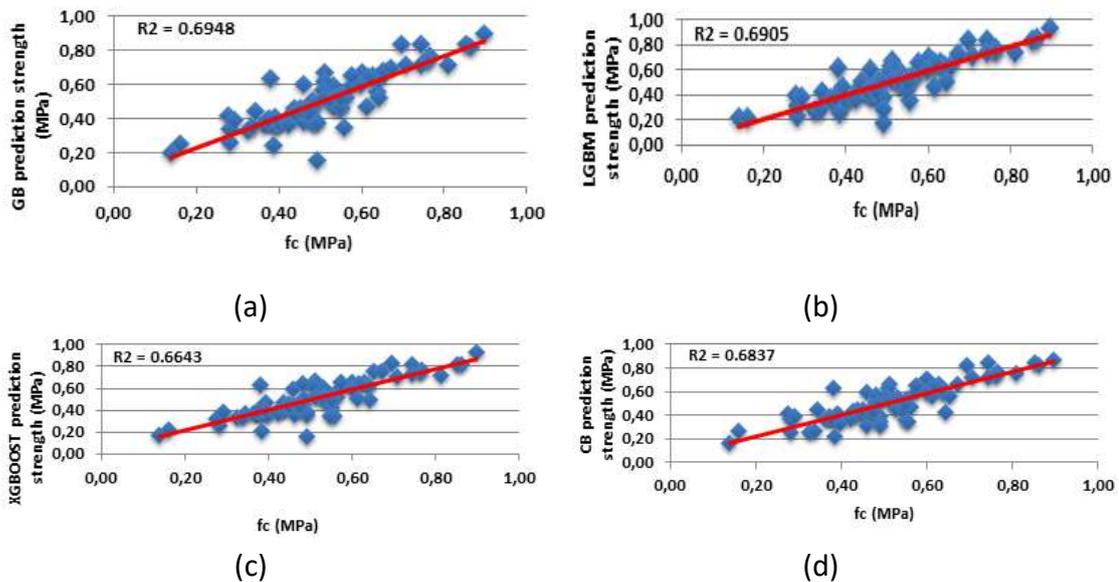
Ahora bien, para evaluar el rendimiento predictivo del modelo, las métricas se basan en el conjunto de los datos de prueba, que sirve como una base más objetiva para una evaluación insesgada de la precisión del modelo en la predicción de la resistencia a la compresión. La tabla 8 muestra que, para los datos de prueba, en los cuatro modelos los valores de R<sup>2</sup> son superiores a 0.65, lo que indica que estos modelos predicen la resistencia a la compresión de manera satisfactoria. Sin embargo, el modelo GB (Figura 22) presenta un R<sup>2</sup> = 0.6948 superior al de los modelos: LGBM, XGB y CB, así como valores bajos de RMSE = 0.0832, MAE = 0.0569 que indican un buen ajuste en las predicciones al ser inferiores a 0.10 (Montaño Moreno et al., 2013; Vivas et al., 2020).

Estos resultados se pueden corroborar en la Figura 23, donde se aprecia que para el modelo GB los valores estimados se ajustan bastante a la línea de predicción, estos presentan una menor dispersión que en comparación con los modelos LGBM, XGB y CB.



Nota. Métricas: a)  $R^2$ , (b) RMSE, MAE y MAPE.

**Figura 22.**  $R^2$ , RMSE, MAE and MAPE de los métodos Boosting.



Nota. Boosting: (a) GB, (b) LGBM, (c) XGB and (d) CB.

**Figura 23.** Comparación de la predicción a la compresión de la resistencia a la compresión con los métodos Boosting, a partir del conjunto de prueba.

#### 4.1.5.1.3 Rendimiento predictivo de los modelos GAM

La tabla 9 muestra las métricas de precisión de los modelos GAM: Gaussiana Inversa (GAM1) y Poisson (GAM2), para los conjuntos de datos de entrenamiento, validación y prueba. Se puede apreciar que para los datos de entrenamiento el modelo GAM 1 presenta un  $R^2 = 0.3534$ , similar resultado presenta GAM2 con un  $R^2 = 0.3630$ , estos resultados son insatisfactorios para predecir la resistencia a la compresión, siendo valores inferiores a 0.6 (Ahmad et al., 2021; Ahmad, Ostrowski, et al., 2021b; Marani y Nehdi, 2020). Por lo tanto, los modelos GAM1 y GAM2 son pobres para predecir la resistencia a la compresión del HAC con RA.

**Tabla 9.** Métricas de rendimiento de los modelos GAM.

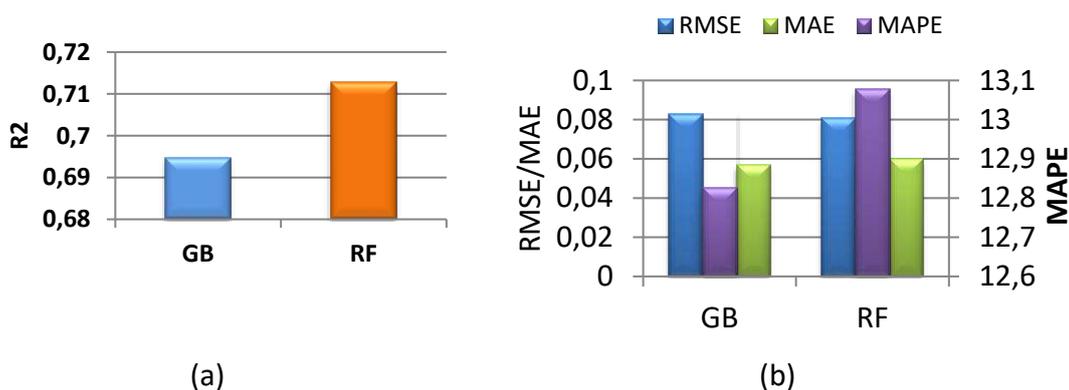
Conjuntos	Métricas	Métodos	
		GAM1	GAM2
Entrenamiento	R <sup>2</sup>	0.3534	0.3630
	RMSE	0.1351	0.1340
	MAE	0.1073	0.1070
	MAPE	24.8118	25.0538
Validación	R <sup>2</sup>	0.2593	0.2755
	RMSE	0.1405	0.1389
	MAE	0.1124	0.1113
	MAPE	23.0691	23.0500
Prueba	R <sup>2</sup>	0.2722	0.2662
	RMSE	0.1285	0.1290
	MAE	0.0978	0.0989
	MAPE	23.7784	24.2997

#### 4.1.5.1.4 Rendimiento predictivo de los mejores modelos de aprendizaje automático

Una vez analizados los modelos Bagging, Boosting y GAM, se obtuvo como resultados que los mejores modelos para predecir la resistencia a la compresión del HAC con RA son los modelos Gradiente Boosting (GB) y Random Forest (RF). En la tabla 10 se presentan las métricas de los modelos GB y RF, donde se puede observar que para los datos de entrenamiento, ambos modelos presentan valores de R<sup>2</sup> superiores a 0.90, indicando esto que GB y RF son buenos predictores de la resistencia a la compresión (Ahmad, Ostrowski, et al., 2021b; Marani y Nehdi, 2020). Sin embargo, al evaluar el desempeño predictivo de los modelos, a través de la comparación de las métricas para los datos de prueba, se puede apreciar que el modelo RF presenta un valor de R<sup>2</sup> = 0.7128 superior al de GB (Figura 24), así como bajos valores de MAE = 0.060 y RMSE = 0.0807 que indican un buen ajuste en las predicciones de la resistencia a la compresión (Ahmad et al., 2021; Nafees et al., 2021; Vivas et al., 2020).

**Tabla 10.** Métricas de rendimiento de los mejores métodos.

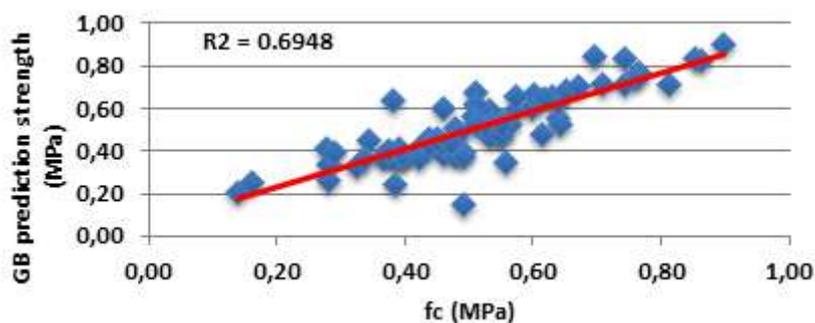
Conjunto de datos	Métricas	Métodos	
		GB	RF
Entrenamiento	R <sup>2</sup>	0.9653	0.9388
	RMSE	0.0313	0.0415
	MAE	0.0134	0.0285
	MAPE	3.1342	6.8785
Validación	R <sup>2</sup>	0.5257	0.5766
	RMSE	0.1124	0.1062
	MAE	0.0771	0.0739
	MAPE	18.2233	17.6191
Prueba	R <sup>2</sup>	0.6948	0.7128
	RMSE	0.0832	0.0807
	MAE	0.0569	0.0600
	MAPE	12.8259	13.0784



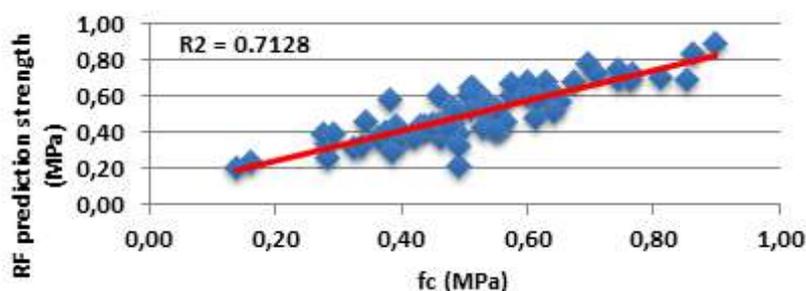
Nota. Métricas: a) R<sup>2</sup>, (b) RMSE, MAE and MAPE.

**Figura 24.** R<sup>2</sup>, RMSE, MAE and MAPE de los mejores modelos ML.

La Figura 25 muestra como en el modelo RF los valores estimados son más similares a los resultados experimentales, estos se agrupan a lo largo de la línea de predicción, presentando menos dispersión con respecto al modelo predictivo GB. En resumen, el modelo Random Forest (RF) mostró una mejor capacidad de predicción, por lo tanto, se considera el mejor modelo para predecir la resistencia a la compresión del HAC con RA.



(a)



(b)

Nota. Modelos: (a) GB and (b) RF.

**Figura 25.** Comparación de la predicción de la resistencia a la compresión de los mejores modelos: a partir del conjunto de datos de prueba.

### 4.1.5.2 Análisis de sensibilidad

El análisis de sensibilidad es una técnica que ayuda a comprender la influencia de cada variable de entrada en la variable de salida. Las variables de entrada con altos valores de sensibilidad tienen mayor incidencia en la variable de salida. Según Ahmad et al. (2021) las variables de entrada tienen un impacto considerable en la predicción de la variable de salida.

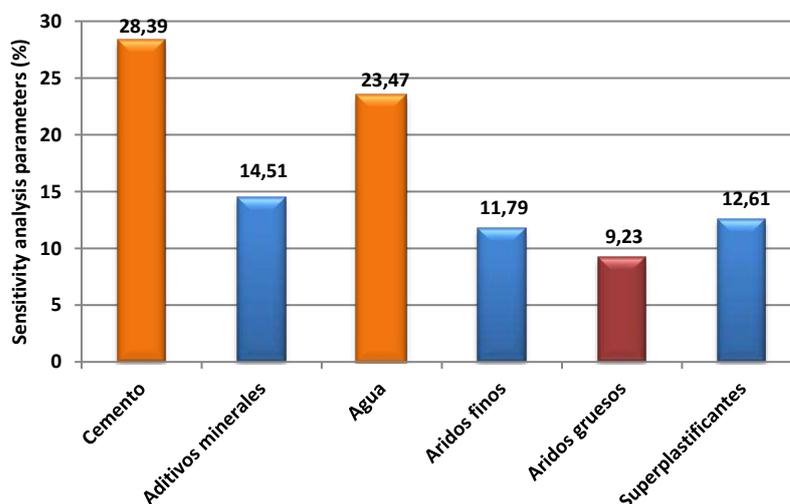
Para evaluar la contribución de cada una de las variables de entrada: cemento, admixture, agua, áridos finos, áridos gruesos y superplastificantes en la incertidumbre de la variable de salida, resistencia a la compresión ( $f_{ck}$ ), se empleó el análisis de sensibilidad. La sensibilidad de la resistencia a la compresión de cada variable de entrada se determinó mediante las ecuaciones 6 y 7:

$$S_i = \frac{N_i}{\sum_{i=1}^n N_i} * 100 \quad (6)$$

$$N_i = f_{max}(x_i) - f_{min}(x_i), i = 1, \dots, n \quad (7)$$

donde,  $f_{max}(x_i)$  y  $f_{min}(x_i)$  son la resistencia a la compresión máxima y mínima estimada en relación con la variable de entrada.

Cada una de las variables de entrada: cemento, admixture, agua, áridos finos, áridos gruesos y superplastificantes juega un papel importante en la predicción de la resistencia a la compresión del HAC con RA. La Figura 26 muestra los resultados de este análisis de sensibilidad, se puede observar que el cemento y el agua son las variables de entrada más influyentes en la predicción de la resistencia a la compresión del HAC con RA. El cemento tiene una contribución de 28.39% y el agua de 23.47%. En este sentido, Ahmad et al. (2021) afirmaron que el cemento es un factor decisivo que influye en la predicción de la resistencia a la compresión. Por otro lado, se aprecia que las variables de entrada: admixture, superplastificante y áridos finos tienen una contribución en niveles similares de 14.51%, 12.61% y 11.79% respectivamente. Los resultados del análisis demostraron que los áridos gruesos (9.23%) es la variable menos efectiva en la contribución de la predicción de la resistencia a la compresión, estos resultados coinciden con los hallazgos de investigaciones anteriores (W. Ahmad et al., 2021).



**Figura 26.** Contribución de las variables de entrada a la resistencia a la compresión en el modelo RF.

## 4.1.6 Conclusiones parciales

Para la predicción de la resistencia a la compresión del HAC con RA, se tomaron en cuenta seis variables de entrada: cemento, agua, admixture, áridos finos, áridos gruesos y superplastificante. La capacidad de predicción de los modelos se evaluó mediante las siguientes métricas:  $R^2$ , RMSE, MAE y MAPE.

1. Este estudio ha descrito la aplicación de los modelos Bagging: KNN, RF y ERT; Boosting: GB, LGBM, XGB y CB, así como los modelos GAM: GAM1 y GAM2 para la predicción de la resistencia a la compresión del HAC con RA. Para el desarrollo de estos modelos se obtuvo una base de datos de 515 muestras procedentes de varios estudios experimentales y divididas en 3 grupos: entrenamiento (70%), validación (15%) y prueba (15%).
2. Los resultados del conjunto de datos de prueba, mostraron que los modelos Bagging RF ( $R^2 = 0.7128$ , RMSE = 0.0807, MAE = 0.06) y Boosting GB ( $R^2 = 0.6948$ , RMSE = 0.0832, MAE = 0.0569) presentan el mayor rendimiento con una alta precisión de predicción. Sin embargo, también se evidenció que los modelos GAM1 ( $R^2 = 0.2722$ ) y GAM2 ( $R^2 = 0.27662$ ) no son buenos modelos para predecir la resistencia a la compresión, esto se comprobó con los valores presentados de  $R^2$  que son mucho menores a 0.60.
3. Random Forest (RF) ( $R^2 = 0.7128$ , RMSE = 0.0807, MAE = 0.06) es el mejor modelo para la predicción de la Resistencia a la compresión.
4. El análisis de sensibilidad del modelo RF señala que, el cemento con una contribución del 28.39%, es la principal variable que influye en la resistencia a la compresión. En el mismo contexto, el agua está presente con una contribución de 23.47% como otra variable importante en la predicción de la resistencia a la compresión. Por otro lado, la variable de menor incidencia fue el árido grueso (9.23%). Todo ello indica que la resistencia a la compresión del HAC con RA aumenta más con el cemento y el agua, mientras que los áridos gruesos la disminuyen. Por otra parte, el admixture, los áridos finos y los superplastificantes contribuyen

modestamente al desarrollo del modelo RF. Por lo tanto, el nivel de contribución de cada variable de entrada es identificada por el modelo RF.

## 4.2 COMPARACIÓN DE HERRAMIENTAS DE APRENDIZAJE AUTOMÁTICO PARA MODELAR LA RESISTENCIA A LA TRACCIÓN DEL HORMIGÓN AUTOCOMPACTANTE CON ÁRIDOS RECICLADOS

En la actualidad, el hormigón, como material de construcción, tiene una gran demanda, debido al rápido y avanzado crecimiento del desarrollo de la infraestructura en muchos países y utilizándose habitualmente en estructuras de ingeniería en todo el mundo (W. Ahmad et al., 2021; Koya, 2021; Silva et al., 2020), esto exige que la tecnología cambie permanentemente, buscando mejoras e innovaciones. Es por ello que, recientemente, han surgido determinados tipos de hormigón, como el hormigón autocompactante (HAC), representando un potencial aceptable, a la vez que atrae el interés por el uso de los áridos reciclados (RA) (Carro-López et al., 2018; Ghalehnovi et al., 2019; Nieto Alcolea, 2015; Santos et al., 2019; Santos et al., 2017) provenientes de los residuos de construcción y demolición (RCD) como sustituto de los áridos convencionales (Azizifar y Babajanzadeh, 2018; Belalia Douma et al., 2017; J. Xu, Zhao, et al., 2019), minimizando o eliminando potencialmente los impactos ambientales producidos por estos RCD (Pacheco et al., 2019), permitiendo combinar el desarrollo económico con la sostenibilidad y la protección del ambiente (Martínez-García, 2021).

El HAC fabricado con RA es uno de los materiales más utilizados en la construcción (Farooq et al., 2021; Kaloop et al., 2020), debido a sus características de compactación (sin vibración mecánica) y a su fluidez. Es un hormigón de alta resistencia y eficacia que garantiza uniformidad. Sin embargo, su compleja estructura requiere un exigente proceso de diseño de la mezcla, compuesta por: cemento (Cmt), agua (W), aditivo mineral (MA), áridos finos (FA), áridos gruesos (CA) y superplastificantes (SP); esto significa que es necesario conocer el comportamiento de sus propiedades mecánicas, como: la resistencia a la tracción ( $f_{st}$ ), resistencia a la compresión ( $f_{ck}$ ), la resistencia a

la flexión, módulo de ruptura, entre otras (Farooq et al., 2021). Por lo general, estas propiedades se identifican y miden realizando experimentos a gran escala, que suelen ser largos, costosos y laboriosos (Koya, 2021; Koya et al., 2021). Por lo tanto, para predecir con exactitud el comportamiento de estas propiedades, se han empleado técnicas de inteligencia artificial, como el aprendizaje automático (ML), por su simplicidad, fiabilidad y su capacidad para aprender de los datos experimentales (Koya, 2021; J. Xu, Zhao, et al., 2019).

Particularmente, en Ingeniería Civil, los métodos de ML han mejorado la seguridad, la productividad, la calidad y el mantenimiento de la construcción (Ayhan y Tokdemir, 2019; Bai et al., 2019), se han utilizado para modelar y predecir las propiedades mecánicas del HAC (Ahmad, Farooq, et al., 2021; Behnood y Golafshani, 2020; Kovačević, et al., 2021; Koya et al., 2021; Lyngdoh et al., 2022). Por lo que, la predicción de estas propiedades mediante ML permite ahorrar: tiempo de laboratorio, desperdicio de los componentes del hormigón, energía y coste (Behnood y Golafshani, 2020; Farooq et al., 2021; Koya, 2021; Koya et al., 2021; Kumar et al., 2022; Zhang et al., 2021). ML también puede manejar grandes volúmenes de datos, y predecir las propiedades mecánicas del HAC con gran precisión (Koya, 2021; Silva et al., 2020; Xu, Zhao, et al., 2019).

Entre los métodos de ML más utilizados para predecir estas propiedades del hormigón se encuentran: Decision Tree Regressor (DTR) (Ahmad, Ostrowski, et al., 2021; Shang et al., 2022; Sharafati et al., 2021; Song et al., 2022), Random Forest (RF) (Shaqadan, 2016; Song et al., 2022; Zhang et al., 2021), Extreme Gradient Boosting (XGBoost) (K. T. Nguyen et al., 2020; Nguyen-Sy et al., 2020), Support Vector Regressor (SVR) (Farooq et al., 2021; Kapoor et al., 2016; Kovačević et al., 2021), Artificial Neural Network (ANN) (Ahmad, Farooq, et al., 2021; Ahmad, Ostrowski, et al., 2021; Awoyera et al., 2020; Golafshani y Pazouki, 2018; Mazloom y Yoosefi, 2013; T. T. Nguyen et al., 2020; Shang et al., 2022) y Gradient Boosting Regressor (GBR) (K. T. Nguyen et al., 2020; Nguyen-Sy et al., 2020; Song et al., 2022). Por ejemplo, Lyngdoh et al. (2022) emplearon K-nearest neighbor (KNN), Support vector machine (SVM), XGBoost, Neural network (NN), Selección de operadores y Contracción del menor Absoluto (LASSO), Random forest (RF), para

predecir la resistencia a la tracción y la resistencia a la compresión del hormigón. Por su parte, Bui et al. (2018) desarrollaron un sistema experto basado en el modelo de red neuronal artificial (ANN) y apoyado por un algoritmo de luciérnaga modificado (MFA) para predecir la resistencia a la tracción y la resistencia a la compresión del hormigón de alto rendimiento. Nguyen et al. (2021) utilizaron cuatro algoritmos de predicción: support vector regression (SVR), perceptrón multicapa (MLP), gradient boosting regressor (GBR), y extreme gradient boosting (XGBoost) para estimar la resistencia a la compresión y a la tracción del hormigón de alto rendimiento. Concluyeron que los modelos XGBoost y GBR predecían mejor la resistencia a la tracción y a la compresión del hormigón del alto rendimiento. Por último, Awoyera et al. (2020) modelaron varias propiedades del hormigón autocompactante geopolímero, a saber, la resistencia a la compresión, la resistencia a la rotura y la resistencia a la flexión, aplicando técnicas de programación genética (GEP) y redes neuronales artificiales (ANN), y concluyeron que tanto los métodos GEP como los ANN arrojan buenas predicciones a partir de los datos experimentales, con errores mínimos.

En particular, la resistencia a la tracción es uno de las propiedades mecánicas de importancia en el diseño de estructuras de hormigón (Eluozo, 2019; Yan et al., 2013), porque la fisuración en el hormigón se debe generalmente a las tensiones de tracción que se producen bajo carga, o debido a los cambios ambientales (Druta, 2003). Se han empleado métodos de aprendizaje automático para predecir la resistencia a la tracción del hormigón, siendo los más utilizados las Redes Neuronales (ANN) (Awoyera et al., 2020; Behnood et al., 2015; Bui et al., 2018; Guo et al., 2021; Nagarajan et al., 2020; Nazari y Riahi, 2011; Shivaraj et al., 2015), Support Vector Machine (SVM) (Behnood et al., 2015; Guo et al., 2021; Guo et al., 2020; Koya et al., 2021; Lyngdoh et al., 2022; H. Nguyen et al., 2021; Ray et al., 2021; Shivaraj et al., 2015; Yan et al., 2013; Q. Zhang y Habibi, 2021), eXtreme Gradient Boosting (XGBoost) (Guo et al., 2021; Lyngdoh et al., 2022; H. Nguyen et al., 2021), Random Forest (RF) (Koya et al., 2021; Lyngdoh et al., 2022; Q. Zhang y Habibi, 2021), Decision Tree Regressor (DTR) (Koya et al., 2021; Shang et al., 2022), Gradient Boosting Regressor (GBR) (Koya et al., 2021; H. Nguyen et al., 2021) y por último perceptrón multicapa (MLPs) (H. Nguyen et al., 2021; Q. Zhang y Habibi, 2021).

## 4.2.1 Importancia de la investigación

Esta publicación tiene como objetivo Comparar cuatro métodos de aprendizaje automático (ML): XGBoost, GB, CB y ETR, para la estimación de la resistencia a la tracción del HAC con RA a los 28 días, con datos obtenidos de la literatura. Según el conocimiento de los autores, no se ha realizado ninguna investigación considerable sobre la comparación de los métodos ML en la resistencia a la tracción del hormigón autocompactante con áridos reciclados, lo que marca la novedad del presente estudio. El rendimiento de los modelos ML se evaluó por medio de las métricas  $R^2$ , RMSE y MAE para determinar el algoritmo de ML más adecuado para obtener predicciones fiables de la resistencia a la tracción.

## 4.2.2 Antecedentes de la investigación

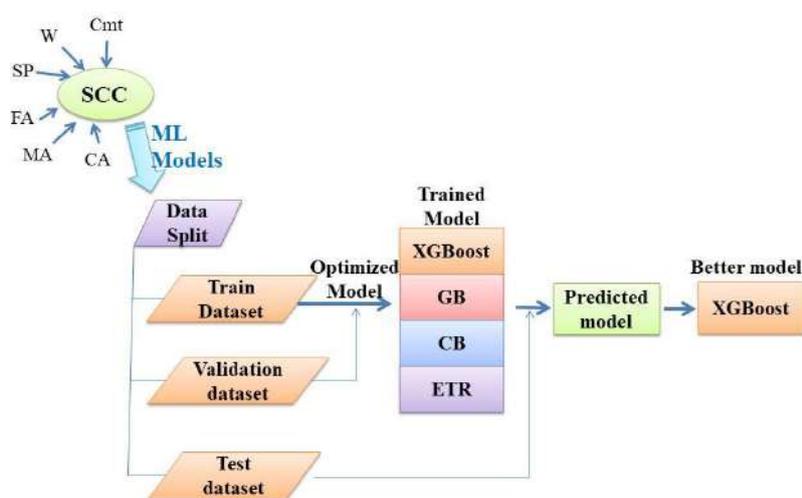
### 4.2.2.1 Métodos de aprendizaje automático

Los métodos de ML aprenden de los datos para luego realizar la clasificación y la predicción. Son cada vez más populares, debido a la creciente potencia computacional utilizada en el sector de la construcción para estimar el rendimiento de los materiales (Awoyera et al., 2020; H. Nguyen et al., 2021). En el presente estudio se aplicaron cuatro métodos de ML para predecir la resistencia a la tracción del HAC con RA: XGBoost, GB, CB y ETR. Estos métodos fueron seleccionados en base a su amplio uso en investigaciones relacionadas. En la Figura 27 se presenta el proceso de ML. A continuación, se presenta una visión resumida de estos métodos.

#### 4.2.2.1.1 Extreme Gradient Boosting (XGBoost)

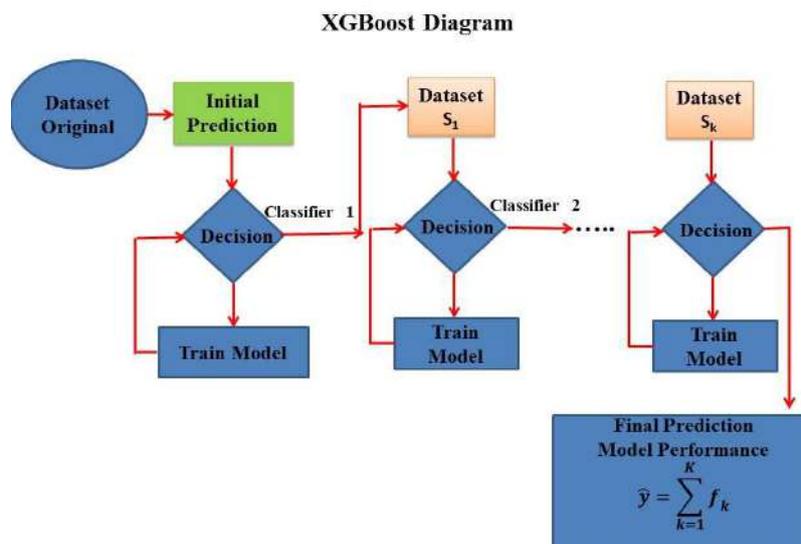
Extreme Gradient Boosting (XGBoost) fue desarrollado por Chen y Guestrin (2016), como un método de aprendizaje de conjunto escalable, para el refuerzo de árboles, útil tanto para el ML como para la minería de datos. XGBoost emplea una formalización más regularizada de la técnica para controlar el sobreajuste y lograr un mejor rendimiento. Como resultado, se la complejidad del modelo decrece y se evita en gran medida el

sobreajuste (Chang et al., 2018; Guelman, 2012). XGBoost puede emplearse como un método avanzado de GB con procesamiento distribuido en paralelo, esto es resultado de la comparación de XGBoost con GB, realizada por Chen y Guestrin (2016). En este sentido, GB sufre los inconvenientes del sobreajuste y la lentitud. Por lo tanto XGBoost es un método de ML que presenta dos funciones reguladoras autocompatibles (contracción de columnas y submuestreo), lo que lo hace más confiable (Kang et al., 2021).



**Figura 27.** Proceso del aprendizaje automático.

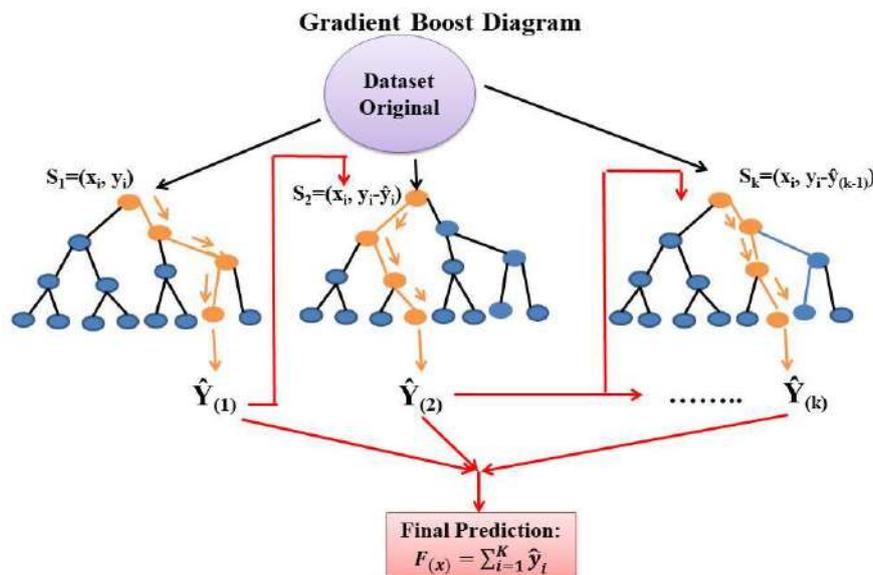
Además, presenta mejor capacidad de predicción, lo que significa que cuando hay gran volumen de datos, el tiempo de procesamiento es menor para XGBoost que para GB. Marani y Nehdi (2020) señalan que XGBoost emplea una función de regularización junto con la función de pérdida para evaluar la "bondad" del modelo. La Figura 28 muestra el diagrama esquemático de XGBoost.



**Figura 28.** Diagrama esquemático de XGBoost.

#### 4.2.2.1.2 Gradiente Boosting (GB)

Gradient Boosting (GB) es un método supervisado de ML que se utiliza tanto para problemas de regresión como de clasificación (Marani y Nehdi, 2020; Olu-Ajayi et al., 2022). Fue diseñado, en el 2001, por Friedman (Friedman, 2001) como un método que combina un conjunto de modelos débiles para formar un modelo más robusto utilizando modelos aditivos. GB conecta numerosos aprendices de base como una suma ponderada para reducir el sesgo y la varianza y preponderar los datos que fueron mal clasificados (Ben Jabeur et al., 2021; Kang et al., 2021), La función de pérdida sirve para minimizar empleando aprendices de base en la iteración de Boosting (Friedman, 2002; Ben Jabeur et al., 2021; Kang et al., 2021). Varios métodos de ML supervisado desarrollados recientemente, como XGBoost, LightGBM y CatBoost, utilizan GB como base para mejorar su capacidad de adaptarse a las necesidades del momento, mejorando la escalabilidad (Ben Jabeur et al., 2021). La Figura 29 muestra el diagrama esquemático de Gradient Boost.



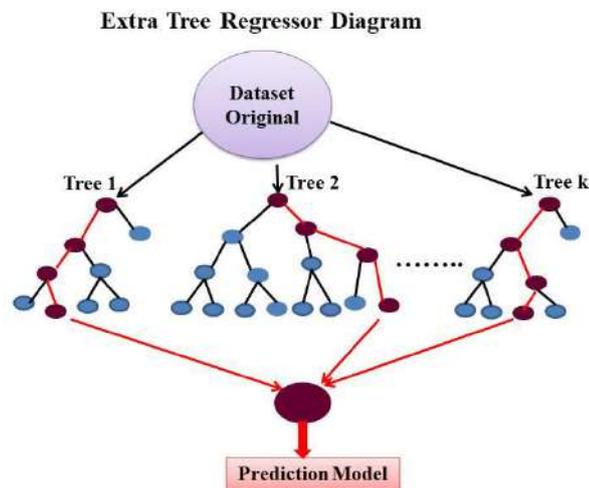
**Figura 29.** Diagrama esquemático de Gradient Boost.

#### 4.2.2.1.3 Cat Boosting (CB)

Cat Boosting (CB) es una implementación de GB, propuesta por Prokhorenkova et al. (2018) que utiliza árboles de decisión binarios como base de predicción. Dos avances algorítmicos fundamentales introducidos en CB son la implementación de boosting ordenado (una alternativa al algoritmo clásico basada en permutaciones) y un algoritmo innovador para procesar características categóricas (Dorogush et al., 2018; Prokhorenkova et al., 201b). CB emplea técnicas de permutación `one_hot_max_size` (OHMS) y estadísticas basadas en objetos enfocándose en columnas categóricas (Al Daoud, 2019b). Mediante el uso del método Greedy, la división en árbol resuelve el crecimiento exponencial de la combinación de características (Prokhorenkova et al., 2018). Para cada característica que tiene más categorías que OHMS (un parámetro de entrada), CB divide aleatoriamente (en subconjuntos) los registros y convierte las etiquetas en números enteros y codifica las características categóricas convirtiéndolas en numéricas (Al Daoud, 2019), lo que significa que el trabajo exitoso con características categóricas se lleva a cabo con la menor pérdida de información (Dorogush et al., 2018)

#### 4.2.2.1.4 Extra Trees Regressor (ETR)

Extra Trees Regressor (ETR) es otro método supervisado de ML, propuesto por Geurts et al. (2006), en el 2005, el mismo puede utilizarse en problemas de regresión y de clasificación. ETR selecciona aleatoriamente características y puntos de corte dividiendo un nodo del árbol para entrenar los estimadores (M. W. Ahmad, Mourshed, et al., 2018; M. W. Ahmad, Reynolds, et al., 2018; Geurts et al., 2006). ETR se desarrolló como una extensión de GB, empleando el mismo principio (M. W. Ahmad, Reynolds, et al., 2018). Sin embargo, es menos probable que sobreajuste un conjunto de datos (Geurts et al., 2006). Una de las diferencias críticas entre estos dos algoritmos es que ETR selecciona el mejor aspecto y valor relacionado para una división más discriminativa (Marani y Nehdi, 2020). Además, ETR, a diferencia GB, utiliza todo el conjunto de datos de entrenamiento para entrenar cada árbol de regresión y no utiliza bootstrapping para el entrenamiento (M. W. Ahmad, Mourshed, et al., 2018; M. W. Ahmad, Reynolds, et al., 2018; Geurts et al., 2006). La Figura 30 muestra el diagrama esquemático de Extra Trees Regressor.



**Figura 30.** Diagrama esquemático de Extra Trees Regressor.

## 4.2.3 Materiales y métodos

### 4.2.3.1 Base de datos experimental

La base de datos para este estudio fue conformada por 381 muestras de HAC con RA procedentes de artículos de investigación publicados en revistas científicas, como se muestra en la Tabla 11. En la cual se indica el autor, el número de mezclas (# mix) y la proporción (% data) aportada a la base de datos.

De estos artículos publicados sobre la resistencia a la tracción del HAC con RA, la Tabla 12 muestra los valores mínimos, máximo, media, desviación estándar, asimetría y kurtosis de las variables de entrada: Cement (Cmt), Aditivo Mineral (MA), agua (W), árido fino (FA), árido grueso (CA), Superplastificante (SP) y de salida resistencia a la tracción (fst) las cuales fueron empleadas para modelar la resistencia a la tracción del HAC con RA, a través del uso de técnicas de ML. Además, la distribución de la frecuencia con la curva Normal de cada una de las variables de entrada se muestra en la Figura 31, donde se puede apreciar el comportamiento de cada una de las variables.

**Tabla 11.** *Experimental database.*

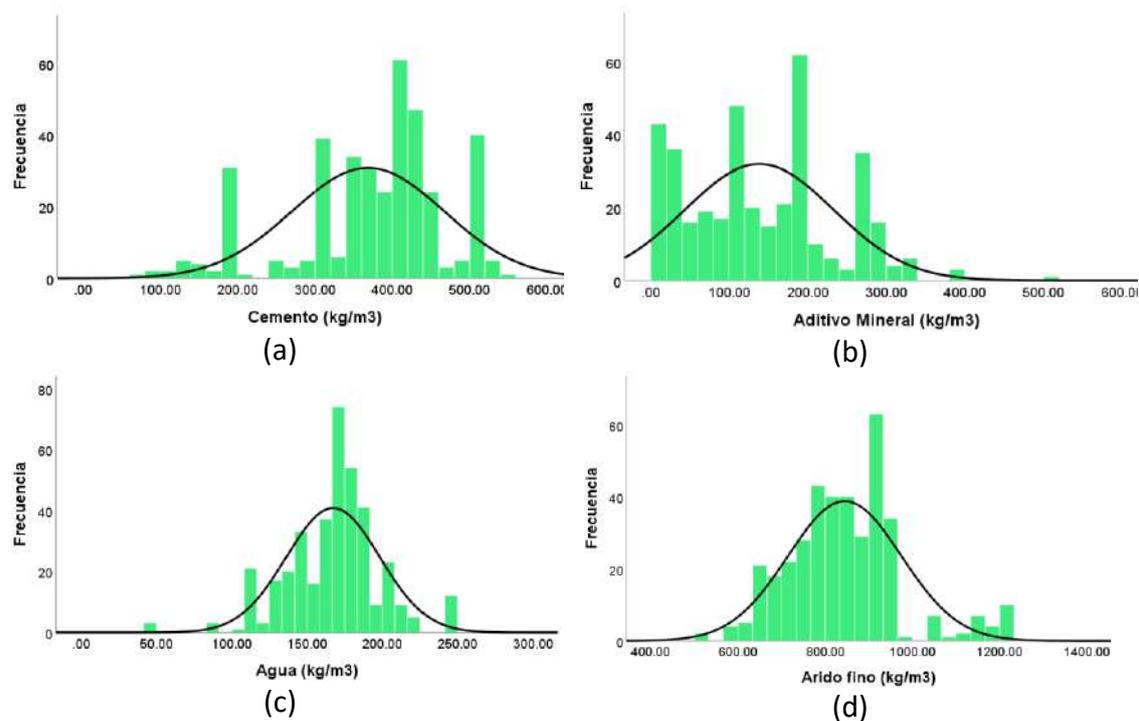
No	Reference	# mix	% data	No	Reference	# mix	% data
1	Ali y Al-Tersawy (2012a)	18	4.73	22	Nieto et al. (2019a)	22	5.78
2	Aslani et al. (2018a)	15	3.94	23	Nili et al. (2019a)	10	2.63
3	Babalola et al. (2020a)	14	3.68	24	Pan et al. (2019a)	6	1.57
4	Bahrami et al. (2020a)	10	2.63	25	Revathi et al. (2013a)	5	1.31
5	Behera et al. (2019a)	6	1.57	26	Revilla-Cuesta et al. (2020a)	5	1.31
6	Chakkamalayath et al. (2020)	6	1.57	27	Sadeghi-Nik et al. (2019a)	12	3.15
7	Duan et al. (2020a)	10	2.63	28	Señas et al. (2016)	6	1.57
8	Fiol et al. (2018)	12	2.33	29	Sharifi et al. (2013)	6	1.57
9	Gesoglu et al. (2015a)	24	6.3	30	Sherif y Ali (2014)	15	3.94
10	Grdic et al. (2010a)	3	0.79	31	Silva et al. (2016)	5	1.31
11	Güneyisi et al. (2014)	5	1.31	32	Singh et al. (2019)	12	3.15
12	Guo et al. (2020a)	11	2.89	33	Sun et al. (2020)	10	2.63
13	Katar et al. (2021)	4	1.05	34	Surendar et al. (2021)	7	1.84
14	Khodair et al., 2017 Khodair y Luqman (2017a)	20	5.25	35	Tang et al. (2016)	5	1.31
15	Kou & Poon (2009a)	13	3.41	36	Thomas et al. (2016)	4	1.05

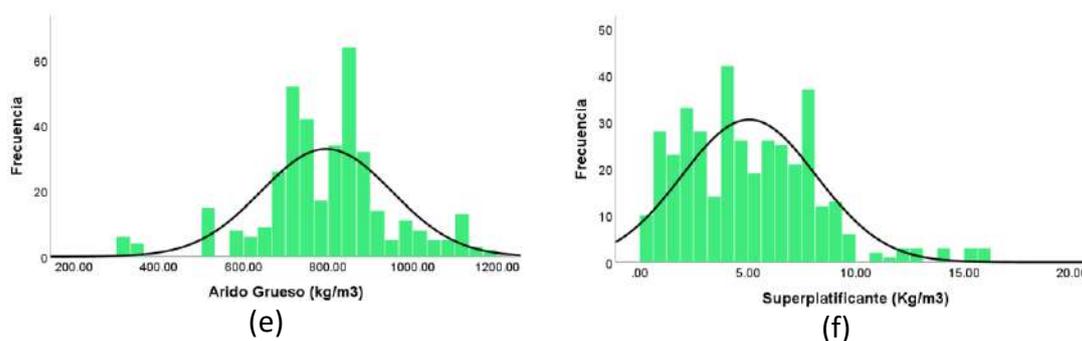
16	Krishna et al. (2018)	5	1.31	37	Tuyan et al. (2014)	12	3.15
17	Kumar et al. (2022)	4	1.05	38	Uygunoğlu et al (2014)	8	2.10
18	Long et al. (2016b)	4	1.05	39	Wang et al. (2020)	5	1.31
19	Mahakavi y Chithra (2020a)	25	6.56	40	Yu et al. (2014)	3	0.79
20	Manziz (2017)	4	1.05	41	Zhou et al. (2013)	6	1.57
21	Martínez-García et al. (2020)	4	1.05		Total	381	100

**Tabla 12.** Valores mínimo, máximo, media, desviación estándar, asimetría y kurtosis de las variables de entrada y salida.

Parámetros	Cmt (kg/m <sup>3</sup> )	MA (kg/m <sup>3</sup> )	W (kg/m <sup>3</sup> )	FA (kg/m <sup>3</sup> )	CA (kg/m <sup>3</sup> )	SP (kg/m <sup>3</sup> )	Fst (MPa)
Min	78.00	0.00	45.50	532.20	328.00	0.00	0.96
Max	550.00	515.00	246.00	1200.00	1170.00	16.00	7.20
media	368.73	138.26	167.29	844.71	796.05	5.07	3.52
SD	98.38	94.94	31.01	130.52	154.06	3.12	1.00
As	-0.849	0.396	-0.365	0.593	-0.292	0.852	0.896
K	0.252	-0.280	1.696	0.728	1.173	1.047	1.477

*Nota:* Min = valor mínimo, Max= valor máximo, SD= desviación estándar, As= asimetría, K= kurtosis





*Nota.* Variables de entrada: (a) Cemento; (b) Aditivo Mineral; (c) Agua; (d) Árido Fino; (e) Árido grueso; (f) Superplastificante.

**Figura 31.** Distribución de frecuencia con curva Normal de las variables de entrada.

### 4.2.3.2 Preprocesamiento de los datos

El pre-procesamiento de los datos es necesario para que los datos sean adecuados para un modelo de ML. La normalización es un procedimiento de pre-procesamiento de los datos; elimina la influencia de las escalas, ya que varias características suelen tener diferentes escalas y dimensiones (Alshdaifat et al., 2021; Liu et al., 2020). La normalización garantiza que todas las características estén en la misma escala. Para ello, los datos de cada característica se convierten en un número entre cero y uno; esto evita que las variables en rango numérico superior dominen a las de rango numérico inferior. Este proceso es fundamental para eliminar la influencia de la dimensión particular y evitar errores durante el desarrollo del modelo (Liu et al., 2020; Özkan et al., 2022). Para normalizar variables de entrada y de salida usadas para modelar de la resistencia a la tracción del HAC con RA, se usó MaxAbs Scaler, donde cada característica se escala empleando su valor máximo, según la Ecuación 8:

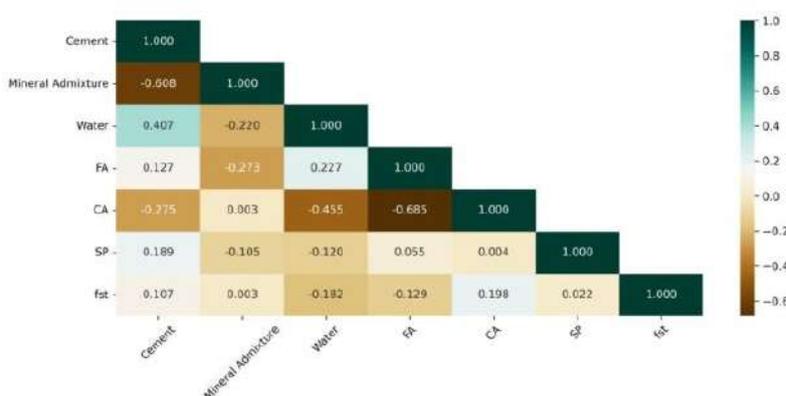
$$x_{scaled} = \frac{x}{\max(|x|)} \quad (8)$$

donde: x es un dato.

