

## Previsión impulsada por IA y evaluación en laboratorio de la resistencia a la compresión en hormigón agregado reciclado.

S. Gopal<sup>1\*</sup> , A. Kumar<sup>2</sup> 

\*Autor de contacto: [swatantragopal.const@gmail.com](mailto:swatantragopal.const@gmail.com)

DOI: <https://doi.org/10.21041/ra.v16i2.967>

Recibido: 12/04/2025 | Recibido en versión revisada: 19/03/2026 | Aceptado: 20/03/2026 | Publicado: 05/01/2026

### RESUMEN

Este estudio tiene como objetivo evaluar y predecir la resistencia a la compresión del hormigón agregado reciclado (RAC) mediante ensayos experimentales y técnicas de aprendizaje automático. Se investigaron veinticinco mezclas de hormigón con contenido variable de agregados reciclados, proporción de agua-cemento, dosis de plastificante y resistencia del hormigón original. La resistencia a la compresión de 28 días osciló entre 31,8 y 45,2 MPa, disminuyendo con mayor contenido de agregados reciclados y mayor absorción de agua. La regresión vectorial de soporte alcanzó la mayor precisión en la predicción ( $R^2 = 0,998$ ), superando a otros modelos. El estudio está limitado por el tamaño del conjunto de datos y la expansión controlada de datos. La originalidad radica en integrar la investigación experimental con el análisis de aprendizaje automático multimodelo. Los resultados demuestran que la IA puede apoyar eficazmente el diseño sostenible de mezclas de hormigón agregado reciclado.

**Palabras clave:** hormigón de áridos reciclados; resistencia a la compresión; aprendizaje automático; regresión de vectores de soporte; construcción sostenible; modelado basado en datos.

**Citar como:** Gopal, S., Kumar, A. (2026), "Previsión impulsada por IA y evaluación de laboratorio de la resistencia a la compresión en hormigón de agregados reciclados.", Revista ALCONPAT, 16 (2), pp. 149 – 185, DOI: <https://doi.org/10.21041/ra.v16i2.967>.

<sup>1</sup> Investigador en el Departamento de Ingeniería Civil, Universidad Sandip, Sijoul, Madhubani-847235, Bihar, India

<sup>2</sup> Profesor Adjunto, Departamento de Ingeniería Civil, Universidad Sandip, Sijoul, Madhubani-847235, Bihar, India.

#### Contribución de cada autor

En este trabajo, el autor Swatantra Gopal aportó el 50% y el autor Dr. Amrendra Kumar aportó el 50% restante. Las actividades serán: idea original; la redacción de manuscritos; experimentación y recogida de datos; desarrollo de modelos de aprendizaje automático; análisis de datos; supervisión conceptual; validación metodológica; interpretación y discusión de resultados; revisión crítica y edición del manuscrito.

#### Licencia Creative Commons

Copyright 2026 por los autores. Este trabajo es un artículo de acceso abierto publicado bajo los términos y condiciones de una Licencia Internacional Creative Commons Atribución 4.0 Internacional ([CC BY 4.0](https://creativecommons.org/licenses/by/4.0/)).

#### Debates y correcciones posteriores a la publicación

Cualquier disputa, incluidas las respuestas de los autores, se publicará en el primer número de 2027 siempre que la información se reciba antes del cierre del tercer número de 2026.

## Predicción y evaluación en laboratorio de la resistencia a compresión en hormigón con árido reciclado mediante IA.

### RESUMEN

Este estudio tiene como objetivo evaluar y predecir la resistencia a compresión del hormigón con árido reciclado (HAR) mediante ensayos experimentales y técnicas de aprendizaje automático. Se analizaron veinticinco mezclas de hormigón con diferentes contenidos de árido reciclado, relación agua-cemento, dosificación de plastificante y resistencia del hormigón base. La resistencia a compresión a los 28 días osciló entre 31,8 y 45,2 MPa, disminuyendo con un mayor contenido de árido reciclado y una mayor absorción de agua. La regresión de vectores de soporte ( $R^2$ ) alcanzó la mayor precisión predictiva ( $R^2 = 0,998$ ), superando a otros modelos. El estudio se ve limitado por el tamaño del conjunto de datos y la expansión controlada de los mismos. Su originalidad reside en la integración de la investigación experimental con el análisis de aprendizaje automático multimodelo. Los resultados demuestran que la IA puede contribuir eficazmente al diseño de mezclas sostenibles de hormigón con árido reciclado.