### 4.2.3.3 Visualización de los datos

Se analizó la correlación entre las características de entrada (variables independientes) para ver si existe o no dependencia entre las diferentes características, este análisis

estadístico contribuye a la optimización del modelo predictivo (Rathakrishnan et al., 2021a), porque maximiza la predicción de los resultados. Para ello se calcula la matriz de correlación de Pearson (mapa de calor) (Figura 32), analizando la correlación entre las variables independientes (variables de entrada). A pesar de que hubo una correlación relativamente alta entre algunas de las características, como aditivo mineral y cemento ( $r = -0.608$ ) y los áridos gruesos y áridos finos ( $r = -0.685$ ), ninguna correlación entre las característica fue superior a 0.80, lo que indica que no existe multicolinealidad (Hassan y El-Hag, 2020; Koya, 2021).



**Figura 32.** Matriz de correlación de las características de entrada.

#### 4.2.3.4 División de los datos

Para realizar el modelado de la resistencia a la tracción a los 28 días del HAC con RA, se realizó una partición aleatoria de los datos en tres conjuntos diferentes: entrenamiento, validación y prueba, lo que ayudó a evaluar la capacidad de generalización del modelo predictivo. El conjunto de datos de entrenamiento se conformó con 267 mezclas (70%), el conjunto de datos de validación con 57 mezclas (15%) y el conjunto de datos de prueba con 57 mezclas (15%). La tabla 13 muestra el rango y la descripción de las variables de entrada y de salida para los tres conjuntos de datos.

**Table 13.** *Mínimo, máximo, media, desviación estándar, asimetría y kurtosis de las variables de entrada y salida, para cada conjunto de datos.*

Conjunto de datos	Parametro	Cmt	MA	W	FA	CA	SP	fst
Entrenamiento	Unit	kg/m <sup>3</sup>	MPa					
	Min	94.00	0.00	45.50	581.00	328.00	0.00	1.40
	Max	520.00	390.00	246.00	1200.00	1170.00	16.00	7.10
	Media	371.83	135.10	168.03	846.72	790.32	4.83	3.51
	SD	93.32	92.02	31.63	129.38	154.51	2.91	0.99
	As	-0.91	0.30	-0.20	0.695	-0.53	0.62	0.91
	K	0.52	-0.68	1.60	0.79	1.35	0.53	0.15
Validación	Min	78.00	0.00	45.50	532.50	335.00	0.00	0.96
	Max	520.00	515.00	246.00	1200.00	1170.00	16.00	6.40
	Media	375.55	143.57	167.53	851.13	789.75	5.86	3.45
	SD	95.29	107.03	32.34	142.14	151.80	3.40	0.13
	As	-1.01	0.92	-1.13	0.25	0.01	1.07	0.76
	K	1.50	1.32	3.21	.17	1.06	1.50	0.32
	Min	111.00	0.00	104.30	532.20	530.00	0.00	1.45
Prueba	Max	550.00	320.00	203.40	1200.00	1150.00	16.00	7.20
	Media	347.36	147.79	163.56	828.85	829.21	5.41	3.61
	SD	121.12	69.60	26.69	127.79	152.64	3.62	1.06
	As	-0.43	0.05	-0.57	0.53	0.57	1.07	0.96
	K	-1.02	-1.14	-0.40	1.55	-0.02	0.89	1.70

*Nota:* Min = valor mínimo, Max= valor máximo, SD= desviación estándar, As= asimetría, K= kurtosis.

### 4.2.3.5 Evaluación de los modelos

Se utilizaron cuatro métricas para evaluar el rendimiento de los modelos: Coeficiente de Determinación ( $R^2$ ) (Ecuación 2), Raíz del Error Medio Cuadrático (RMSE) (Ecuación 3) y Error Absoluto Medio (MAE) (Ecuación 4). Estas métricas estiman los errores en las predicciones de la resistencia a la tracción a los 28 días del HAC con RA cuando se comparan con las observaciones reales (Azizifar y Babajanzadeh, 2018; Kang et al., 2021; Nafees et al., 2021; Olu-Ajayi et al., 2022).

Ahora bien, el valor  $R^2$  se considera el mejor de estas métricas para la evaluación de modelos (Nafees et al., 2021; Rathakrishnan et al., 2021). La Tabla 14 muestra el rango de valores de  $R^2$  para las evaluaciones de los modelos de predicción (Marani y Nehdi, 2020; Nafees et al., 2022; Ray et al., 2021).

**Tabla 14.** *Criterios estadísticos para  $R^2$ .*

$R^2$	Tasa de rendimiento	Poder de pronóstico
$\geq 0.95$	Excelente	Predicción muy precisa
0.75 - 0.95	Muy bueno	Predicción buena
0.65 - 0.75	Satisfactorio	Predicción aceptable
$< 0.65$	Insatisfactorio	Imprecisa para la predicción

Por otro lado, mientras más cercanos a cero sean los valores de la raíz del error medio cuadrático y del Error Absoluto Medio, mejor será el rendimiento del modelo ML en la predicción de la resistencia a la tracción del HAC con RA a los 28 días (Farooq et al., 2021; Kovačević et al., 2021; Olu-Ajayi et al., 2022; Song et al., 2021).

## 4.2.4 Resultados y discusión

### 4.2.4.1 Comparación del rendimiento predictivo de los modelos ML

Dado que la métrica  $R^2$  es más intuitivo y conveniente para Comparar el rendimiento de diferentes modelos ML (Nafees et al., 2021; Rathakrishnan et al., 2021), en el siguiente análisis se adopta como índice métrico principal. La precisión de la predicción se refleja en el valor de  $R^2$ , y un valor elevado de esta métrica indica que el modelo presenta una alta precisión de la predicción. También, se consideraron los valores de las métricas RMSE y MAE; los valores inferiores a 0.05 indican que el modelo ML presenta un buen ajuste (Rathakrishnan et al., 2021; Schermelleh-Engel et al., 2003) para predecir la resistencia a la tracción del HAC con RA a los 28 días. La tabla 15 muestra los resultados de  $R^2$  tanto del conjunto global de datos como los del conjunto de datos de entrenamiento y prueba de los modelos: XGBoost, GB, CB y ETR. Los valores de  $R^2$  del conjunto global de datos de los cuatro modelos oscilaron entre 0.7717 y 0.8428 MPa, mostrando valores superiores a 0.75. Estos valores indican que los modelos tienen una buena capacidad de predicción, según los criterios estadísticos establecidos para  $R^2$  (Nafees et al., 2022; Ray et al., 2021). Además, los valores de la raíz del error medio cuadrático y del Error Absoluto Medio oscilaron entre 0.0225 y 0.0270 MPA y 0.0066 y

0.0078 MPa, respectivamente. Estos valores, tan cercanos a cero, indican que los modelos de predicción XGBoost, GB, CB y ETR presentan una gran concordancia entre los datos predichos y los datos experimentales reales obtenidos del HAC con RA.

Por otro lado, en lo que respecta a los datos de entrenamiento, se puede observar que los valores de  $R^2$  oscilan entre 0.9292 y 0.9421 (Tabla 15), siendo todos los valores superiores a 0.90, esto muestra que los cuatro modelos son buenos predictores de la resistencia a la tracción para el HAC con RA.

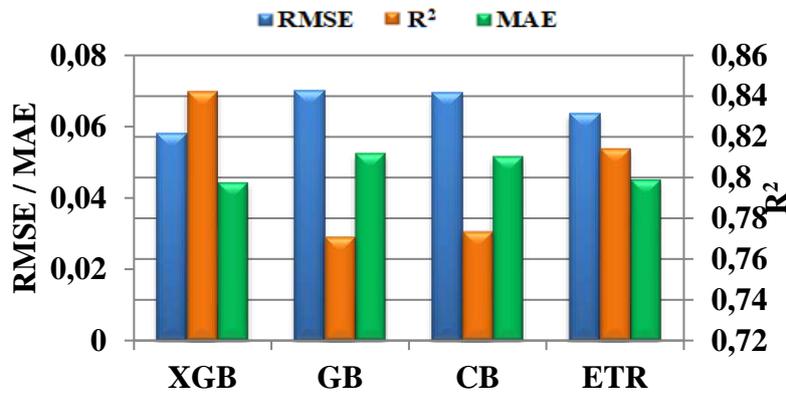
**Tabla 15.** Rendimiento de XGBoost, GB, CB y ETR con diferentes parámetros.

Parámetros		XGBoost	GB	CB	ETR
$R^2$	Prueba	0.8423	0.7709	0.7736	0.8143
	Entrenamiento	0.9421	0.9292	0.9382	0.9484
	Global	0.8428	0.7717	0.7744	0.8149
RMSE	Prueba	0.0581	0.0700	0.0696	0.0636
	Entrenamiento	0.0329	0.0365	0.0341	0.0311
	Global	0.0225	0.0270	0.0269	0.0244
MAE	Prueba	0.0443	0.0525	0.0516	0.0451
	Entrenamiento	0.0188	0.0239	0.0217	0.0127
	Global	0.0066	0.0078	0.0077	0.0067

Para seleccionar el modelo que mejor se ajusta a una buena predicción de la resistencia a la tracción a los 28 días (del HAC con RA), se realizó una comparación de las métricas de los datos de prueba. El modelo XGBoost tuvo el mejor rendimiento predictivo, con el valor más alto de  $R^2 = 0.8423$  (Tabla 15). Considerando así, que XGBoost predice la resistencia a la tracción con muy buena precisión (Nafees et al., 2022; Ray, Rahman, Haque, et al., 2021); así como los valores de RMSE y MAE más bajos (0.0581 MPa y 0.0443 MPa, respectivamente), indican que es un buen ajuste del modelo y una gran capacidad para generalizar. Según Guo et al. (2021) la alta precisión del modelo XGBoost puede atribuirse a su arquitectura, que permite una mejor representación de la relación entre las variables de entrada y salida.

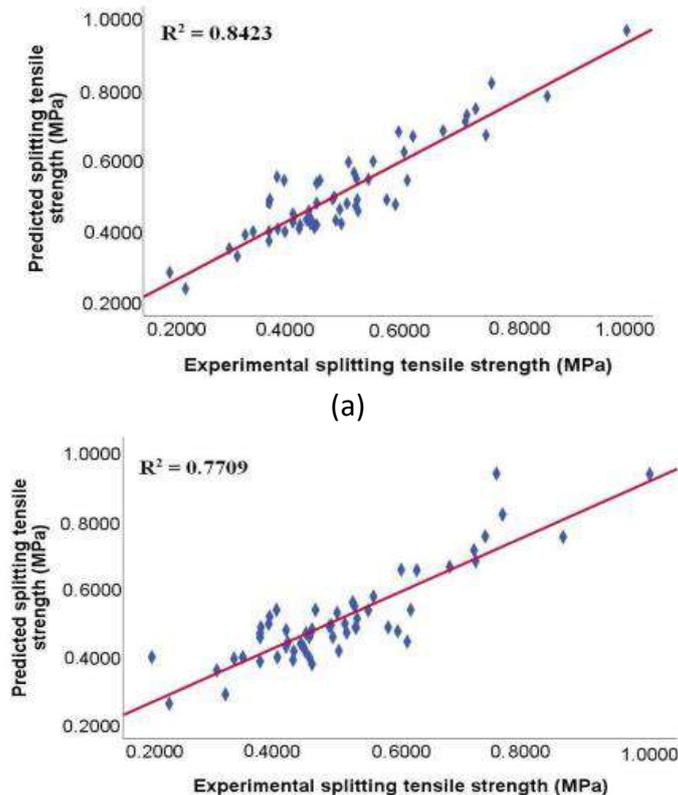
La Figura 33 muestra el comportamiento predictivo del modelo XGBoost, superando a los modelos GB, CB y ETR en lo que respecta al valor de  $R^2$ , además de tener los valores más bajos de la raíz del error medio cuadrático y del Error Absoluto Medio, lo que indica

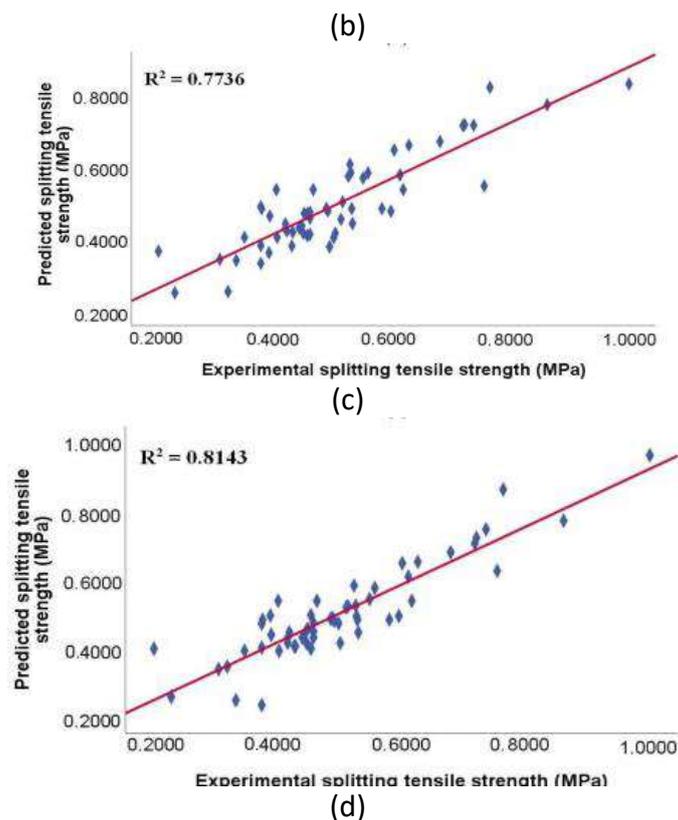
que el modelo XGBoost presenta un buen ajuste en la predicción de la resistencia a la tracción a los 28 días del HAC con RA (Guo et al., 2021; Lyngdoh et al., 2022; H. Nguyen et al., 2021).



**Figura 33.** R2, RMSE, MAE and MAPE de los modelos ML.

Por otro parte, la Figura 34 muestra la correlación entre la resistencia a la tracción experimental y la predicha para los datos de prueba, donde puede observarse que todos los modelos predicen bien las mediciones reales.





Nota. Modelos: (a) XGBoost; (b) GB; (c) CB; (d) ETR.

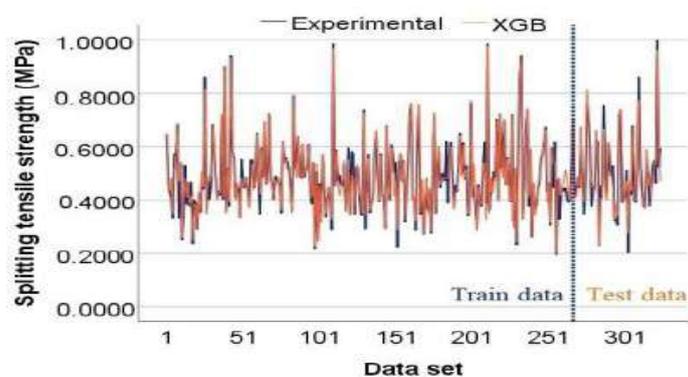
**Figura 34.** Comparación de la resistencia a la tracción de los modelos, para la data de prueba.

Sin embargo, en el gráfico de dispersión del modelo XGBoost (Figura 34a) los valores se agrupan mejor con respecto a la línea de predicción en comparación con los otros modelos, presentando así menos dispersión. Estos resultados muestran que el modelo XGBoost puede predecir razonablemente la resistencia a la tracción, estos resultados son similares a hallazgos de estudios anteriores (Guo et al., 2021; Lyngdoh et al., 2022; H. Nguyen et al., 2021). Por el contrario, GradientBoost (GB) fue el modelo que mostró la precisión más baja con un valor de  $R^2 = 0.9292$  (Tabla 15), esto se ve reflejado en el gráfico de dispersión (Fig 34b), donde se aprecian una mayor dispersión de los valores alrededor de la línea de predicción. Este resultado coincide con los hallazgos de (H. Nguyen et al., 2021), al contrastar los valores de XGBoost con Gradient Boost.

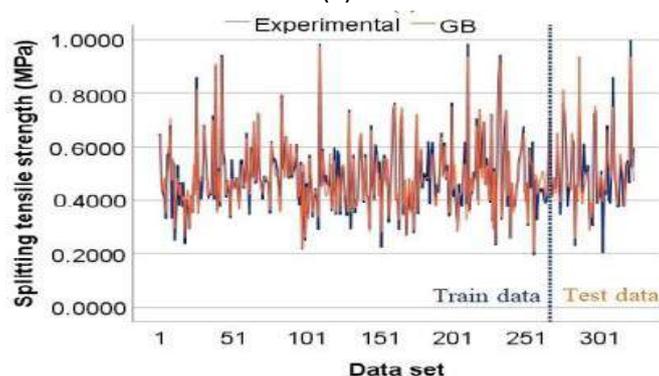
## 4.2.4.2 Comparación de los resultados de los modelos

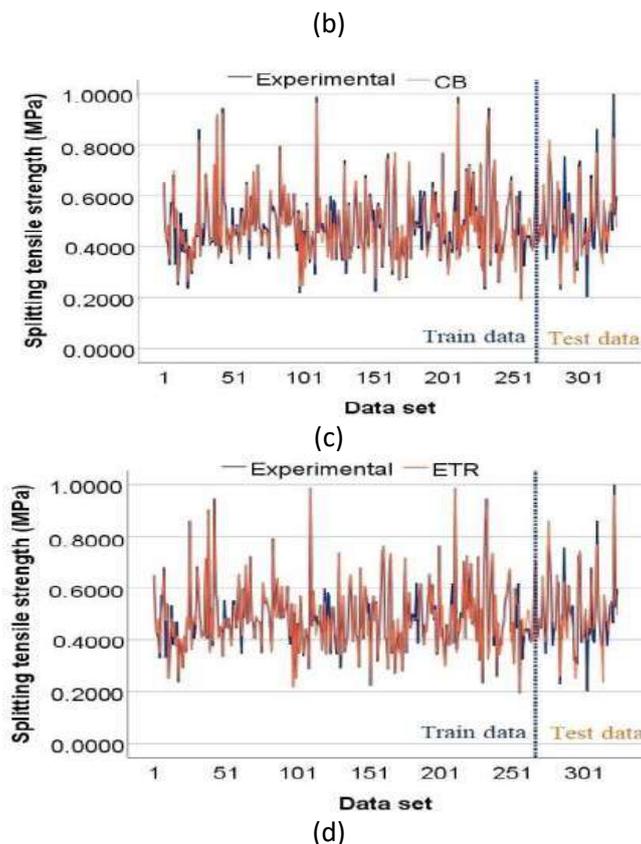
### ML

La Figura 35 muestra la resistencia a la tracción del HAC con RA experimental y predicha para los modelos: XGBoost, GB, CB y ETR, donde el número de muestras igual a 267 es el margen de los resultados de los datos de entrenamiento y de prueba, este está representado por la línea pespunteada vertical azul. Las curvas dadas ilustran que los valores predichos a partir de los modelos XGBoost, GB, CB y ETR están bien correlacionados con los valores experimentales de la resistencia a la tracción. Estos modelos permiten reconocer los patrones incrustados en los datos experimentales. Las líneas de color azul reflejan el comportamiento de los datos experimentales en cada gráfico, mientras que las de color rojo muestran los valores predichos. Cuanto más significativa es la diferencia entre las líneas de los valores experimentales y los valores predichos, esto indica mayores errores. Así el gráfico que mejor ajuste presenta es la del modelo XGBoost (Figura 35a). Esto sugiere que el modelo XGBoost puede predecir con precisión la resistencia a la tracción mejor que GB, CB y ETR, por tanto, es el mejor modelo.



(a)





Nota. Modelos: (a) XGB; (b) GB; (c) CB; (d) ETR.

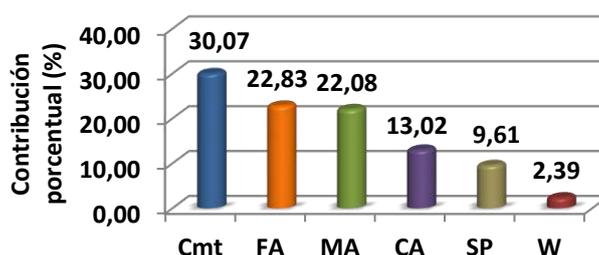
Figura 35. Resistencia a la tracción experimental y predicha para los modelos.

### 4.2.4.3 Análisis de sensibilidad

El análisis de ayuda a comprender la influencia de cada variable de entrada sobre la variable de salida. Cuanto más alto sean los valores de sensibilidad, más significativo será la incidencia de las variables de entrada sobre la variable de salida. Según Shang et al. (2022) las variables de entrada tienen un impacto notable en la predicción de la variable de salida. Para evaluar el efecto de cada variable de entrada: cemento, aditivo mineral, agua, áridos finos, áridos gruesos y superplastificantes en la incertidumbre de la resistencia a la tracción (del HAC con RA) se determinó el análisis de sensibilidad mediante las ecuaciones 6 y 7.

Cada una de las anteriores variables de entrada juega un papel importante en la predicción de la resistencia a la tracción del HAC con RA, tal como se muestra en la Figura 36. El cemento (30.07%), el árido fino (22.83%) y el aditivo mineral (22.08%) son las que más contribuyen en la predicción del fst del HAC con RA. En relación a esto, Shang et al.

(2022) afirmaron que el cemento es un elemento que influye decisivamente en la predicción de la resistencia a la tracción del hormigón autocompactante fabricado con áridos reciclados. También se puede observar que las variables de entrada árido grueso y superplastificante tuvieron contribuciones similares de 13.02% y 9.61% respectivamente. Finalmente, el agua (2.39%) fue la variable menos influyente en la predicción de la resistencia a la tracción, estos resultados coinciden con los hallazgos de investigaciones anteriores (Shang et al., 2022).



*Nota.* Cmt = Cemento; FA= árido fino; MA = aditivo mineral; CA = árido grueso; SP = superplastificante y W = agua.

**Figura 36.** Contribución de las variables de entrada a la resistencia a la tracción en el modelo XGBoost.

## 4.2.5 Conclusiones parciales

El objetivo de este apartado fue Comparar las capacidades para predecir la resistencia a la tracción a los 28 días del HAC con RA de cuatro métodos de ML: XGBoost, GB, CB y ETR. Además, se investigó la contribución de cada variable de entrada en la predicción de la resistencia a la tracción a los 28 días del HAC con RA a través del análisis de sensibilidad. Para este propósito se consideraron las siguientes variables de entrada: cemento, agua, aditivo mineral, áridos finos, áridos gruesos y superplastificante. Para evaluar la capacidad predictiva de los modelos se utilizaron las métricas:  $R^2$ , RMSE y MAE. De esta investigación se extrajeron las siguientes conclusiones:

1. Para el desarrollo de los modelos ML: XGBoost, GB, CB y ETR se utilizó una base de datos de 381 muestras procedentes de literatura publicada en revistas científicas. Las mismas se dividieron aleatoriamente en tres conjuntos de datos:

entrenamiento, validación y prueba, cada uno con 267 (70%), 57 (15%) y 57 (15%) muestras, respectivamente.

2. Los cuatro métodos de ML predijeron la resistencia a la tracción del HAC con RA con una precisión satisfactoria; los valores de  $R^2$  de los datos de entrenamiento para XGBoost, GB, CRB y ETR iguales 0.9421; 0.9292; 0.9382 y 0.9484, respectivamente, y todos los modelos alcanzaron un valor superior a 0.75.
3. XGBoost fue el modelo con mejor rendimiento, al mostrar para el conjunto de datos de prueba, el valor más alto de  $R^2 = 0.8423$ , así como los valores más bajos de RMSE = 0.0581 y MAE = 0.0443, en comparación con los modelos GB, CB y ETR.
4. XGBoost se considera el mejor modelo para predecir la resistencia a la tracción a los 28 días del HAC con RA
5. El análisis de sensibilidad reveló que el cemento es la variable de entrada que más contribuye (30.07%) a la predicción de la resistencia a la tracción a los 28 días del HAC con RA, seguido de áridos finos y aditivos minerales con una contribución superior al 20%. En cambio, el agua es el parámetro que menos contribuye (2.39%) a la misma predicción.

### 4.3 PREDICCIÓN DE LA RESISTENCIA A LA TRACCIÓN DEL HORMIGÓN AUTOCOMPACTANTE CON ÁRIDOS RECICLADOS USANDO MÉTODOS DE APRENDIZAJE PROFUNDO

El hormigón es el material de construcción más utilizado en todo el mundo. Una de las principales tareas arduas es producir un hormigón duradero sin excesivos huecos y con una larga vida útil (Bilim et al., 2009). Debido a una amplia investigación, la tecnología de diseño del hormigón ha mejorado en los últimos años mediante la adición de determinados aditivos (Li, 2011; Saidova et al., 2021). El hormigón autocompactante, creado en Japón en la década de 1980 para conseguir edificios de hormigón de alto rendimiento y larga duración, es uno de los resultados de la mejora de la tecnología de

diseño del hormigón (Okamura y Ouchi, 2003; Zaid et al., 2021; Zaid, Hashmi, et al., 2022). La principal distinción entre el hormigón autocompactante y el convencional es la proporción de mezcla de los materiales (Smirnova et al., 2021; Yakovlev et al., 2021; Zaid, Mukhtar, et al., 2022). El HAC se asienta bajo su peso haciendo su recorrido como un fluido (Nikbin et al., 2014; Smirnova, 2018; Smirnova et al., 2021). El HAC se considera innovador porque puede utilizarse fácilmente en zonas congestionadas donde el hormigonado no es fácil. Con el HAC se reduce la contaminación acústica y se mejora la capacidad de llenado y la velocidad de construcción (Althoey et al., 2022; Nikbin et al., 2014; Zaid et al., 2021).

La población está creciendo a un ritmo alarmante en todo el mundo con la adopción e implementación de nuevas tecnologías de diseño de hormigón, lo que provoca un mayor consumo de recursos y la degradación del medio ambiente. En consecuencia, ha aumentado la cantidad de residuos de la construcción (Borrero et al., 2021; Tam et al., 2007). En cuanto a la composición del hormigón, los áridos gruesos (piedra natural triturada) y los finos (arena) constituyen la mayor parte del hormigón autocompactante, aproximadamente el 60-70% (Aslam et al., 2022; Daungwilailuk et al., 2017; Huang et al., 2020; Jiradilok et al., 2020). Al mismo tiempo, los recursos naturales se están agotando a gran velocidad debido a la urbanización moderna (J. Ahmad et al., 2021; Aslam et al., 2022; Smirnova et al., 2022). La principal fuente de áridos de buena calidad, es decir, las montañas, se está agotando a un ritmo alarmante (Carvalho, 2017; Zaid, Hashmi, et al., 2022; Zaid, Martínez-García, et al., 2022). Por ello, las catástrofes naturales han golpeado a muchos países del mundo (Kaewunruen y Meesit, 2020; Smirnova, 2019; Smirnova, 2020). Por otra parte, cada año se derriban muchos edificios a causa de los terremotos o después de completar su vida útil (Daungwilailuk et al., 2017; Kaewunruen y Meesit, 2020; H. Y. T. Nguyen et al., 2018). Por ello, cada año se genera una cantidad considerable de residuos de la construcción. Para contrarrestar esta situación, la revolución más sostenible es utilizar áridos reciclados en el hormigón autocompactante. Los áridos reciclados (RA) son productos de desecho abundantes mediante la demolición del edificio y su posterior trituración, cribado y limpieza adecuada (Berndt, 2009). El segundo procedimiento consiste en obviar todos estos

trabajos experimentales, reduciendo así la degradación medioambiental y otros desperdicios de materiales naturales.

En la actualidad, muchos investigadores están trabajando en el uso de técnicas de soft computing. Una de estas técnicas es el uso de una red neuronal artificial (ANN) para validar y predecir parámetros específicos del hormigón. La técnica de las redes neuronales artificiales está generalmente motivada por nuestro cerebro humano, que está compuesto por miles de millones de neuronas. La ANN funciona de forma similar, aprendiendo de las experiencias y utilizando los datos para predecir diferentes parámetros (Dabiri et al., 2022; Nikoo et al., 2015).

## 4.3.1 Literatura de referencia

### 4.3.1.1 Redes neuronales artificiales

Las Redes Neuronales Artificiales (ANNs) son una técnica fundamental en el Aprendizaje Profundo. El Aprendizaje Profundo (DL) es un subconjunto del Aprendizaje Automático (ML) que permite el cálculo de redes neuronales multicapa. El Aprendizaje Automático es un subconjunto de la Inteligencia Artificial (IA) que utiliza métodos estadísticos para permitir que los ordenadores se desarrollen a lo largo del tiempo, a diferencia del tema principal de la IA, que permite a las máquinas imitar el comportamiento humano. La principal diferencia entre el ML y el DL es que, en el Aprendizaje Profundo, la máquina hace la extracción de características, y la clasificación. Sin embargo, en el Aprendizaje Automático, debemos realizar la extracción de características nosotros mismos, y la máquina hace la clasificación y la predicción (Du et al., 2016).

Una red neuronal artificial (ANN) es un modelo matemático o informático inspirado en la enorme red neuronal biológica del cerebro humano (Schmidhuber, 2015). Puede mejorar su rendimiento aprendiendo de sus errores, que es como una Red Neuronal Artificial recibe la información, es decir, aprendiendo. Se compone de varias funciones y pesos que operan como neuronas artificiales y se conectan en red. Se utilizan principalmente en proyectos de inteligencia artificial que resuelven problemas complicados y complejos (Nikoo et al., 2015). Las ANN pueden funcionar mediante

algoritmos específicos que son únicos en su género. Desde el punto de vista del artículo, a continuación, se analizan LM, BR y SCGB.

#### 4.3.1.1.1 Algoritmo Levenberg-Marquardt

El algoritmo de Levenberg-Marquardt (LM) es un procedimiento compuesto por varias iteraciones. Estas iteraciones se utilizan para encontrar el valor mínimo de una función multivariante escrita como la suma de cuadrados de funciones no lineales de valor real (Levenberg, 1944; Marquardt, 1963). Los investigadores han adoptado recientemente este enfoque para resolver problemas complejos de mínimos cuadrados no lineales en una amplia gama de campos (Mittelmann, 2004). En el algoritmo LM, se combinan dos métodos para acelerar las iteraciones y minimizar el error, es decir, el descenso más pronunciado y el método de Gauss-Newton. Cuando el resultado actual es correcto, el algoritmo se convierte en el método de Gauss-Newton más rápido que otro. Y cuando el resultado es incorrecto, se comporta como el descenso Steepest que es relativamente lento pero siempre converge (Madsen et al., 2004). Este algoritmo generalmente utiliza más memoria, pero menos tiempo.

#### 4.3.1.1.2 Regularización Bayesiana

Las redes de retropropagación estándar son menos fiables que las redes neuronales artificiales regularizadas bayesianas (BRANNs), que pueden disminuir o eliminar el requisito de una validación cruzada prolongada (Mackay, 1992). De la misma manera que la regresión de cresta convierte una regresión no lineal en una cuestión estadística "bien planteada", la regularización bayesiana hace lo mismo con la regresión no lineal. Utilizan más tiempo, pero el modelo tiene numerosas ventajas sobre los datos complejos (Winkler y Burden, 2000). La ventaja de utilizar las BRANNs es que los modelos son fiables y no es necesario el procedimiento de validación (Hawkins et al., 2003; Mackay, 1992). Estas redes abordan varias cuestiones que surgen en el modelado de la relación cuantitativa estructura-actividad (QSAR), incluyendo la selección del modelo, la robustez, la selección del conjunto de validación y la optimización de la arquitectura de la red (Lučić et al., 2000). Los criterios bayesianos se detienen para el entrenamiento por los procesos empíricos, haciendo imposible el sobreentrenamiento.

### 4.3.1.1.3 Gradiente escalado conjugado de retropropagación

Los pesos se sintonizan en la dirección de descenso más pronunciada, es decir, la más negativa del gradiente, mediante el método fundamental de retropropagación. Este es el camino de reducción más rápido para la función de rendimiento. Se observa que, aunque la función se reduce más rápidamente junto con el negativo del gradiente, esto no conduce a la convergencia más rápida (Hagan et al., 2002)

Los algoritmos de gradiente conjugado buscan en un camino que produce generalmente una convergencia más rápida que la dirección de descenso más aguda, manteniendo la reducción de error realizada en las fases anteriores (Kişi y Uncuoğlu, 2005). La dirección conjugada es el nombre dado a esta dirección. El tamaño del paso se modifica en la mayoría de los algoritmos de gradiente conjugado en cada iteración. Se realiza una búsqueda a lo largo de la dirección del gradiente conjugado para calcular el tamaño de paso que disminuirá la función de rendimiento a lo largo de esa línea (Demuth et al., 2009). También es razonable aproximar el tamaño del paso utilizando un método distinto a la metodología de búsqueda de líneas. El objetivo es fusionar el método de la región de confianza del modelo del algoritmo de Levenberg con la técnica del gradiente conjugado. SCG es el nombre dado a este método, que fue descrito por primera vez en la literatura por Møller (1993) En cada usuario de la iteración, los parámetros de diseño se actualizan de forma independiente, lo que es crítico para el éxito del algoritmo. Esta es una ventaja esencial de los algoritmos basados en la búsqueda de líneas (Møller, 1993).

### 4.3.1.2 Importancia de la investigación

Esta publicación tuvo como objetivo validar y predecir la resistencia a la tracción del hormigón autocompactante incorporado con áridos reciclados mediante Redes Neuronales Artificiales. No se han realizado estudios significativos sobre la aplicación de diferentes métodos de aprendizaje profundo para predecir la resistencia a la tracción del HAC con RA. Para ello, se implementaron diferentes algoritmos, a saber, los algoritmos de Levenberg Marquardt (LM), de Regularización Bayesiana (BR), y de Gradiente Escalado Conjugado de Retropropagación (SCGB). Se seleccionó el mejor

modelo tras Compararlos mediante indicadores estadísticos: coeficiente de correlación (R) y error medio cuadrático (MSE). Al final, se realizó un análisis de sensibilidad para ver cómo afectaba cada variable de entrada a la de salida

## 4.3.2 Metodología

### 4.3.2.1 Recogida de datos

Los datos se recogen de varios artículos de investigación. La Tabla 16 muestra la base de datos que contiene un total de 381 muestras que comprenden la resistencia a la tracción del hormigón autocompactante con áridos reciclados con diversas variables como agua, cemento, aditivos, áridos gruesos, agua, áridos finos y superplastificantes. La base de datos incluye el número de referencia que indica el número total de artículos de investigación, las referencias de los autores, la cantidad de datos (# datos) que aporta cada artículo y el porcentaje (% datos) de los datos globales.

**Tabla 16.** Base de datos experimental.

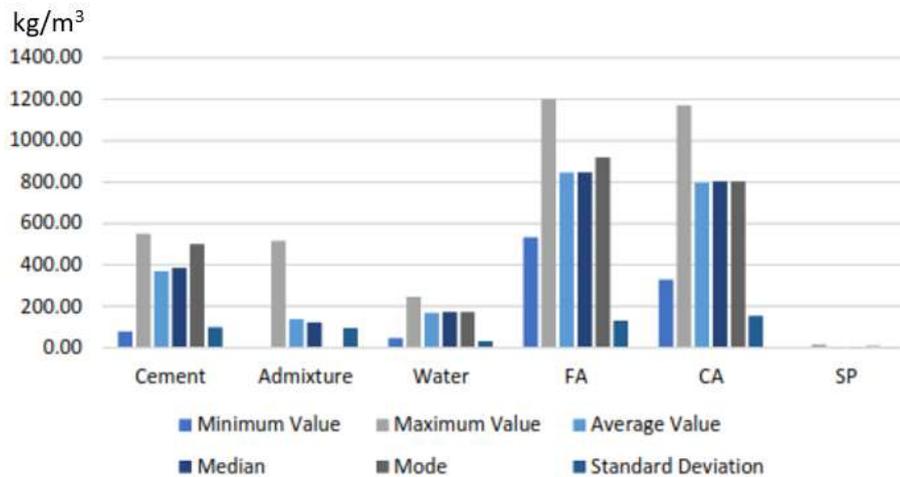
No	Referencia	# data	% data	No	Referencia	# data	% data
1	Ali y Al-Tersawy (2012)	18	4.72	22	Nieto et al. (2019)	22	5.77
2	Aslani et al. (2018)	15	3.94	23	Nili et al. (2019)	10	2.62
3	Babalola et al. (2020)	14	3.67	24	Pan et al. (2019)	6	1.57
4	Bahrami et al. (2020)	10	2.62	25	Revathi et al. (2013)	5	1.31
5	Behera et al. (2019)	6	1.57	26	Revilla-Cuesta et al. (2020)	5	1.31
6	Chakkamalayath et al. (2020)	6	1.57	27	Sadeghi-Nik et al. (2019)	12	3.15
7	Duan et al. (2020)	10	2.62	28	Señas et al. (2016)	6	1.57
8	Fiol et al. (2018)	12	3.15	29	Sharifi et al. (2013)	6	1.57
9	Gesoglu et al. (2015)	24	6.30	30	Khafaga (2014)	15	3.94
10	Grdic et al. (2010)	3	0.79	31	Silva et al. (2020)	5	1.31
11	Güneyisi et al. (2014)	5	1.31	32	Singh et al. (2019)	12	3.15
12	Guo et al. (2020)	11	2.89	33	Sun et al. (2020)	10	2.62

13	Katar et al. (2021)	4	1.05	34	Surendar et al. (2021)	7	1.84
14	Khodair & Luqman (2017)	20	5.25	35	Tang et al. (2016)	5	1.31
15	Kou & Poon (2009)	13	3.41	36	Thomas et al. (2016)	4	1.05
16	Krishna et al. (2018)	5	1.31	37	Tuyan et al. (2014)	12	3.15
17	Kumar et al. (2022)	4	1.05	38	Uygunoğlu et al. (2014)	8	2.10
18	Long et al. (2016)	4	1.05	39	Wang et al. (2020)	5	1.31
19	Mahakavi & Chithra (2020)	25	6.56	40	Yu et al. (2014)	3	0.79
20	Manzi et al. (2017)	4	1.05	41	Zhou et al. (2013)	6	1.57
21	Martínez-García et al. (2020)	4	1.05		Total	381	100

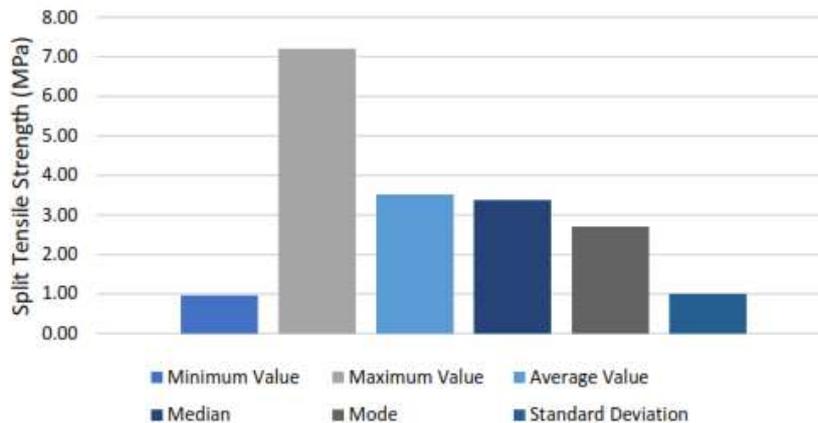
La Tabla 17 presenta las características estadísticas, como el mínimo, el máximo, la media, la mediana, la moda y la desviación estándar, de ciertas variables como entradas (agua, cemento, aditivos, áridos gruesos, agua, áridos finos y superplastificantes) y una posible salida de estos artículos de investigación publicados, es decir, la resistencia a la tracción del hormigón autocompactante de áridos reciclados. Su representación gráfica se muestra en la Figura 37 y la Figura 38.

**Tabla 17.** *Valores mínimos, medios y máximos de las variables de entrada y salida.*

	Variables	Abreviatura	Mínimo	Media	Máximo
Entrada (kg/m <sup>3</sup> )	Cemento	C	78.00	368.73	550.00
	Aditivos	A	0.00	138.27	515.00
	Agua	W	45.50	167.29	246.00
	Áridos fino	FA	532.20	844.71	1200.00
	Áridos gruesos	CA	328.00	196.05	1170.00
	Superplastificantes	SP	0.00	5.07	16.00
Salida (MPa)	Resistencia a la tracción	TS	0.96	3.52	7.20



**Figura 37.** Características estadísticas de las variables de entrada.

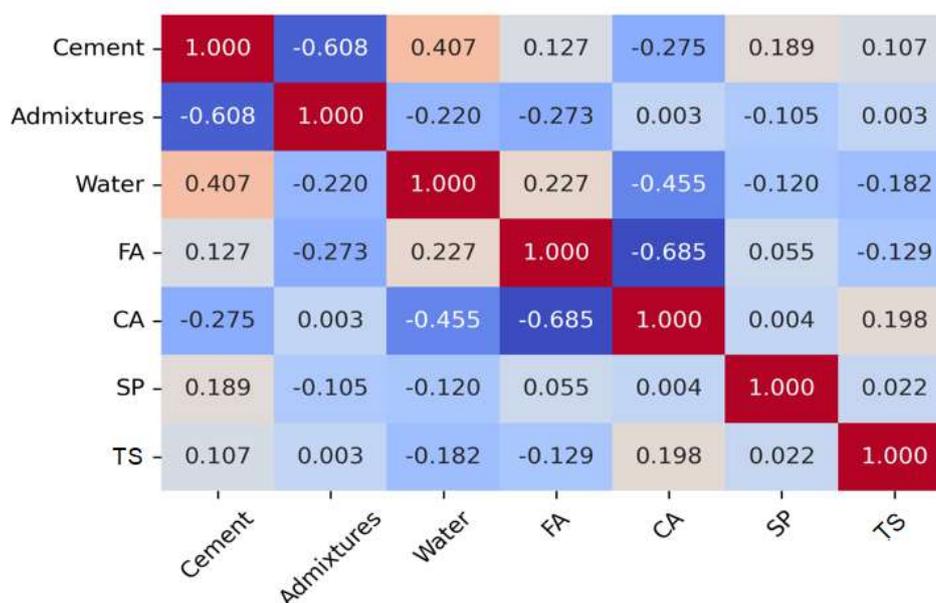


**Figura 38.** Características estadísticas de la variable de salida.

### 4.3.2.2 Visualización de datos

La correlación entre las variables de entrada: agua, cemento, aditivos, agregados gruesos, agregados finos y superplastificantes, y la variable de salida: resistencia a la tracción (TS), se investigó para ver si había una relación entre ellos; este análisis estadístico ayudó a la creación del modelo de predicción mediante el aumento de la precisión de la predicción del resultado (Rathakrishnan et al., 2021). Para ello, se generó la matriz de correlación de Pearson (mapa de calor), como se muestra en la Figura 39, que analizó la correlación entre las variables de entrada independientes. Una correlación ( $|r| > 0,8$ ) entre las variables de entrada podría indicar que existe actualmente multicolinealidad entre las variables, lo que podría alterar los resultados

de la modelización y sesgar el modelo. Como se ve en el mapa de calor, aunque existe correlación entre algunas de las características, como entre los aditivos y el cemento ( $r = -0.608$ ) y entre los áridos gruesos y los finos ( $r = -0.685$ ), ninguna de las características correlaciona más de 0,80, lo que demuestra que no se produce multicolinealidad (Koya, 2021; Nayyar Hassan y El-Hag, 2020).



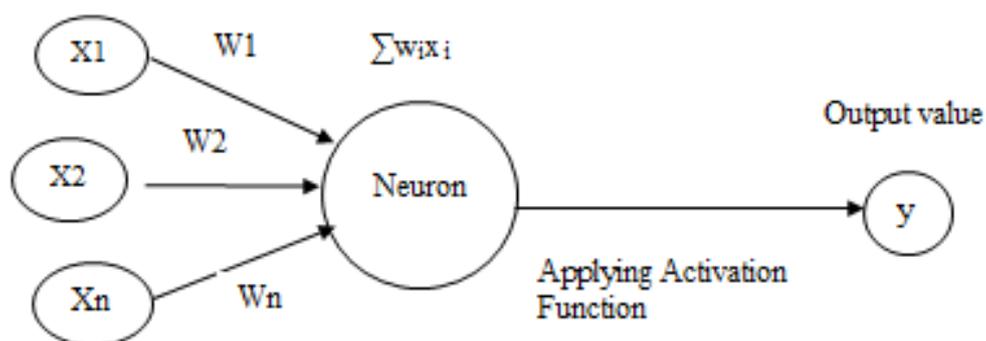
**Figura 39.** Mapa de calor del coeficiente de correlación entre las variables de entrada y salida.

### 4.3.2.3 Redes neuronales artificiales para el entrenamiento, validación y la predicción de la resistencia a tracción

Una red neuronal artificial (ANN) es un modelo matemático o computacional influenciado por las características estructurales y/o funcionales de las redes neuronales biológicas. Puede mejorar su rendimiento aprendiendo de sus errores. Las redes neuronales artificiales, al igual que los cerebros humanos, adquieren conocimientos mediante el aprendizaje. Están formadas por una red de neuronas artificiales que se comunican entre sí y analizan los datos mediante un enfoque conexionista de la computación. Se emplean principalmente para simular complicadas interacciones de

entrada-salida o patrones de datos (Althoey et al., 2022). El entrenamiento, la validación y la prueba son las tres fases de las ANNs. El modelo se repite hasta alcanzar el resultado deseado en la fase de entrenamiento. Los errores de la fase de validación se detectan durante la fase de entrenamiento (Khademi et al., 2016).

Un modelo de ANN suele constar de varias capas, la primera de las cuales es la de entrada y salida, que contiene los datos de entrada y salida. Dependiendo del modelo, entre estas capas existen una o varias capas ocultas. Se compone de neuronas que están unidas por pesos. La salida de cada neurona viene determinada por su función de activación. Las funciones de activación tienen varias formas diferentes. Las funciones de activación no lineales, como la sigmoidea y la escalonada, se emplean habitualmente (Bilim et al., 2009). La estructura general de la ANN se muestra en la Figura 40.



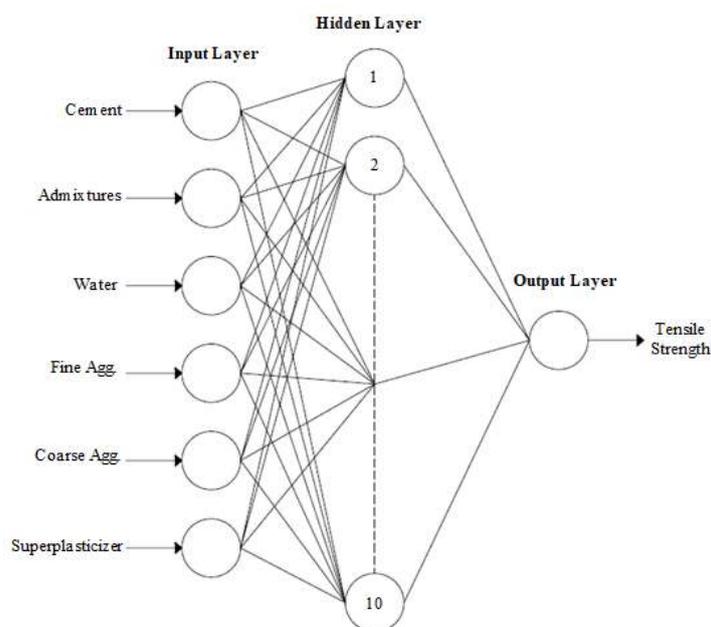
**Figura 40.** Estructura general de ANN.

Al crear un modelo de ANN hay que tener en cuenta una serie de factores. El primer paso es seleccionar la estructura más adecuada para el modelo de ANN. A continuación, se insertan los datos en el modelo de ANN seleccionado en términos de entrada y salida. A continuación, en la función de activación, el número de capas y el número de capas ocultas, así como algunas neuronas en cada capa oculta deben seleccionarse por experiencia (Hanbay et al., 2008; Uysal y Tanyildizi, 2011).

En esta investigación, en relación con la Tabla 16 y la Tabla 17, la red se realiza utilizando seis parámetros de entrada y uno de salida con una capa oculta. La capa de entrada consiste en variables como el cemento, los aditivos, el agua, los áridos finos y gruesos y el superplastificante. El parámetro de salida se seleccionó mediante la resistencia a la

tracción del hormigón autocompactante de áridos reciclados. En este estudio se utilizó la red neuronal feedforward backpropagation. La arquitectura de la presente investigación de la RNA se muestra en la Figura 41.

Cabe destacar que en este estudio se utilizaron y Compararon tres algoritmos, a saber, Levenberg-Marquardt (LM), Regularización Bayesiana (BR) y Gradiente Conjugado Escalado (SCG). El diseño y la ejecución de la red se realizaron en el software MATLAB. El algoritmo de Levenberg-Marquardt suele necesitar más memoria, pero tarda menos tiempo. El entrenamiento termina cuando la generalización deja de mejorar, como demuestra el aumento del error cuadrático medio de las muestras de validación. Pero en el caso de la Regularización Bayesiana, aunque esta técnica lleva más tiempo, puede proporcionar una fuerte generalización para conjuntos de datos complejos, diminutos o ruidosos. La reducción adaptativa del peso hace que el entrenamiento llegue a su fin (regularización). Por otro lado, el algoritmo de retropropagación de Gradiente Conjugado Escalado utiliza menos memoria que el anterior. El entrenamiento termina automáticamente cuando la generalización deja de mejorar, como lo demuestra el aumento del error cuadrático medio de las muestras de validación (Baghirli, 2015; Demuth et al., 2009; Hanbay et al., 2008; Kişi y Uncuoğlu, 2005).



**Figura 41.** Arquitectura de la red neuronal artificial.

La red se dividió en tres fases, es decir, entrenamiento, validación y prueba. En la etapa de entrenamiento, se seleccionan 10 neuronas para la capa oculta. La red elige aleatoriamente los datos para el entrenamiento (60%), validación (10%) y prueba (30%) según el porcentaje seleccionado, con 229 muestras para entrenamiento, 38 muestras para validación y 114 muestras para la etapa de prueba. En el caso de la Regularización Bayesiana (BR), la validación no es necesaria, por lo que el número de muestras tomadas para el entrenamiento y la prueba fueron 267 y 114, respectivamente. Esto se debe a que la validación suele emplearse como un tipo de regularización, mientras que los algoritmos de BR tienen su forma de validación incorporada. La división de los datos se resume en la Tabla 18.

**Tabla 18.** *División de los datos para la prueba del modelo.*

Paso	Porcentaje %	No. de muestras
Levenberg-Marquardt Algorithm		
Entrenamiento	60	229
Validación	10	38
Prueba	30	114
Total	100	381
Regularización Bayesiana		
Entrenamiento	70	267
Validación	-	0
Prueba	30	114
Total	100	381
Gradiente conjugado escalado de retropropagación		
Entrenamiento	60	229
Validación	10	38
Prueba	30	114
Total	100	381

#### 4.3.2.4 Evaluación del modelo de red ANN

Utilizando la herramienta ANN para el desarrollo de la Red Neuronal, se evaluó el rendimiento de los modelos utilizando dos medidas, el Coeficiente de Correlación (R) (ecuación 1) y el Error Medio Cuadrático (MSE) (Azizifar y Babajanzadeh, 2018; Olu-Ajayi et al., 2022) como se indica en la Ecuación 9.

$$MSE = \frac{1}{n} \sum (y_i - \hat{y}_i)^2 \quad (9)$$

Donde,  $n$  = número de puntos de datos,  $Y_i$  = valores observados y  $\hat{Y}_i$  = valores predichos.

La regresión se considera la mejor medida de evaluación para comprobar la precisión de la red global. La correlación entre las salidas y los objetivos predichos se midió mediante los valores  $R$ . Una relación fuerte tiene un  $R$  de 1, mientras que una relación aleatoria tiene un  $R$  de 0 (Ali y Al-Tersawy, 201b; Azizifar y Babajanzadeh, 2018).

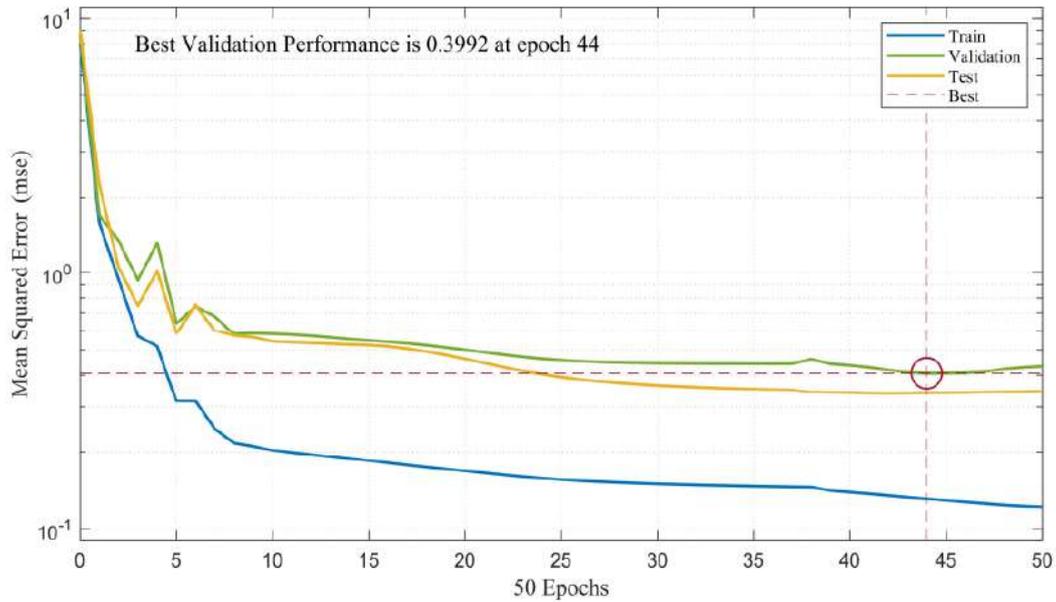
La distancia media al cuadrado entre los resultados y los valores estimados se conoce como Error Medio al Cuadrado. Cuanto más bajo sea el valor, mejor. No hay error si el valor es cero.

### 4.3.3 Resultados y discusión

El modelo se ha ejecutado en base a tres algoritmos: LM, BR y SCG por separado y sus resultados se comparan y discuten a continuación

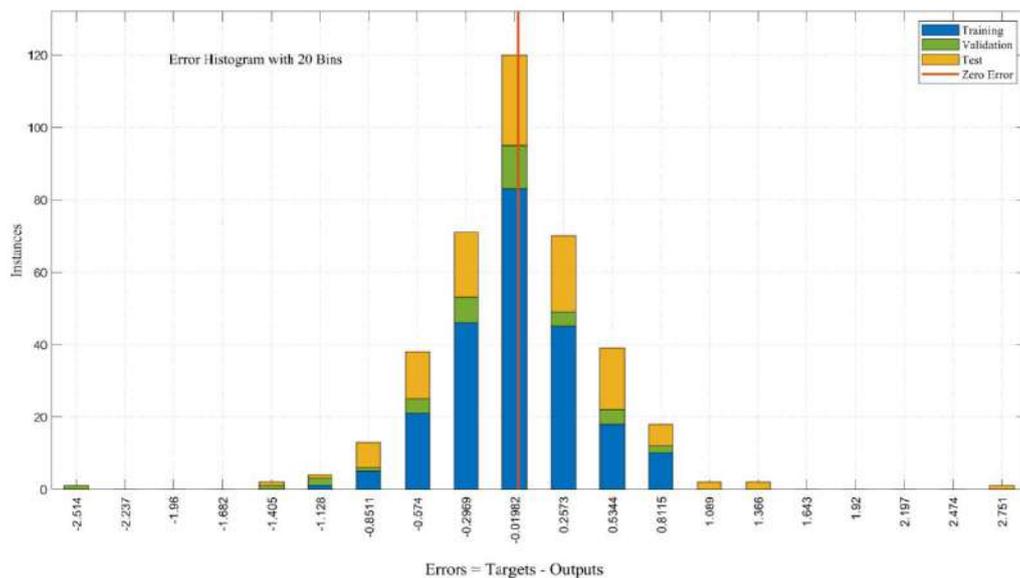
#### 4.3.3.1 Algoritmo Levenberg-Marquardt

La red se entrenó una y otra vez para encontrar el modelo más adecuado. El rendimiento del modelo se muestra en la Figura 42 con 10 neuronas. La Figura contiene líneas de diferentes colores que indican el entrenamiento, la validación y la prueba. El modelo comenzó a entrenarse con un MSE elevado, que finalmente se reduce en función de los parámetros de validación para evitar el sobreajuste de los datos. Muestra que después de 44 epochs, el error de entrenamiento seguía disminuyendo, pero los errores de validación y prueba aumentaban. Por lo tanto, después de seis epochs más, se detuvo el entrenamiento del modelo y se produjo un modelo optimizado con un MSE mínimo.



**Figura 42.** Rendimiento del modelo del algoritmo LM.

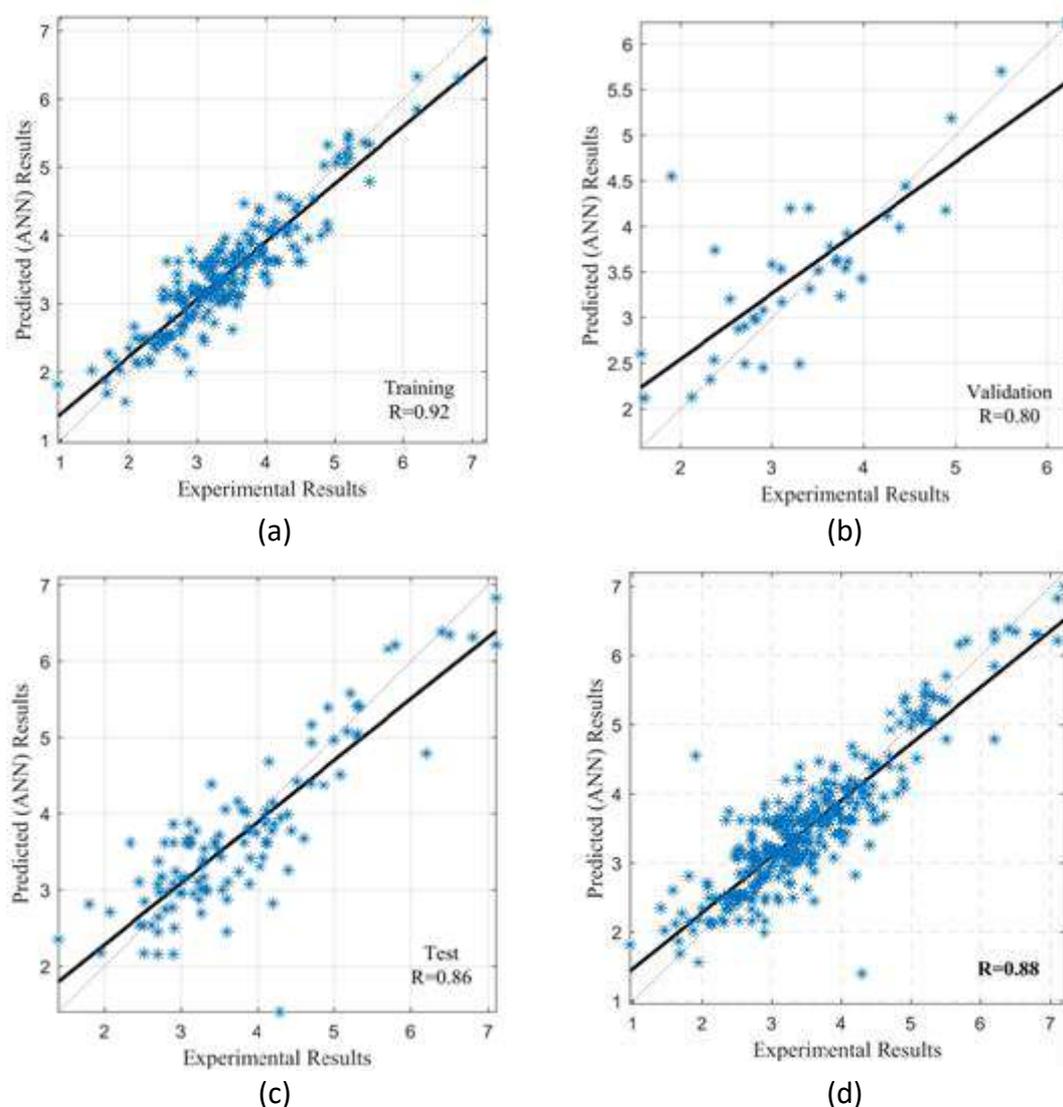
En la figura 43 se muestra el histograma de errores del modelo entre el entrenamiento, la validación y la prueba. El gráfico muestra que las barras de error convergen a la línea de error cero. Los resultados de los criterios de rendimiento muestran que el modelo es adecuado para predecir los resultados de la resistencia a la tracción del HAC con RA.



**Figura 43.** Histograma de error del modelo del algoritmo LM.

A continuación, se realizó un análisis de regresión. La Figura 44 muestra la correlación de entrenamiento, validación y prueba entre los valores de entrada y salida del modelo. La precisión global del modelo, es decir, la correlación total, se muestra en la Figura 44d.

En cada escenario, se muestra la línea de predicción de color negro. Cabe destacar que el valor R Total fue de 0.86, lo que muestra que la correlación estaba muy cerca de un ajuste lineal, lo que confirma que se trata de un buen modelo para predecir los valores de la resistencia a la tracción del HAC utilizando RA. Finalmente, todos los resultados de los parámetros de rendimiento, es decir, R y el MSE del modelo global con entrenamiento, validación y prueba, se resumen en la Tabla 19. En general, estos resultados indican que el algoritmo de Levenberg-Marquardt es un buen algoritmo para predecir la resistencia a la tracción del hormigón autocompactante con áridos reciclados.



Nota. Conjunto de datos de: (a) Entrenamiento; (b) Validación; (c) Prueba y (d) Total.

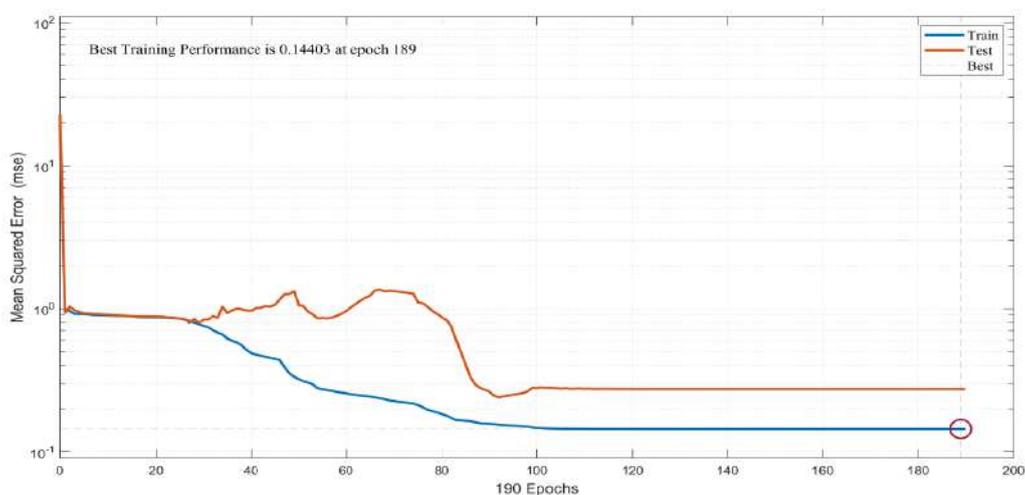
**Figura 44.** Gráficos de regresión del algoritmo LM entre la resistencia a la tracción experimental y la predicha.

**Tabla 19.** Resumen de los diferentes parámetros de evaluación del modelo del algoritmo LM.

Paso	Función	MSE	R
Entrenamiento	trainlm	0.1508	0.9267
Validación	trainlm	0.3992	0.7899
Prueba	trainlm	0.3282	0.8294
Total	trainlm	0.2927	0.8573

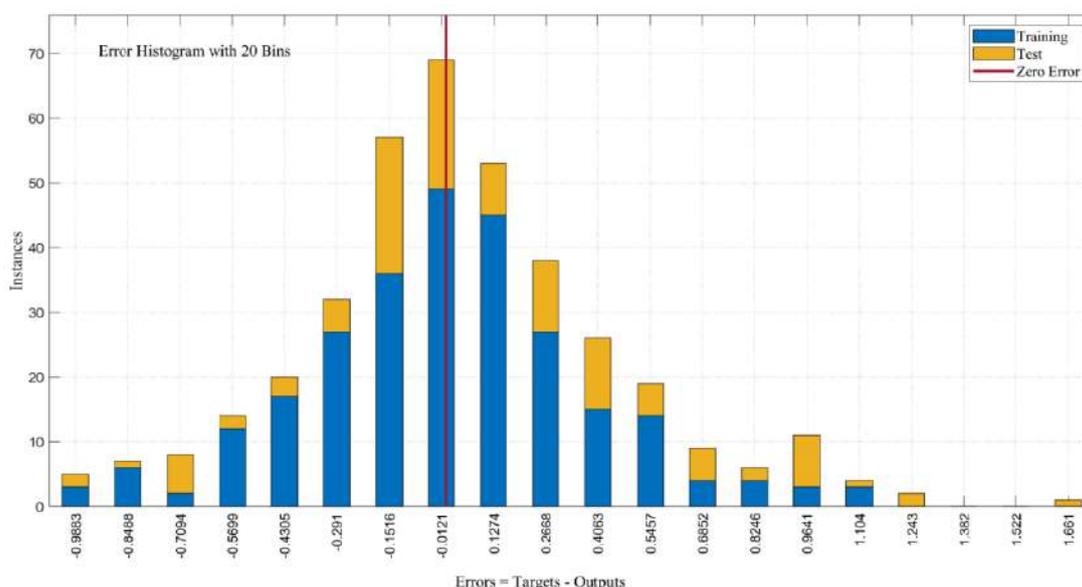
### 4.3.3.2 Regularización Bayesiana

De la misma manera, el modelo fue entrenado utilizando el enfoque de Regularización Bayesiana. El rendimiento del modelo se muestra en la Figura 45 con el mismo número de neuronas. En la Figura se muestran dos líneas de color que indican sólo el entrenamiento (azul) y la prueba (roja), ya que la BR no necesita un paso de validación porque tiene una forma de validación incorporada en el paso de entrenamiento. El modelo comenzó a entrenarse con un MSE elevado, que finalmente se redujo gracias a que los parámetros de entrenamiento evitaron el sobreajuste de los datos. Como la BR requiere más tiempo, la Figura muestra que el modelo tardó varias epochs, y después de 100 epochs, las líneas de error de entrenamiento y prueba se redujeron considerablemente y se convirtieron aproximadamente en una línea recta. El modelo se entrena aún más para validar a fondo, y el entrenamiento se detiene a las 190 epochs. El modelo optimizado tiene un indicador de rendimiento de 0.14403 a las 189 epochs.



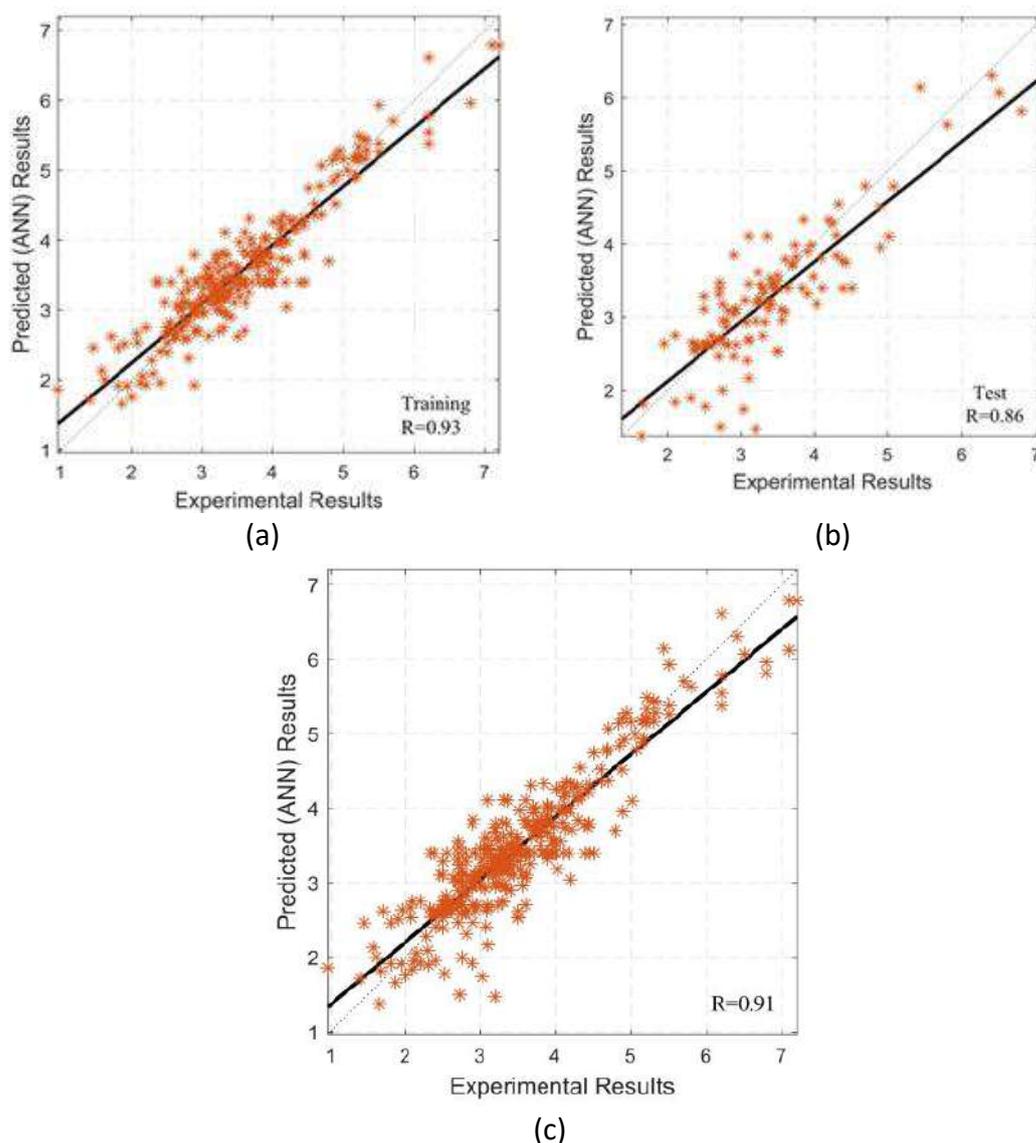
**Figura 45.** Rendimiento del modelo BR.

En la Figura 46 se muestra el histograma de errores del modelo entre el entrenamiento y la prueba. La Figura 46 muestra que la convergencia de las barras a la línea de error cero es excelente, y el error también es pequeño en comparación con el algoritmo LM. Los resultados de este criterio de rendimiento muestran que el modelo es perfecto para predecir los resultados de la resistencia a la tracción del HAC con RA. A continuación, se realiza un análisis de regresión de la misma manera.



**Figura 46.** Histograma de error del modelo BR.

La Figura 47 muestra la correlación de entrenamiento y prueba entre los valores de entrada y salida del modelo. La correlación Total se muestra en la Figura 47c. En cada escenario, se muestra una línea de tendencia de color negro. Se observa que el valor R global es de 0.91. El modelo entrenado por la Regularización Bayesiana tiene una excelente precisión para predecir la salida, es decir, la resistencia a la tracción de SCC con RA. Finalmente, todos los resultados de los parámetros de rendimiento: R y el MSE del modelo global, así como de entrenamiento y prueba, se resumen en la tabla 20. En general, estos resultados indican que la Regularización Bayesiana puede ser adoptada para predecir la resistencia a la tracción del hormigón autocompactante con áridos reciclados.



Nota. Conjunto de datos de: (a) Entrenamiento; (b) Prueba y (c) Total.

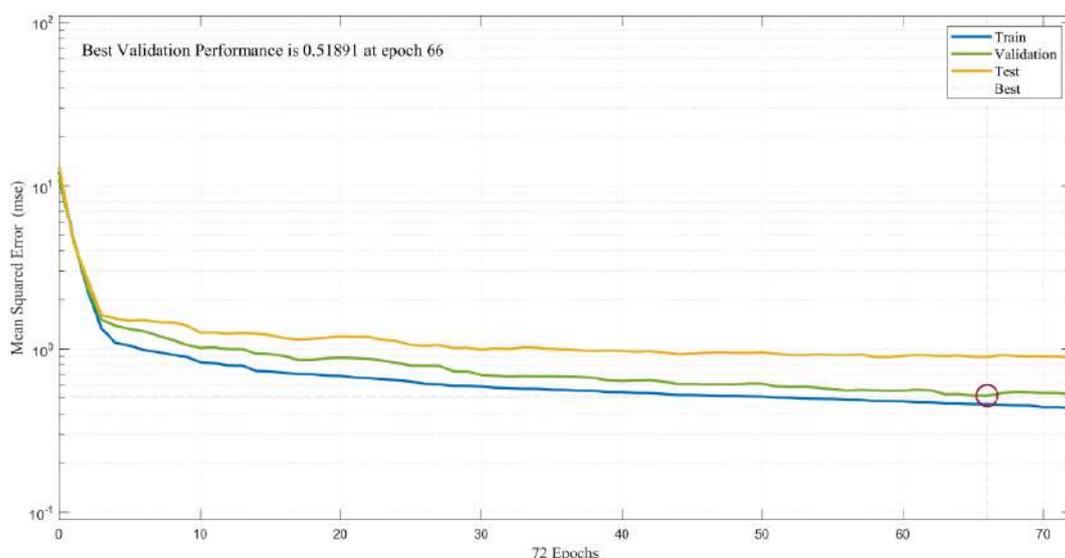
**Figura 47.** Gráficos de regresión de regularización bayesiana entre la resistencia a la tracción experimental y la predicha.

**Tabla 20.** Resumen de los diferentes parámetros de evaluación del modelo de BR.

Paso	Función	MSE	R
Entrenamiento	trainbr	0.1440	0.9254
Prueba	trainbr	0.2734	0.8638
Total	trainbr	0.2087	0.9049

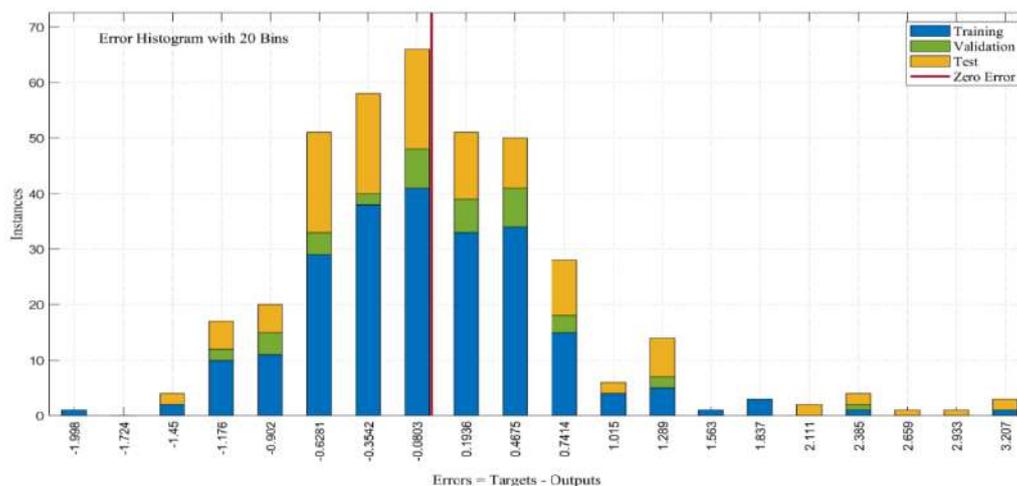
### 4.3.3.3 Gradiente conjugado escalado de retropropagación

El modelo se entrena utilizando el enfoque de retropropagación de gradiente conjugado escalado. El rendimiento del modelo se muestra en la Figura 48 con 10 neuronas. La Figura contiene líneas de diferentes colores que indican el entrenamiento (azul), la validación (verde) y la prueba (amarilla). El modelo empieza a entrenarse con un MSE elevado, que se reduce finalmente gracias a los parámetros de validación que evitan el sobreajuste de los datos. La Figura muestra que el MSE no se redujo mucho en comparación con los otros dos algoritmos. Muestra que después de 66 epochs, los errores de entrenamiento disminuyen, pero los errores de validación y prueba aumentan un poco. Por lo tanto, después de ocho epochs más, se detuvo el entrenamiento del modelo y se produjo un modelo optimizado, con un MSE mínimo.



**Figura 48.** Rendimiento del modelo SCG.

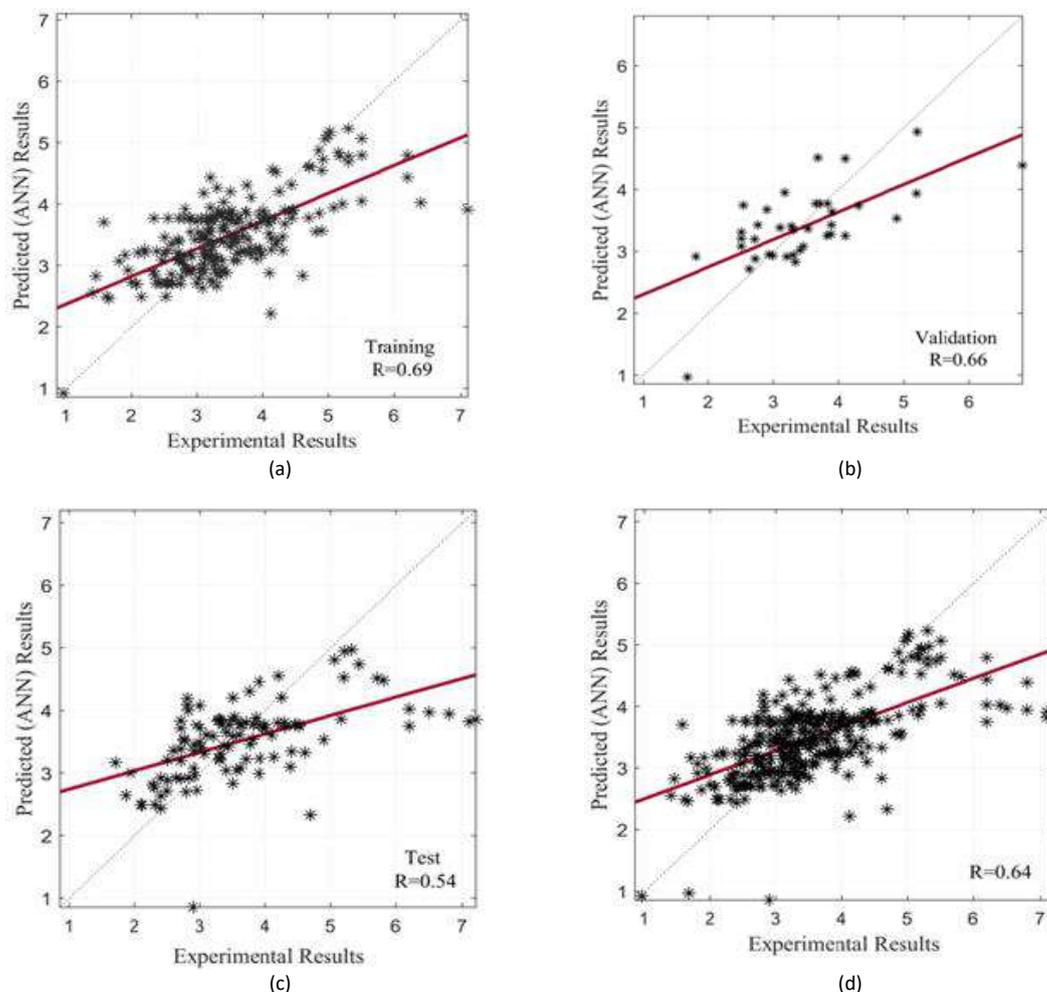
En la Figura 49 se muestra el histograma de errores del modelo entre el entrenamiento, la validación y la prueba. La Figura muestra que las barras de error convergen a la línea de error cero con baja precisión. Los resultados de este criterio de rendimiento muestran que el modelo tiene valores de error elevados en comparación con otros algoritmos y está por debajo del par para predecir los resultados de la resistencia a la tracción del HAC con RA. A continuación, se realiza un análisis de regresión.



**Figura 49.** Histograma de error del modelo de SCG.

La Figura 50 muestra la correlación de entrenamiento, validación y prueba entre los valores de entrada y salida del modelo. La precisión global del modelo, es decir, la correlación, se muestra en la figura 50d. En cada escenario, se muestra una recta de predicción de color granate. Cabe señalar que el valor R global fue de 0.64, lo que muestra que la correlación estaba lejos del ajuste lineal, lo que confirma un modelo por debajo de la media para predecir los valores de la resistencia a la tracción del HAC utilizando el RA.

Finalmente, todos los resultados de los parámetros de rendimiento, es decir, el valor R y el MSE del modelo global, así como de entrenamiento, validación y la prueba, se resumen en la Tabla 21. Estos resultados indican que la retropropagación del gradiente conjugado escalado se clasifica como un algoritmo inferior a LM y BR para predecir la resistencia a la tracción del hormigón autocompactante de áridos reciclados.



Nota. Conjunto de datos de: (a) Entrenamiento; (b) Validación; (c) Prueba y (d) Total.

**Figura 50.** Gráficos de regresión del algoritmo SCG entre la resistencia a la tracción experimental y la predicha.

**Tabla 21.** Resumen de los diferentes parámetros de evaluación del modelo del Algoritmo SCGB.

Paso	Función	MSE	R
Entrenamiento	trainscg	0.4588	0.6920
Validación	trainscg	0.5189	0.6616
Prueba	trainscg	0.8925	0.5425
Total	trainscg	0.6234	0.6368

#### 4.3.3.4 Comparación de los enfoques LM, BR y SCG

La comparación entre los tres algoritmos se realizó a partir de los resultados experimentales y los resultados predichos por la ANN. La Figura 51 muestra la

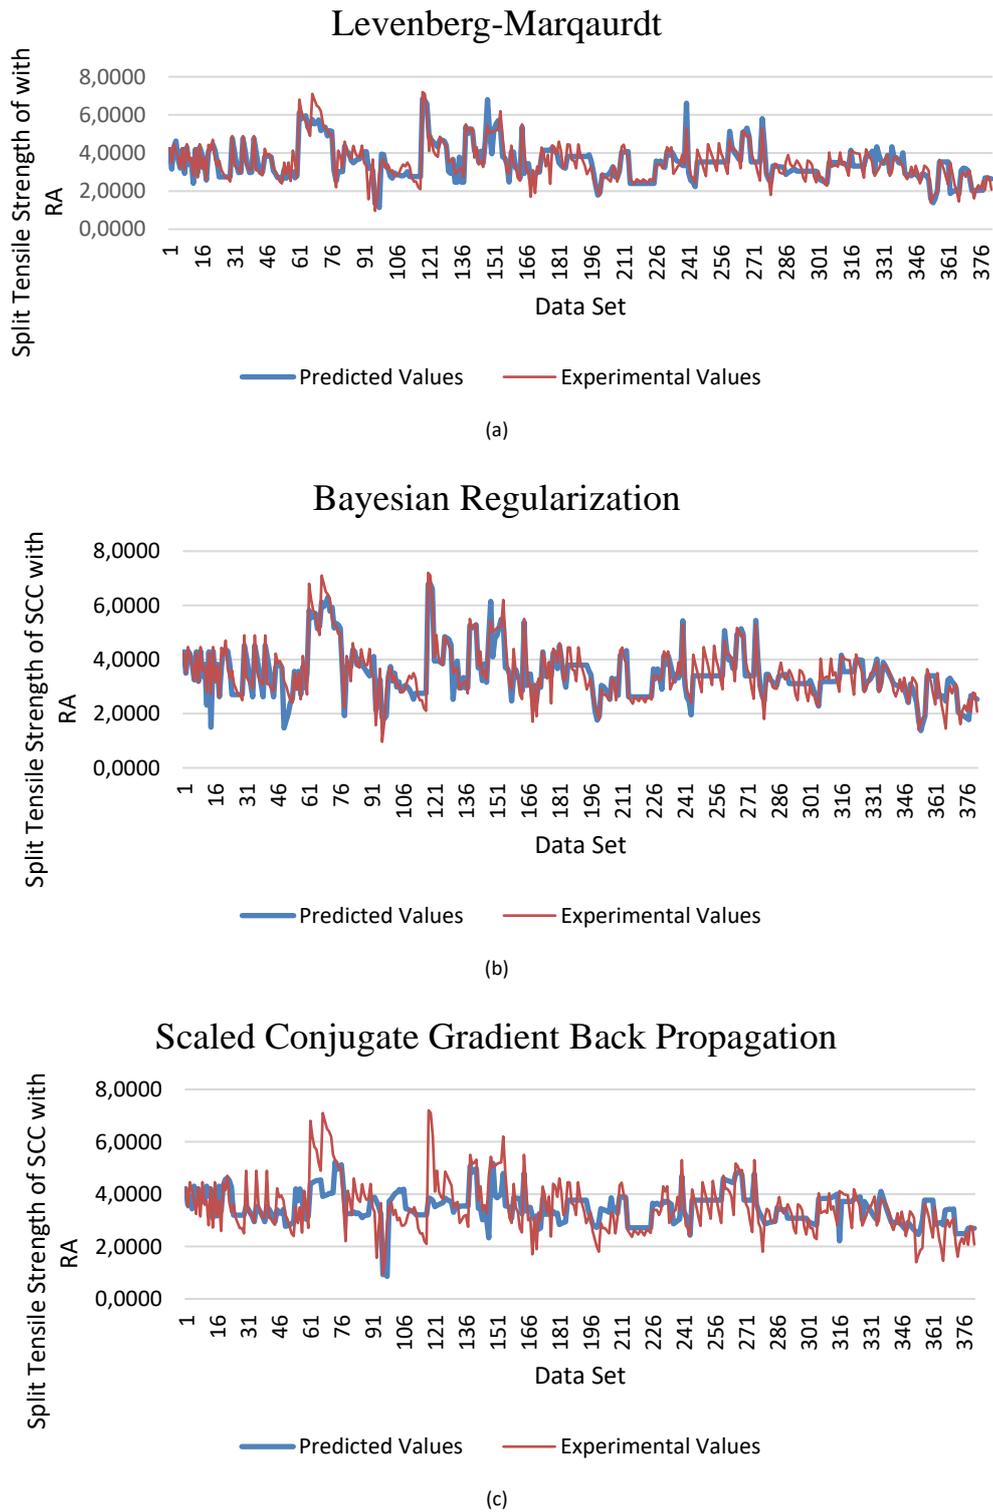
Predicción de resistencia a compresión y a tracción de hormigones autocompactantes con áridos reciclados utilizando métodos de Machine Learning y algoritmos de redes neuronales

comparación entre los valores experimentales y los predichos de un modelo entrenado por los enfoques LM, BR y SCG, respectivamente. En el eje y, la línea azul indica los valores predichos, y la línea roja muestra los valores experimentales de la resistencia a la tracción del HAC con áridos reciclados. En el eje de las abscisas, se indica el conjunto de datos de 381 muestras.

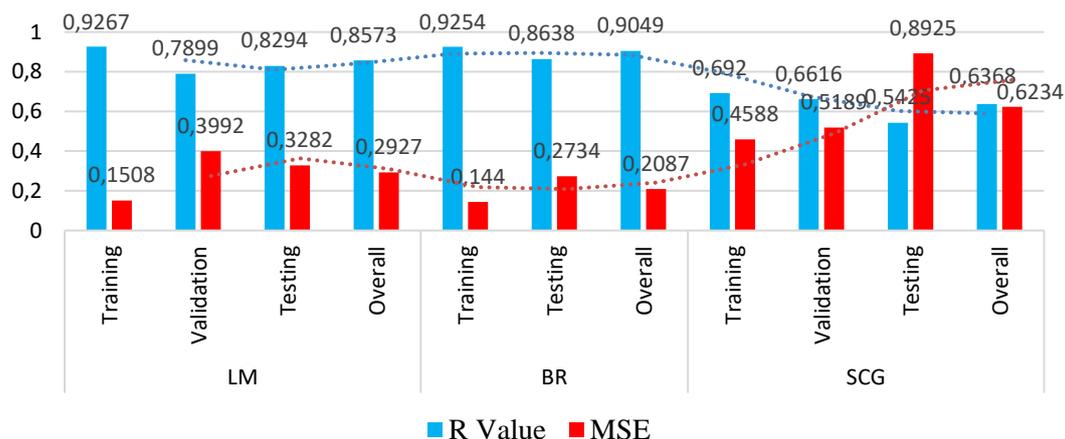
La Figura 51 indica que los valores predichos por los tres algoritmos se correlacionan bien con los valores experimentales. La diferencia más significativa entre ambas líneas indica un elevado error entre los dos parámetros. El valor de R total y el error medio cuadrático de los tres algoritmos se muestran en la Figura 52.

Así, las Figuras 51 y 52 confirman que el gráfico que mejor se ajusta es el de la regularización bayesiana (Figura 51b), que tiene el valor de R más significativo y un MSE mínimo. El enfoque de la BR obtuvo mejores resultados debido a la heterogeneidad de los datos, ya que puede proporcionar una fuerte generalización para conjuntos de datos complejos (Suescum-Morales et al., 2021).

Se concluye que entre los tres algoritmos: Levenberg-Marquardt, Regularización Bayesiana y Gradiente Conjugado Escalado de Retropropagación; la Regularización Bayesiana tuvo la mayor precisión (>90%) y pudo predecir con precisión la resistencia a la tracción del Hormigón Autocompactante con Áridos Reciclados.



**Figura 51.** Comparación de los valores experimentales y predichos por de los algoritmos ANN: a) LM, b) BR, y c) SCGB.



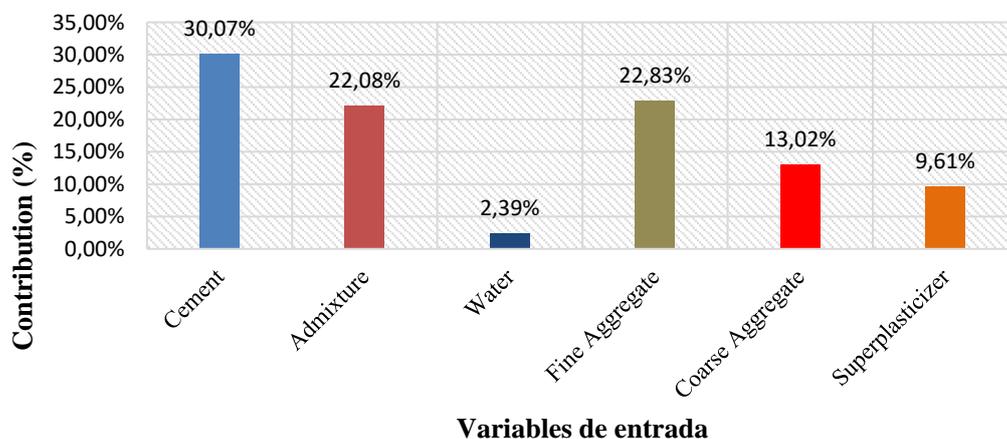
**Figura 52.** R y MSE de los algoritmos LM, BR y SCGB.

### 4.3.3.5 Análisis de sensibilidad

El análisis de sensibilidad permite ver cómo cada variable de entrada afecta a la variable de salida. Cuanto más significativa sea la influencia de las variables de entrada en la variable de salida, mayores serán los valores de sensibilidad. Según Shang et al. (2022), las variables de entrada tienen una influencia significativa en la predicción de la variable de salida. El análisis de sensibilidad se utilizó para examinar el impacto de cada variable de entrada - árido fino, cemento, árido grueso, agua y superplastificantes en la variabilidad de la resistencia a la tracción del hormigón autocompactante con agregados reciclados. Las ecuaciones 6 y 7 se utilizaron para determinar el análisis de sensibilidad.

Como se indica en la Figura 53, cada una de las variables de entrada –cemento, áridos gruesos, agua, superplastificantes, áridos finos y aditivos minerales- tuvo un impacto considerable en la predicción de la resistencia a la tracción del hormigón autocompactante con áridos reciclados. Las contribuciones más significativas a la estimación de la resistencia a la tracción del hormigón autocompactante con áridos reciclados fueron el cemento (30.07 %), el árido fino (22.83 %) y el aditivo mineral (22.08 %). Según. Shang et al. (2022), el cemento es un factor que impacta significativamente en la predicción de la resistencia a la tracción del HAC con AR. Las variables de entrada de árido grueso y superplastificante tuvieron una contribución del 13.02 % y 9.61 %, respectivamente. Por otro lado, el agua fue la variable menos eficiente en la predicción

de la resistencia a la tracción del HAC con RA (2.39 %); estos resultados son consistentes con estudios anteriores (Suescum-Morales et al., 2021)



**Figura 53.** Contribución de las variables de entrada a la resistencia a la tracción por hendidura del HAC con RA en el enfoque BR.

### 4.3.4 Conclusiones parciales

Este estudio tuvo como objetivo predecir y Comparar los resultados de la predicción de la resistencia a la tracción del HAC modificado con RA utilizando diferentes algoritmos de Red Neural Artificial, a saber, LM, BR y SCG. El modelo fue entrenado con seis parámetros de entrada: cemento, agua, aditivos, áridos gruesos y finos, y superplastificante. Para la evaluación, se utilizaron dos métricas, R y MSE. De este estudio se extrajeron las siguientes conclusiones.

1. Se recogió un conjunto de datos de 381 muestras a través de revistas y se dividió aleatoriamente en un 60%, 10% y 30% para el entrenamiento (267), la validación (38) y la prueba (114), respectivamente, para el desarrollo de los modelos LM, BR y SCG. Sin embargo, en el caso de BR, la proporción fue del 70% para el entrenamiento y del 30% para la prueba debido a la función de validación incorporada en el paso de entrenamiento.

2. Para este estudio se entrenaron y probaron diferentes algoritmos, a saber, LM, BR y SCG, que dieron una precisión global del 85%, 91% y 64%, con un MSE de 0.2927; 0.2087 y 0.6234.
3. El algoritmo SCG fue un modelo pobre para predecir la resistencia a la tracción del HAC con RA, obtuvo el R más bajo y el MSE más alto.
4. La Regularización Bayesiana dio el mejor rendimiento con un alto coeficiente de correlación ( $R > 90\%$ ) y un MSE mínimo (0.2087) respecto a LM y SCG.
5. Los resultados mostraron que el algoritmo BR es un buen modelo y puede ser adoptado para la predicción de la resistencia a la tracción a 28 días del hormigón autocompactante modificado con áridos reciclados
6. Según el análisis de sensibilidad, el cemento es la variable de entrada esencial en la predicción de la resistencia a la tracción a 28 días del HAC con RA (30.07 %). Por otro lado, el agua tuvo la menor influencia en la resistencia a la tracción a 28 días del HAC con RA (2.39 %).

Este apartado tiene algunas limitaciones en cuanto a la recogida de datos. Como no había suficientes datos experimentales, no se pudo reunir grandes conjuntos de datos para esta investigación. Como resultado, se deben recoger más conjuntos de datos para futuras investigaciones sobre este tema para evitar esta limitación y hacer un modelo de predicción más preciso. Con más datos, se pueden examinar más a fondo varias entradas y salidas.

## 4.4 ESTUDIO DE LA PREDICCIÓN DE LA RESISTENCIA A COMPRESIÓN DEL HORMIGÓN AUTOCOMPACTANTE UTILIZANDO NOVEDOSOS ENFOQUES COMPUTACIONALES

El componente más importante de la construcción es el hormigón. Debido a que la durabilidad se ha convertido en una de las cuestiones más críticas en la construcción de

estructuras de hormigón armado con una larga vida útil y con el desarrollo de las tecnologías de la construcción en los últimos años, es necesario fabricar un hormigón bien diseñado como material robusto para la construcción (Mehta, 2002; Yüksel et al., 2007; Zaid, Hashmi, et al., 2022).

El hormigón es el material de construcción más utilizado en todo el mundo. Dado que se están creando numerosos tipos de hormigón con diferentes aditivos, se ha ampliado el conocimiento de los procedimientos avanzados de diseño del hormigón (Zaid, Mukhtar, et al., 2022). El hormigón autocompactante es uno de los resultados del hormigón avanzado, desarrollado en Japón (1980) para producir estructuras de hormigón de alta resistencia y durabilidad (De Schutter et al., 2015; Okamura y Ouchi, 2003).

La diferencia fundamental entre el hormigón autocompactante y el ordinario es la cantidad de componentes utilizados en el proceso de mezcla. El HAC es reconocido como el hormigón más creativo de la era, con la capacidad de autocompactarse en las zonas de construcción sin necesidad de energía vibratoria. El hormigón autocompactante se hunde bajo su peso siguiendo un curso fluido (Shi et al., 2015). El HAC destaca por ser novedoso, ya que puede utilizarse en regiones densas donde el hormigón es difícil de acceder (Nikbin et al., 2014)

El crecimiento sin precedentes del sector de la construcción a lo largo de las décadas ha dado lugar a un uso desproporcionado de los recursos naturales, los residuos de demolición y construcción (RCD) se han acumulado en un gran volumen, y el vertido de áridos reciclados (RA) puede causar la destrucción del medio ambiente (B K A et al., 2021; Señas et al., 201a; Zaid, Hashmi, et al., 2022). El sector de la construcción en la Unión Europea ha experimentado una expansión exponencial en las últimas décadas y, debido a este crecimiento, la producción de RCD ha aumentado. Con el rápido crecimiento del sector de la construcción, las tasas de demolición crecen cada día, lo que hace necesario la reutilización efectiva de los RCD (Ali et al., 2020; Jagadesh et al., 2021; Padmini et al., 2009). Los áridos finos (arena) y los áridos gruesos (piedra) constituyen la mayor parte del hormigón, representando aproximadamente el 75% del volumen total (de-Prado-Gil et al., 2022; Zaid, Martínez-García, et al., 2022)

Al mismo tiempo, los recursos naturales están disminuyendo a causa de una urbanización rápida moderna. Las montañas, el principal suministro de áridos de alta calidad, disminuyen rápidamente (Althoey et al., 2022; Carvalho, 2017). Como consecuencia, numerosas naciones del mundo han sufrido catástrofes naturales (Kaewunruen y Meesit, 2020). Por otro lado, muchas estructuras son demolidas cada año por los terremotos o porque han superado su utilidad (Daungwilailuk et al., 2017; H. Y. T. Nguyen et al., 2018). Por tanto, cada año se produce una cantidad significativa de basura de construcción en todo el mundo.

Los recientes avances en la investigación de materiales de hormigón han allanado el camino para que materiales alternativos sustituyan a largo plazo a los tradicionales (Adesina y Awoyera, 2019; J. Ahmad et al., 2021; Zaid, Aslam et al. 2021). El uso de áridos reciclados en el hormigón autocompactante es la primera y más sostenible revolución para contrarrestar estos problemas. Los áridos reciclados (RA) se fabrican mediante el reprocesamiento de materiales minerales de desecho, siendo los escombros de construcción y demolición la fuente más común. Para la misma cantidad de áridos, el hormigón de áridos reciclados (RC) tiene un rendimiento inferior al del hormigón de áridos naturales (NC). Varios aditivos pueden compensar las deficiencias mecánicas y de durabilidad (J. Ahmad et al., 2021; El Ouni et al., 2022; Zaid, Ahmad et al., 2021). En consecuencia, un buen diseño de la mezcla es esencial para que el hormigón fabricado con RA tenga las propiedades necesarias (Fonseca et al., 2011; Grdic et al., 2010; Kou y Poon, 2009b; Uysal y Yilmaz, 2011)

La segunda técnica consiste en omitir todo el trabajo experimental, disminuyendo el deterioro medioambiental y el desperdicio de recursos naturales. Actualmente, muchos investigadores se centran en estrategias de computación blanda. Estos enfoques computacionales, como el aprendizaje automático o las técnicas de redes neuronales artificiales, últimamente, han surgido como herramientas prácticas para modelar y estimar diversas cuestiones, especialmente modelando las características de concreto (Deifalla et al., 2021). El cerebro humano, que comprende miles de millones de neuronas, es un modelo para las redes neuronales artificiales. Al igual que un humano

aprende a través de la experiencia, una red neuronal artificial (ANN) utiliza datos para anticipar variables (Nikoo et al., 2015).

En ANN, existen diferentes algoritmos. En este estudio, se seleccionaron tres algoritmos en función de sus prestaciones. El algoritmo de Levenberg-Marquardt suele requerir más memoria, pero es más rápido. La Regularización Bayesiana, aunque requiere más tiempo, puede producir una fuerte generalización para conjuntos de datos difíciles, pequeños o complejos. Por otro lado, el algoritmo de Gradiente Conjugado Escalado de Retropropagación utiliza menos memoria que los anteriores.

El objetivo principal de esta publicación es utilizar las redes neuronales artificiales para validar y pronosticar la resistencia a la compresión del HAC utilizando RA. Para ello se desarrollan y comparan diferentes técnicas, como la de Levenberg-Marquardt (LM), la de Regularización Bayesiana (BR) y la de Gradiente Conjugado Escalado (SCGB).

## 4.4.1 Revisión de literatura

### 4.4.1.1 Redes neuronales artificiales

En el aprendizaje profundo, las redes neuronales artificiales (ANN) son un método crucial. Un subconjunto del aprendizaje automático denominado aprendizaje profundo (DL) permite el cálculo de redes neuronales multicapa. En contraste con el objetivo principal de la inteligencia artificial de permitir que las máquinas imiten el comportamiento humano, el aprendizaje automático emplea técnicas estadísticas para permitir que los ordenadores crezcan con el tiempo. El contraste clave entre el aprendizaje automático y el aprendizaje profundo es que, en el DL, la extracción de patrones y la categorización se completan automáticamente. Sin embargo, con el aprendizaje automático, la extracción de características sigue siendo necesaria, y el ordenador se encarga de la categorización y la predicción (Du et al., 2016).

Una red neuronal artificial (ANN) es un modelo matemático y computacional complejo que se basa en la extensa red neuronal biológica del cerebro humano (Schmidhuber, 2015). Puede aumentar su rendimiento aprendiendo de sus errores, que es como conoce una red neuronal artificial. Está formada por una red de funciones y pesos que

actúan como neuronas artificiales. Suelen utilizarse en aplicaciones de inteligencia artificial que requieren que analicen problemas difíciles y complicados (Nikoo et al., 2015).

Cada algoritmo único y específico puede utilizarse para ejecutar una ANN. En las siguientes secciones se tratan los algoritmos LM, BR y SCGB desde el punto de vista de la investigación.

#### 4.4.1.1 Algoritmo Levenberg-Marquardt

El algoritmo de Levenberg-Marquardt (LM) busca iterativamente el menor valor de la función. Una función multidimensional puede expresarse como la suma de cuadrados de funciones no lineales de valor real (Levenberg, 1944; Marquardt, 1963). Este método ha sido aplicado por los investigadores a problemas de mínimos cuadrados no lineales en varios diferentes dominios (El Ghaoui y Le Bret, 1997). En este algoritmo, se fusionan dos enfoques, el descenso más pronunciado y el método de Gauss-Newton, para acelerar las iteraciones y reducir el error. El algoritmo pasa al enfoque de Gauss-Newton más rápidamente que el otro cuando el resultado más reciente es preciso. Cuando el resultado es incorrecto, actúa como un declive más pronunciado, lento pero siempre capaz de aproximar (Wang et al., 2022). La principal ventaja es que, aunque esta aproximación requiere más memoria, requiere poco tiempo.

#### 4.4.1.2 Regularización Bayesiana

Las redes neuronales artificiales regularizadas bayesianas (BPNNs), que pueden acortar o eliminar el requisito de la validación cruzada, que requiere mucho tiempo, son más fiables que las redes neuronales tradicionales de retropropagación (BPNNs), las cuales son menos fiables (Mackay, 1992). La Regularización Bayesiana transforma de la misma manera una regresión no lineal en un problema estadístico preciso utilizando la Regresión Ridge. Llevan más tiempo, pero el modelo ofrece muchas ventajas sobre los datos difíciles (Winkler y Burden, 2000). La ventaja de utilizar BRANNs es que no se requiere una fase de validación porque los modelos son resistentes (Hawkins et al., 2003; Mackay, 1992). Los retos del modelado de la relación cuantitativa estructural-

actividad (QSAR) incluyen la predicción, la fiabilidad, la elección de los conjuntos de validación adecuados y la optimización del diseño de la red. Los procesos empíricos impiden el uso de criterios Bayesianos para el entrenamiento, lo que hace casi imposible el sobreentrenamiento (Lučić et al., 2000)

#### 4.4.1.1.3 Gradiente conjugado escalado de retropropagación

El método básico de retropropagación se utiliza para modificar los pesos en la dirección de la caída más pronunciada o del gradiente negativo más alto. Este es el método a través del cual la función de rendimiento puede degradarse más rápidamente. Aunque la función desciende el gradiente negativo más rápidamente, está demostrado que esto no indica necesariamente la integración más rápida (Hagan et al., 2002).

Los algoritmos de gradiente conjugado (CG) buscan una dirección que logre una convergencia más rápida que la vía de descenso más pronunciado, manteniendo la reducción de error alcanzada en las etapas anteriores, y esta actividad se conoce como la dirección conjugada. En la mayoría de los algoritmos CG, el tamaño del paso cambia con cada iteración. Se realiza una búsqueda a lo largo de la dirección del gradiente conjugado para determinar el tamaño del paso que minimizará la función de rendimiento a lo largo de esa línea (Özgür y Erdal, 2005).

Un método distinto al enfoque de búsqueda de líneas también puede estimar el tamaño del paso. El objetivo es combinar el modelo de región de confianza del algoritmo LM con la metodología CG. Esta estrategia se conoce como SCGB, que fue reportada inicialmente en la literatura por Møller (1993).

Los parámetros de diseño se ajustan por separado para cada usuario de la iteración, lo que es esencial para el éxito del algoritmo. Esta es una ventaja sustancial sobre las búsquedas de algoritmos basados en líneas (Møller, 1993).

#### 4.4.1.2 Importancia de la investigación

En este estudio se valida y predice la resistencia a la compresión del hormigón autocompactante que contiene áridos reciclados mediante redes neuronales artificiales.

En base al mejor conocimiento del autor sobre la investigación actualmente disponible, no se ha realizado un estudio significativo sobre el uso de varias técnicas de aprendizaje profundo para predecir la resistencia a la compresión del HAC con RA, lo que marca su novedad. Para este objetivo se aplican varias técnicas, como los algoritmos de Levenberg-Marquardt (LM), de Regularización Bayesiana (BR) y Gradiente Conjugado Escalado de Retropropagación (SCGB). Dos indicadores estadísticos, el coeficiente de correlación (R) y el error medio cuadrático (MSE), son empleados para la selección del mejor modelo. El análisis de sensibilidad se lleva a cabo para determinar el impacto de cada variable de entrada en la variable de salida. El presente estudio proporcionará un conocimiento exhaustivo a los lectores sobre estos tres algoritmos para la predicción y validación del HAC con RA.

## 4.4.2 Materiales y métodos

### 4.4.2.1 Plan experimental

La información se obtiene de numerosos artículos de investigación. La Tabla 22 presenta la base de datos que contiene 515 muestras de la resistencia a la compresión  $f'_c$  de HAC con RA, incluyendo seis variables denominadas X1 a X6 y una salida Y, es decir, la resistencia a la compresión. Las variables de entrada incluyen cemento Portland (X1), materiales cementantes suplementarios (X2), agua (X3), FA (X4), CA (X5), y aditivos (X6). La base de datos comprende el número, que muestra la colección global de artículos, las referencias de los autores, la cantidad de información (# datos) suministrada por cada artículo y el porcentaje de los datos totales (% datos).

**Tabla 22.** *Datos experimentales.*

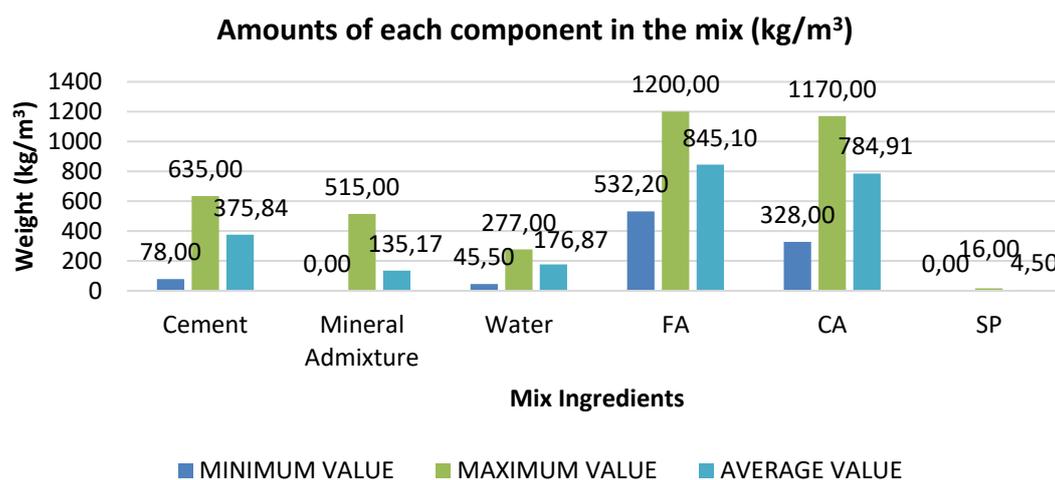
No	Referencia	# mix	% data	No	Referencia	# mix	% data
1	Ali et al. (2012)	18	3.50	28	Nili et al. (2019)	10	1.94
2	Aslani et al. (2018)	15	2.91	29	Pan et al. (2019)	6	1.17
3	Babalola et al. (2020)	14	2.72	30	Pereira-de-Oliveira et al. (2014)	4	0.78
4	Bahrami et al. (2020)	10	1.94	31	Poomgodi et al. (2020)	9	1.75
5	Barriqueiro et al. (2020)	6	1.17	32	Revathi et al. (2013)	5	0.97
6	Behera et al (2019)	6	1.17	33	Revilla Cuesta et al. (2020)	5	0.97
7	Bidabadi et al. (2020)	11	2.14	34	Sadeghi-Nik et al. (2019)	12	2.33
8	Chakkamalayath et al. (2020)	6	1.57	35	Salesa et al. (2017)	4	0.78
9	Duan et al. (2020)	10	1.94	36	Sasanipour et al. (2019)	10	1.94
10	Fiol et al. (2018)	12	2.33	37	Señas et al. (2016)	6	1.17
11	Gesoglu et al. (2015)	24	4.66	38	Sharifi et al. (2013)	6	1.17
12	Grdic et al. (2010)	3	0.58	39	Ali and Al-Tersawy (2014)	15	2.91
13	Guneyisi et al. (2014)	5	0.97	40	Silva et al. (2016)	15	2.91
14	Guo et al. (2020)	27	5.24	41	Singh et al. (2019)	12	2.33
15	Kapoor et al. (2016)	8	1.55	42	Sua-iam et al. (201.)	20	3.88
16	Katar et al. (2021)	4	0.78	43	Sun et al. (2020)	10	1.94
17	Khodair et al. (2017)	20	3.88	44	Surendar et al. (2021)	7	1.36
18	Kou et al. (2009)	13	2.52	45	Tang et al. (2016)	5	0.97
19	Krishna et al. (2018)	5	0.97	46	Thomas et al. (2016)	4	0.78
20	Kumar et al. (2017)	4	0.78	47	Tuyan et al. (2014)	12	2.33
21	Li et al. (2019)	4	0.78	48	Uygunoglu et al. (2014)	8	1.55
22	Long et al. (2016)	4	0.78	49	Wang et al. (2020)	5	0.97
23	Mahakavi and Chitra (2019)	25	4.85	50	Yu et al. (2014)	3	0.58
24	Manzi et al. (2017)	4	0.78	51	Yu et al. (2019)	3	1.14
25	Martínez-García et al. (2020)	4	0.78	52	Yu et al. (2021)	21	4.08
26	Mo et al. (2021)	5	0.97	53	Zhou et al. (2013)	6	1.17
27	Nieto et al. (2018)	22	4.27	Total		515	100

La Tabla 23 ilustra el valor mínimo, máximo y media de las variables determinadas como entrada (cemento, materiales cementantes suplementarios, árido fino, agua, áridos gruesos y superplastificantes) y salida potencial (resistencia a la compresión del

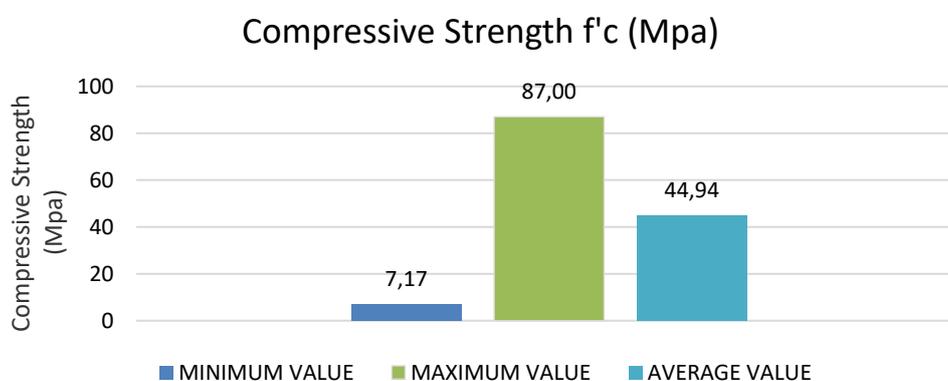
hormigón autocompactante de áridos reciclados) basado en estas publicaciones de investigación. Las Figuras 54 y 55 ilustran su representación gráfica.

**Tabla 23.** Valores mínimo, media y máximo de las variables de entrada y salida.

	Variables	Abreviatura	Mínimo	Media	Máximo
Entrada	Cemento (kg/m <sup>3</sup> )	C	78.00	375.84	635.00
	Aditivo Mineral (kg/m <sup>3</sup> )	MA	0.00	135.17	515.00
	Agua (kg/m <sup>3</sup> )	W	45.50	176.87	277.00
	Áridos fino (kg/m <sup>3</sup> )	FA	532.20	845.10	1200.00
	Áridos grueso (kg/m <sup>3</sup> )	CA	328.00	784.91	1170.00
	Superplastificantes (Kg/m <sup>3</sup> )	SP	0.00	4.50	16.00
	Salida	Resistencia a compresión (MPa)	f'c	7.17	44.94



**Figura 54.** Valores mínimo, media y máximo de las variables de entrada.

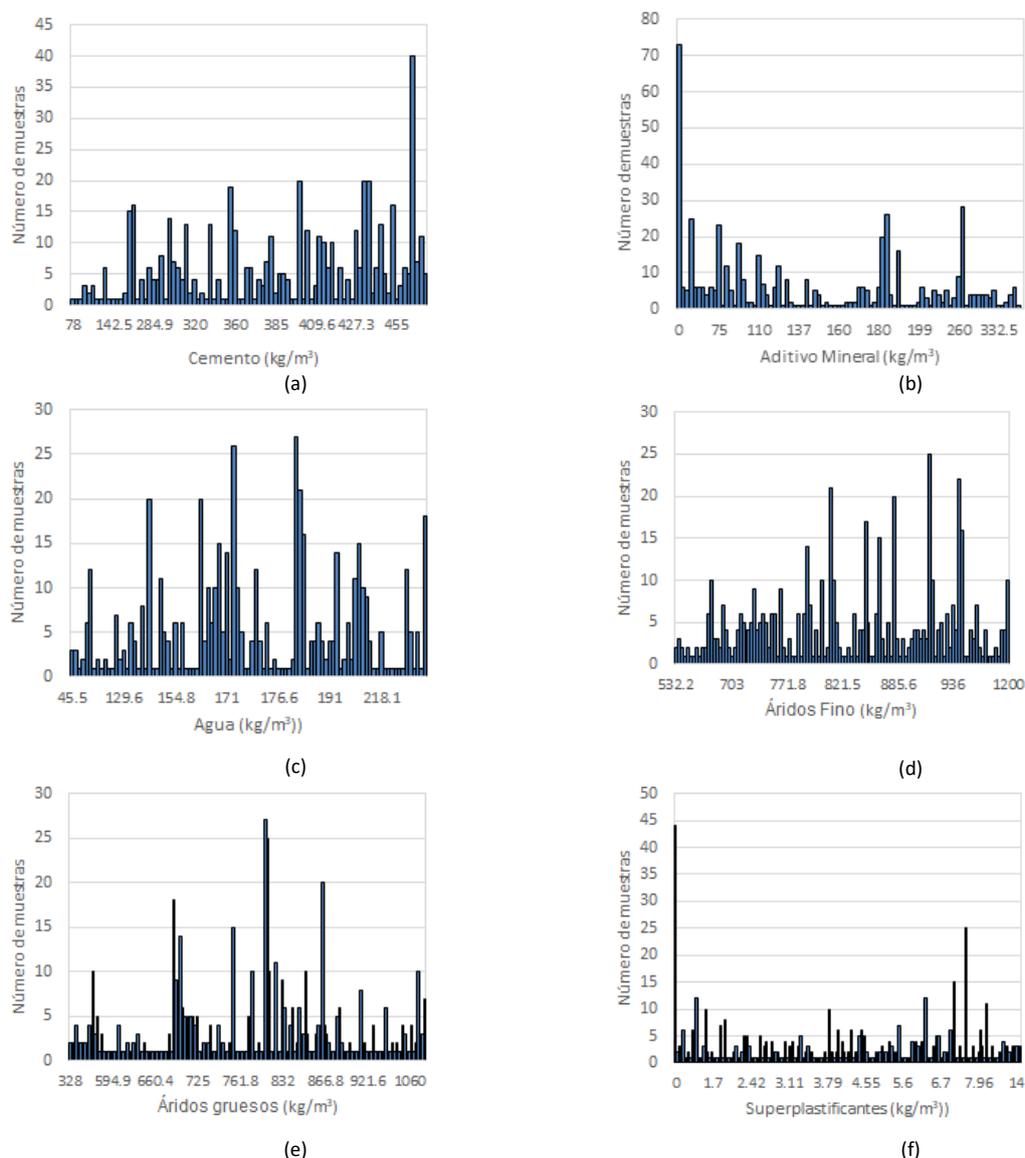


**Figura 55.** Valores mínimo, media y máximo de la variable de salida.

## 4.4.2.2 Visualización de datos

### 4.4.2.2.1 Distribución de frecuencias

Las variables de entrada de X1 a X5 tienen un amplio rango de valores, pero la variable X6 tiene un rango de valores limitado. El contenido de cemento (X1) oscila entre 78 y 635 (kg/m<sup>3</sup>), estando la mayor parte entre 180 y 600 (kg/m<sup>3</sup>). El número máximo de muestras se sitúa alrededor de 40, lo que corresponde a una concentración de cemento de 635 kg/m<sup>3</sup>. Asimismo, el aditivo mineral (X2) varía entre 0 y 515 kg/m<sup>3</sup>. El contenido de agua (X3) varía entre unos 45 y 277 (kg/m<sup>3</sup>), como se indica en la Figura 56.



**Figura 56.** Análisis de frecuencia (histograma) de las variables de entrada: a) Cemento; b) Aditivo Mineral; c) Agua; d) Áridos Finos; e) Áridos gruesos y f) Superplastificantes.

El contenido de áridos finos o arena ( $X_4$ ) oscila entre 532 y 1200 ( $\text{kg}/\text{m}^3$ ), con la mayoría de los valores entre 770 y 1000 ( $\text{kg}/\text{m}^3$ ). Los áridos gruesos ( $X_5$ ) oscilan entre 328 y 1170 ( $\text{kg}/\text{m}^3$ ), con valores típicos entre 680 y 920 ( $\text{kg}/\text{m}^3$ ). El contenido de superplastificante ( $X_6$ ) está entre 0 y 16  $\text{kg}/\text{m}^3$ . En la Figura 56, se puede ver la contribución de cada de las 515 muestras a la respectiva variable de entrada.

#### 4.4.2.2.2 Gráfico de multicorrelación (Mapa de calor)

El análisis estadístico ayuda en el desarrollo del modelo de predicción mejorando la precisión de la predicción del resultado. Se investigó la relación entre las variables de entrada (Áridos Finos, Agua, Cemento, Aditivos, Superplastificantes y Áridos Gruesos) y la variable de salida (Resistencia a la Compresión) para ver si había una asociación (Rathakrishnan et al., 2021). La matriz de correlación de Pearson (mapa de calor) se crea para analizar la correlación entre las variables de entrada (independientes), como se muestra en la Figura 57. Las predicciones del modelo pueden estar sesgadas si las variables de entrada tienen correlaciones ( $|R| > 0,8$ ) que sugieren multicolinealidad entre las variables. Aunque varias características están significativamente correlacionadas, por ejemplo, el cemento y los aditivos minerales tienen una correlación de -0.639 mientras que la CA y la FA tienen una correlación de -0.605. Sin embargo, ninguna de las características mostró una correlación ( $|R|$ ) superior a 0,80, lo que demuestra la ausencia de multicolinealidad (Koya, 2021; Nayyar Hassan y El-Hag, 2020).

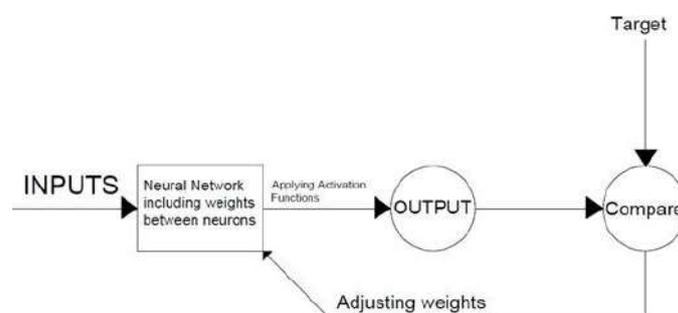
	<i>Cement</i>	<i>Mineral Admixture</i>	<i>Water</i>	<i>FA</i>	<i>CA</i>	<i>SP</i>	<i>f<sub>c</sub> (MPa)</i>
<i>Cement</i>	1.000	-0.639	0.404	0.120	-0.319	0.028	0.305
<i>Mineral Admixture</i>	-0.639	1.000	-0.201	-0.255	-0.017	0.008	-0.060
<i>Water</i>	0.404	-0.201	1.000	0.157	-0.446	-0.229	-0.170
<i>FA</i>	0.120	-0.255	0.157	1.000	-0.605	-0.008	-0.262
<i>CA</i>	-0.319	-0.017	-0.446	-0.605	1.000	0.054	0.105
<i>SP</i>	0.028	0.008	-0.229	-0.008	0.054	1.000	0.299
<i>f<sub>c</sub> (MPa)</i>	0.305	-0.060	-0.170	-0.262	0.105	0.299	1.000

**Figura 57.** Gráfico de multicorrelación entre las variables de entrada y salida.

### 4.4.2.3 Metodología de modelos de redes neuronales artificial

Una red neuronal artificial es un marco de predicción de datos basado en las características actuales desarrolladas a partir de la estructura de la mente humana conocida como red neuronal artificial (ANN). Este sistema está formado por neuronas, que son bloques funcionales. Los pesos unen las neuronas, que generalmente se eligen inicialmente de forma aleatoria. Varios epochs aumentan o reducen la importancia de un proceso de aprendizaje para producir finalmente la red ideal que pueda predecir con bastante precisión (Park y Lek, 2016).

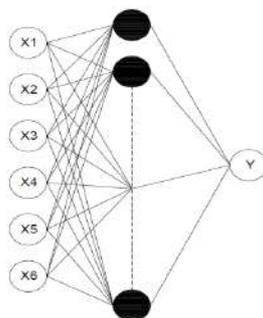
Como resultado, una red neuronal entrenada puede producir la salida deseada al recibir las entradas y considerar los pesos actualizados, como se muestra en la Figura 58. El sistema se fortalece calculando el error y comparando la entrada y la salida requeridas. ANN incluye tres pasos: entrenamiento, validación y prueba. El modelo se ejecuta repetidamente durante la fase de entrenamiento hasta que se obtiene el resultado deseado. Los errores de la fase de validación se descubren durante el entrenamiento (Khademi et al., 2016). El hecho de que el modelo de aprendizaje automático mejore con el tiempo implica que la precisión del modelo de predicción puede aumentar y que los resultados proyectados son fiables. Las funciones de activación no lineales, como la sigmoidea (tansig y logsig), se utilizan habitualmente debido a su excepcional capacidad de respuesta (Bilim et al., 2009).



**Figura 58.** Estructura general de la ANN.

Cuando se desarrolla un modelo de ANN, hay que tener en cuenta varios aspectos. El paso inicial es elegir la estructura más óptima del modelo de ANN. Los datos de entrada y salida deben introducirse en el modelo de ANN elegido. Después, hay que utilizar la experiencia para seleccionar la función de activación, el número de capas, el número de capas ocultas y el número de neuronas en cada capa (Hanbay et al., 2008; Uysal y Tanyildizi, 2011).

Con respecto a las Tablas 22 y 23, la red en este estudio comprende seis variables de entrada, una de salida y una sola capa oculta. El cemento, los aditivos, el agua, los áridos finos y gruesos y el superplastificante son todas las variables de la capa de entrada. El parámetro de salida se eligió como la resistencia a la compresión del hormigón autocompactante con áridos reciclados. Esta investigación emplea una red neuronal de retropropagación de avance. La Figura 59 muestra la arquitectura de la presente investigación de ANN.



**Figura 59.** *Arquitectura del modelo de ANN.*

En este trabajo se emplearon y Compararon las técnicas de Levenberg-Marquardt (LM), Regularización Bayesiana (BR) y Gradiente Conjugado Escalado de Retropropagación (SCGB). Se utilizó el software MATLAB para diseñar y ejecutar la red.

Aunque el método de Levenberg-Marquardt es más rápido, frecuentemente utiliza más memoria. Como se observa por el aumento del error medio cuadrático de las muestras de validación, el entrenamiento termina automáticamente cuando la generalización deja de mejorar. Sin embargo, aunque la Regularización Bayesiana lleva más tiempo, puede producir una buena generalización para conjuntos de datos complicados, menores o difíciles. El entrenamiento llega a su fin debido a la pérdida de peso

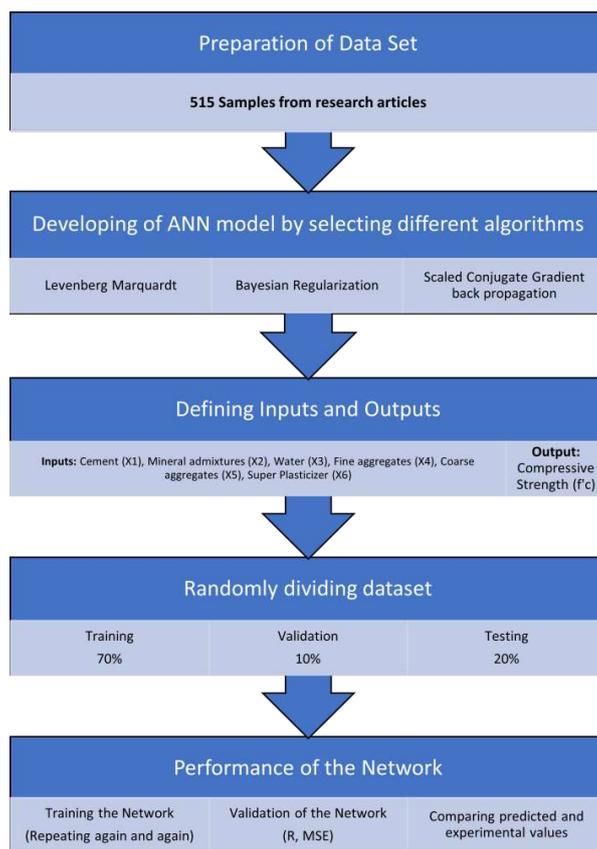
adaptativa (regularización). Por otro lado, la técnica de Gradiente Conjugado Escalado de Retropropagación utiliza menos memoria que las anteriores. Cuando la generalización deja de mejorar, el entrenamiento termina automáticamente, por el aumento del error medio cuadrático de las muestras de validación (Baghirli, 2015; Møller, 1993).

Las tres fases de la red son entrenamiento, validación y prueba. La Tabla 24 muestra la división de los datos para el entrenamiento, la validación y la prueba del modelo. El setenta por ciento de los datos se elige para el entrenamiento, mientras que el diez y el veinte por ciento restantes se selecciona para las fases de validación y prueba.

**Tabla 24.** *División de los datos para el entrenamiento, validación y prueba del modelo.*

Algoritmo de Levenberg-Marquardt		
Paso	Porcentaje %	No. de muestras
Entrenamiento	70	360
Validación	10	52
Prueba	20	103
Total	100	515
Regularización Bayesiana		
Entrenamiento	80	412
Validación	-	0
Prueba	20	103
Total	100	515
Gradiente Conjugado Escalado de Retropropagación		
Entrenamiento	70	360
Validación	10	52
Prueba	20	103
Total	100	515

En la primera fase, se eligen diez neuronas para la capa oculta. En función de su porcentaje, la red seleccionó aleatoriamente 360 muestras para el entrenamiento, 52 para la validación y 103 para la prueba. Para la Regularización Bayesiana (BR), no se requiere la validación, por lo que las muestras de entrenamiento y prueba son 412 y 103, respectivamente. Esto es así porque la regularización suele implicar una validación, sin embargo, las técnicas de BR ya incluyen una validación de tipo in-built-in. La metodología del trabajo de investigación se muestra en la Figura 60.



**Figura 60.** Metodología del trabajo de investigación.

#### 4.4.2.4 Evaluación del modelo de red ANN

Para evaluar el rendimiento del modelo se utilizó el error medio cuadrático (MSE) (ecuación 9) y el coeficiente de correlación (R) (ecuación 1) (Azizifar y Babajanzadeh, 2018; Olu-Ajayi et al., 2022), como se muestra en las ecuaciones 17 y 18, respectivamente..

El coeficiente de correlación es reconocido como la métrica más importante para determinar la precisión general de una red. Los valores de R se utilizan para evaluar la relación entre las salidas y los objetivos previstos. El valor de R de una asociación fuerte es 1, mientras que el valor R de una relación aleatoria es 0 (Azizifar y Babajanzadeh, 2018).

El error medio cuadrático es la diferencia media al cuadrado entre los resultados y los objetivos. Es preferible que el valor sea lo más bajo posible. Si el valor es 0, no hay error.

### 4.4.3 Resultados y discusión

El modelo se realizó utilizando tres algoritmos diferentes: LM, BR y SCG con los resultados comparados y explicados a continuación.

#### 4.4.3.1 Algoritmo Levenberg-Marquardt

Para encontrar el mejor modelo, el algoritmo se entrena continuamente. El rendimiento del modelo con 10 neuronas totales se muestra en la Figura 61. En la Figura se presentan varias líneas de color que representan el entrenamiento (azul), la validación (verde) y la prueba (amarilla). Para evitar el sobreajuste de los datos, el modelo comienza con un MSE alto y posteriormente decrece en función de los criterios de validación. Después de 47 epochs, el error de entrenamiento sigue disminuyendo, pero los errores de validación y prueba fueron aumentando. Como resultado, el proceso de entrenamiento del modelo concluyó tras otras cinco epochs, y en la 47ª iteración se creó un modelo optimizado con el MSE más bajo de 61.6038.

El epoch 47 resulta ser el más adecuado para el entrenamiento de la red con el algoritmo LM porque, mientras que los errores en los datos de entrenamiento disminuyen con el tiempo, los errores en los datos de validación y prueba aumentan. En el método Levenberg-Marquardt,  $\mu$  es la tasa de aprendizaje, y se eligió 0.01 después de determinadas iteraciones (Figura 62b). El proceso de entrenamiento se ha detenido tras seis fallos de validación.

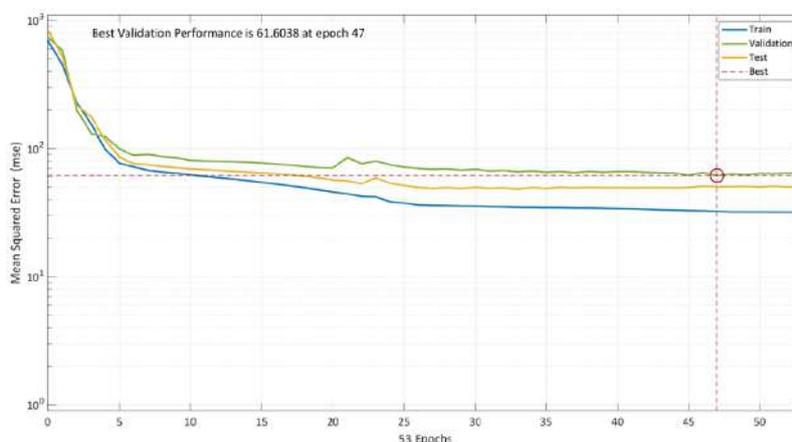
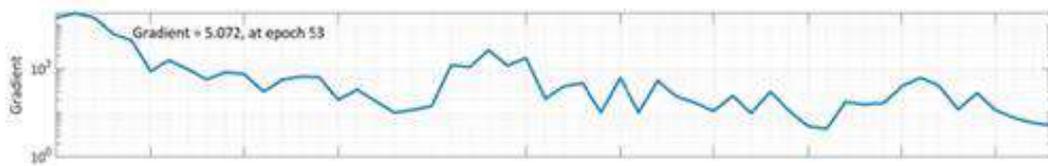
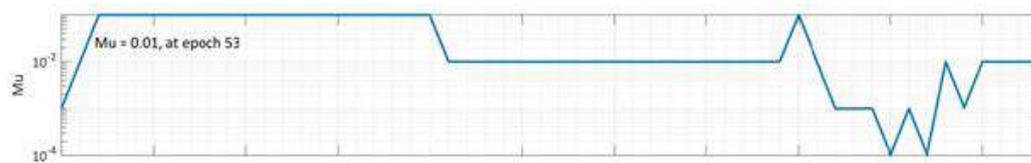


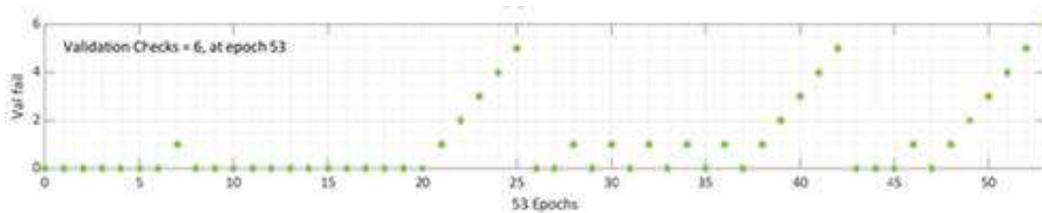
Figura 61. Rendimiento del modelo usando el algoritmo LM.



(a)



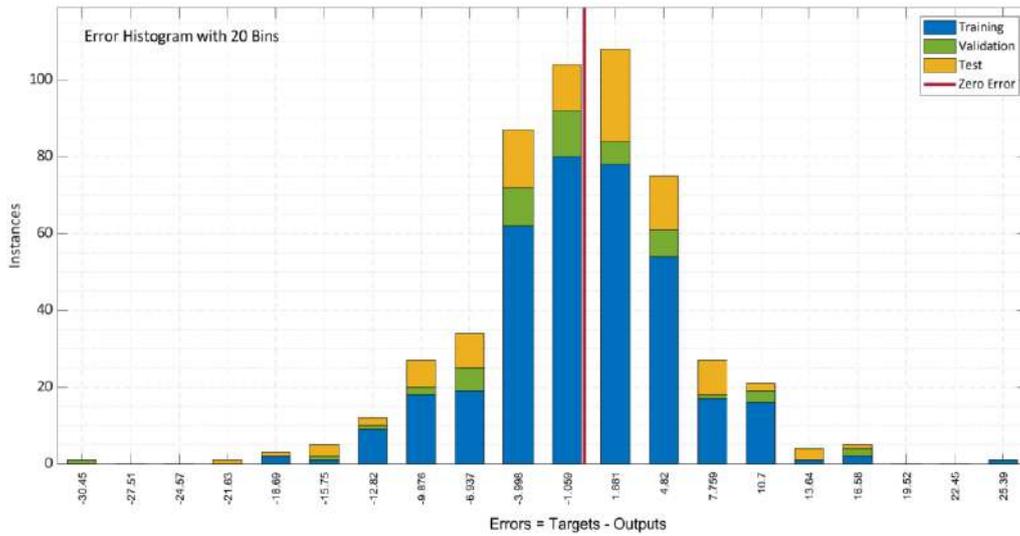
(b)



(c)

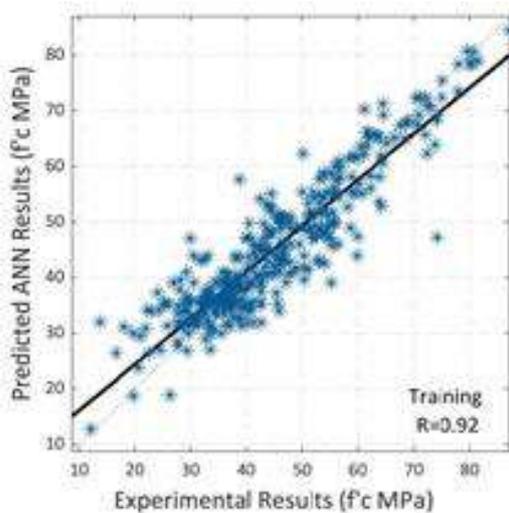
**Figura 62.** Estado de entrenamiento del algoritmo LM: a) Gráfico de gradiente en epoch 53; b) Gráfico de Mu en epoch 53; c) Gráfico de comprobaciones de validación en epoch 53.

La Figura 63 representa el histograma de errores del modelo para el entrenamiento, la validación y la prueba. Las barras convergen a la línea roja centrada, que indica un error cero en la Figura. Estos resultados concluyen que el modelo LM es apropiado para predecir los resultados de la resistencia a la compresión del HAC con AR.

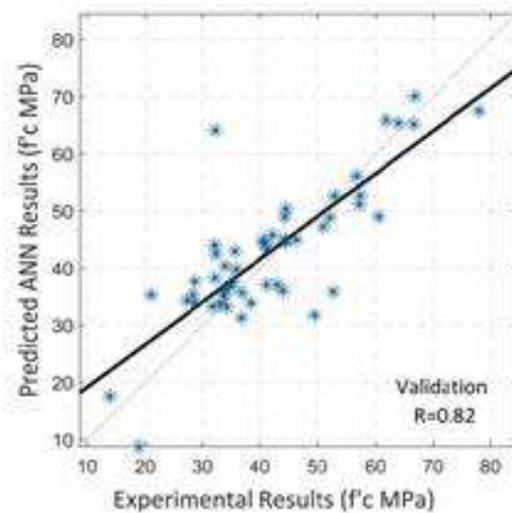


**Figura 63.** Histograma de error del modelo del algoritmo LM.

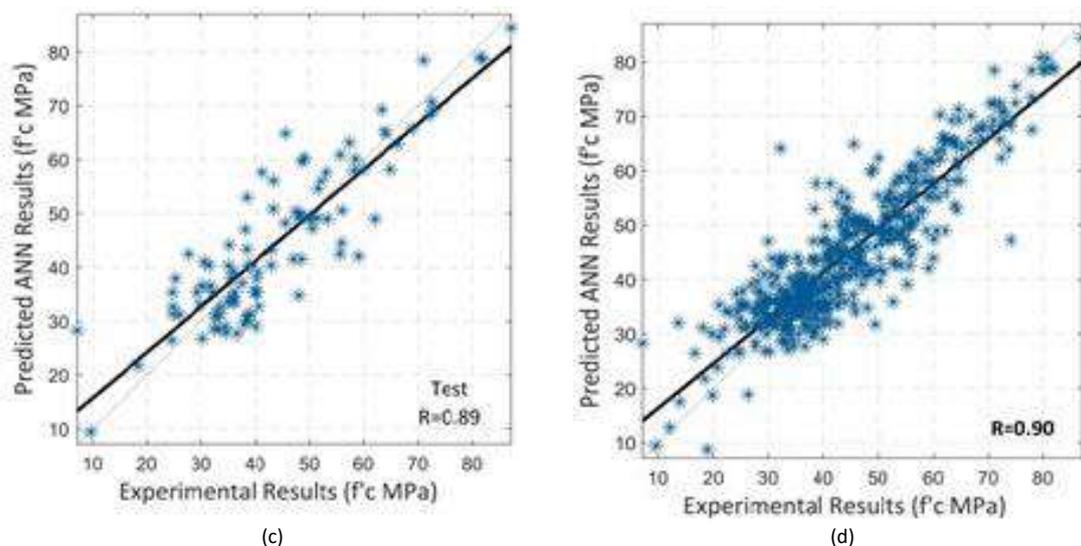
A continuación, se realiza el análisis de regresión. La Figura 64 ilustra la correlación de entrenamiento, validación y prueba entre los parámetros de entrada y salida del modelo. La Figura 64d representa la correlación global del modelo. Se presenta la línea de predicción de color negro en cada caso. El valor R total de 0.90 indica que la correlación es bastante cercana a la línea de predicción, indicando que LM, es un modelo robusto para predecir los valores de resistencia a la compresión de HAC.



(a)



(b)



**Figura 64.** *Análisis de Regresión entre la resistencia a la compresión experimental y predicha mediante el algoritmo LM, Conjunto de datos de: a) entrenamiento; b) validación; c) prueba; d) total.*

En la tabla 25 se resumen los resultados de las medidas de rendimiento, el valor R y el MSE de todo el modelo con el entrenamiento, la validación y la prueba. Por lo tanto, estos resultados sugieren que el método de Levenberg-Marquardt es adecuado para estimar la Resistencia a la Compresión del Hormigón Autocompactante utilizando Áridos Reciclados.

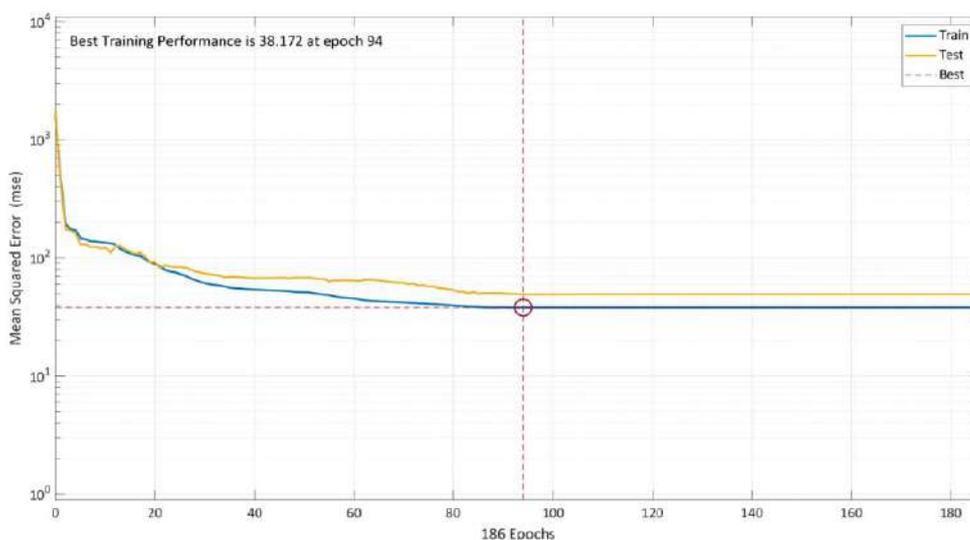
**Tabla 25.** *Resumen de los parámetros de evaluación del modelo del algoritmo LM.*

Paso	Función	MSE	R
Entrenamiento	trainLM	32.41	0.921
Validación	trainLM	61.60	0.823
Prueba	trainLM	50.42	0.890
Total	trainLM	48.14	0.902

### 4.4.3.2 Regularización Bayesiana

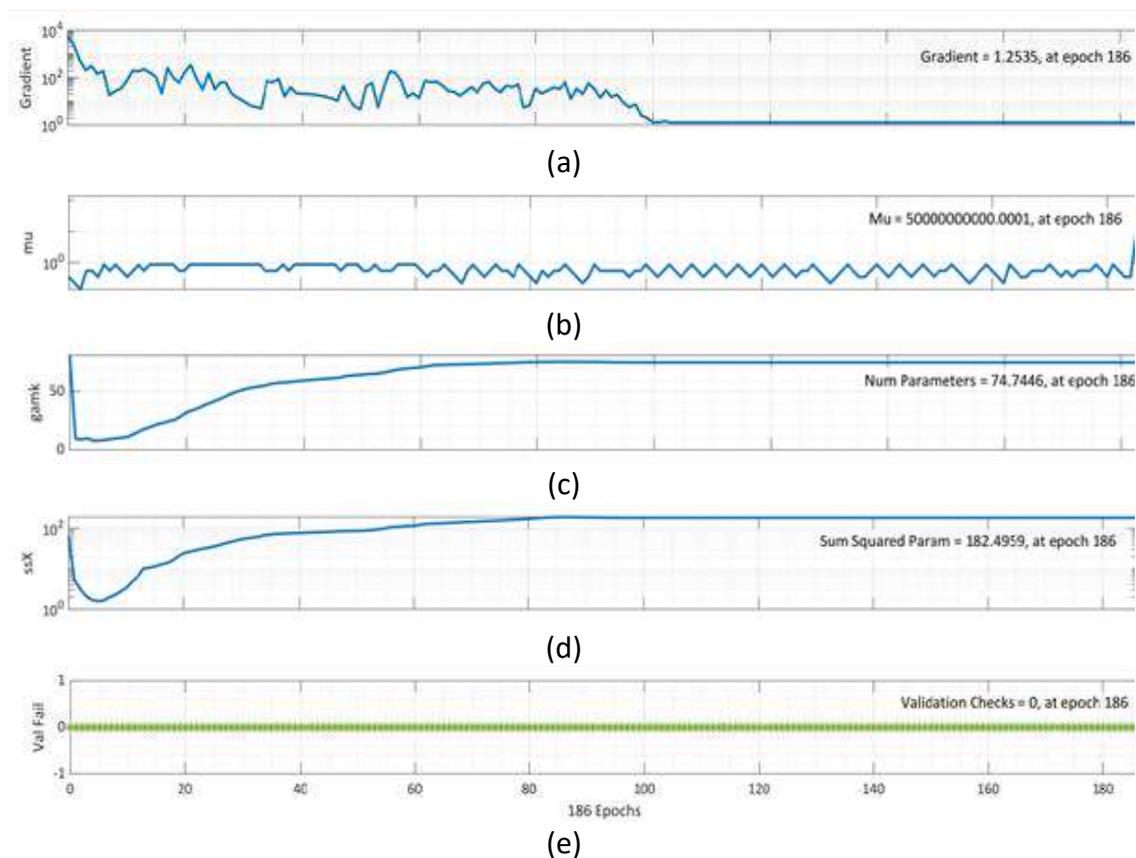
Del mismo modo, el enfoque de Regularización Bayesiana se utiliza para entrenar el modelo. El rendimiento del modelo con el mismo número de neuronas se representa en la Figura 65. En la Figura 65 se observan líneas de dos colores que sólo indican el entrenamiento (azul) y la prueba (amarilla) porque este algoritmo ya lleva incorporado un tipo de validación durante la etapa de entrenamiento. Para evitar el sobreajuste de los datos, el modelo comienza con un MSE alto y reduce gradualmente su dependencia

de los parámetros de entrenamiento. La Figura muestra que el modelo necesitó varios epochs, ya que la RB requiere un tiempo ligeramente superior. Después de 94 epochs, las líneas de error de entrenamiento y de prueba habían disminuido significativamente, y eran casi rectas. El modelo se sigue entrenando para garantizar una validación completa, y el entrenamiento se detiene después de 190 epochs. El modelo evaluó que el mejor rendimiento de entrenamiento por parte del algoritmo BR se encuentra en la iteración 94, es decir, un MSE mínimo de 38.172.



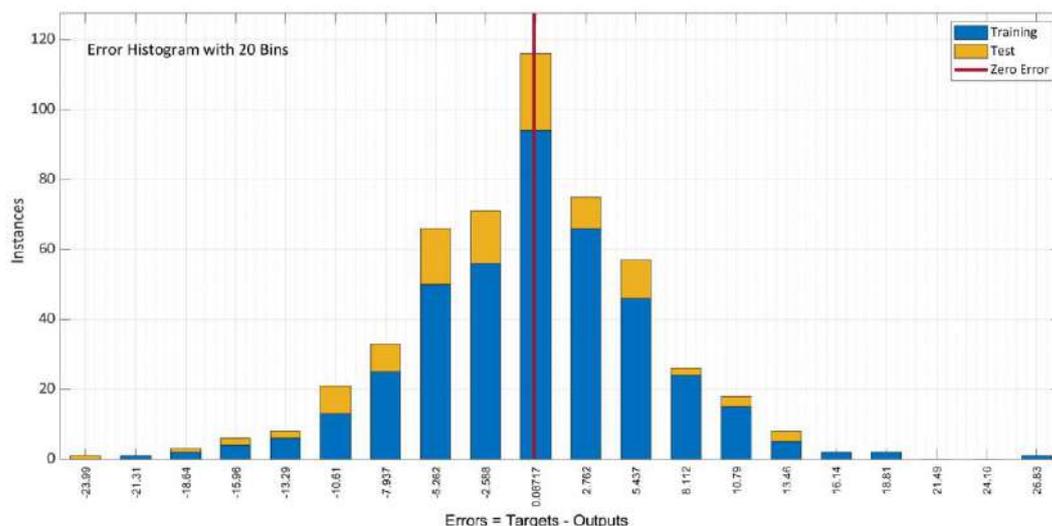
**Figura 65.** Rendimiento del modelo utilizando el algoritmo BR.

En la Figura 66a se observa que los errores de los datos de entrenamiento disminuyen con el tiempo. Sin embargo, los errores de los datos de validación y de prueba aumentan. Por lo tanto, el modelo se entrena más en 186 epochs para una validación completa, y epochs 94 resulta ser la opción más adecuada para el entrenamiento de esta red, como se muestra en la Figura 65. Como  $\mu$  es el parámetro de control para entrenar en el Algoritmo BR, se eligió  $5 \times 10^{10}$  después de varias rondas, como se ve en la Figura 66b. Los parámetros efectivos utilizados por este algoritmo fueron aproximadamente 74 a 186 epochs. La Figura 66e muestra además que no se realizaron comprobaciones de validación, ya que BR tiene un tipo de validación incorporada durante la etapa de entrenamiento, negando la necesidad de un paso de validación.



**Figura 66.** Estado de entrenamiento del algoritmo BR: a) Gráfico de gradiente en epochs 186; b) Gráfico de Mu en epochs 186; c) Gráfico de parámetros numéricos en epochs 186; d) Gráfico de S.S.X. en epochs 186; e) Gráfico de comprobaciones de validación en epochs 186.

La Figura 67 muestra el histograma de errores del modelo entre el entrenamiento y la prueba. La Figura ilustra que, en comparación con el enfoque LM, la aproximación de la barra a la línea de error cero es bastante excepcional y el error es muy bajo. De acuerdo con los resultados de este criterio de rendimiento, el modelo realiza un trabajo aceptable de predicción de los resultados de las características de compresión del HAC con RA.



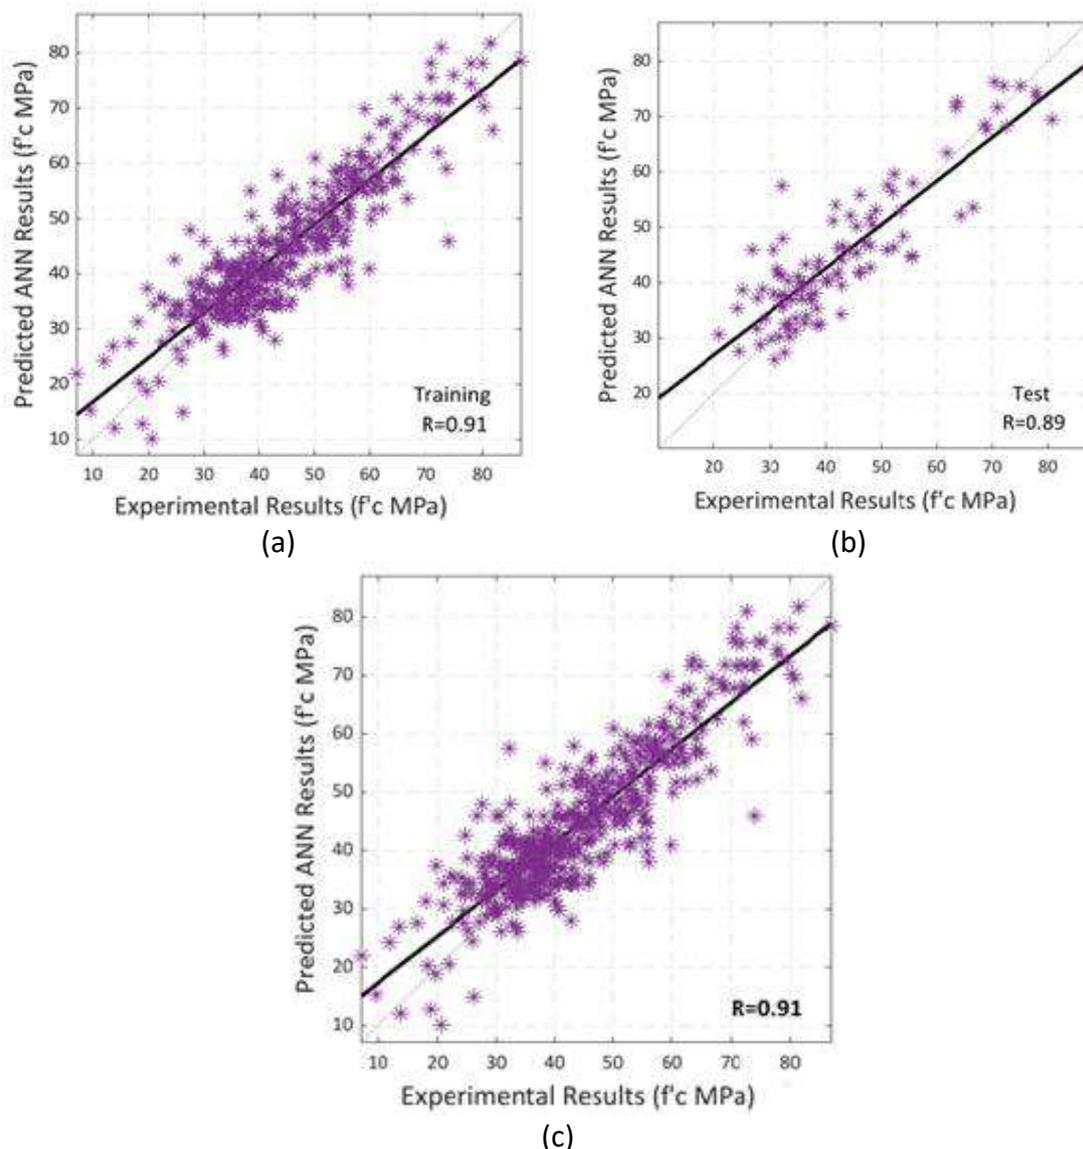
**Figura 67.** Histograma de errores del modelo del algoritmo BR.

A continuación, se llevó a cabo un análisis de regresión de la misma manera. Las correlaciones de entrenamiento y prueba entre los valores de entrada y salida del modelo se muestran en la Figuras 68, que representan la correlación global. En cada escenario se presenta una línea de estimación de color negro. El valor total de R de 0.91 indica que el modelo entrenado utilizando la Regularización Bayesiana tiene un alto nivel de precisión en la predicción de la salida, es decir, la resistencia a la compresión del HAC utilizando RA.

La Tabla 26 concluye resumiendo todos los resultados del parámetro de rendimiento, incluyendo el valor R y el MSE del modelo completo con el entrenamiento y la prueba. En general, nuestros resultados implican que la Regularización Bayesiana puede ser utilizada para calcular la resistencia a la compresión del hormigón autocompactante construido a partir de recursos reciclados.

**Tabla 26.** Resumen de los parámetros de evaluación del modelo del algoritmo BR.

Paso	Función	MSE	R
Entrenamiento	trainbr	38.17	0.9154
Prueba	trainbr	49.34	0.8923
Total	trainbr	43.755	0.9100

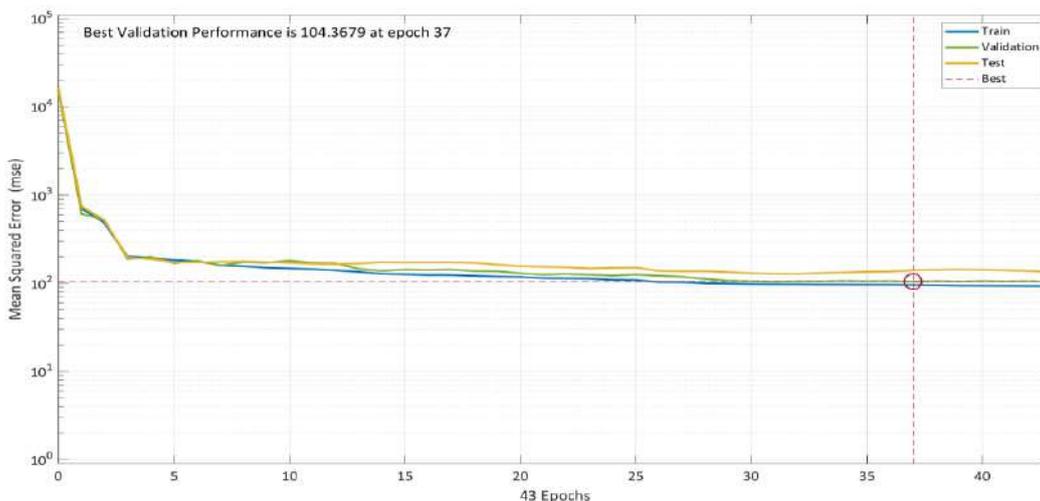


**Figura 68.** Análisis de regresión utilizando el algoritmo BR entre la resistencia a la compresión experimental y la predicha. Conjunto de datos: a) Entrenamiento; b) Prueba; c) Global.

#### 4.4.3.3 Gradiente Conjugado Escalado de Retropropagación

El Gradiente Conjugado Escalado de Retropropagación (SCGB) se utiliza para el entrenamiento del modelo. El rendimiento del modelo con 10 neuronas en total se muestra en la Figura 69. El gráfico se compone de varias líneas de color, que representan el entrenamiento (azul), la validación (verde) y la prueba (amarilla). Para evitar el

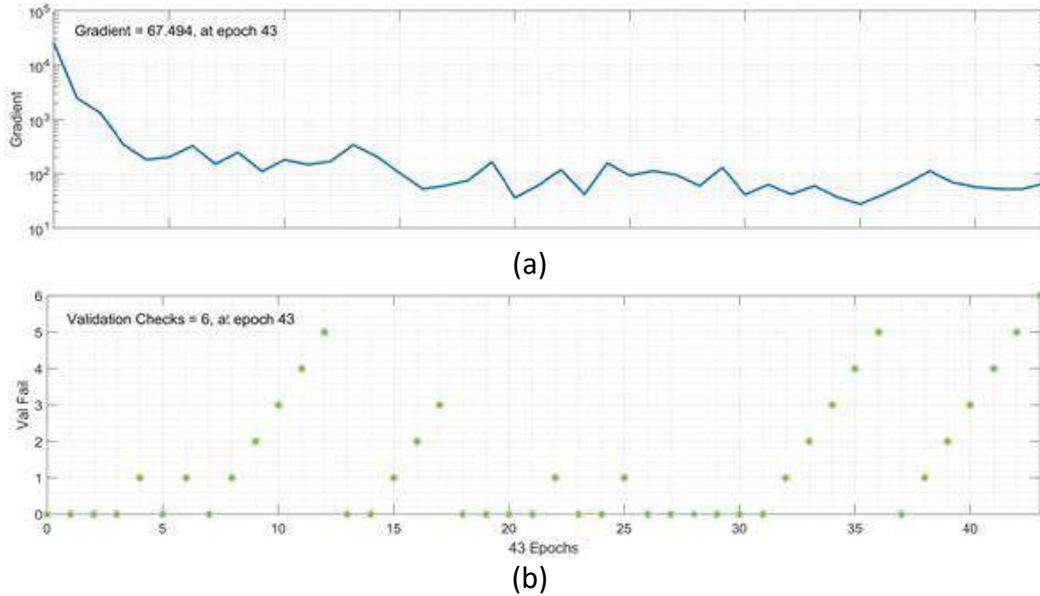
sobreajuste de los datos, el modelo comienza con un MSE alto y lo reduce gradualmente en función de los parámetros de validación. Según la figura 69, el MSE no disminuyó significativamente en comparación con los otros dos enfoques. El error de entrenamiento disminuyó después de 37 epochs, sin embargo, los errores de validación y prueba aumentaron un poco. El entrenamiento del modelo terminó después de seis repeticiones más, y se produjo el modelo optimizado con el MSE más bajo.



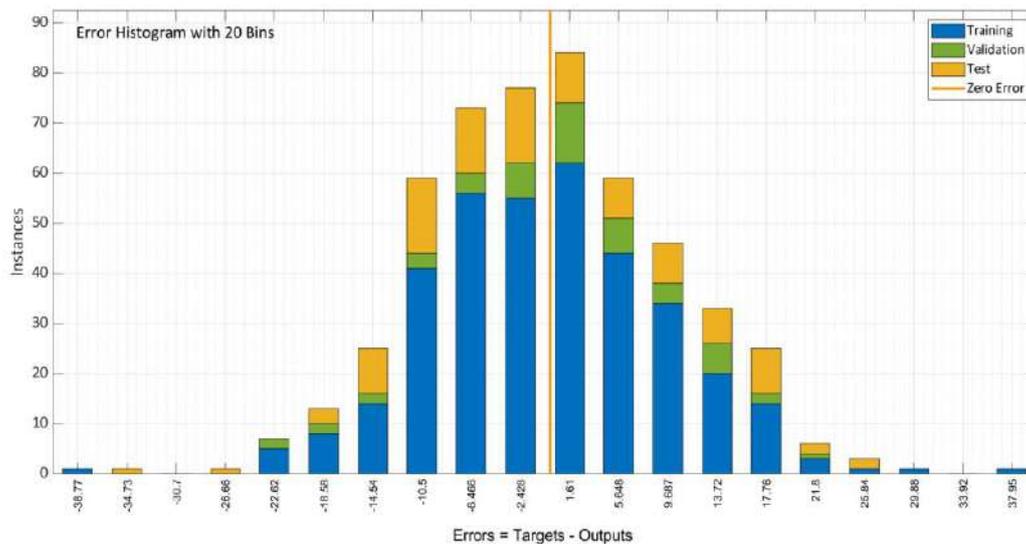
**Figura 69.** Rendimiento del modelo utilizando el algoritmo SCGB.

Epoch 37 es una opción adecuada para el entrenamiento de esta red porque mientras los errores de los datos de entrenamiento disminuyen con el tiempo, los errores de validación y los datos de prueba aumentan. La figura 70b deja claro que el proceso de entrenamiento se detuvo tras seis fallos de validación.

Para el entrenamiento, la validación y la prueba, la Figura 71 muestra el histograma de errores del modelo. La Figura muestra la inexactitud con la que las barras de error parecen converger a la línea de error cero. Los resultados concluyen que el modelo tiene unos valores de error elevados en comparación con los algoritmos LM y BR y tiene un bajo rendimiento en la predicción de los resultados de la resistencia a la compresión de HAC con RA.

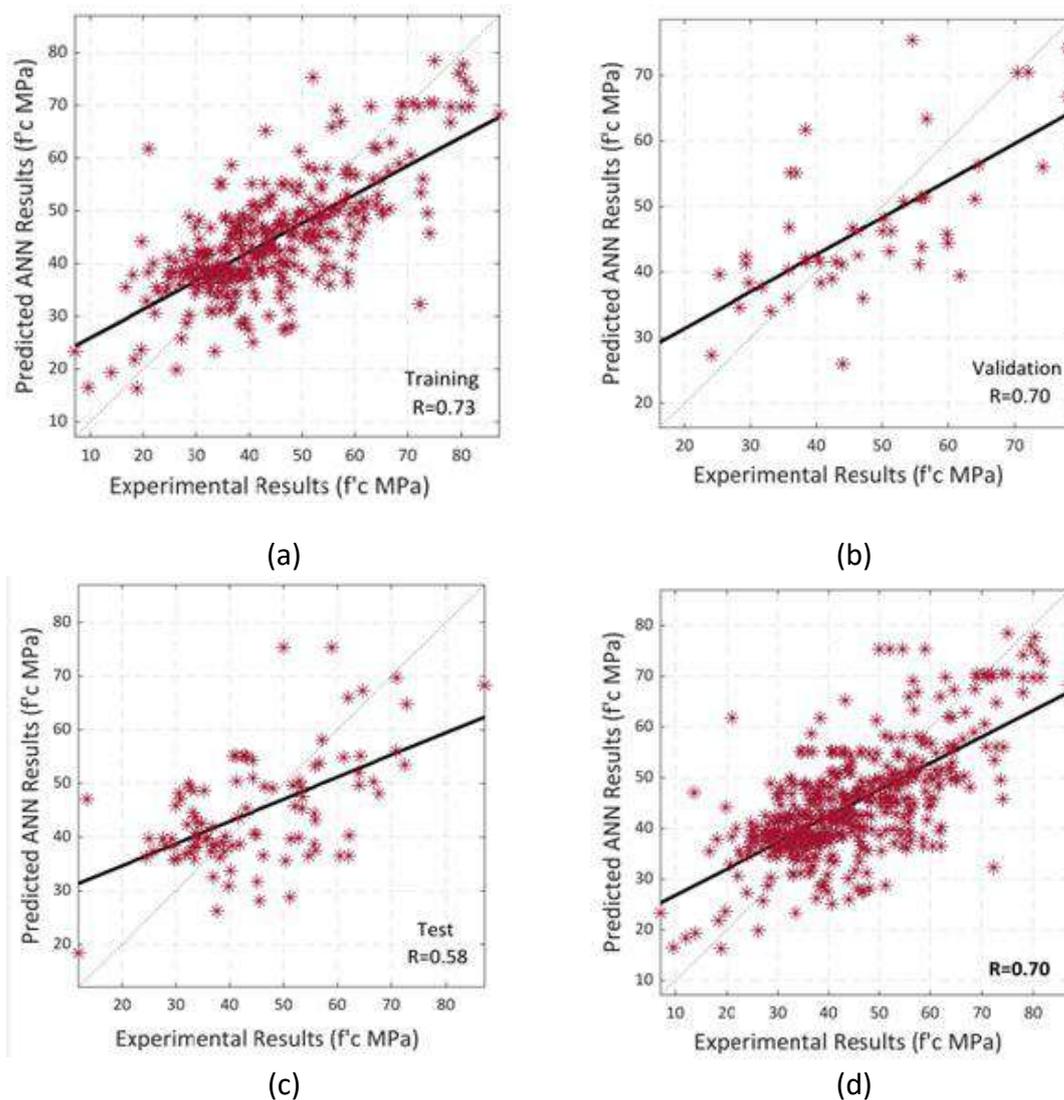


**Figura 70.** Estado de entrenamiento del algoritmo SCG: a) Gráfico de gradiente en la epoch 43; b) Gráfico de comprobaciones de validación en la epoch 43.



**Figura 71.** Histograma de errores del modelo del algoritmo SCG.

A continuación, se realiza un estudio de regresión. La Figuras 72 ilustra la relación entre el entrenamiento, la validación y la prueba para los valores de entrada y salida del modelo. La Figura 72d muestra la precisión o correlación global del modelo. La recta de predicción se muestra en negro en cada caso. El valor R total de 0.70, indica un modelo mediocre o promedio para la predicción de la resistencia a la compresión del HAC utilizando el RA, el valor de R debería dejar claro que su conexión no es lineal.



**Figura 72.** Análisis de regresión mediante el algoritmo SCG entre la resistencia a la compresión experimental y la predicha. Conjunto de datos: a) Entrenamiento; b) Validación; c) Prueba; d) global.

La Tabla 27 presenta los resultados de las medidas de rendimiento, el valor R y el MSE para el modelo total, así como entrenamiento, validación y prueba. De acuerdo con nuestra investigación, el algoritmo SCGB es menos preciso que LM y BR en la predicción de la resistencia a la compresión del hormigón autocompactante que incorpora áridos reciclados.

**Tabla 27.** Resumen de los parámetros de evaluación del modelo del algoritmo SCGB.

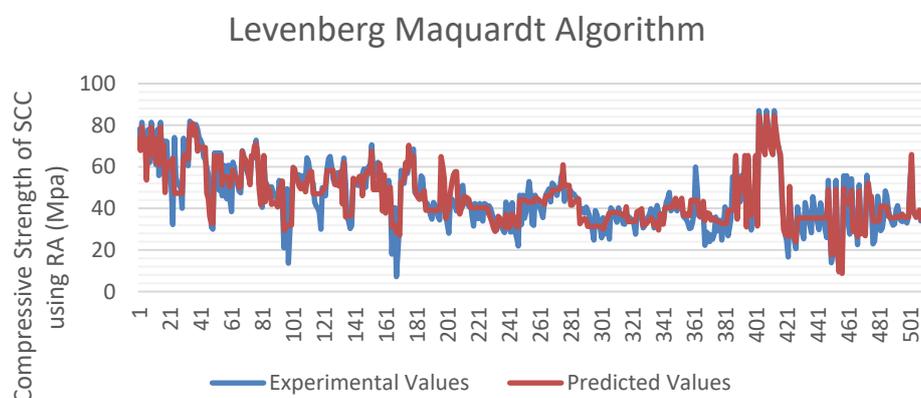
Paso	Función	MSE	R
Entrenamiento	trainSCG	95.62	0.732
Validación	trainSCG	104.36	0.704
Prueba	trainSCG	140.27	0.581
Total	trainSCG	113.42	0.701

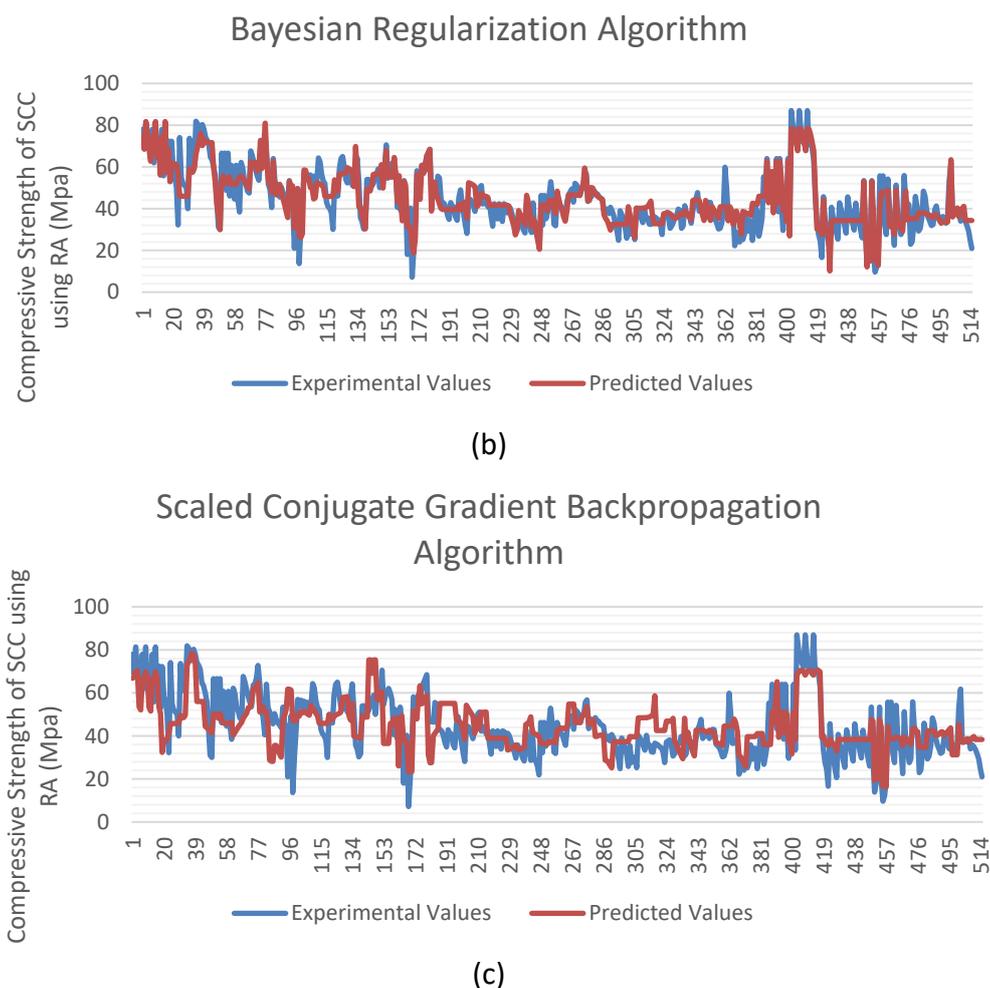
#### 4.4.3.4 Comparación de algoritmos

Los tres enfoques se Compararon basándose en los datos experimentales y en las predicciones de ANN. La Figura 73 compara los valores experimentales y los predichos de los modelos entrenados con los algoritmos LM, BR y SCG, respectivamente. La línea roja en el eje Y representa los valores proyectados, mientras que la línea azul representa los valores experimentales de la resistencia a la compresión de HAC utilizando áridos reciclados. El conjunto de datos de 515 muestras se muestra en el eje X.

La mayor discrepancia entre las dos líneas muestra el mayor error entre los dos parámetros. Los valores predichos por los algoritmos LM y BR se correlacionan bien con los valores experimentales, como se evidencia en la Figura 73. En cambio, el algoritmo SCG indica una diferencia más significativa entre las dos líneas. La Figura 74 representa el valor R total (en porcentaje) y el error medio cuadrático de los todos los algoritmos.

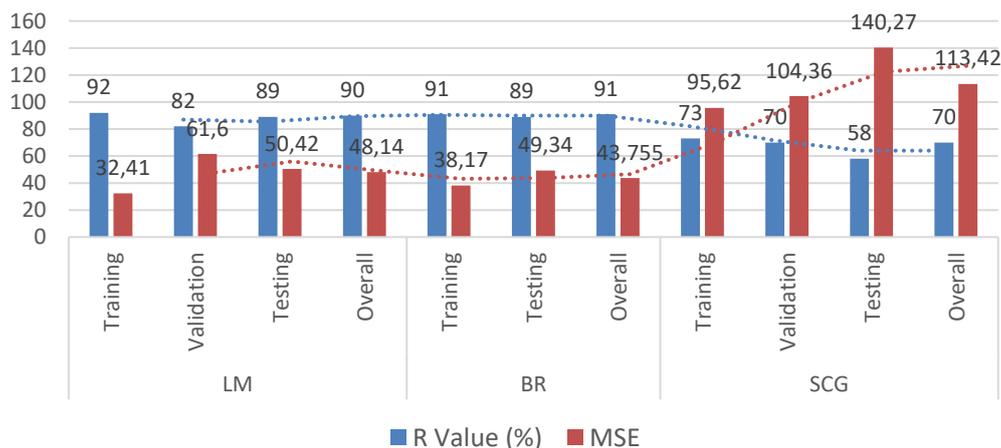
Como se muestra en las Figuras 73 y 74, tanto el algoritmo de Regularización Bayesiana como el de Levenberg-Marquardt tienen casi los mismos gráficos de mejor ajuste, y ambos tienen aproximadamente el mismo valor R y MSE.





**Figura 73.** Comparación de los valores experimentales de resistencia a la compresión y los predichos por los diferentes algoritmos empleados en la ANN. Algoritmos de ANN: a) LM; b) BR, y c) SCG.

Dada la variedad de los datos, la técnica de BR obtuvo mejores rendimientos porque puede ofrecer una generalización significativa para conjuntos de datos complicados (Suescum-Morales et al., 2021) También se concluye que utilizando el extenso conjunto de datos actuales, el algoritmo de Levenberg-Marquardt tiene una alta velocidad y casi la misma tasa de predicción que el algoritmo BR y puede predecir la Resistencia a la compresión del Hormigón *Autocompactante* utilizando áridos reciclados con alta precisión. El algoritmo SCG mostró resultados pobres en *comparación* con los otros dos algoritmos



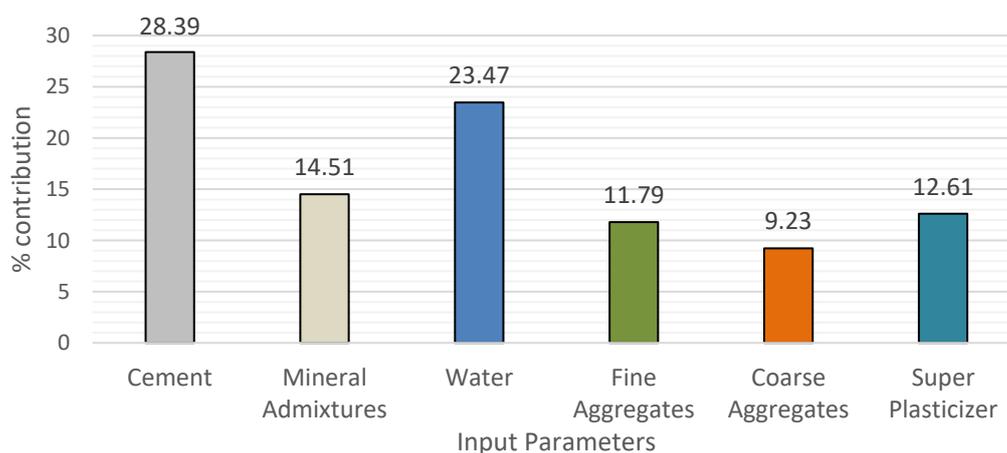
**Figura 74.** Valor R (%) y MSE de los algoritmos LM, BR y SCG.

#### 4.4.3.5 Análisis de sensibilidad

El análisis de sensibilidad demuestra cómo una sola variable de entrada influye en la variable de salida. El impacto de las variables de entrada en la variable de salida aumenta con el incremento de los niveles de sensibilidad. La variable de entrada tiene una influencia considerable en las variables de predicción de salida, como afirman Shang et al. (2022). El análisis de sensibilidad se llevó a cabo para evaluar el impacto de una sola variable de entrada, incluyendo el árido fino, el cemento, el agua, el aditivo, el superplastificante y los áridos gruesos, en la variabilidad de la resistencia a la compresión del hormigón autocompactante que incorpora áridos reciclados. El análisis de sensibilidad se calcula utilizando las ecuaciones 6 y 7.

El árido fino, el cemento, el agua, el aditivo, el superplastificante y el árido grueso son factores de entrada importantes para estimar la resistencia a la compresión del hormigón autocompactante con árido reciclado. Los resultados de este estudio de sensibilidad se muestran en la Figura 75, donde se puede demostrar que el agua y el cemento Portland son los factores de entrada críticos en la determinación de la resistencia a la compresión del HAC con áridos reciclado. El cemento Portland representa el 28.39 % del total, mientras que el agua representa el 24.37 %. Shang et al. (2022) señalan que el cemento Portland es un elemento crítico en la predicción de la resistencia a la compresión. Sin embargo, las variables de entrada, tales como, los áridos

finos, el aditivo y el superplastificante muestran contribuciones comparables de 14.51 %, 12.61 % y 11.79 %, respectivamente. Los resultados del estudio revelaron que CA (9,32 %) es la variable menos eficiente en la predicción de la resistencia a la compresión, lo cual es consistente con los resultados de investigaciones anteriores (W. Ahmad, Ahmad, et al., 2021).



**Figura 75.** Contribución de las variables de entrada a la resistencia a la compresión del HAC con RA.

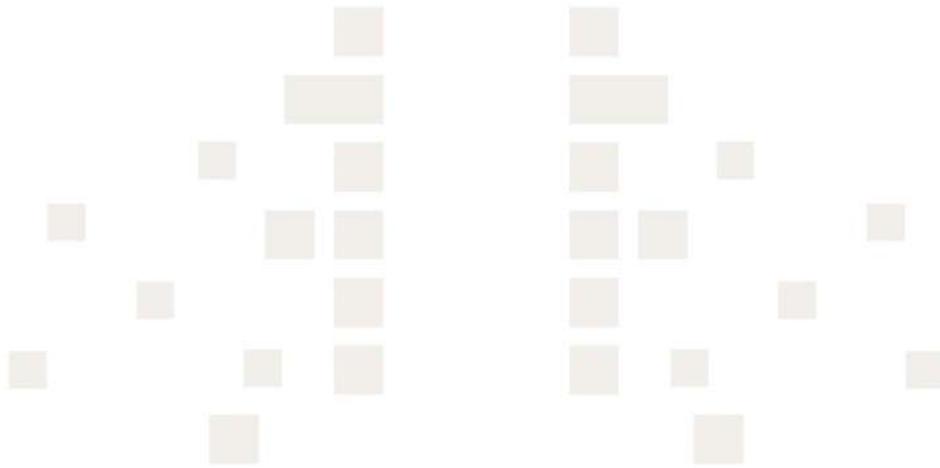
#### 4.4.4 Conclusiones parciales

Esta investigación tiene como objetivo predecir y Comparar la resistencia a la compresión del hormigón autocompactante (HAC) modificado con áridos reciclados (RA) utilizando tres algoritmos diferentes de redes neuronales artificiales (ANN): LM, BR y SCG. Los seis parámetros de entrada que entrenan el modelo son el cemento, el agua, los aditivos, los áridos gruesos, los áridos finos y el superplastificante. Se emplearon R y el MSE como medidas de evaluación. De esta investigación se obtuvieron las siguientes conclusiones.

1. Para el desarrollo de los modelos LM, BR y SCG, se adquirieron un total de 515 muestras de artículos de investigación y se distribuyeron aleatoriamente en un 70%, 10% y 20% para el entrenamiento (360), validación (52) y prueba (103), respectivamente. Debido al mecanismo de validación incorporado en la fase de

entrenamiento del algoritmo de la RB, la proporción pasó a ser del 80% para entrenamiento y del 20% para prueba.

2. Se entrenaron y evaluaron tres algoritmos, LM, BR y SCG, que dieron una precisión global del 90%, 91% y 70%, respectivamente, con un MSE de 48.14, 43.75 y 113.42. El algoritmo SCG es el peor modelo para pronosticar la resistencia a la compresión del HAC con RA, teniendo una baja correlación y error medio cuadrático alto.
3. La Regularización Bayesiana arrojó mejores resultados que LM y SCG, con el mayor coeficiente de correlación ( $R=91\%$ ) y el menor MSE (43.75). Sin embargo, mientras tanto, el algoritmo LM también dio casi el mismo coeficiente de correlación ( $R=90\%$ ) con un tiempo de procesamiento mucho más corto que el algoritmo BR.
4. Los hallazgos demostraron que los algoritmos LM y BR son modelos adecuados y pueden adaptarse para predecir la resistencia a la compresión a 28 días del hormigón autocompactante modificado con áridos reciclados.
5. De acuerdo al análisis de sensibilidad del modelo, el parámetro más significativo que determina la resistencia a la compresión es el cemento, con una contribución del 28.39%. El agua tiene una contribución del 23.47%, siendo otra variable relevante en la predicción de la resistencia a la compresión en el mismo fraguado. Por el contrario, la variable con menor incidencia es el árido grueso (9.23%). Todos los datos sugieren que el cemento y el agua mejoran la resistencia a la compresión del HAC con RA, pero el árido grueso la disminuye. Por otro lado, el aditivo, los áridos finos y los superplastificantes juegan un papel menor en el desarrollo del modelo.





**CAPÍTULO V**  
**Conclusiones**

CHAPTER IV. Conclusions

## 5.1 CONCLUSIONES GENERALES

A continuación, se presentan las principales conclusiones de las publicaciones que componen el capítulo de publicaciones de la presente Tesis. Dichas conclusiones se organizan a la luz de los objetivos específicos planteados en la presente investigación.

**1. Objetivo específico 2:** *Predecir la resistencia a compresión a 28 días del hormigón autocompactante con áridos reciclados (HACR) a través de la aplicación de modos Ensemble de aprendizaje automático (ML).*

- ❖ Los resultados del conjunto de datos de prueba, mostraron que los modelos Bagging RF ( $R^2 = 0.7128$ , RMSE = 0.0807, MAE = 0.06) y Boosting GB ( $R^2 = 0.6948$ , RMSE = 0.0832, MAE = 0.0569) presentan el mayor rendimiento con una alta precisión de predicción. Sin embargo, también se evidenció que los modelos GAM1 ( $R^2 = 0.2722$ ) y GAM2 ( $R^2 = 0.27662$ ) no son buenos modelos para predecir la resistencia a la compresión, esto se comprobó con los valores presentados de  $R^2$  que son mucho menores a 0.60.
- ❖ El modelo Random Forest (RF) ( $R^2 = 0.7128$ , RMSE = 0.0807, MAE = 0.06) es el mejor modelo para la predicción de la Resistencia a la compresión, en comparación con los otros modelos.
- ❖ El cemento y el agua son los componentes de la mezcla que tienen más influencia en la resistencia a la compresión del HAC con RA, con una contribución, cada uno, superior al 20%.
- ❖ El árido grueso es el componente de la mezcla que menos contribuye a la resistencia a la compresión del HAC con RA
- ❖ La resistencia a la compresión del HAC con RA aumenta más con el cemento y el agua, mientras que los áridos gruesos la disminuyen.

**2. Objetivo específico 3:** *Comparar cuatro métodos de aprendizaje automático (ML): Extreme Gradient Boosting (XGBoost), Gradient Boosting, CatBoost y Extremely Randomized Trees (ETR) para predecir la resistencia a la tracción a 28 días del hormigón autocompactante con áridos reciclados (HACR).*

- ❖ Los cuatro métodos de ML predijeron la resistencia a la tracción del HAC con RA con una precisión satisfactoria; los valores de  $R^2$  de los datos de entrenamiento para XGBoost, GB, CRB y ETR iguales 0.9421; 0.9292; 0.9382 y 0.9484, respectivamente, y todos los modelos alcanzaron un valor superior a 0.75.
  - ❖ XGBoost fue el modelo con mejor rendimiento, al mostrar para el conjunto de datos de prueba, el valor más alto de  $R^2 = 0.8423$ , así como los valores más bajos de RMSE = 0.0581 y MAE = 0.0443, en comparación con los modelos GB, CB y ETR.
  - ❖ El modelo XGBoost se considera el mejor para predecir la resistencia a la tracción a los 28 días del HAC con RA
  - ❖ El cemento es el componente de la mezcla que más contribuye (30.07%) a la predicción de la resistencia a la tracción a los 28 días del HAC con RA.
  - ❖ El agua es el componente que menos contribuye (2.39%) a la predicción de la resistencia a la tracción a los 28 días del HAC con RA.
  - ❖ La resistencia a la tracción a los 28 días del HAC con RA, aumenta al aumentar la proporción de cemento en la mezcla.
- 3. Objetivo específico 4:** *Predecir la resistencia a la tracción a los 28 días del hormigón autocompactante con áridos reciclados (HACR) utilizando la técnica de redes neuronales artificiales, comparando los siguientes algoritmos: Levenberg-Marquardt (LM), Regularización Bayesiana (BR) y Gradiente Conjugado Escalado de Retropropagación (SCGB).*
- ❖ Los algoritmos: LM, BR y SCG, que dieron una precisión global del 85%, 91% y 64%, con un MSE de 0,2927, 0,2087 y 0,6234.
  - ❖ SCG no es un buen algoritmo para predecir la resistencia a la tracción del HAC con RA, debido a que el R es muy bajo y el MSE muy alto.
  - ❖ La Regularización Bayesiana presenta el mejor rendimiento, al presentar un coeficiente de correlación ( $R > 90\%$ ) y un MSE mínimo (0,2087) respecto a LM y SCG.
  - ❖ El algoritmo BR es el mejor modelo para la predicción de la resistencia a la tracción a 28 días del hormigón autocompactante con áridos reciclados

- ❖ El cemento es la variable de entrada esencial en la predicción de la resistencia a la tracción a 28 días del HAC con RA, al presentar una contribución del 30.07 %.
- ❖ El agua tuvo la menor influencia en la resistencia a la tracción a 28 días del HAC con RA (2,39 %).

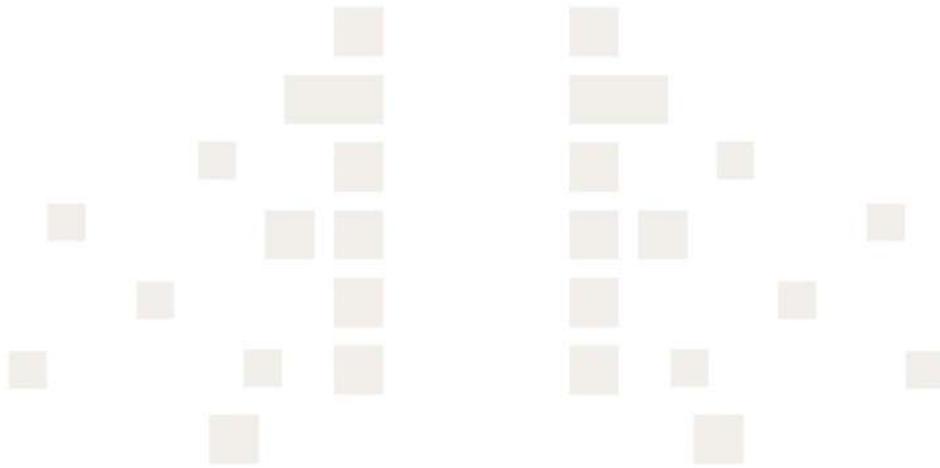
**4. Objetivo específico 5:** *Utilizar redes neuronales artificiales (ANN) para validar y pronosticar la resistencia a compresión del hormigón autocompactante con áridos reciclados (HACR), desarrollando y comparando diferentes técnicas, como la de Levenberg-Marquardt (LM), Regularización Bayesiana (BR) y Gradiente Conjugado Escalado de Retropropagación (SCGB).*

- ❖ Para predecir la resistencia a la compresión del HAC con RA, se entrenaron y evaluaron los algoritmos: LM, BR y SCG, que dieron una precisión global del 90%, 91% y 70%, respectivamente, con un MSE de 48.14, 43.75 y 113.42.
- ❖ El algoritmo SCG es el peor modelo para pronosticar la resistencia a la compresión del HAC con RA.
- ❖ La Regularización Bayesiana arrojó mejores resultados que LM y SCG, con el mayor coeficiente de correlación ( $R=91\%$ ) y el menor MSE (43.75).
- ❖ Sin embargo, el algoritmo LM también dio casi el mismo coeficiente de correlación ( $R=90\%$ ), aun cuando el MSE es relativamente un poco más elevado que el de BR, por 5 puntos, su tiempo de procesamiento mucho más corto que el algoritmo BR.
- ❖ Los algoritmos LM y BR son buenos predictores de la resistencia a la compresión a 28 días del hormigón autocompactante modificado con áridos reciclados.
- ❖ El cemento y el agua son los parámetros que tienen una mayor incidencia en la resistencia a la compresión, con una contribución del 28.39 y 23.47%, respectivamente.
- ❖ El árido grueso es el componente de la mezcla con menor incidencia en la resistencia a la compresión. Presenta una contribución del 9.23%.
- ❖ El cemento y el agua mejoran la resistencia a la compresión del HAC con RA, pero el árido grueso la reduce.

## 5.2 LÍNEAS FUTURAS DE INVESTIGACIÓN

En función de los resultados alcanzados en la presente investigación, en lo referido a la aplicación de técnicas de aprendizaje automático (M) y redes neuronales artificiales (ANN) para la predicción de la resistencia a la compresión y la resistencia a la tracción del HAC con RA, se plantea el desarrollo de futuras líneas de investigación que permitan complementar o profundizar acerca de la temática desarrollada:

- ❖ Comparar con otras bases de datos de diferente procedencia los algoritmos empleados en la presente investigación.
- ❖ Comparar el modelo Random Forest con los algoritmos Regularización Bayesiana y Levenberg-Marquardt para la predicción de la resistencia a la compresión a 28 días del HAC con RA.
- ❖ Comparar el modelo XGBoost con el algoritmo Regularización Bayesiana para la predicción de la resistencia a la tracción a 28 días del HAC con RA.
- ❖ Incluir como variable predictora la relación agua-cemento en el modelado de la resistencia a la compresión y a la tensión por división.
- ❖ Modelar la resistencia a la tracción y a la compresión considerando como variables cada uno de los áridos reciclados empleados en las muestras, para poder evaluar cómo inciden en la predicción.





# **CAPÍTULO VI** **Referencias**

CHAPTER VI. References

## 6.1 REFERENCIAS

- Abdon Dantas, A. T. A., Batista Leite, M., y de Jesus Nagahama, K. (2013). Prediction of compressive strength of concrete containing construction and demolition waste using artificial neural networks. *Construction and Building Materials*, 38, 717-722. <https://doi.org/10.1016/j.conbuildmat.2012.09.026>
- Abu Yaman, M., Abd Elaty, M., y Taman, M. (2017). Predicting the ingredients of self-compacting concrete using artificial neural network. *Alexandria Engineering Journal*, 56(4), 523-532. <https://doi.org/10.1016/j.aej.2017.04.007>
- Adesina, A., y Awoyera, P. (2019). Overview of trends in the application of waste materials in self-compacting concrete production. *SN Applied Sciences*, 1(9), 962. <https://doi.org/10.1007/s42452-019-1012-4>
- Ahmad, A., Farooq, F., Niewiadomski, P., Ostrowski, K., Akbar, A., Aslam, F., y Alyousef, R. (2021). Prediction of Compressive Strength of Fly Ash Based Concrete Using Individual and Ensemble Algorithm. *Materials*, 14(4), Art. 4. <https://doi.org/10.3390/ma14040794>
- Ahmad, A., Ostrowski, K. A., Maślak, M., Farooq, F., Mehmood, I., y Nafees, A. (2021). Comparative Study of Supervised Machine Learning Algorithms for Predicting the Compressive Strength of Concrete at High Temperature. *Materials*, 14(15), Art. 15. <https://doi.org/10.3390/ma14154222>
- Ahmad, J., Tufail, R. F., Aslam, F., Mosavi, A., Alyousef, R., Faisal Javed, M., Zaid, O., y Khan Niazi, M. S. (2021). A Step towards Sustainable Self-Compacting Concrete by Using Partial Substitution of Wheat Straw Ash and Bentonite Clay Instead of Cement. *Sustainability*, 13(2), Art. 2. <https://doi.org/10.3390/su13020824>

- Ahmad, J., Zaid, O., Aslam, F., Shahzaib, M., Ullah, R., Alabduljabbar, H., y Khedher, K. M. (2021). A Study on the Mechanical Characteristics of Glass and Nylon Fiber Reinforced Peach Shell Lightweight Concrete. *Materials*, 14(16), Art. 16.  
<https://doi.org/10.3390/ma14164488>
- Ahmad, M. W., Mourshed, M., y Rezgui, Y. (2018). Tree-based ensemble methods for predicting PV power generation and their Comparison with support vector regression. *Energy*, 164, 465-474.  
<https://doi.org/10.1016/j.energy.2018.08.207>
- Ahmad, M. W., Reynolds, J., y Rezgui, Y. (2018). Predictive modelling for solar thermal energy systems: A Comparison of support vector regression, random forest, extra trees and regression trees. *Journal of Cleaner Production*, 203, 810-821.  
<https://doi.org/10.1016/j.jclepro.2018.08.207>
- Ahmad, W., Ahmad, A., Ostrowski, K. A., Aslam, F., Joyklad, P., y Zajdel, P. (2021). Application of Advanced Machine Learning Approaches to Predict the Compressive Strength of Concrete Containing Supplementary Cementitious Materials. *Materials*, 14(19), Art. 19. <https://doi.org/10.3390/ma14195762>
- Al Daoud, E. (2019). Comparison between XGBoost, LightGBM and CatBoost Using a Home Credit Dataset. *International Journal of Information, Control and Computer Sciences*, 12(1). <https://doi.org/10.5281/zenodo.3607805>
- Aldaaja, M. (2019). *Quantifying the Impact of Circular Economy Applied to the Built Environment: A Study of Construction and Demolition Waste to Identify Leverage Points* [Arizona State University].  
<https://keep.lib.asu.edu/items/157200>

- Ali, B., Qureshi, L. A., Shah, S. H. A., Rehman, S. U., Hussain, I., y Iqbal, M. (2020). A step towards durable, ductile and sustainable concrete: Simultaneous incorporation of recycled aggregates, glass fiber and fly ash. *Construction and Building Materials*, 251, 118980. <https://doi.org/10.1016/j.conbuildmat.2020.118980>
- Ali, E. E., y Al-Tersawy, S. H. (2012). Recycled glass as a partial replacement for fine aggregate in self compacting concrete. *Construction and Building Materials*, 35(October), 785-791. <https://doi.org/10.1016/j.conbuildmat.2012.04.117>
- Ali, N., Neagu, D., y Trundle, P. (2019). Evaluation of k-nearest neighbour classifier performance for heterogeneous data sets. *SN Applied Sciences*, 1(12), 1559. <https://doi.org/10.1007/s42452-019-1356-9>
- Alpaydin, E. (2010). *Introduction to Machine Learning* (Second). The MIT Press.
- Alshdaifat, E., Alshdaifat, D., Alsarhan, A., Hussein, F., y El-Salhi, S. M. F. S. (2021). The effect of preprocessing techniques, applied to numeric features, on classification algorithms' performance. *Data*, 6(2), 1-23. <https://doi.org/10.3390/data6020011>
- Althoey, F., Zaid, O., de-Prado-Gil, J., Palencia, C., Ali, E., Hakeem, I., y Martínez-García, R. (2022). Impact of sulfate activation of rice husk ash on the performance of high strength steel fiber reinforced recycled aggregate concrete. *Journal of Building Engineering*, 54, 104610. <https://doi.org/10.1016/j.jobbe.2022.104610>
- Altman, N. S. (1992). An Introduction to Kernel and Nearest-Neighbor Nonparametric Regression. *The American Statistician*, 46(3), 175-185. <https://doi.org/10.1080/00031305.1992.10475879>

- Alvarez, J. (2014). *Hormigón Autocompactante con Nano Adiciones y Fibras* [Master, E.T.S.I. Caminos, Canales y Puertos (UPM)].  
[https://oa.upm.es/35549/1/Tesis\\_master\\_Jose%20Luis\\_Alvarez\\_Gonzalez.pdf](https://oa.upm.es/35549/1/Tesis_master_Jose%20Luis_Alvarez_Gonzalez.pdf)
- Alyamaç, K. E., y Ince, R. (2009). A preliminary concrete mix design for SCC with marble powders. *Construction and Building Materials*, 23(3), 1201-1210.  
<https://doi.org/10.1016/j.conbuildmat.2008.08.012>
- ANEFA. (2018). *Informe de situación económica sectorial 2018*. Asociación Nacional de Empresarios Fabricantes de áridos. <https://www.aridos.org/wp-content/uploads/2018/10/Informe-sectorial-Asamblea-General-ANEFA-2018.pdf>
- Anjaneyulu, B., Alisha, S. S., Neeraja, S., y Divya, K. (2017). Experimental Study on Self-Compacting Concrete with various Percentage of Steel Fibres. *IJIRST-International Journal for Innovative Research in Science & Technology*, 3(10), 5.
- Anjaneyulu, B., Subhan, S., Neeraja, S., y Divya, K. (2017). Experimental Study on Self-Compacting Concrete with various Percentage of Steel Fibres. *IJIRST-International Journal for Innovative Research in Science & Technology*, 3(10), 22-25.
- Arun Kumar, B., Sangeetha, G., Srinivas, A., Awoyera, P. O., Gobinath, R., y Venkata Ramana, V. (2020). Models for Predictions of Mechanical Properties of Low-Density Self-compacting Concrete Prepared from Mineral Admixtures and Pumice Stone. En K. N. Das, J. C. Bansal, K. Deep, A. K. Nagar, P. Pathipooranam, y R. C. Naidu (Eds.), *Soft Computing for Problem Solving* (pp. 677-690). Springer.  
[https://doi.org/10.1007/978-981-15-0184-5\\_58](https://doi.org/10.1007/978-981-15-0184-5_58)

- Aslam, F., Zaid, O., Althoey, F., Alyami, S. H., Qaidi, S. M. A., de Prado Gil, J., y Martínez-García, R. (2022). Evaluating the influence of fly ash and waste glass on the characteristics of coconut fibers reinforced concrete. *Structural Concrete*, *n/a(n/a)*, 1-20. <https://doi.org/10.1002/suco.202200183>
- Aslani, F., Ma, G., Yim Wan, D. L., y Muselin, G. (2018). Development of high-performance self-compacting concrete using waste recycled concrete aggregates and rubber granules. *Journal of Cleaner Production*, *182*, 553-566. <https://doi.org/10.1016/j.jclepro.2018.02.074>
- Awoyera, P. O., Kirgiz, M. S., Viloría, A., y Ovallos-Gazabon, D. (2020). Estimating strength properties of geopolymer self-compacting concrete using machine learning techniques. *Journal of Materials Research and Technology*, *9(4)*, 9016-9028. <https://doi.org/10.1016/j.jmrt.2020.06.008>
- Ayhan, B. U., y Tokdemir, O. B. (2019). Safety assessment in megaprojects using artificial intelligence. *Safety Science*, *118*, 273-287. <https://doi.org/10.1016/j.ssci.2019.05.027>
- Azimi-Pour, M., y Eskandari-Naddaf, H. (2018). ANN and GEP prediction for simultaneous effect of nano and micro silica on the compressive and flexural strength of cement mortar. *Construction and Building Materials*, *189*, 978-992. <https://doi.org/10.1016/j.conbuildmat.2018.09.031>
- Azizifar, V., y Babajanzadeh, M. (2018). Compressive Strength Prediction of Self-Compacting Concrete Incorporating Silica Fume Using Artificial Intelligence Methods. *Civil Engineering Journal*, *4(7)*, Art. 7. <https://doi.org/10.28991/cej-0309193>

- B K A, M. A. R., Ngamkhanong, C., Wu, Y., y Kaewunruen, S. (2021). Recycled Aggregates Concrete Compressive Strength Prediction Using Artificial Neural Networks (ANNs). *Infrastructures*, 6(2), Art. 2.  
<https://doi.org/10.3390/infrastructures6020017>
- Babajanzadeh, M., y Azizifar, V. (2018). Compressive Strength Prediction of Self-Compacting Concrete Incorporating Silica Fume Using Artificial Intelligence Methods. *Civil Engineering Journal*, 4(7), 1542. <https://doi.org/10.28991/cej-0309193>
- Babalola, O. E., Awoyera, P. O., Tran, M. T., Le, D. H., Olalusi, O. B., Vilorio, A., y Ovallos-Gazabon, D. (2020). Mechanical and durability properties of recycled aggregate concrete with ternary binder system and optimized mix proportion. *Journal of Materials Research and Technology*, 9(3), 6521-6532.  
<https://doi.org/10.1016/j.jmrt.2020.04.038>
- Baghirli, O. (2015). *Comparison of Lavenberg-Marquardt, Scaled Conjugate Gradient and Bayesian Regularization Backpropagation Algorithms for multistep ahead wind speed forecasting using multilayer perceptron feedforward Neural Network* [Uppsala University]. <http://www.diva-portal.org/smash/get/diva2:828170/FULLTEXT01.pdf>
- Bahrami, N., Zohrabi, M., Mahmoudy, S. A., y Akbari, M. (2020). Optimum recycled concrete aggregate and micro-silica content in self-compacting concrete: Rheological, mechanical and microstructural properties. *Journal of Building Engineering*, 31(september 2020), 101361.  
<https://doi.org/10.1016/j.jobbe.2020.101361>

- Bai, S., Li, M., Kong, R., Han, S., Li, H., y Qin, L. (2019). Data mining approach to construction productivity prediction for cutter suction dredgers. *Automation in Construction*, 105, 102833. <https://doi.org/10.1016/j.autcon.2019.102833>
- Bal, L., y 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>
- Barrientos, F. (2016). Los escombros: La gestión de RCD en el mundo. *Blog CARTIF*. <https://blog.cartif.es/los-escombros-la-gestion-de-rcd-en-el-mundo/>
- Barroqueiro, T., da Silva, P. R., y de Brito, J. (2020). High-Performance Self-Compacting Concrete with Recycled Aggregates from the Precast Industry: Durability Assessment. *Buildings*, 10(6), Art. 6. <https://doi.org/10.3390/buildings10060113>
- Behera, M., Minocha, A. K., y Bhattacharyya, S. K. (2019). Flow behavior, microstructure, strength and shrinkage properties of self-compacting concrete incorporating recycled fine aggregate. *Construction and Building Materials*, 228, 116819. <https://doi.org/10.1016/j.conbuildmat.2019.116819>
- Behnood, A., y Golafshani, E. M. (2018). Predicting the compressive strength of silica fume concrete using hybrid artificial neural network with multi-objective grey wolves. *Journal of Cleaner Production*, 202, 54-64. <https://doi.org/10.1016/j.jclepro.2018.08.065>
- Behnood, A., y Golafshani, E. M. (2020). Machine learning study of the mechanical properties of concretes containing waste foundry sand. *Construction and*

*Building Materials*, 243, 118152.

<https://doi.org/10.1016/j.conbuildmat.2020.118152>

Behnood, A., Verian, K. P., y Modiri Gharehveran, M. (2015). Evaluation of the splitting tensile strength in plain and steel fiber-reinforced concrete based on the compressive strength. *Construction and Building Materials*, 98, 519-529.

<https://doi.org/10.1016/j.conbuildmat.2015.08.124>

Belalia Douma, O., Boukhatem, B., Ghrici, M., y Tagnit-Hamou, A. (2017). Prediction of properties of self-compacting concrete containing fly ash using artificial neural network. *Neural Computing and Applications*, 28(1), 707-718.

<https://doi.org/10.1007/s00521-016-2368-7>

Berk, R. A. (2006). An Introduction to Ensemble Methods for Data Analysis. *Sociological Methods & Research*, 34(3), 263-295.

<https://doi.org/10.1177/0049124105283119>

Bermejo Núñez, E. B. (2009). *Dosificación, propiedades y durabilidad en hormigón autocompactante para edificación* [Ph.D. Thesis, E.T.S.I. Caminos, Canales y Puertos (UPM)]. <https://oa.upm.es/1733/>

Berndt, M. L. (2009). Properties of sustainable concrete containing fly ash, slag and recycled concrete aggregate. *Construction and Building Materials*, 23(7), 2606-2613. <https://doi.org/10.1016/j.conbuildmat.2009.02.011>

Berthold, M., Borgelt, C., Höppner, F., y Klawonn, F. (2010). *Guide to Intelligent Data Analysis: How to Intelligently Make Sense of Real Data*. Springer Publishing CoMPany.

- Bidabadi, M., Akbari, M., y Panahi, O. (2020). Optimum mix design of recycled concrete based on the fresh and hardened properties of concrete. *Journal of Building Engineering*, 32(5), 101483. <https://doi.org/10.1016/j.jobbe.2020.101483>
- Bilim, C., Atiş, C. D., Tanyildizi, H., y Karahan, O. (2009). Predicting the compressive strength of ground granulated blast furnace slag concrete using artificial neural network. *Advances in Engineering Software*, 40(5), 334-340. <https://doi.org/10.1016/j.advengsoft.2008.05.005>
- Bingöl, A. F., Tortum, A., y Gül, R. (2013). Neural networks analysis of compressive strength of lightweight concrete after high temperatures—ScienceDirect. *Materials & Design*, 52, 258-264. <https://doi.org/10.1016/j.matdes.2013.05.022>
- Bizcocho Tocón, N. (2014). *Aplicación del análisis de ciclo de vida a la gestión de los residuos de construcción* [Ph.D. Thesis, Universidad de Sevilla]. <https://idus.us.es/handle/11441/56324>
- Borrero, E. L. S., Farhangi, V., Jadidi, K., y Karakouzian, M. (2021). An Experimental Study on Concrete's Durability and Mechanical Characteristics Subjected to Different Curing Regimes. *Civil Engineering Journal*, 7(4), Art. 4. <https://doi.org/10.28991/cej-2021-03091681>
- Bradu, A., Cazacu, N., Florea, N., y Mihai, P. (2016). Compressive strength of self compacting concrete. *BULETINUL INSTITUTULUI POLITEHNIC DIN IAȘI*, 62(66), 59-68.
- Breiman, L. (2001). Random Forests. *Machine Learning*, 45(1), 5-32. <https://doi.org/10.1023/A:1010933404324>

- Brouwers, H. J. H., y Radix, H. J. (2005). Self-Compacting Concrete: Theoretical and Experimental Study. *Cement and Concrete Research*, 35(11), 2116-2136.  
<https://doi.org/10.1016/j.cemconres.2005.06.002>
- Bui, D.-K., Nguyen, T., Chou, J.-S., Nguyen-Xuan, H., y Ngo, T. D. (2018). A modified firefly algorithm-artificial neural network expert system for predicting compressive and tensile strength of high-performance concrete. *Construction and Building Materials*, 180, 320-333.  
<https://doi.org/10.1016/j.conbuildmat.2018.05.201>
- Burden, F., y Winkler, D. (2008). Bayesian regularization of neural networks. *Methods in Molecular Biology (Clifton, N.J.)*, 458, 25-44. [https://doi.org/10.1007/978-1-60327-101-1\\_3](https://doi.org/10.1007/978-1-60327-101-1_3)
- Burón Maestro, M., Fernández Gómez, J., y Garrido Romero, L. (2006). Hormigón autocompactante. Criterios para su utilización. *Hormigón*, 887, 52-64.
- Butler, L., West, J. S., y Tighe, S. L. (2011). The effect of recycled concrete aggregate properties on the bond strength between RCA concrete and steel reinforcement. *Cement and Concrete Research*, 41(10), 1037-1049.  
<https://doi.org/10.1016/j.cemconres.2011.06.004>
- Carrasco, J. C. (2020). *Modelos predictivos aplicados a la resistencia a compresión del hormigón de un proyecto hidroeléctrico en Ecuador* [Tesis de Máster, Universitat Politècnica de Valencia].  
<https://riunet.upv.es/handle/10251/155554>
- Carro-López, D., González-Fonteboa, B., Martínez-Abella, F., González-Taboada, I., de Brito, J., y Varela-Puga, F. (2018). Proportioning, fresh-state properties and

- rheology of self-compacting concrete with fine recycled aggregates. *Hormigón y Acero*, 69(286), 213-221. <https://doi.org/10.1016/j.hya.2017.04.023>
- Carvalho, F. P. (2017). Mining industry and sustainable development: Time for change. *Food and Energy Security*, 6(2), 61-77. <https://doi.org/10.1002/fes3.109>
- Ceballos, F., Muñoz, L. E., y Cadavid, J. M. (2011). Selección de perceptrones multicapa usando aprendizaje bayesiano. *Scientia et Technica*, XVI(49), 110-115.
- CEDEX. (2014). FICHA TÉCNICA. Residuos de construcción y demolición. *Centro de Estudios y Experimentación de Obras Públicas (CEDEX). Ministerio de Fomento, España.*  
[http://www.cedexmateriales.es/upload/docs/es\\_RESIDUOSDECONSTRUCCION YDEMOLICIONNOV2014.pdf](http://www.cedexmateriales.es/upload/docs/es_RESIDUOSDECONSTRUCCION YDEMOLICIONNOV2014.pdf)
- Chaabene, W., Flah, M., y Nehdi, M. L. (2020). Machine learning prediction of mechanical properties of concrete: Critical review. *Construction and Building Materials*, 260, 119889. <https://doi.org/10.1016/j.conbuildmat.2020.119889>
- Chakkamalayath, J., Joseph, A., Al-Baghli, H., Hamadah, O., Dashti, D., y Abdulmalek, N. (2020). Performance evaluation of self-compacting concrete containing volcanic ash and recycled coarse aggregates. *Asian Journal of Civil Engineering*, 21(2). <https://doi.org/10.1007/s42107-020-00242-2>
- Chakradhara Rao, M., Bhattacharyya, S. K., y Barai, S. V. (2011). Influence of field recycled coarse aggregate on properties of concrete. *Materials and Structures*, 44, 205-220. <https://doi.org/10.1617/s11527-010-9620-x>
- Chandwani, V., Agrawal, V., y 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>

Chang, Y.-C., Chang, K.-H., y Wu, G.-J. (2018). Application of eXtreme gradient boosting trees in the construction of credit risk assessment models for financial institutions. *Applied Soft Computing*, 73, 914-920.

<https://doi.org/10.1016/j.asoc.2018.09.029>

Chen, K., Wang, J., Yu, B., Wu, y Zhang, J. (2020). Critical evaluation of construction and demolition waste and associated environmental impacts: A Scientometric analysis. *Journal of Cleaner Production*, 125071.

<https://doi.org/10.1016/j.jclepro.2020.125071>

Chen, T., y Guestrin, C. (2016). XGBoost: A Scalable Tree Boosting System. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 785-794. <https://doi.org/10.1145/2939672.2939785>

Chou, J.-S., Chiu, C.-K., y Farfoura, M. (2011). Optimizing the Prediction Accuracy of Concrete Compressive Strength Based on a Comparison of Data-Mining Techniques | Journal of Computing in Civil Engineering | Vol 25, No 3. *ournal of Computing in Civil Engineering*, 25(3).

<https://ascelibrary.org/doi/10.1061/%28ASCE%29CP.1943-5487.0000088>

Cihan, M. T. (2020). Corrigendum to "Prediction of Concrete Compressive Strength and Slump by Machine Learning Methods". *Advances in Civil Engineering*, 2020, e8201734. <https://doi.org/10.1155/2020/8201734>

Comisión Europea. (2014). 2014/955/UE: Decisión de la Comisión, de 18 de diciembre de 2014, por la que se modifica la Decisión 2000/532/CE, sobre la lista de

- residuos, de conformidad con la Directiva 2008/98/CE del Parlamento Europeo y del Consejo. *Diario Oficial de la Unión Europea*, 30-12-2014(370), 43.
- Comisión Permanente de Hormigón. (2010). *EHE-08, Instrucción de Hormigón Estructural*. Ministerios de Fomento, España.
- Commission of the European Communities. (1991). *BRITE EURAM Programme. Synopses of Current Projects 1990-1991*. <https://op.europa.eu/en/publication-detail/-/publication/bcd22c3e-f9c0-49c4-8428-1bf60a5e5eb7>
- Consejería del Medio Ambiente y Ordenación del Territorio. (2018). *Plan de gestión de residuos de construcción y demolición*. Comunidad de Madrid. [https://www.comunidad.madrid/sites/default/files/doc/medio-ambiente/5\\_plan\\_de\\_gestion\\_de\\_residuos\\_de\\_construccion\\_y\\_demolicion.pdf](https://www.comunidad.madrid/sites/default/files/doc/medio-ambiente/5_plan_de_gestion_de_residuos_de_construccion_y_demolicion.pdf)
- Cover, T., y Hart, P. (1967). Nearest neighbor pattern classification. *IEEE Transactions on Information Theory*, 13(1), 21-27. <https://doi.org/10.1109/TIT.1967.1053964>
- Cutler, A., Cutler, D. R., y Stevens, J. R. (2012). Random Forests. En C. Zhang y Y. Ma (Eds.), *Ensemble Machine Learning: Methods and Applications* (pp. 157-175). Springer. [https://doi.org/10.1007/978-1-4419-9326-7\\_5](https://doi.org/10.1007/978-1-4419-9326-7_5)
- Dabiri, H., Farhangi, V., Moradi, M. J., Zadehmohamad, M., y Karakouzian, M. (2022). Applications of Decision Tree and Random Forest as Tree-Based Machine Learning Techniques for Analyzing the Ultimate Strain of Spliced and Non-Spliced Reinforcement Bars. *Applied Sciences*, 12(10), Art. 10. <https://doi.org/10.3390/app12104851>
- Dantas, A. T. A., Batista Leite, M., y de Jesus Nagahama, K. (2013). Prediction of compressive strength of concrete containing construction and demolition

- waste using artificial neural networks. *Construction and Building Materials*, 38, 717-722. <https://doi.org/10.1016/j.conbuildmat.2012.09.026>
- Daungwilailuk, T., Cao, T. N., Pansuk, W., y Pheinsusom, P. (2017). Evaluating Damaged Concrete Depth in Reinforced Concrete Structures under Different Fire Exposure Times by Means of NDT and DT Techniques. *Engineering Journal*, 21(7), 233-249. <https://doi.org/10.4186/ej.2017.21.7.233>
- Dawood, E. T. (2020). Behavior of self-compacting concrete produced from recycled aggregate: AIP Conference Proceedings: Vol 2213, No 1. *AIP Conference Proceedings*, 2213(1), 020023. <https://doi.org/10.1063/5.0000035>
- De Schutter, G., Yuan, Y., Liu, X., y Jiang, W. (2015). Degree of hydration-based creep modeling of concrete with blended binders: From concept to real applications. *Journal of Sustainable Cement-Based Materials*, 4(1), 1-14. <https://doi.org/10.1080/21650373.2014.928808>
- Deifalla, A. F., Zapris, A. G., y Chalioris, C. E. (2021). Multivariable Regression Strength Model for Steel Fiber-Reinforced Concrete Beams under Torsion. *Materials*, 14(14), Art. 14. <https://doi.org/10.3390/ma14143889>
- Demuth, H., Beale, M., y Hagan, M. (2009). *Neural Network Toolbox™ 6. User's Guide*. The MathWorks, Inc.
- de-Prado-Gil, J., Palencia, C., Jagadesh, P., y Martínez-García, R. (2022a). A Comparison of Machine Learning Tools That Model the Splitting Tensile Strength of Self-Compacting Recycled Aggregate Concrete. *Materials*, 15, 4164. <https://doi.org/10.3390/ma15124164>

- de-Prado-Gil, J., Palencia, C., Jagadesh, P., y Martínez-García, R. (2022b). A Study on the Prediction of Compressive Strength of Self-Compacting Recycled Aggregate Concrete Utilizing Novel Computational Approaches. *Materials*, 15(15), Art. 15. <https://doi.org/10.3390/ma15155232>
- de-Prado-Gil, J., Palencia, C., Silva-Monteiro, N., y Martínez-García, R. (2022). To predict the compressive strength of self compacting concrete with recycled aggregates utilizing ensemble machine learning models. *Case Studies in Construction Materials*, 16, e01046. <https://doi.org/10.1016/j.cscm.2022.e01046>
- de-Prado-Gil, J., Zaid, O., Palencia, C., y Martínez-García, R. (2022). Prediction of Splitting Tensile Strength of Self-Compacting Recycled Aggregate Concrete Using Novel Deep Learning Methods. *Mathematics*, 10, 2245. <https://doi.org/10.3390/math10132245>
- DeRousseau, M. A., Laftchiev, E., Kasprzyk, J. R., Rajagopalan, B., y Srubar, W. V. (2019). A Comparison of machine learning methods for predicting the compressive strength of field-placed concrete. *Construction and Building Materials*, 228, 116661. <https://doi.org/10.1016/j.conbuildmat.2019.08.042>
- Dietterich, T. G. (2000). Ensemble Methods in Machine Learning. *Multiple Classifier Systems*, 1-15. [https://doi.org/10.1007/3-540-45014-9\\_1](https://doi.org/10.1007/3-540-45014-9_1)
- Dinakar, P., Sethy, K. P., y Sahoo, U. C. (2013). Design of self-compacting concrete with ground granulated blast furnace slag. *Materials & Design*, 43, 161-169. <https://doi.org/10.1016/j.matdes.2012.06.049>

- Dorogush, A. V., Ershov, V., y Gulin, A. (2018). CatBoost: Gradient boosting with categorical features support. *Computer Science*.  
<https://doi.org/10.48550/arXiv.1810.11363>
- Druta, C. (2003). *Tensile Strength and Bonding Characteristics of Self Compacting Concrete* [Master's Thesis, Luisiana State University and Agricultural and Mechanical College].  
[https://digitalcommons.lsu.edu/cgi/viewcontent.cgi?article=5227&context=gradschool\\_theses](https://digitalcommons.lsu.edu/cgi/viewcontent.cgi?article=5227&context=gradschool_theses)
- Du, X., Cai, Y., Wang, S., y Zhang, L. (2016). Overview of deep learning. *2016 31st Youth Academic Annual Conference of Chinese Association of Automation (YAC)*, 159-164. <https://doi.org/10.1109/YAC.2016.7804882>
- Duan, Z., Singh, A., Xiao, J., y Hou, S. (2020). Combined use of recycled powder and recycled coarse aggregate derived from construction and demolition waste in self-compacting concrete. *Construction and Building Materials*, 254, 119323.  
<https://doi.org/10.1016/j.conbuildmat.2020.119323>
- edu1975. (2012). *Puente del Tercer Milenio desde el hotel Hiberus, Zaragoza*.  
[https://commons.wikimedia.org/wiki/File:Puente\\_del\\_Tercer\\_Milenio\\_desde\\_el\\_hotel\\_Hiberus,\\_Zaragoza\\_-\\_panoramio.jpg](https://commons.wikimedia.org/wiki/File:Puente_del_Tercer_Milenio_desde_el_hotel_Hiberus,_Zaragoza_-_panoramio.jpg)
- El Ghaoui, L., y Lebret, H. (1997). Robust Solutions to Least-Squares Problems with Uncertain Data. *SIAM Journal on Matrix Analysis and Applications*, 18(4), 1035-1064. <https://doi.org/10.1137/S0895479896298130>
- El Haggag, S. M. (2007). *Sustainable Industrial Design and Waste Management: Cradle-to-Cradle for Sustainable Development*. Elsevier Academic Press.

- El Ouni, M. H., Shah, S. H. A., Ali, A., Muhammad, S., Mahmood, M. S., Ali, B., Marzouki, R., y Raza, A. (2022). Mechanical performance, water and chloride permeability of hybrid steel-polypropylene fiber-reinforced recycled aggregate concrete. *Case Studies in Construction Materials*, 16, e00831.  
<https://doi.org/10.1016/j.cscm.2021.e00831>
- Eluozo, S. (2019). Model Prediction on Split Tensile Strength of Concrete from Course Aggregate and Granite Modified with Metakaolin Substance. *Material Science & Engineering Journal*, 2(1), 1009.
- Erdal, H. I., Karakurt, O., y Namli, E. (2013). High performance concrete compressive strength forecasting using ensemble models based on discrete wavelet transform. *Engineering Applications of Artificial Intelligence*, 26(4), 1246-1254.  
<https://doi.org/10.1016/j.engappai.2012.10.014>
- España, Jefatura del Estado. (2022). Ley 7/2022, de 8 de abril, de residuos y suelos contaminados para una economía circular. *Boletín Oficial del Estado*, 9-4-2022(85). <https://www.boe.es/eli/es/l/2022/04/08/7/con>
- España, Ministerio de la Presidencia. (2008). Real Decreto 105/2008, de 1 de febrero, por el que se regula la producción y gestión de los residuos de construcción y demolición. *Boletín Oficial del Estado*, 13-2-2008(38), 7724-7730.
- España, Ministerio de la Presidencia. (2021). Real Decreto 470/2021, de 29 de junio, por el que se aprueba el Código Estructural. *Boletín Oficial del Estado*, 13-08-2021(190), 1789.
- EUROSTAT. (2022a). *Eurostat-DATABASE*. Eurostat-Your key to European Statistics.  
<https://ec.europa.eu/eurostat/web/main/data/database>

EUROSTAT. (2022b). *Generation of waste by economic activity (online data code:*

*TEN00106 )*.

<https://ec.europa.eu/eurostat/databrowser/view/ten00106/default/table?lang=en>

EUROSTAT. (2022c). *Generation of waste by waste category, hazardousness and NACE*

*Rev. 2 activity*.

[https://ec.europa.eu/eurostat/databrowser/view/env\\_wasgen/default/table?lang=en](https://ec.europa.eu/eurostat/databrowser/view/env_wasgen/default/table?lang=en)

EUROSTAT. (2022d). *Recycling rate of all waste excluding major mineral waste*.

[https://ec.europa.eu/eurostat/databrowser/view/cei\\_wm010/default/table?lang=en](https://ec.europa.eu/eurostat/databrowser/view/cei_wm010/default/table?lang=en)

Falah, M. W., Hussein, S. H., Saad, M. A., Ali, Z. H., Tran, T. H., Ghoniem, R. M., y Ewees,

A. A. (2022). Compressive Strength Prediction Using Coupled Deep Learning Model with Extreme Gradient Boosting Algorithm: Environmentally Friendly Concrete Incorporating Recycled Aggregate. *Complexity*, 2022, e5433474.

<https://doi.org/10.1155/2022/5433474>

Farooq, F., Czarnecki, S., Niewiadomski, P., Aslam, F., Alabduljabbar, H., Ostrowski, K.

A., Śliwa-Wieczorek, K., Nowobilski, T., y Malazdrewicz, S. (2021). A

comparative study for the prediction of the compressive strength of self-compacting concrete modified with fly ash. *Materials*, 14(17), 4934.

<https://doi.org/10.3390/ma14174934>

Feng, D.-C., Liu, Z.-T., Wang, X.-D., Chen, Y., Chang, J.-Q., Wei, D.-F., y Jiang, Z.-M.

(2020). Machine learning-based compressive strength prediction for concrete:

- An adaptive boosting approach. *Construction and Building Materials*, 230, 117000. <https://doi.org/10.1016/j.conbuildmat.2019.117000>
- Fernández Gómez, J., y Burón Maestro, M. (2005). *Guía práctica para la utilización del hormigón autocompactante*. Instituto Español del Cemento y sus Aplicaciones (IECA). <https://www.ieca.es/producto/guia-practica-para-la-utilizacion-del-hormigon-autocompactante/>
- Ferov, M., y Modrý, M. (2016). Enhancing LambdaMART Using Oblivious Trees. *Information Retrieval*. <https://doi.org/10.48550/arXiv.1609.05610>
- Fiol, F., Thomas, C., Muñoz, C., Ortega-López, V., y Manso, J. M. (2018). The influence of recycled aggregates from precast elements on the mechanical properties of structural self-compacting concrete. *Construction and Building Materials*, 182, 309-323. <https://doi.org/10.1016/j.conbuildmat.2018.06.132>
- Flores, V., y Keith, B. (2019). Gradient Boosted Trees Predictive Models for Surface Roughness in High-Speed Milling in the Steel and Aluminum Metalworking Industry. *Complexity*, 2019, e1536716. <https://doi.org/10.1155/2019/1536716>
- Fonseca, N., de Brito, J., y Evangelista, L. (2011). The influence of curing conditions on the mechanical performance of concrete made with recycled concrete waste. *Cement and Concrete Composites*, 33(6), 637-643. <https://doi.org/10.1016/j.cemconcomp.2011.04.002>
- Friedman, J. H. (2001). Greedy function approximation: A gradient boosting machine. *Annals of Statistics*, 29(5), 1189-1232. <https://doi.org/10.1214/aos/1013203451>

- Friedman, J. H. (2002). Stochastic gradient boosting. *Computational Statistics & Data Analysis*, 38(4), 367-378. [https://doi.org/10.1016/S0167-9473\(01\)00065-2](https://doi.org/10.1016/S0167-9473(01)00065-2)
- Fueyo Editores. (2022). El sector de los áridos en España en 2021 y perspectivas para el 2022. *Rocas y Minerales*, 591(Julio 2022).  
<https://www.fueyoeditores.com/rocas-y-minerales/articulos-tecnicos-rocas-y-minerales/3423-el-sector-de-los-aridos-en-espana-en-2021-y-perspectivas-para-el-2022>
- Gagne, R., y Pigeon, M. (1990). Deicer Salt Scaling Resistance of High-Performance Concrete. *Symposium Paper*, 122, 29-44. <https://doi.org/10.14359/2444>
- García Ballester, L. V. (2016). *Propiedades mecánicas y reológicas de hormigones autocompactantes sometidos a carga a edades muy tempranas y tempranas* [Ph.D. Thesis, Universitat Politècnica de València].  
<https://doi.org/10.4995/Thesis/10251/63274>
- García-González, J. (2016). *Hormigón elaborado con residuos de construcción y demolición mixtos cerámicos: Optimización de sus propiedades físicas, mecánicas y durables mediante pre-saturación de los áridos, uso de superplastificantes y precipitación microbiológica de carbonato cálcico* [Ph.D. Thesis, Universidad de León].  
<https://dialnet.unirioja.es/servlet/tesis?codigo=61419>
- Gavin, H. (2020). *The Levenberg-Marquardt method for nonlinear least squares curve-fitting problems*. Duke University, Department of Civil and Environmental Engineering.

- Gayatri Vineela, M., Dave, A., y Kiran Chaganti, P. (2018). Artificial Neural Network based Prediction of Tensile Strength of Hybrid Composites. *Materials Today: Proceedings*, 5(9, Part 3), 19908-19915.  
<https://doi.org/10.1016/j.matpr.2018.06.356>
- Gesoglu, M., Güneysisi, E., Öz, H. Ö., Taha, I., y Yasemin, M. T. (2015). Failure characteristics of self-compacting concretes made with recycled aggregates. *Construction and Building Materials*, 98, 334-344.  
<https://doi.org/10.1016/j.conbuildmat.2015.08.036>
- Getahun, M. A., Shitote, S. M., y 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>
- Geurts, P., Ernst, D., y Wehenkel, L. (2006). Extremely randomized trees. *Machine Learning*, 63(1), 3-42. <https://doi.org/10.1007/s10994-006-6226-1>
- Ghalehnovi, M., Roshan, N., Hakak, E., Shamsabadi, E. A., y de Brito, J. (2019). Effect of red mud (bauxite residue) as cement replacement on the properties of self-compacting concrete incorporating various fillers. *Journal of Cleaner Production*, 240, 118213. <https://doi.org/10.1016/j.jclepro.2019.118213>
- Ghorpade, Vv., Sudarsana Rao, H., y Ramana, B. V. (2013). Deriving Mix Proportions For Different Grades Of Phosphogypsum Based Self Compacting Concrete. *International Journal of Engineering Research and Applications*, 3(3), 467-473.

GME. (s.f.). *Puente Akashi Kaikyo*. Mecánica de Estructuras.

<http://gme.udc.es/iniciativas/era-2000/otros-enlaces-recientes/puente-akashi-kaikyo>

Goharzay, M., Noorzad, A., Mahboubi, A., y Jalal, M. (2020). Computer-aided SPT-based reliability model for probability of liquefaction using hybrid PSO and GA.

*Journal of Computational Design and Engineering*, 7(1), 107-127.

<https://doi.org/10.1093/jcde/qwaa011>

Golafshani, E. M., y Pazouki, G. (2018). Predicting the compressive strength of self-compacting concrete containing fly ash using a hybrid artificial intelligence method. *Computers and Concrete*, 22(4), Art. 4.

<https://doi.org/10.12989/cac.2018.22.4.419>

Gołaszewski, J., y Cygan, G. (2017). The concept of the composition of self-compacting concrete with low hardening heat. *Czasopismo Techniczne*, 10, Art. Volume 10.

<https://doi.org/10.4467/2353737XCT.17.173.7281>

Gomes, P. (2002). *Optimización y caracterización del hormigón autocompactante de alta resistencia*. Universidad Politécnica de cataluña.

González-Fonteboa, B. (2002). *Hormigones con áridos reciclados procedentes de demoliciones: Dosificaciones, propiedades mecánicas y comportamiento estructural a cortante* [Ph.D. Thesis].

<https://ruc.udc.es/dspace/handle/2183/12377>

Goodfellow, I., Bengio, Y., y Courville, A. (2016). *Deep Learning: Vol. Volume 1*. MIT Press.

- Goodier, C. I. (2003). Development of self-compacting concrete. *Structures & Building*, 156(4), 405-414. <https://doi.org/10.1680/stbu.2003.156.4.405>
- Gouravaraju, S., Narayan, J., Sauer, R. A., y Gautam, S. S. (2021). A Bayesian regularization-backpropagation neural network model for peeling computations. *The Journal of Adhesion*, 1-24. <https://doi.org/10.1080/00218464.2021.2001335>
- Grdic, Z. J., Toplicic-Curcic, G., Despotovic, I. M., y Ristic, N. (2010). Properties of self-compacting concrete prepared with coarse recycled concrete aggregate. *Construction and Building Materials*, 24(7), 1129-1133. <https://doi.org/10.1016/j.conbuildmat.2009.12.029>
- Guelman, L. (2012). Gradient boosting trees for auto insurance loss cost modeling and prediction. *Expert Systems with Applications*, 39(3), 3659-3667. <https://doi.org/10.1016/j.eswa.2011.09.058>
- Güneysi, E., Gesoğlu, M., Algin, Z., y Yazici, H. (2014). Effect of surface treatment methods on the properties of self-compacting concrete with recycled aggregates. *Construction and Building Materials*, 64(August), 172-183. <https://doi.org/10.1016/j.conbuildmat.2014.04.090>
- Guo, P., Meng, W., Xu, M., Li, V. C., y Bao, Y. (2021). Predicting mechanical properties of high-performance fiber-reinforced cementitious composites by integrating micromechanics and machine learning. *Materials*, 14(12), 3143. <https://doi.org/10.3390/ma14123143>
- Guo, Z., Jiang, T., Zhang, J., Kong, X., Chen, C., y Lehman, D. (2020). Mechanical and durability properties of sustainable self-compacting concrete with recycled

- concrete aggregate and fly ash, slag and silica fume. *Construction and Building Materials*, 231, 117115. <https://doi.org/10.1016/j.conbuildmat.2019.117115>
- HAC/BAC. (s.f.). *HAC/BAC Congreso Iberoamericano de Hormigón Autocompactante*. <http://hac-bac.webs.upv.es/>
- Hagan, M., Demuth, H., y De Jesús, O. (2002). An introduction to the use of neural networks in control systems. *International Journal of Robust and Nonlinear Control*, 12(11), 959-985. <https://doi.org/doi.org/10.1002/rnc.727>
- Hagan, M. T., Demuth, H., Beale, M. H., y De Jesús, O. (1996). *Neural network design* (Second). Martin Hagan, Oklahoma State University, Stillwater, OK, United States.
- Hanbay, D., Turkoglu, I., y Demir, Y. (2008). Prediction of wastewater treatment plant performance based on wavelet packet decomposition and neural networks. *Expert Systems with Applications*, 34(2), 1038-1043. <https://doi.org/10.1016/j.eswa.2006.10.030>
- Hassan, A. N., y El-Hag, A. (2020). Two-layer ensemble-based soft voting classifier for transformer oil interfacial tension prediction. *Energies*, 13(7), 1735. <https://doi.org/10.3390/en13071735>
- Hastie, T., Tibshirani, R., y Friedman, J. H. (2009). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*,. Springer.
- Hawkins, D. M., Basak, S. C., y Mills, D. (2003). Assessing Model Fit by Cross-Validation. *Journal of Chemical Information and Computer Sciences*, 43(2), 579-586. <https://doi.org/10.1021/ci025626i>

- Hernández, J. M. H. H.-. (2010). *Ciudad de la Justicia, Barcelona, Spain* [Photo].  
<https://www.flickr.com/photos/jmhdezhddez/4926855263/>
- Huang, X., Ge, J., Kaewunruen, S., y Su, Q. (2020). The Self-Sealing Capacity of Environmentally Friendly, Highly Damped, Fibre-Reinforced Concrete. *Materials*, 13(2), Art. 2. <https://doi.org/10.3390/ma13020298>
- Huang, X., Zhang, J., Sresakoolchai, J., y Kaewunruen, S. (2021). Machine Learning Aided Design and Prediction of Environmentally Friendly Rubberised Concrete. *Sustainability*, 13(4), Art. 4. <https://doi.org/10.3390/su13041691>
- Iacoboaia, C., Aldea, M., y Petruscu, F. (2019). CONSTRUCTION AND DEMOLITION WASTE - A CHALLENGE FOR THE EUROPEAN UNION? *Theoretical and Empirical Researches in Urban Management*, 14(1), 30-52.
- Ibrahim, A. A., Ridwan, R. L., Muhammed, M. M., Abdulaziz, R. O., y Saheed, G. A. (2020). Comparison of the CatBoost Classifier with other Machine Learning Methods. *International Journal of Advanced Computer Science and Applications (IJACSA)*, 11(11), Art. 11. <https://doi.org/10.14569/IJACSA.2020.0111190>
- INE. (2022). *Cantidad de residuos generados por actividad económica CNAE-2009, clase de residuo y tipo de peligrosidad*. Instituto Nacional de Estadística, España.  
<https://www.ine.es/jaxi/dlgExport.htm?tpx=33004&L=0&nocab=1>
- Jabeur, S. Ben, Gharib, C., Mefteh-Wali, S., y Arfi, W. Ben. (2021). CatBoost model and artificial intelligence techniques for corporate failure prediction. *Technological Forecasting and Social Change*, 166, 120658.  
<https://doi.org/10.1016/j.techfore.2021.120658>

- Jagadesh, P., Juan-Valdés, A., Guerra-Romero, M. I., Morán-del Pozo, J. M., García-González, J., y Martínez-García, R. (2021). Effect of Design Parameters on Compressive and Split Tensile Strength of Self-Compacting Concrete with Recycled Aggregate: An Overview. *Applied Sciences*, 11(13), Art. 13.  
<https://doi.org/10.3390/app11136028>
- Jefatura de Estado. (2011). Ley 22/2011, de 28 de julio, de residuos y suelos contaminados. *Boletín Oficial del Estado* 29, 29-7-2011(181).  
<https://www.boe.es/buscar/act.php?id=BOE-A-2011-13046>
- Jiménez, J. R., Agrela, F., Ayuso, J., y López, M. (2011). A comparative study of recycled aggregates from concrete and mixed debris as material for unbound road sub-base. *Materiales de Construcción*, 61(302), Art. 302.  
<https://doi.org/10.3989/mc.2010.54009>
- Jiradilok, P., Wang, Y., Nagai, K., y Matsumoto, K. (2020). Development of discrete meso-scale bond model for corrosion damage at steel-concrete interface based on tests with/without concrete damage. *Construction and Building Materials*, 236, 117615. <https://doi.org/10.1016/j.conbuildmat.2019.117615>
- John, V., Liu, Z., Guo, C., Mita, S., y Kidono, K. (2016). Real-Time Lane Estimation Using Deep Features and Extra Trees Regression. En T. Bräunl, B. McCane, M. Rivera, y X. Yu (Eds.), *Image and Video Technology. PSIVT 2015* (Vol. 9431, pp. 721-733). Springer International Publishing.  
[https://link.springer.com/chapter/10.1007/978-3-319-29451-3\\_57#citeas](https://link.springer.com/chapter/10.1007/978-3-319-29451-3_57#citeas)

- Kaewunruen, S., y Meesit, R. (2020). Eco-friendly High-Strength Concrete Engineered by Micro Crumb Rubber from Recycled Tires and Plastics for Railway Components. *Advances in Civil Engineering Materials*, 9(1), 210-226.
- Kaloop, M. R., Samui, P., Shafeek, M., y Hu, J. W. (2020). Estimating Slump Flow and Compressive Strength of Self-Compacting Concrete Using Emotional Neural Networks. *Applied Sciences*, 10(23), Art. 23.  
<https://doi.org/10.3390/app10238543>
- Kang, M. C., Yoo, D. Y., y Gupta, R. (2021). Machine learning-based prediction for compressive and flexural strengths of steel fiber-reinforced concrete. *Construction and Building Materials*, 266, 121117.  
<https://doi.org/10.1016/j.conbuildmat.2020.121117>
- Kang, P., Lin, Z., Teng, S., Zhang, G., y Guo, L. (2019). Catboost-based Framework with Additional User Information for Social Media Popularity Prediction. En L. Amsaleg, B. Huet, y M. Larson (Eds.), *Proceedings of the 27th ACM International Conference on Multimedia*. Association for Computing Machinery.  
<https://doi.org/10.1145/3343031.3356060>
- Kapoor, K., Singh, S. P., y Singh, B. (2016). Water Permeation Properties of Self Compacting Concrete Made with Coarse and Fine Recycled Concrete Aggregates. *International Journal of Civil Engineering*, 16(1), 47-56.  
<https://doi.org/10.1007/s40999-016-0062-x>
- Katar, I., Ibrahim, Y., Malik, M., y Khahro, S. (2021). Mechanical Properties of Concrete with Recycled Concrete Aggregate and Fly Ash. *Recycling*, 6(23), 629-643.  
<https://doi.org/10.3390/recycling6020023>

Kathirvel, P., Murali, G., Vatin, N. I., y Abid, S. R. (2022). Experimental Study on Self Compacting Fibrous Concrete Comprising Magnesium Sulphate Solution Treated Recycled Aggregates. *Materials*, 15(1), Art. 1.  
<https://doi.org/10.3390/ma15010340>

Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., Ye, Q., y Liu, T.-Y. (2017). LightGBM: A Highly Efficient Gradient Boosting Decision Tree. En U. von Luxburg y I. Guton (Eds.), *NIPS'17: Proceedings of the 31st International Conference on Neural Information Processing Systems (Vol. 30)*. Curran Associates, Inc.  
<https://proceedings.neurips.cc/paper/2017/hash/6449f44a102fde848669bdd9eb6b76fa-Abstract.html>

Khademi, F., Jamal, S. M., Deshpande, N., y Londhe, S. (2016). Predicting strength of recycled aggregate concrete using Artificial Neural Network, Adaptive Neuro-Fuzzy Inference System and Multiple Linear Regression. *International Journal of Sustainable Built Environment*, 5(2), 355-369.  
<https://doi.org/10.1016/j.ijbsbe.2016.09.003>

Khafaga, S. A. (2014). Production of high strength self compacting concrete using recycled concrete as fine and/or coarse aggregates. *World Applied Sciences Journal*, 29(4), 465-474. <https://doi.org/10.5829/idosi.wasj.2014.29.04.13916>

Khodair, Y. y Luqman. (2017). Self-compacting concrete using recycled asphalt pavement and recycled concrete aggregate. *Journal of Building Engineering*, 12, 282-287. <https://doi.org/10.1016/j.jobee.2017.06.007>

- Kişi, Ö., y Uncuoğlu, E. (2005). Comparison of three backpropagation training algorithms for two case studies. *Indian Journal of Engineering and Materials Sciences (IJEMS)*, 12, 443-450.
- Kononenko, I., y Kukar, M. (2007). *Machine learning and data mining*. Academic Press.  
<https://doi.org/10.1016/B0-12-227410-5/00837-1>
- Kou, S. C., y Poon, C. S. (2009). Properties of self-compacting concrete prepared with coarse and fine recycled concrete aggregates. *Cement and Concrete Composites*, 31(9), 622-627.  
<https://doi.org/10.1016/j.cemconcomp.2009.06.005>
- Kou, S. C., y Poon, C. S. (2009b). Properties of self-compacting concrete prepared with recycled glass aggregate. *Cement and Concrete Composites*, 31(2), 107-113.  
<https://doi.org/10.1016/j.cemconcomp.2008.12.002>
- Kovačević, M., Lozančić, S., Nyarko, E. K., y Hadzima-Nyarko, M. (2021). Modeling of Compressive Strength of Self-Compacting Rubberized Concrete Using Machine Learning. *Materials*, 14, 4346. <https://doi.org/10.3390/ma14154346>
- Kovačević, M., Lozančić, S., Nyarko, E. K., y Hadzima-Nyarko, M. (2022). Application of Artificial Intelligence Methods for Predicting the Compressive Strength of Self-Compacting Concrete with Class F Fly Ash. *Materials*, 15(12), 4191.  
<https://doi.org/10.3390/ma15124191>
- Koya, B. P. (2021). *Comparison of different machine learning algorithms to predict mechanical properties of concrete* [University of Victoria].  
<https://dspace.library.uvic.ca/handle/1828/12574>

- Koya, B. P., Aneja, S., Gupta, R., y Valeo, C. (2021). Comparative analysis of different machine learning algorithms to predict mechanical properties of concrete. *Mechanics of Advanced Materials and Structures*, 28, 1-18.  
<https://doi.org/10.1080/15376494.2021.1917021>
- Krishna, S. S. R., Vani, V. S., y Baba, S. K. V. (2018). Studies on mechanical properties of ternary blended self compacting concrete using different percentages of recycled aggregate. *International Journal of Civil Engineering and Technology*, 9(11), 1672-1680. <https://doi.org/10.13140/RG.2.2.22194.56007>
- Kumar, A., Arora, H. C., Kapoor, N. R., Mohammed, M. A., Kumar, K., Majumdar, A., y Thinnukool, O. (2022). Compressive Strength Prediction of Lightweight Concrete: Machine Learning Models. *Sustainability*, 14(4), Art. 4.  
<https://doi.org/10.3390/su14042404>
- Kumar, L., Manasa, V., y Harish, M. (2018). Evaluation of workability characteristics of Self Compacting Concrete. *International Research Journal of Engineering and Technology (IRJET)*, 5(6), 1193-1198.
- Kushwaha, M., Akhtar, y Rajput, S. (2013). Development of the Self Compacting Concrete By Industrial Waste (Red Mud). / *International Journal of Engineering Research and Applications (IJERA)*, 3(4), 539-542.
- La Comisión Europea. (2014). REGLAMENTO (UE) No 1357/2014 DE LA COMISIÓN, de 18 de diciembre de 2014, por el que se sustituye el anexo III de la Directiva 2008/98/CE del Parlamento Europeo y del Consejo, sobre los residuos y por la que se derogan determinadas Directivas. *Diario Oficial de*

- la Unión Europea, 19-12-2014*(365). <https://eur-lex.europa.eu/legal-content/ES/TXT/PDF/?uri=CELEX:32014R1357&from=ES>
- Lai, S., y Serra, M. (1997). Concrete strength prediction by means of neural network. *Construction and Building Materials, 11*(2), 93-98.  
[https://doi.org/10.1016/S0950-0618\(97\)00007-X](https://doi.org/10.1016/S0950-0618(97)00007-X)
- Larose, D. (2015). *Data mining and predictive analytics*. Wiley.
- Larose, D., y Larose, C. (2014). *Discovering knowledge in data: An introduction to data mining*. Wiley.
- Levenberg, K. (1944). A method for the solution of certain non-linear problems in least squares. *Quarterly of Applied Mathematics, 2*(2), 164-168.  
<https://doi.org/10.1090/qam/10666>
- Li, F., Wu, J., Dong, F., Lin, J., Sun, G., Chen, H., y Shen, J. (2018). Ensemble Machine Learning Systems for the Estimation of Steel Quality Control. *Proceedings - 2018 IEEE International Conference on Big Data, 2245-2252*.  
<https://doi.org/10.1109/BigData.2018.8622583>
- Li, F., Wu, J., Dong, F., Lin, J., Sun, G., Chen, H., y Shen, J. (2019). Ensemble Machine Learning Systems for the Estimation of Steel Quality Control. *Proceedings - 2018 IEEE International Conference on Big Data, Big Data 2018, 2245-2252*.  
<https://doi.org/10.1109/BigData.2018.8622583>
- Li, N., Long, G., Cong, M., Fu, Q., Zeng, X., Ma, K., Xie, Y., y Luo, B. (2019). Properties of self-compacting concrete (SCC) with recycled tire rubber aggregate: A comprehensive study. *Journal of Cleaner Production, 236*(11), 117707.  
<https://doi.org/10.1016/j.jclepro.2019.117707>

- Li, Z. (2011). *Advanced Concrete Technology*. John Wiley & Sons, INC.  
<https://www.sciencedirect.com/book/9780750656863/advanced-concrete-technology>
- Liu, K., Alam, M. S., Zhu, J., Zheng, J., y Chi, L. (2021). Prediction of carbonation depth for recycled aggregate concrete using ANN hybridized with swarm intelligence algorithms. *Construction and Building Materials*, 301, 124382.  
<https://doi.org/10.1016/j.conbuildmat.2021.124382>
- Liu, M. (2009). *Wider application of additions in self-compacting concrete* [Ph.D. Thesis]. University College London.
- Liu, W., Zhang, M., Luo, Z., y Cai, Y. (2017). An Ensemble Deep Learning Method for Vehicle Type Classification on Visual Traffic Surveillance Sensors. *IEEE Access*, 5, 24417-24425. <https://doi.org/10.1109/ACCESS.2017.2766203>
- Liu, Y., Chen, H., Wang, X. jia, y Wu, X. (2020). Energy consumption prediction and diagnosis of public buildings based on support vector machine learning: A case study in China. *Journal of Cleaner Production*, 272, 122542.  
<https://doi.org/10.1016/j.jclepro.2020.122542>
- Long, W., Shi, J., Wang, W., y Fang, X. (2016). Shrinkage of Hybrid Fiber Reinforced Self-Consolidating Concrete with Recycled Aggregate. En K. H. Khayat (Ed.), *SCC-2016. 8th International RILEM Symposium on Self-Compacting Concrete. Flowing toward sustainability* (pp. 751-762). <https://cies.mst.edu/media/research/cies/documents/SCC2016NPRConferenceProceedings.pdf>
- Lučić, B., Amić, D., y Trinajstić, N. (2000). Nonlinear Multivariate Regression Outperforms Several Concisely Designed Neural Networks on Three QSPR Data

- Sets. *Journal of Chemical Information and Computer Sciences*, 40(2), 403-413.  
<https://doi.org/10.1021/ci990061k>
- Lyngdoh, G. A., Zaki, M., Krishnan, N. M. A., y Das, S. (2022). Prediction of concrete strengths enabled by missing data imputation and interpretable machine learning. *Cement and Concrete Composites*, 128, 104414.  
<https://doi.org/10.1016/j.cemconcomp.2022.104414>
- Mackay, D. (1992). Bayesian Interpolation. *Neural Computation*, 4(3), 415-447.  
<https://doi.org/10.1162/neco.1992.4.3.415>
- Madsen, K., Nielsen, H. B., y Tingleff, O. (2004). *Methods for non-linear least squares problems* (2nd ed.). DTU.
- Maekawa, K., y Ozawa, K. (1999). Development of SCC's prototype. *Self-Compacting High-Performance Concrete*, 20-32.
- Mahakavi, P., y Chithra, R. (2020). Effect of recycled coarse aggregate and manufactured sand in self compacting concrete. *Australian Journal of Structural Engineering*, 21(1), 33-43. <https://doi.org/10.1080/13287982.2019.1636519>
- Manzi, S., Mazzotti, C., y Chiara Bignozzi, M. (2017). Self-compacting concrete with recycled concrete aggregate: Study of the long-term properties. *Construction and Building Materials*, 157, 582-590.  
<https://doi.org/10.1016/j.conbuildmat.2017.09.129>
- Marani, A., y Nehdi, M. (2020). Machine learning prediction of compressive strength for phase change materials integrated cementitious composites. *Construction and Building Materials*, 265(12), 1-10.  
<https://doi.org/10.1016/j.conbuildmat.2020.120286>

- Marquardt, D. W. (1963). An Algorithm for Least-Squares Estimation of Nonlinear Parameters. *Journal of the Society for Industrial and Applied Mathematics*, 11(2), 431-441. <https://doi.org/10.1137/0111030>
- Martínez, R., Guerra-Romero, M. I., Morán-Del pozo, J., De Brito, J., y Juan-Valdez, A. (2020). Recycling Aggregates for Self-Compacting Concrete Production-A Feasible Option. *Materials*, 13(4), 868. <https://doi.org/10.3390/ma13040868>
- Martínez-García, R. (2021). *Evaluación del uso de áridos reciclados de hormigón en la fabricación de hormigones autocompactantes y morteros de cemento* [Ph.D. Thesis, Universidad de León]. <http://hdl.handle.net/10612/13363>
- Martínez-García, R., Guerra-Romero, M. I., Morán-del Pozo, J. M., De Brito, J., y Juan-Valdés, A. (2020). Recycling Aggregates for Self-Compacting Concrete Production: A Feasible Option. *Materials*, 13(4), Art. 4. <https://doi.org/10.3390/ma13040868>
- Mazloom, M., y Yoosefi, M. M. (2013). Predicting the indirect tensile strength of self-compacting concrete using artificial neural networks. *Computers and Concrete*, 12(3), Art. 3.
- Mehta, K. (2002). Greening of the concrete industry for sustainable development. *Concrete International*, July 2002. <http://ecosmartconcrete.com/docs/trmehta02.pdf>
- Mejía, E., Giraldo, J., y Martínez, L. (2013). Residuos de construcción y demolición Revisión sobre su composición, impactos y gestión. *Revista Cintex*, 18, 105-130.

- Mendes, J. A., de Valeriola, S., Mahy, S., y Maréchal, X. (2017). *Machine Learning applications to non-life pricing. Frequency modelling: An educational case study*. Reacfin.
- Mittelman, D. W. (2004). *The Least Squares Problem*.  
<http://plato.asu.edu/topics/problems/nlolsq>
- Mo, K. H., Ling, T.C., y Cheng, Q. (2021). Examining the Influence of Recycled Concrete Aggregate on the Hardened Properties of Self-compacting Concrete. *Waste and biomass valorization*, 12(2), 1133-1141. <https://doi.org/10.1007/s12649-020-01045-x>
- Møller, M. F. (1993). A scaled conjugate gradient algorithm for fast supervised learning. *Neural Networks*, 6(4), 525-533. [https://doi.org/10.1016/S0893-6080\(05\)80056-5](https://doi.org/10.1016/S0893-6080(05)80056-5)
- Montaño Moreno, J. J., Palmer Pol, A., Sesé Abad, A., y Cajal Blasco, B. (2013). Using the R-MAPE index as a resistant measure of forecast accuracy. *Psicothema*, 25(4), 500-506. <https://doi.org/10.7334/psicothema2013.23>
- Murphy, K. (2012). *Machine Learning. A probabilistic perspective*. The MIT Press.
- Nafees, A., Amin, M. N., Khan, K., Nazir, K., Ali, M., Javed, M. F., Aslam, F., Musarat, M. A., y Vatin, N. I. (2022). Modeling of mechanical properties of silica fume-based green concrete using machine learning techniques. *Polymers*, 14(30).  
<https://doi.org/10.3390/polym14010030>
- Nafees, A., Javed, M. F., Khan, S., Nazir, K., Farooq, F., Aslam, F., Musarat, M. A., y Vatin, N. I. (2021). Predictive Modeling of Mechanical Properties of Silica Fume-Based Green Concrete Using Artificial Intelligence Approaches: MLPNN, ANFIS,

and GEP. *Materials* 2021, Vol. 14, Page 7531, 14(24), 7531.

<https://doi.org/10.3390/ma14247531>

Naganna, S. R., Beyaztas, B. H., Bokde, N., y Armanuos, A. M. (2020). ON THE EVALUATION OF THE GRADIENT TREE BOOSTING MODEL FOR GROUNDWATER LEVEL FORECASTING. *Knowledge-Based Engineering and Sciences*, 1(01), Art.

01. <https://doi.org/10.51526/kbes.2020.1.01.48-57>

Nagarajan, D., Rajagopal, T., y Meyappan, N. (2020). A comparative study on prediction models for strength properties of LWA concrete using artificial neural network.

*Revista de La Construcción*, 19(1), Art. 1.

<https://doi.org/10.7764/RDLC.19.1.103-111>

Nair, S., y Jayaraj, G. (2020). Self-Compacting Concrete using Recycled Coarse

Aggregate—A feasible solution for waste demolish concrete. *International Journal of Advanced Research*, 8(Jul), 836-847.

<https://doi.org/10.21474/IJAR01/11346>

Nalanth, N., Venkatesan, P. V., y Ravikumar, M. S. (2014). Evaluation of the Fresh and Hardened Properties of Steel Fibre Reinforced Self-Compacting Concrete Using Recycled Aggregates as a Replacement Material. *Advances in Civil Engineering*,

2014(Article ID 671547), 6. <https://doi.org/10.1155/2014/671547>

Naseri, H., Jahanbakhsh, H., Moghadas Nejad, F., y Golroo, A. (2020). Developing a Novel Machine Learning Method to Predict the Compressive Strength of Fly Ash Concrete in Different Ages. *AUT Journal of Civil Engineering*, 4(4), 3-3.

<https://doi.org/10.22060/ajce.2019.16124.5569>

- Nasrullah, M., Vainikka, P., Hannula, J., Hurme, M., y Kärki, J. (2014). Mass, energy and material balances of SRF production process. Part 1: SRF produced from commercial and industrial waste. *Waste Management*, 34(8), 1398-1407.  
<https://doi.org/10.1016/j.wasman.2014.03.011>
- Nayyar Hassan, A., y El-Hag, A. (2020). Two-Layer Ensemble-Based Soft Voting Classifier for Transformer Oil Interfacial Tension Prediction. *Energies*, 13(7), Art. 7.  
<https://doi.org/10.3390/en13071735>
- Nazari, A., y Riahi, S. (2011). Computer-aided design of the effects of Fe<sub>2</sub>O<sub>3</sub> nanoparticles on split tensile strength and water permeability of high strength concrete. *Materials & Design*, 32(7), 3966-3979.  
<https://doi.org/10.1016/j.matdes.2011.01.064>
- Neto, E., Cachim, P., y Said, J. (2010). Self-Compacting Concrete: Composition Methodology. *SCC 2010, Montreal - Design, Production and Placement of Self-Consolidating Concrete 6th International RILEM Symposium on Self-Compacting Concrete, II*. <https://hdl.handle.net/1822/65605>
- Nguyen, H., Vu, T., Vo, T. P., y Thai, H. T. (2021). Efficient machine learning models for prediction of concrete strengths. *Construction and Building Materials*, 266, 120950. <https://doi.org/10.1016/j.conbuildmat.2020.120950>
- Nguyen, H. Y. T., Pansuk, W., y Sancharoen, P. (2018). The Effects of Electro-Chemical Chloride Extraction on the Migration of Ions and the Corrosion State of Embedded Steel in Reinforced Concrete. *KSCE Journal of Civil Engineering*, 22(8), 2942-2950. <https://doi.org/10.1007/s12205-017-2022-7>

- Nguyen, K. T., Nguyen, Q. D., Le, T. A., Shin, J., y Lee, K. (2020). Analyzing the compressive strength of green fly ash based geopolymer concrete using experiment and machine learning approaches. *Construction and Building Materials*, 247, 118581. <https://doi.org/10.1016/j.conbuildmat.2020.118581>
- Nguyen, T. T., Pham Duy, H., Pham Thanh, T., y Vu, H. H. (2020). Compressive Strength Evaluation of Fiber-Reinforced High-Strength Self-Compacting Concrete with Artificial Intelligence. *Advances in Civil Engineering*, 2020, e3012139. <https://doi.org/10.1155/2020/3012139>
- Nguyen-Sy, T., Wakim, J., To, Q.-D., Vu, M.-N., Nguyen, T.-D., y Nguyen, T.-T. (2020). Predicting the compressive strength of concrete from its compositions and age using the extreme gradient boosting method. *Construction and Building Materials*, 260, 119757. <https://doi.org/10.1016/j.conbuildmat.2020.119757>
- Nielsson, I., y Wallevik, O. (2003). Rheological evaluation of some empirical test methods-preliminary results. *Rheological Evaluation of Some Empirical Test Methods - Preliminary Results*, 33, 59-68.
- Nieto Alcolea, D. (2015). *Estudio de hormigón autocompactante con árido reciclado* [Ph.D. Thesis, Universidad Politécnica de Madrid]. [https://oa.upm.es/38871/1/DAVID\\_NIETO\\_ALCOLEA.pdf](https://oa.upm.es/38871/1/DAVID_NIETO_ALCOLEA.pdf)
- Nieto, D., Dapena, E., Alaejos, P., Olmedo, J., y Pérez, D. (2019). Properties of Self-Compacting Concrete Prepared with Coarse Recycled Concrete Aggregates and Different Water: Cement Ratios. *Journal of Materials in Civil Engineering*, 31(2). [https://doi.org/10.1061/\(ASCE\)MT.1943-5533.0002566](https://doi.org/10.1061/(ASCE)MT.1943-5533.0002566)

- Nikbin, I. M., Beygi, M. H. A., Kazemi, M. T., Vaseghi Amiri, J., Rabbanifar, S., Rahmani, E., y Rahimi, S. (2014). A comprehensive investigation into the effect of water to cement ratio and powder content on mechanical properties of self-compacting concrete. *Construction and Building Materials*, 57, 69-80.  
<https://doi.org/10.1016/j.conbuildmat.2014.01.098>
- Nikoo, M., Torabian Moghadam, F., y Sadowski, Ł. (2015). Prediction of Concrete Compressive Strength by Evolutionary Artificial Neural Networks. *Advances in Materials Science and Engineering*, 2015, e849126.  
<https://doi.org/10.1155/2015/849126>
- Nili, M., Sasanipour, H., y Aslani, F. (2019). The effect of fine and coarse recycled aggregates on fresh and mechanical properties of self-compacting concrete. *Materials*, 12(7), 1120. <https://doi.org/10.3390/ma12071120>
- Niu, D., Diao, L., Zang, Z., Che, H., Zhang, T., y Chen, X. (2021). A Machine-Learning Approach Combining Wavelet Packet Denoising with Catboost for Weather Forecasting. *Atmosphere*, 12(12), Art. 12.  
<https://doi.org/10.3390/atmos12121618>
- Okamura, H. (1997). Self-Compacting High-Performance Concrete. *Concrete International*, 19(7), 50-54.
- Okamura, H., y Ouchi, M. (1998). Self-compacting high performance concrete. *Progress in Structural Engineering and Materials*, 1(4), 378-383.  
<https://doi.org/10.1002/pse.2260010406>

- Okamura, H., y Ouchi, M. (1999). Self-compacting concrete. Development, present and future. En Å. Skarendahl y Ö. Petersson (Eds.), *1st International RILEM Symposium on Self-Compacting Concrete* (pp. 3-14). RILEM Publications SARL.
- Okamura, H., y Ouchi, M. (2003). Self-Compacting Concrete. *Journal of Advanced Concrete Technology*, 1(1), 5-15. <https://doi.org/10.3151/jact.1.5>
- Okamura, H., y Ozawa, K. (1996). Self-Compacting High-Performance Concrete. *Structural Engineering International*, 6(4), 269-270.  
<https://doi.org/10.2749/101686696780496292>
- Okamura, H., Ozawa, K., y Ouchi, M. (1995). Self-Compacting High Performance Concrete. *Magazine of the Korea Concrete Institute*, 7(5), 33-41.  
<https://doi.org/10.22636/MKCI.1995.7.5.33>
- Okamura, H., Ozawa, K., y Ouchi, M. (2000). Self-compacting concrete. *Structural Concrete*, 1(1), 3-17. <https://doi.org/10.1680/stco.2000.1.1.3>
- Olu-Ajayi, R., Alaka, H., Sulaimon, I., Sunmola, F., y Ajayi, S. (2022). Building energy consumption prediction for residential buildings using deep learning and other machine learning techniques. *Journal of Building Engineering*, 45, 103406.  
<https://doi.org/10.1016/j.jobbe.2021.103406>
- Onyari, E. K., y Ikotun, B. D. (2018). Prediction of compressive and flexural strengths of a modified zeolite additive mortar using artificial neural network. *Construction and Building Materials*, 187, 1232-1241.  
<https://doi.org/10.1016/j.conbuildmat.2018.08.079>
- Ortiz-Bejar, J., Graff, M., Tellez, E. S., Ortiz-Bejar, J., y Jacobo, J. C. (2018). K-Nearest Neighbor Regressors Optimized by using Random Search. *2018 IEEE*

- International Autumn Meeting on Power, Electronics and Computing (ROPEC)*,  
1-5. <https://doi.org/10.1109/ROPEC.2018.8661399>
- Ouchi, M., Hibino, M., y Okamura, H. (1997). Effect of Superplasticizer on Self-  
Compactability of Fresh Concrete. *Transportation Research Record: Journal of  
the Transportation Research Board*, 1574(1), 37-40.  
<https://doi.org/10.3141/1574-05>
- Özgür, K., y Erdal, U. (2005). Comparison of three back-propagation training algorithms  
for two case studies. *Indian J. Eng. Mater. Sci.*, 12, 432-442.
- Özkan, Y., Demirarslan, M., y Suner, A. (2022). Effect of data preprocessing on  
ensemble learning for classification in disease diagnosis. *Communications in  
Statistics - Simulation and Computation*, 51(4).  
<https://doi.org/10.1080/03610918.2022.2053717>
- Öztaş, A., Pala, M., Özbay, E., Kanca, E., Çag'lar, N., y Bhatti, M. A. (2006). Predicting  
the compressive strength and slump of high strength concrete using neural  
network. *Construction and Building Materials*, 20(9), 769-775.  
<https://doi.org/10.1016/j.conbuildmat.2005.01.054>
- Pacheco Bustos, C. A. P., Fuentes Pumarejo, L. G. F., Sánchez CotteQuintana, E., y  
Rondón Quintana, H. (2017). Residuos de construcción y demolición (RCD), una  
perspectiva de aprovechamiento para la ciudad de barranquilla desde su  
modelo de gestión. *Ingeniería y Desarrollo*, 35(2), 533-555.
- Pacheco, J., de Brito, J., Chastre, C., y Evangelista, L. (2019). Uncertainty Models of  
Reinforced Concrete Beams in Bending: Code Comparison and Recycled

- Aggregate Incorporation. *Journal of Structural Engineering*, 145(4), 04019013.  
[https://doi.org/10.1061/\(ASCE\)ST.1943-541X.0002296](https://doi.org/10.1061/(ASCE)ST.1943-541X.0002296)
- Padmini, A. K., Ramamurthy, K., y Mathews, M. S. (2009). Influence of parent concrete on the properties of recycled aggregate concrete. *Construction and Building Materials*, 23(2), 829-836. <https://doi.org/10.1016/j.conbuildmat.2008.03.006>
- Pan, X., Xiao, Y., Suhail, S. A., Ahmad, W., Murali, G., Salmi, A., y Mohamed, A. (2022). Use of Artificial Intelligence Methods for Predicting the Strength of Recycled Aggregate Concrete and the Influence of Raw Ingredients. *Materials*, 15(12), 4194. <https://doi.org/10.3390/ma15124194>
- Pan, Z., Zhou, J., Jiang, X., Xu, Y., Jin, R., Ma, J., Zhuang, Y., Diao, Z., Zhang, S., Si, Q., y Chen, W. (2019). Investigating the effects of steel slag powder on the properties of self-compacting concrete with recycled aggregates. *Construction and Building Materials*, 200, 570-577.  
<https://doi.org/10.1016/j.conbuildmat.2018.12.150>
- Panda, K. C., y Bal, P. K. (2013). Properties of Self Compacting Concrete Using Recycled Coarse Aggregate. *Procedia Engineering*, 51, 159-164.  
<https://doi.org/10.1016/j.proeng.2013.01.023>
- Park, Y.-S., y Lek, S. (2016). Chapter 7 - Artificial Neural Networks: Multilayer Perceptron for Ecological Modeling. *Developments in Environmental Modelling*, 28, 123-140. <https://doi.org/10.1016/B978-0-444-63623-2.00007-4>
- Parlamento Europeo y Consejo de la Union Europea. (2008). Directiva 2008/98/CE del Parlamento Europeo y del Consejo, de 19 de noviembre de 2008 , sobre los

residuos y por la que se derogan determinadas Directivas. *Diario Oficial de la Unión Europea*.

Parlamento Europeo y El Consejo de la Unión Europea. (2006). DIRECTIVA 2006/21/CE DEL PARLAMENTO EUROPEO Y DEL CONSEJO, de 15 de marzo de 2006, sobre la gestión de los residuos de industrias extractivas y por la que modifica la Directiva 2004/35/CE. *Diario Oficial de la Unión Europea*, 11-4-2006(102).  
<https://www.boe.es/doue/2006/102/L00015-00033.pdf>

Parlamento Europeo y El Consejo de la Unión Europea. (2008). Directiva 2008/98/CD del Parlamento Europeo y del Consejo, de 19 de noviembre de 2008 sobre los residuos y por la que se derogan determinadas Directivas. *Diario Oficial de la Unión Europea*, 22-11-2008(312), 32.

Parlamento Europeo y El Consejo de la Unión Europea. (2018). DIRECTIVA (UE) 2018/851 DEL PARLAMENTO EUROPEO Y DEL CONSEJO, de 30 de mayo de 2018, por la que se modifica la Directiva 2008/98/CE sobre los residuos. *Diario Oficial de la Unión Europea*, 14-6-2018(150). <https://eur-lex.europa.eu/legal-content/ES/TXT/PDF/?uri=CELEX:32018L0851&from=ES>

Patel, A., Bhuva, P., George, E., y Bhatt, D. (2011). Compressive Strength and Modulus of Elasticity of Self-Compacting Concrete. *National Conference on Recent Trends in Engineering & Technology (NCRTEET- 2011)*, 5(1), 4.

Peláez Carretero, A. (2014). *Hormigón autocompactante con nano-adiciones de sílice y alúmina* [Master, Universidad Politécnica de Madrid].  
[https://oa.upm.es/31173/1/Tesis\\_master\\_Alfonso\\_Pelaez\\_Carretero.pdf](https://oa.upm.es/31173/1/Tesis_master_Alfonso_Pelaez_Carretero.pdf)

- Pereira-De-Oliveira, L. A., Nepomuceno, M. C. S., Castro-Gomes, J. P., y Vila, M. F. C. (2014). Permeability properties of self-Compacting concrete with coarse recycled aggregates. *Construction and Building Materials*, 51, 113-120. <https://doi.org/10.1016/j.conbuildmat.2013.10.061>
- Pérez-Benedicto, J. A., Río-Merino, M. del, Peralta-Canudo, J. L., y Mata, M. de la R.-L. (2012). Características mecánicas de hormigones con áridos reciclados procedentes de los rechazos en prefabricación. *Materiales de Construcción*, 62(305), Art. 305. <https://doi.org/10.3989/mc.2011.62110>
- Pinedo, A. (2009). *Hormigón autocompactante en componentes de edificación*. Universitat Politecnica de Catalunya.
- Polikar, R. (2012). Ensemble Learning. En C. Zhang y Y. Ma (Eds.), *Ensemble Machine Learning: Methods and Applications* (pp. 1-34). Springer. [https://doi.org/10.1007/978-1-4419-9326-7\\_1](https://doi.org/10.1007/978-1-4419-9326-7_1)
- Poongodi, K., Muthi, P., Awoyera, P. O., Gobinath, R., y Olalusi, O. B. (2021). Durability Properties of Self-compacting Concrete Made With Recycled Aggregate. *Silicon*, 13, 2727-2735. <https://doi.org/10.1007/s12633-020-00635-7>
- Prokhorenkova, L., Gusev, G., Vorobev, A., Dorogush, A. V., y Gulin, A. (2018a). CatBoost: Unbiased boosting with categorical features. En S. Bengio, H. Wallach, H. Larochelle, K. Grauman, N. Cesa-Bianchi, y R. Garnett (Eds.), *Advances in Neural Information Processing Systems 31 (NeurIPS 2018)* (Vol. 31). Curran Associates, Inc. <https://proceedings.neurips.cc/paper/2018>
- Rathakrishnan, V., Beddu, S., y Ahmed, A. N. (2021). Comparison studies between machine learning optimisation technique on predicting concrete compressive

- strength. *Research square, April*, 54. <https://doi.org/10.21203/rs.3.rs-381936/v1>
- Rathakrishnan, V., Beddu, S., y Ahmed, A. N. (2022). Predicting compressive strength of high-performance concrete with high volume ground granulated blast-furnace slag replacement using boosting machine learning algorithms. *Scientific Reports*, 12(1), Art. 1. <https://doi.org/10.1038/s41598-022-12890-2>
- Ray, S., Haque, M., Ahmed, T., y Nahin, T. T. (2021). Comparison of artificial neural network (ANN) and response surface methodology (RSM) in predicting the compressive and splitting tensile strength of concrete prepared with glass waste and tin (Sn) can fiber. *Journal of King Saud University - Engineering Sciences*, March 2021. <https://doi.org/10.1016/j.jksues.2021.03.006>
- Ray, S., Haque, M., Rahman, Md. M., Sakib, Md. N., y Al Rakib, K. (2021). Experimental investigation and SVM-based prediction of compressive and splitting tensile strength of ceramic waste aggregate concrete. *Journal of King Saud University - Engineering Sciences*, In Press. <https://doi.org/10.1016/j.jksues.2021.08.010>
- Ray, S., Rahman, M. M., Haque, M., Hasan, M. W., y Alam, M. M. (2021). Performance evaluation of SVM and GBM in predicting compressive and splitting tensile strength of concrete prepared with ceramic waste and nylon fiber. *Journal of King Saud University - Engineering Sciences*, xxxx. <https://doi.org/10.1016/j.jksues.2021.02.009>
- RCD. (2018). *Guía española de áridos reciclados provenientes de residuos de construcción y demolición (RCD)*. Asociación española de reciclaje de residuosde

construcción y demolición. <https://rcdasociacion.es/wp-content/uploads/2022/04/Guia-Espanola-de-RCD.pdf>

Recarey Fernández, R. (2021). *Métodos de ensamblado en Machine Learning*

[Universidad de Santiago de Compostella].

[http://eio.usc.es/pub/mte/descargas/ProyectosFinMaster/Proyecto\\_1686.pdf](http://eio.usc.es/pub/mte/descargas/ProyectosFinMaster/Proyecto_1686.pdf)

Revathi, P., Selvi, R. S., y Velin, S. S. (2013). Investigations on Fresh and Hardened

Properties of Recycled Aggregate Self Compacting Concrete. *Journal of The Institution of Engineers (India): Series A*, 94(3), 179-185.

<https://doi.org/10.1007/s40030-014-0051-5>

Revilla-Cuesta, V., Ortega-López, V., Skaf, M., y Manso, J. (2020). Effect of fine recycled

concrete aggregate on the mechanical behavior of self-compacting concrete.

*Construction and Building Materials*, 263(10 December), 120671.

<https://doi.org/10.1016/j.conbuildmat.2020.120671>

RILEM. (2022). *10th International RILEM Symposium on Self-compacting Concrete &*

*5th International Symposium on Design, Performance and Use of Self-*

*consolidating Concrete & 2nd International Workshop on Rheology and*

*Pumping of Fresh Concrete*. [https://www.rilem.net/agenda/10th-international-](https://www.rilem.net/agenda/10th-international-rilem-symposium-on-self-compacting-concrete-5th-international-symposium-on-design-performance-and-use-of-self-consolidating-concrete-2nd-international-workshop-on-rheology-and-pumping-of-fresh-concrete-1498)

[rilem-symposium-on-self-compacting-concrete-5th-international-symposium-](https://www.rilem.net/agenda/10th-international-rilem-symposium-on-self-compacting-concrete-5th-international-symposium-on-design-performance-and-use-of-self-consolidating-concrete-2nd-international-workshop-on-rheology-and-pumping-of-fresh-concrete-1498)

[on-design-performance-and-use-of-self-consolidating-concrete-2nd-](https://www.rilem.net/agenda/10th-international-rilem-symposium-on-self-compacting-concrete-5th-international-symposium-on-design-performance-and-use-of-self-consolidating-concrete-2nd-international-workshop-on-rheology-and-pumping-of-fresh-concrete-1498)

[international-workshop-on-rheology-and-pumping-of-fresh-concrete-1498](https://www.rilem.net/agenda/10th-international-rilem-symposium-on-self-compacting-concrete-5th-international-symposium-on-design-performance-and-use-of-self-consolidating-concrete-2nd-international-workshop-on-rheology-and-pumping-of-fresh-concrete-1498)

RILEM Technical Committee. (2008). Final report of RILEM TC 205-DSC: Durability of

self-compacting concrete. *Materials and Structures*, 41, 225-233.

<https://doi.org/10.1617/s11527-007-9319-9>

- Rimanic, L., Renggli, C., Li, B., y Zhang, C. (2020). On Convergence of Nearest Neighbor Classifiers over Feature Transformations. *Neural Information Processing Systems, October 2020*. <https://doi.org/10.48550/arXiv.2010.07765>
- Robas, A. H. (2009). *Influencia de la variación de las propiedades del árido reciclado en el hormigón endurecido* [Tesis de Máster, Universitat Politècnica de Catalunya]. <https://upcommons.upc.edu/handle/2099.1/8508>
- Rodriguez-Galiano, V., Sanchez-Castillo, M., Chica-Olmo, M., y Chica-Rivas, M. (2015). Machine learning predictive models for mineral prospectivity: An evaluation of neural networks, random forest, regression trees and support vector machines. *Ore Geology Reviews, 71*, 804-818. <https://doi.org/10.1016/j.oregeorev.2015.01.001>
- Romero Esquinas, Á. (2018). *Estudio de hormigones autocompactantes fabricados con residuos industriales como filler* [Ph.D. Thesis, Escuela politécnica Superior de Belmez, Universidad de Córdoba]. <http://helvia.uco.es/xmlui/handle/10396/17588>
- Rouhiainen, L. (2008). *Igencia artificial 101 cosas que debes saber hoy sobre nuestro futuro*. Alienta.
- Sadeghi-Nik, A., Berenjian, J., Alimohammadi, S., Lotfi-Omran, O., Sadeghi-Nik, A., y Karimaei, M. (2019). The Effect of Recycled Concrete Aggregates and Metakaolin on the Mechanical Properties of Self-Compacting Concrete Containing Nanoparticles. *Iranian Journal of Science and Technology - Transactions of Civil Engineering, 45*, 503-515. <https://doi.org/10.1007/s40996-018-0182-4>

- Saidova, Z., Yakovlev, G., Smirnova, O., Gordina, A., y Kuzmina, N. (2021). Modification of Cement Matrix with Complex Additive Based on Chrysotyl Nanofibers and Carbon Black. *Applied Sciences*, 11(15), Art. 15.  
<https://doi.org/10.3390/app11156943>
- Sainz-Aja Guerra, J. A. (2019). *Reciclado de via tradicional para la fabricacion de via placa*. Programa de Doctorado de Ingenieria Civil, Universidad de Cantabria.
- Salesa, A., Pérez-Benedicto, J. A., Esteban, L. M., Vicente-Vas, R., y Orna-Carmona, M. (2017). Physico-mechanical properties of multi-recycled self-compacting concrete prepared with precast concrete rejects. *Construction and Building Materials*, 153(30 October), 364-373.  
<https://doi.org/10.1016/j.conbuildmat.2017.07.087>
- Sánchez Roldán, Z. (2019). *Utilización de árido reciclado para la fabricación de piezas de hormigón prefabricado de mobiliario urbano* [Ph.D. Thesis, Universidad de Granada]. <https://digibug.ugr.es/handle/10481/55703>
- Santos, S. A., Da Silva, P. R., y De Brito, J. (2017). Mechanical Performance Evaluation of Self-Compacting Concrete with Fine and Coarse Recycled Aggregates from the Precast Industry. *Materials*, 10(8), Art. 8.  
<https://doi.org/10.3390/ma10080904>
- Santos, S., da Silva, P. R., y de Brito, J. (2019). Self-compacting concrete with recycled aggregates – A literature review. *Journal of Building Engineering*, 22, 349-371.  
<https://doi.org/10.1016/j.jobbe.2019.01.001>

- Sariev, E., y Germano, G. (2020). Bayesian regularized artificial neural networks for the estimation of the probability of default. *Quantitative Finance*, 20(2), 311-328.  
<https://doi.org/10.1080/14697688.2019.1633014>
- Sarıdemir, M. (2009). Prediction of compressive strength of concretes containing metakaolin and silica fume by artificial neural networks. *Advances in Engineering Software*, 40(5), 350-355.  
<https://doi.org/10.1016/j.advengsoft.2008.05.002>
- Sasanipour, H., y Aslani, F. (2019). Effect of specimen shape, silica fume, and curing age on durability properties of self-compacting concrete incorporating coarse recycled concrete aggregates. *Construction and Building Materials*, 228(20 December), 117054. <https://doi.org/10.1016/j.conbuildmat.2019.117054>
- Sasanipour, H., y Aslani, F. (2020). Durability properties evaluation of self-compacting concrete prepared with waste fine and coarse recycled concrete aggregates. *Construction and Building Materials*, 236, 117540.  
<https://doi.org/10.1016/j.conbuildmat.2019.117540>
- Schermelleh-Engel, K., Moosbrugger, H., y Müller, H. (2003). Evaluating the fit of structural equation models: Tests of significance and descriptive goodness-of-fit measures. *MPR-online*, 8(2), 23-74.
- Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural Networks*, 61, 85-117. <https://doi.org/10.1016/j.neunet.2014.09.003>
- Secretaría del Estado de Medio Ambiente. (2022). *MEMORIA ANUAL DE GENERACIÓN Y GESTIÓN DE RESIDUOS RESIDUOS DE CONSTRUCCIÓN Y DEMOLICIÓN (RCD)*. Ministerio para la Transición Ecológica y el reto demográfico.

[https://www.miteco.gob.es/es/calidad-y-evaluacion-ambiental/publicaciones/generacionygestiondercd2014-2018\\_tcm30-527685.pdf](https://www.miteco.gob.es/es/calidad-y-evaluacion-ambiental/publicaciones/generacionygestiondercd2014-2018_tcm30-527685.pdf)

Señas, L., Priano, C., y Marfil, S. (2016). Influence of recycled aggregates on properties of self-consolidating concretes. *Construction and Building Materials*, 113, 498-505. <https://doi.org/10.1016/j.conbuildmat.2016.03.079>

Servén, D., Brummitt, C., y Abedi, H. (2018). PyGAM: generalized additive models in python. *Zenodo*. <https://doi.org/10.5281/zenodo.1208723>.

Servigon Ruiz, G. (2021). *Influencia de los residuos de construcción y demolición de edificaciones en la calidad de vida humana y ambiental en el distrito de Ferreñafe 2020* [Universidad Católica Santo Toribio de Mogroviejo]. <http://tesis.usat.edu.pe/handle/20.500.12423/3719>

Shang, M., Li, H., Ahmad, A., Ahmad, W., Ostrowski, K. A., Aslam, F., Joyklad, P., y Majka, T. M. (2022). Predicting the Mechanical Properties of RCA-Based Concrete Using Supervised Machine Learning Algorithms. *Materials*, 15(2), Art. 2. <https://doi.org/10.3390/ma15020647>

Shaqadan, A. (2016). Prediction of concrete mix strength using random forest model. *International Journal of Applied Engineering Research*, 11(22), 11024-11029.

Sharafati, A., Haji Seyed Asadollah, S. B., y Al-Ansari, N. (2021). Application of bagging ensemble model for predicting compressive strength of hollow concrete masonry prism. *Ain Shams Engineering Journal*, 12(4), 3521-3530. <https://doi.org/10.1016/j.asej.2021.03.028>

- Sharifi, Y., Houshiar, M., y Aghebati, B. (2013). Recycled glass replacement as fine aggregate in self-compacting concrete. *Frontiers of Structural and Civil Engineering*, 7(4), 419-428. <https://doi.org/10.1007/s11709-013-0224-8>
- Shi, C., Ou, Z., y Khayat, K. (2014). *Design, Performance and Use of Self-Consolidating Concrete*. RILEM Publications SARL.
- Shi, C., Wu, Z., Lv, K., y Wu, L. (2015). A review on mixture design methods for self-compacting concrete. *Construction and Building Materials*, 84, 387-398. <https://doi.org/10.1016/j.conbuildmat.2015.03.079>
- Shivaraj, M., Ravi Kumar, H., Prema Kumar, W. P., y Preetham, S. (2015). Prediction of Compressive, Flexural and Splitting Tensile Strengths of Concrete using Machine Learning Tools. *International Journal of Engineering Research & Technology (IJERT)*, 4(5). <https://doi.org/10.17577/IJERTV4IS050950>
- Silva, P., y de Brito, J. (2017). Experimental study of the mechanical properties and shrinkage of self-compacting concrete with binary and ternary mixes of fly ash and limestone filler. *European Journal of Environmental and Civil Engineering*, 21(4), 430-453. <https://doi.org/10.1080/19648189.2015.1131200>
- Silva, P. F. S., Moita, G. F., y Arruda, V. F. (2020). Machine learning techniques to predict the compressive strength of concrete. *Revista Internacional de Métodos Numéricos Para Cálculo y Diseño En Ingeniería*, 36(4). <https://doi.org/10.23967/j.rimni.2020.09.008>
- Silva, Y. F., Robayo, R. A., Matthey, P. E., y Delvasto, S. (2016). Properties of self-compacting concrete on fresh and hardened with residue of masonry and

- recycled concrete. *Construction and Building Materials*, 124, 639-644.  
<https://doi.org/10.1016/j.conbuildmat.2016.07.057>
- Sims, I., John, L., y Ferrari, J. (2019). Concrete Aggregates. En P. Hewlett y M. Liska (Eds.), *Leas's Chemistry of Cement and Concrete* (5.<sup>a</sup> ed.). Elsevier. <https://es.book.lat/book/5568379/c1bc2e>
- Singh, A., Arora, S., Sharma, V., y Bhardwaj, B. (2019). Workability Retention and Strength Development of Self-Compacting Recycled Aggregate Concrete Using Ultrafine Recycled Powders and Silica Fume. *ournal of Hazardous, Toxic, and Radioactive Waste*, 23(4). [https://doi.org/10.1061/\(ASCE\)HZ.2153-5515.0000456](https://doi.org/10.1061/(ASCE)HZ.2153-5515.0000456)
- Singh, P., Usman, M., Chandramauli, A., y Kumar, D. (2018). Brief experimental study on self compacting concrete. *International Journal of Civil Engineering and Technology*, 9(5), 77-82. <https://doi.org/10.13140/RG.2.2.34399.28323>
- Singh, W. R., y Jain, M. K. (2015). Continuous Hydrological Modeling using Soil Moisture Accounting Algorithm in Vamsadhara River Basin, India. *Journal of Water Resource and Hydraulic Engineering*, 4(4), 398-408.  
<https://doi.org/10.5963/jwrhe0404011>
- Skarendahl, A., y Petersson, O. (2000). *Self-compacting concrete: State-of-art report of RILEM technical committee 174-SCC*. RILEM publications S.A.R.L.
- Smirnova, O. (2018). Development of classification of rheologically active microfillers for disperse systems with Portland cement and superplasticizer.  
<http://www.iaeme.com/IJCIET/index.asp> 1966 editor@iaeme.com

*International Journal of Civil Engineering and Technology (IJCIET)*, 9(10), 1966-1973.

Smirnova, O. (2019). CoMPatibility of Shungisite microfillers with polycarboxylate admixtures in cement compositions. *ARP Journal of Engineering and Applied Sciences*, 14(3).  
[http://www.arnjournals.org/jeas/research\\_papers/rp\\_2019/jeas\\_0219\\_7595.pdf](http://www.arnjournals.org/jeas/research_papers/rp_2019/jeas_0219_7595.pdf)

Smirnova, O., Kazanskaya, L., Koplík, J., Tan, H., y Gu, X. (2021). Concrete Based on Clinker-Free Cement: Selecting the Functional Unit for Environmental Assessment. *Sustainability*, 13(1), Art. 1. <https://doi.org/10.3390/su13010135>

Smirnova, O. M. (2020). Low-Clinker Cements with Low Water Demand. *Journal of Materials in Civil Engineering*, 32(7), 06020008.  
[https://doi.org/10.1061/\(ASCE\)MT.1943-5533.0003241](https://doi.org/10.1061/(ASCE)MT.1943-5533.0003241)

Smirnova, O. M., Menéndez Pidal de Navascués, I., Mikhailevskii, V. R., Kolosov, O. I., y Skolota, N. S. (2021). Sound-Absorbing Composites with Rubber Crumb from Used Tires. *Applied Sciences*, 11(16), Art. 16.  
<https://doi.org/10.3390/app11167347>

Smirnova, O. M., Menendez Pidal, I., Alekseev, A. V., Petrov, D. N., y Popov, M. G. (2022). Strain Hardening of Polypropylene Microfiber Reinforced Composite Based on Alkali-Activated Slag Matrix. *Materials*, 15(4), Art. 4.  
<https://doi.org/10.3390/ma15041607>

Song, H., Ahmad, A., Farooq, F., Ostrowski, K. A., Maślak, M., Czarnecki, S., y Aslam, F. (2021). Predicting the compressive strength of concrete with fly ash admixture

- using machine learning algorithms. *Construction and Building Materials*, 308, 125021. <https://doi.org/10.1016/j.conbuildmat.2021.125021>
- Song, Y., Zhao, J., Ostrowski, K. A., Javed, M. F., Ahmad, A., Khan, M. I., Aslam, F., y Kinasz, R. (2022). Prediction of Compressive Strength of Fly-Ash-Based Concrete Using Ensemble and Non-Ensemble Supervised Machine-Learning Approaches. *Applied Sciences*, 12(1), Art. 1. <https://doi.org/10.3390/app12010361>
- Srour, I. M., Chehab, G. R., El-Fadel, M., y Tamraz, S. (2013). Pilot-based assessment of the economics of recycling construction demolition waste. *Waste Management & Research: The Journal for a Sustainable Circular Economy*, 31(11), 1170-1179. <https://doi.org/10.1177/0734242X13479430>
- Sua-lam, G., y Makul, N. (2013). Use of recycled alumina as fine aggregate replacement in self-compacting concrete. *Construction and Building Materials*, 47, 701-710. <https://doi.org/10.1016/j.conbuildmat.2013.05.065>
- Suárez Silgado, S. S. (2016). Propuesta metodológica para evaluar el comportamiento ambiental y económico de los residuos de construcción y demolición (RCD) en la producción de materiales pétreos [Ph.D. Thesis, Universitat Politècnica de Catalunya]. En *TDX (Tesis Doctorals en Xarxa)*. <http://www.tdx.cat/handle/10803/376709>
- Suescum-Morales, D., Salas-Morera, L., Jiménez, J. R., y García-Hernández, L. (2021). A Novel Artificial Neural Network to Predict Compressive Strength of Recycled Aggregate Concrete. *Applied Sciences*, 11(22), Art. 22. <https://doi.org/10.3390/app112211077>

- Sun, C., Chen, Q., Xiao, J., y Liu, W. (2020). Utilization of waste concrete recycling materials in self-compacting concrete. *Resources, Conservation and Recycling*, 161, 104930. <https://doi.org/10.1016/j.resconrec.2020.104930>
- Surendar, M., Beulah Gnana Ananthi, G., Sharaniya, M., Deepak, M. S., y Soundarya, T. V. (2021). Mechanical properties of concrete with recycled aggregate and M-sand. *Materials Today: Proceedings*, 44(1), 1723-1730. <https://doi.org/10.1016/j.matpr.2020.11.896>
- Surendar, M., Gnana Ananthi, G. B., Sharaniya, M., Deepak, M. S., y Soundarya, T. V. (2021). Mechanical properties of concrete with recycled aggregate and M-sand. *Materials Today: Proceedings*, 44(January), 1723-1730. <https://doi.org/10.1016/j.matpr.2020.11.896>
- Tam, V. W. Y., Shen, L. Y., Fung, I. W. H., y Wang, J. Y. (2007). Controlling construction waste by implementing governmental ordinances in Hong Kong. *Construction Innovation*, 7(2), 149-166. <https://doi.org/10.1108/14714170710738522>
- Tang, W., Khavarian, M., Yousefi, A., y Cui, H. (2020). Properties of self-compacting concrete with recycled concrete aggregates. En *Self-Compacting Concrete: Materials, Properties and Applications* (pp. 219-248). Elsevier. <https://doi.org/10.1016/B978-0-12-817369-5.00009-X>
- Tang, W., Ryan, P. C., Cui, H. Z., y Liao, W. (2016). Properties of Self-Compacting Concrete with Recycled Coarse Aggregate. *Advances in Materials Science and Engineering*, 2016(Article ID 2761294), 11. <https://doi.org/10.1155/2016/2761294>

- Thomas, C., Setién, J., y Polanco, J. A. (2016). Structural recycled aggregate concrete made with precast wastes. *Construction and Building Materials*, 114, 536-546.  
<https://doi.org/10.1016/j.conbuildmat.2016.03.203>
- Ticknor, J. L. (2013). A Bayesian regularized artificial neural network for stock market forecasting. *Expert Systems with Applications*, 40(14), 5501-5506.  
<https://doi.org/10.1016/j.eswa.2013.04.013>
- Toirac Corral, J. (2009). La resistencia a compresión del hormigón, condición necesaria pero no suficiente para el logro de la durabilidad de las obras. *Ciencia y Sociedad*, XXXIV(4), 463-504.
- Topçu, İ. B., y Sarıdemir, M. (2007). Prediction of properties of waste AAC aggregate concrete using artificial neural network. *Computational Materials Science*, 41(1), 117-125. <https://doi.org/10.1016/j.commatsci.2007.03.010>
- Torres-Barrán, A., Alonso, Á., y Dorransoro, J. R. (2019). Regression tree ensembles for wind energy and solar radiation prediction. *Neurocomputing*, 326-327, 151-160. <https://doi.org/10.1016/j.neucom.2017.05.104>
- Tuyan, M., Mardani-Aghabaglou, A., y Ramyar, K. (2014). Freeze-thaw resistance, mechanical and transport properties of self-consolidating concrete incorporating coarse recycled concrete aggregate. *Materials and Design*, 53(112), 983-991. <https://doi.org/10.1016/j.matdes.2013.07.100>
- UNE. (2021). *UNE-Asociación Española de Normalización* [Sitio web].  
<https://www.une.org/>
- UNE Normalización Española. (2009). UNE-EN 12620:2003+A1:2009 Áridos para hormigón. *Asociación Española de Normalización*, 27-05-2009.

<https://www.une.org/encuentra-tu-norma/busca-tu-norma/norma?c=N0043155>

UNE Normalización Española. (2021). UNE-EN 206:2013+A2:2021 Hormigón. Especificaciones, prestaciones, producción y conformidad. *Asociación Española de Normalización*, 22-12-2021. <https://www.une.org/encuentra-tu-norma/busca-tu-norma/norma?c=norma-une-en-206-2013-a2-2021-n0067954>

Uygunoğlu, T., Topçu, I., y Celik, A. G. (2014). Use of waste marble and recycled aggregates in self-compacting concrete for environmental sustainability. *Journal of Cleaner Production*, 84(1), 691-700. <https://doi.org/10.1016/j.jclepro.2014.06.019>

Uysal, M., y Tanyildizi, H. (2011). Predicting the core compressive strength of self-compacting concrete (SCC) mixtures with mineral additives using artificial neural network. *Construction and Building Materials*, 25(11), 4105-4111. <https://doi.org/10.1016/j.conbuildmat.2010.11.108>

Uysal, M., y Yilmaz, K. (2011). Effect of mineral admixtures on properties of self-compacting concrete. *Cement and Concrete Composites*, 33(7), 771-776. <https://doi.org/10.1016/j.cemconcomp.2011.04.005>

Van Assche, A., y Blockeel, H. (2007). Seeing the Forest Through the Trees: Learning a Comprehensible Model from an Ensemble. En J. N. Kok, J. Koronacki, R. L. de Mantaras, S. Matwin, D. Mladenič, y A. Skowron (Eds.), *Machine Learning: ECML 2007* (pp. 418-429). Springer. [https://doi.org/10.1007/978-3-540-74958-5\\_39](https://doi.org/10.1007/978-3-540-74958-5_39)

- Vilanova, A. (2009). *Influencia de la dosificación y empleo de diferentes tipos de cemento y adiciones en las propiedades mecánicas del hormigón autocompactante* [Ph.D. Thesis, Universidad Politécnica de Madrid].  
<https://oa.upm.es/1813/>
- Villoria Sáez, P. (2014). *Sistema de gestión de residuos de construcción y demolición en obras de edificación residencial. Buenas prácticas en la ejecución de obra* [PhD Thesis, Universidad Politécnica de Madrid].  
<https://doi.org/10.20868/UPM.thesis.32681>
- Vinay Kumar, B. M., Ananthan, H., y Balaji, K. V. A. (2017). Experimental studies on utilization of coarse and finer fractions of recycled concrete aggregates in self compacting concrete mixes. *Journal of Building Engineering*, 9, 100-108.  
<https://doi.org/10.1016/j.jobbe.2016.11.013>
- Vitale, P., Arena, N., Di Gregorio, F., y Arena, U. (2017). Life cycle assessment of the end-of-life phase of a residential building. *Waste Management (New York, N.Y.)*, 60, 311-321. <https://doi.org/10.1016/j.wasman.2016.10.002>
- Vivas, E., Allende-Cid, H., y Salas, R. (2020). A systematic review of statistical and machine learning methods for electrical power forecasting with reported mape score. *Entropy*, 22(12), 1412. <https://doi.org/10.3390/e22121412>
- Vu, C.-C., Plé, O., Weiss, J., y Amtrano, D. (2020). Revisiting the concept of characteristic compressive strength of concrete. *Construction and Building Materials*, 263, 120126. <https://doi.org/10.1016/j.conbuildmat.2020.120126>

- Walczak, S., y Cerpa, N. (2003). Artificial neural network. En R. Meyers (Ed.), *Encyclopedia of physical science and technology* (pp. 631-645). Elsevier Academic Press.
- Wallevik, O., y Nielsson, I. (2003). *3rd International RILEM Symposium on Self-Compacting Concrete*. RILEM Publications SARL.
- Wang, J., Dai, Q., Si, R., Ma, Y., y Guo, S. (2020). Fresh and mechanical performance and freeze-thaw durability of steel fiber-reinforced rubber self-compacting concrete (SRSCC). *Journal of Cleaner Production*, 277, 123180.  
<https://doi.org/10.1016/j.jclepro.2020.123180>
- Wang, S., Xu, M., Zhang, X., y Wang, Y. (2022). Fitting Nonlinear Equations with the Levenberg–Marquardt Method on Google Earth Engine. *Remote Sensing*, 14(9), Art. 9. <https://doi.org/10.3390/rs14092055>
- Wang, Y., Zhao, B., Yang, G., Jia, Y., Yang, L., Li, M., Tang, X., Huang, Z., Sun, J., y Shen, W. (2019). Effect of recycled coarse aggregate on the properties of C40 self-compacting concrete. *Advanced Composites Letters*, 28, 096369351988512.  
<https://doi.org/10.1177/0963693519885128>
- Winkler, D. A., y Burden, F. R. (2000). Robust QSAR Models from Novel Descriptors and Bayesian Regularised Neural Networks. *Molecular Simulation*, 24(4-6), 243-258.  
<https://doi.org/10.1080/08927020008022374>
- Wood, S. N. (2017). *Generalized Additive Models: An Introduction with R* (2.<sup>a</sup> ed.). Chapman and Hall/CRC. <https://doi.org/10.1201/9781315370279>

- Wu, Z., Yu, A. T. W., Shen, L., y Liu, G. (2014). Quantifying construction and demolition waste: An analytical review. *Waste Management*, 34(9), 1683-1692.  
<https://doi.org/10.1016/j.wasman.2014.05.010>
- Xie, T., Gholampour, A., y Ozbakkaloglu, T. (2018). Toward the Development of Sustainable Concretes with Recycled Concrete Aggregates: Comprehensive Review of Studies on Mechanical Properties. *Journal of Materials in Civil Engineering*, 30(9), 04018211. [https://doi.org/10.1061/\(ASCE\)MT.1943-5533.0002304](https://doi.org/10.1061/(ASCE)MT.1943-5533.0002304)
- Xie, T., Yang, G., Zhao, X., Xu, J., y Fang, C. (2020). A unified model for predicting the compressive strength of recycled aggregate concrete containing supplementary cementitious materials. *Journal of Cleaner Production*, 251, 119752.  
<https://doi.org/10.1016/j.jclepro.2019.119752>
- Xu, J., Chen, Y., Xie, T., Zhao, X., Xiong, B., y Chen, Z. (2019). Prediction of triaxial behavior of recycled aggregate concrete using multivariable regression and artificial neural network techniques. *Construction and Building Materials*, 226, 534-554. <https://doi.org/10.1016/j.conbuildmat.2019.07.155>
- Xu, J. J., Chen, W. G., Demartino, C., Xie, T. Y., Yu, Y., Fang, C. F., y Xu, M. (2021). A Bayesian model updating approach applied to mechanical properties of recycled aggregate concrete under uniaxial or triaxial compression. *Construction and Building Materials*, 301, 124274.  
<https://doi.org/10.1016/j.conbuildmat.2021.124274>
- Xu, J., Zhao, X., Yu, Y., Xie, T., Yang, G., y Xue, J. (2019). Parametric sensitivity analysis and modelling of mechanical properties of normal- and high-strength recycled

- aggregate concrete using grey theory, multiple nonlinear regression and artificial neural networks. *Construction and Building Materials*, 211, 479-491.  
<https://doi.org/10.1016/j.conbuildmat.2019.03.234>
- Yakovlev, G., Polyanskikh, I., Gordina, A., Pudov, I., Černý, V., Gumenyuk, A., y Smirnova, O. (2021). Influence of Sulphate Attack on Properties of Modified Cement Composites. *Applied Sciences*, 11(18), Art. 18.  
<https://doi.org/10.3390/app11188509>
- Yan, K., Xu, H., Shen, G., y Liu, P. (2013). Prediction of Splitting Tensile Strength from Cylinder Compressive Strength of Concrete by Support Vector Machine. *Advances in Materials Science and Engineering*, 2013, e597257.  
<https://doi.org/10.1155/2013/597257>
- Yang, B., y Cao, B. (2018). Research on Ensemble Learning-based Housing Price Prediction Model. *Big Geospatial Data and Data Science*, 1(1), 1-8.  
<https://doi.org/10.23977/bgdds.2018.11001>
- Yaseen, Z. M., Deo, R. C., Hilal, A., Abd, A. M., Bueno, L. C., Salcedo-Sanz, S., y Nehdi, M. L. (2018). Predicting compressive strength of lightweight foamed concrete using extreme learning machine model. *Advances in Engineering Software*, 115, 112-125. <https://doi.org/10.1016/j.advengsoft.2017.09.004>
- Ye, G., Yuan, H., Shen, L., y Wang, H. (2012). Simulating effects of management measures on the improvement of the environmental performance of construction waste management. *Rosoueces, Conservation & Recycling*, 62, 56-63. <https://doi.org/10.1016/j.resconrec.2012.01.010>

- Ye, L., Jabbar, S. F., Abdul Zahra, M. M., y Tan, M. L. (2021). Bayesian Regularized Neural Network Model Development for Predicting Daily Rainfall from Sea Level Pressure Data: Investigation on Solving Complex Hydrology Problem. *Complexity*, 2021, e6631564. <https://doi.org/10.1155/2021/6631564>
- Yu, F., Feng, C., Wang, S., Huang, W., Fang, Y., y Bu, S. (2021). MECHANICAL PERFORMANCE OF RECYCLED AGGREGATE SELF-CONSOLIDATING CONCRETE COLUMN. *Journal of Civil Engineering and Management*, 27(3), 188-202. <https://doi.org/10.3846/jcem.2021.14117>
- Yu, F., Qin, C., Wang, S., Jiang, J., y Fang, Y. (2020). Stress-strain relationship of recycled self-compacting concrete filled steel tubular column subjected to eccentric compression. *Frontiers of Structural and Civil Engineering*, 14(3), 760-772. <https://doi.org/10.1007/s11709-020-0618-3>
- Yu, J. J., Gong, J., Zou, J. M., y Kang Yang, W. (2014). Study on Properties of Self-Compacting Concrete Prepared with Coarse Recycled Concrete Aggregate. *Applied Mechanics and Materials*, 638, 1494-1498. <https://doi.org/10.4028/www.scientific.net/amm.638-640.1494>
- Yu, T., Fang, X. L., y Teng, J. G. (2014). FRP-Confined Self-Compacting Concrete under Axial Compression. *Journal of Materials in Civil Engineering*, 26(11), 04014082. [https://doi.org/10.1061/\(ASCE\)MT.1943-5533.0000993](https://doi.org/10.1061/(ASCE)MT.1943-5533.0000993)
- Yuan, H. (2013). A SWOT analysis of successful construction waste management. *Journal of Cleaner Production*, 39, 1-8. <https://doi.org/10.1016/j.jclepro.2012.08.016>

- Yuan, H., y Shen, L. (2011). Trend of the research on construction and demolition waste management. *Waste Management*, 31(4), 670-679.  
<https://doi.org/10.1016/j.wasman.2010.10.030>
- Yüksel, İ., Bilir, T., y Özkan, Ö. (2007). Durability of concrete incorporating non-ground blast furnace slag and bottom ash as fine aggregate. *Building and Environment*, 42(7), 2651-2659. <https://doi.org/10.1016/j.buildenv.2006.07.003>
- Zador, A. M. (2019). A critique of pure learning and what artificial neural networks can learn from animal brains. *Nature Communications*, 10(1), Art. 1.  
<https://doi.org/10.1038/s41467-019-11786-6>
- Zaid, O., Ahmad, J., Siddique, M. S., y Aslam, F. (2021). Effect of Incorporation of Rice Husk Ash Instead of Cement on the Performance of Steel Fibers Reinforced Concrete. *Frontiers in Materials*, 8, 665625.  
<https://doi.org/10.3389/fmats.2021.665625>
- Zaid, O., Ahmad, J., Siddique, M. S., Aslam, F., Alabduljabbar, H., y Khedher, K. M. (2021). A step towards sustainable glass fiber reinforced concrete utilizing silica fume and waste coconut shell aggregate. *Scientific Reports*, 11(1), Art. 1.  
<https://doi.org/10.1038/s41598-021-92228-6>
- Zaid, O., Aslam, F., y Alabduljabbar, H. (2021). To evaluate the performance of waste marble powder and wheat straw ash in steel fiber reinforced concrete. *Structural Concrete*, 23(3), 1947-1947.  
<https://doi.org/10.1002/suco.202100736>
- Zaid, O., Hashmi, S. R. Z., Aslam, F., Abedin, Z. U., y Ullah, A. (2022). Experimental study on the properties improvement of hybrid graphene oxide fiber-reinforced

- composite concrete. *Diamond and Related Materials*, 124, 108883.  
<https://doi.org/10.1016/j.diamond.2022.108883>
- Zaid, O., Martínez-García, R., Abadel, A. A., Fraile-Fernández, F. J., Alshaikh, I. M. H., y Palencia-Coto, C. (2022). To determine the performance of metakaolin-based fiber-reinforced geopolymer concrete with recycled aggregates. *Archives of Civil and Mechanical Engineering*, 22(3), 114. <https://doi.org/10.1007/s43452-022-00436-2>
- Zaid, O., Mukhtar, F. M., M-García, R., El Sherbiny, M. G., y Mohamed, A. M. (2022). Characteristics of high-performance steel fiber reinforced recycled aggregate concrete utilizing mineral filler. *Case Studies in Construction Materials*, 16, e00939. <https://doi.org/10.1016/j.cscm.2022.e00939>
- Zalapa, A. (2021). *Incorporación del aprendizaje automático para la predicción de la capacidad portante en vigas de concreto presforzado dañadas por corrosión* [Ph.D. Thesis, Universidad Michoacana de San Nicolás de Hidalgo].  
[http://bibliotecavirtual.dgb.umich.mx:8083/xmlui/bitstream/handle/DGB\\_UMI/CH/5761/FIQ-D-2021-0901.pdf?sequence=1&isAllowed=y](http://bibliotecavirtual.dgb.umich.mx:8083/xmlui/bitstream/handle/DGB_UMI/CH/5761/FIQ-D-2021-0901.pdf?sequence=1&isAllowed=y)
- Zhang, C., y Ma, Y. (2012). *Ensemble Machine Learning | SpringerLink*. Springer.  
<https://link.springer.com/book/10.1007/978-1-4419-9326-7>
- Zhang, C.-X., y Zhang, J.-S. (2009). A novel method for constructing ensemble classifiers. *Statistics and Computing*, 19(3), 317-327.  
<https://doi.org/10.1007/s11222-008-9094-7>
- Zhang, Q., y Habibi, H. (2021). Comparison of Data Mining Methods to Predict Mechanical Properties of Concrete with Fly Ash and Alccofine. *Journal of*

*Materials Research and Technology*, 15, 2188-2201.

<https://doi.org/0.1016/j.jmrt.2021.09.024>

Zhang, X., Akber, M. Z., y Zheng, W. (2021). Prediction of seven-day compressive strength of field concrete. *Construction and Building Materials*, 305, 124604.

<https://doi.org/10.1016/j.conbuildmat.2021.124604>

Zhou, A. G., Yin, J., Song, W. M., y Chi, Y. (2013). Research on Self-Compacting Concrete Made with Recycled Aggregate. *Advanced Materials Research*, 639-

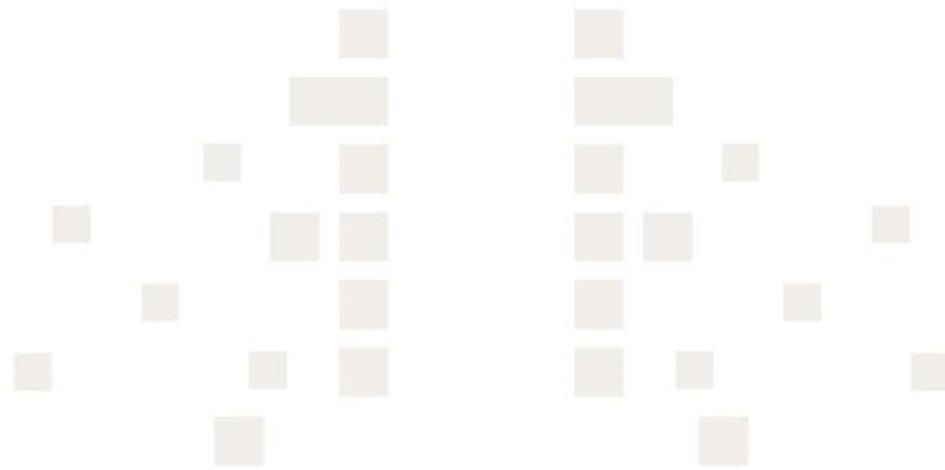
640(January), 399-403. [https://doi.org/10.4028/www.scientific.net/AMR.639-](https://doi.org/10.4028/www.scientific.net/AMR.639-640.399)

640.399

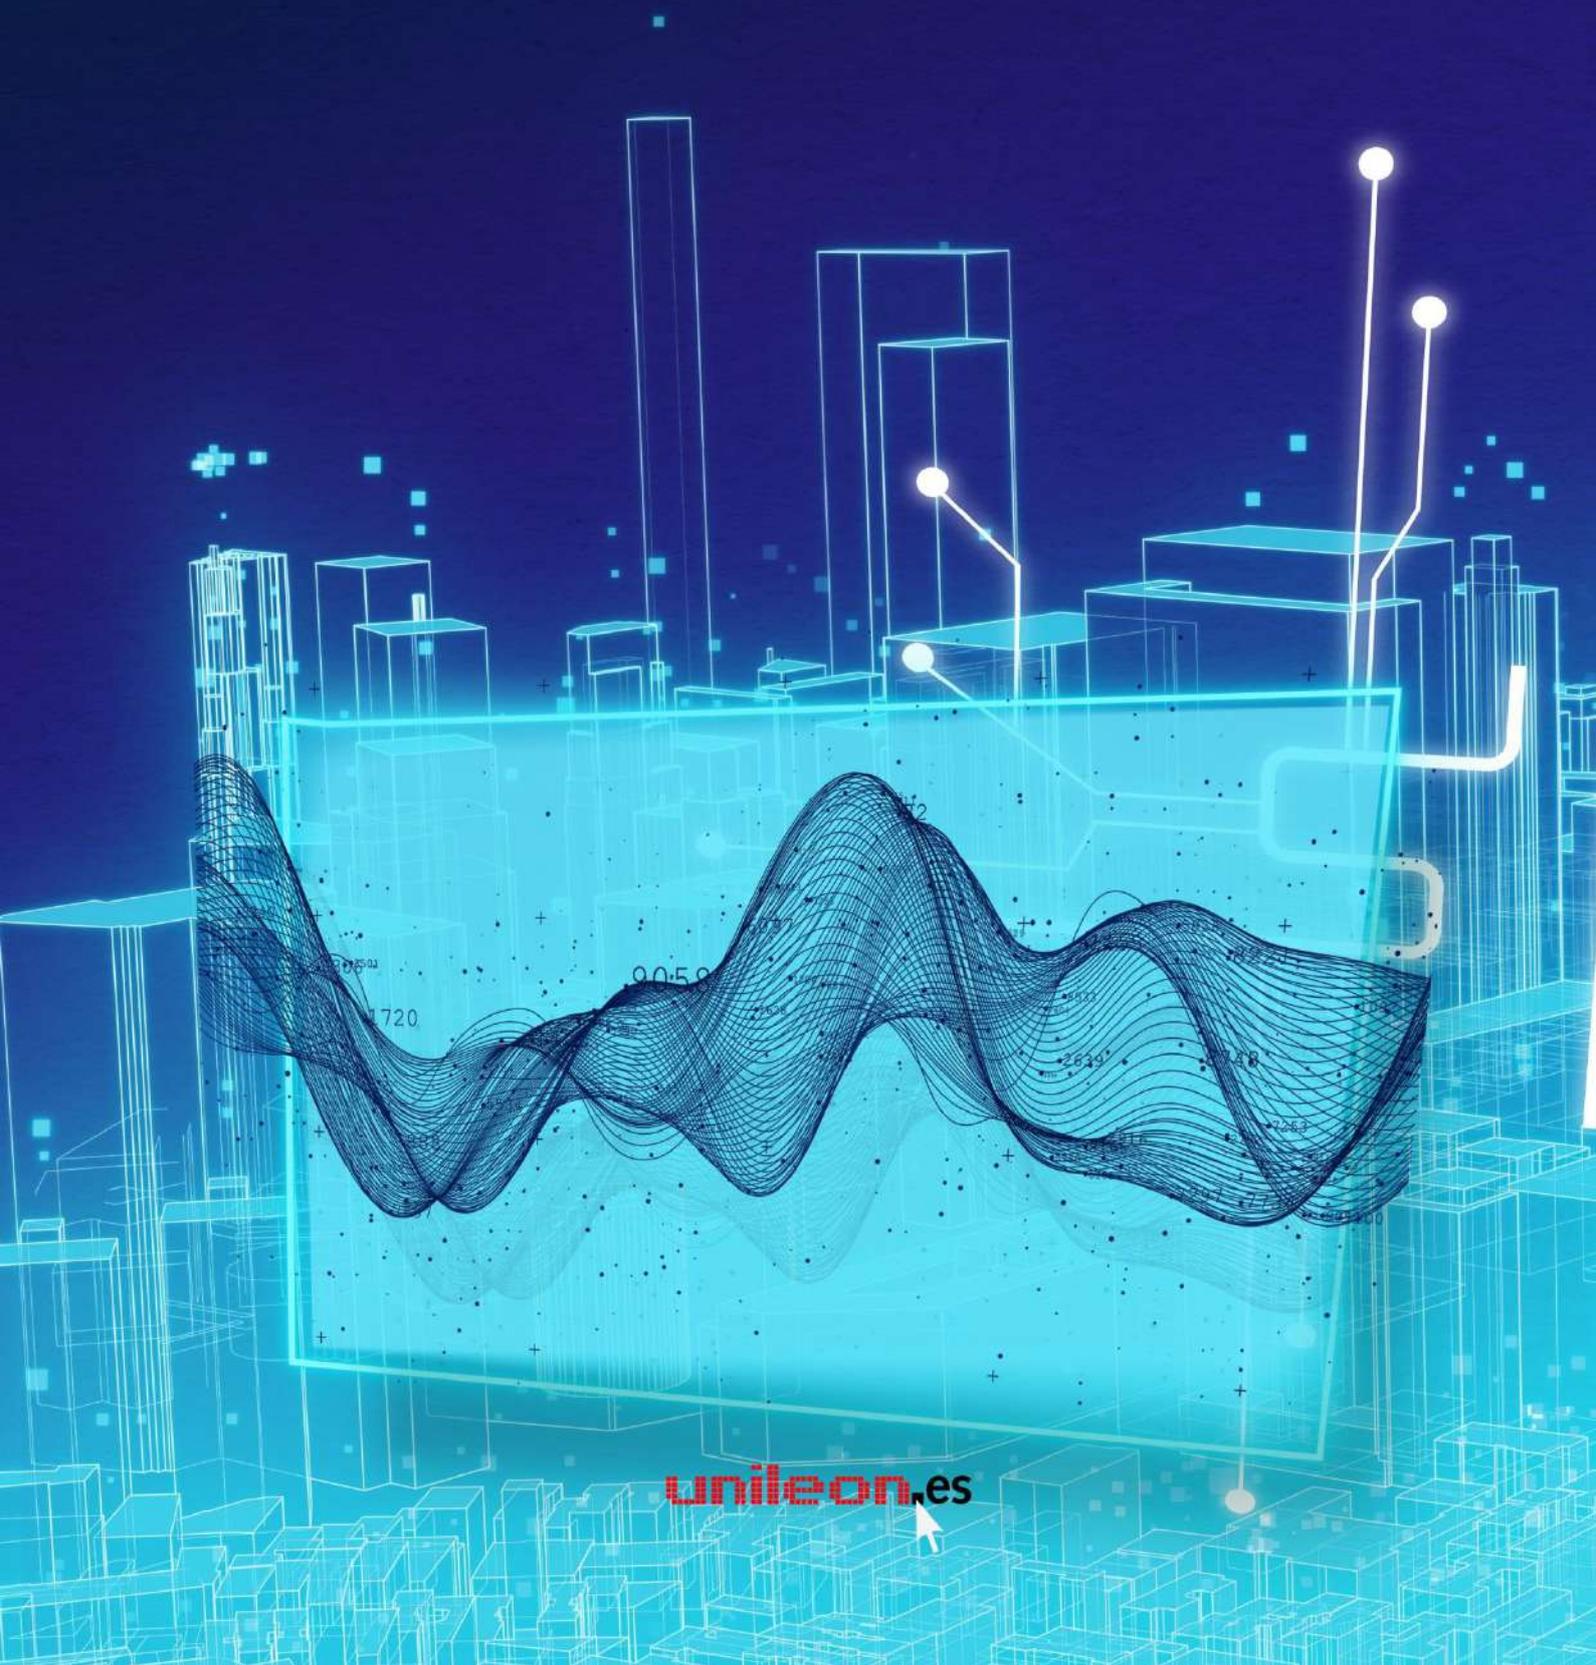
Zhou, X., He, G., Fan, Y., Xiao, Y., Kunnath, S., y Monti, G. (2013). Research on Self-Compacting Concrete Made with Recycled Aggregate. *Advanced Materials*

*Research*, 639-640, 399-403.

<https://doi.org/10.4028/www.scientific.net/AMR.639-640.399>



Doctorado en Ciencia y  
Tecnología del Medio Ambiente  
Universidad de León



[unileon.es](http://unileon.es)