**Palabras clave:** hormigón con árido reciclado; resistencia a compresión; aprendizaje automático; regresión de vectores de soporte; construcción sostenible; modelado basado en datos.

## Previsão orientada por IA e avaliação laboratorial da resistência à compressão do concreto com agregados reciclados

### RESUMO

Este estudo tem como objetivo avaliar e prever a resistência à compressão do concreto com agregados reciclados (CAR) por meio de ensaios experimentais e técnicas de aprendizado de máquina. Foram investigadas vinte e cinco misturas de concreto com variação do teor de agregados reciclados, da relação água/cimento, da dosagem de aditivo plastificante e da resistência do concreto de origem. A resistência à compressão aos 28 dias variou de 31,8 a 45,2 MPa, reduzindo-se com o aumento do teor de agregados reciclados e da absorção de água. A Regressão por Vetores de Suporte (SVR) alcançou a maior precisão preditiva ( $R^2 = 0,998$ ), superando os demais modelos. O estudo é limitado pelo tamanho do conjunto de dados e pela expansão controlada desses dados. A originalidade está na integração da investigação experimental com a análise de aprendizado de máquina com múltiplos modelos. Os resultados demonstram que a IA pode apoiar, de forma efetiva, a dosagem sustentável de concretos com agregados reciclados.

**Palavras-chave:** concreto com agregados reciclados; resistência à compressão; aprendizado de máquina; regressão por vetores de suporte; construção sustentável; modelagem orientada por dad.

### Información legal

Revista ALCONPAT es una publicación trimestral de la Asociación Latinoamericana de Control de Calidad, Patología y Recuperación de la Construcción, Internacional, A.C., Km. 6 antigua carretera a Progreso, Mérida, Yucatán, 97310, Tel. +52 1 983 419 8241, [alconpat.int@gmail.com](mailto:alconpat.int@gmail.com), Sitio web: [www.alconpat.org](http://www.alconpat.org)

Reserva de derechos de uso exclusivo n° 04-2013-011717330300-203 e ISSN 2007-6835, ambos concedidos por el Instituto Nacional de Derecho de Autor. Editor responsable: Pedro Castro Borges, Ph.D. Responsable de la última actualización de este número, Unidad de Informática ALCONPAT, Elizabeth Sabido Maldonado.

Las opiniones de los autores no reflejan necesariamente la posición del editor.

La reproducción total o parcial del contenido e imágenes de la publicación se realiza conforme al código COPE y a la licencia CC BY 4.0 de la Revista ALCONPAT.

## 1. INTRODUCCIÓN

El hormigón es la base de la infraestructura moderna, pero su producción conlleva un importante coste medioambiental. La fabricación de cemento por sí sola contribuye significativamente a las emisiones globales de carbono. Análisis recientes muestran que la industria del cemento sigue siendo una fuente sustancial de CO<sub>2</sub> a través del consumo energético y procesos químicos (por ejemplo, la descarbonización de piedra caliza). Al mismo tiempo, las actividades de construcción y demolición (C&D) generan grandes volúmenes de residuos, lo que genera presión en el uso del suelo y desafíos en la eliminación. La eliminación de residuos C&D no solo carga los vertederos, sino que también implica riesgos de pérdida de materiales y degradación ambiental. (Akbar & Liew, 2020b; Khalil & AbouZeid, 2025) (Cakiroglu et al., 2023; Pal & Singh, 2024)

Reutilizar escombros de construcción y demolición para crear agregados de hormigón reciclados (RAs) es una solución viable a ambos problemas. Los RA pueden obtenerse triturando y purificando hormigón demolido después de eliminar impurezas como madera, plásticos y refuerzos de acero. El material resultante, conocido como Hormigón Agregado Reciclado (RAC), puede tener cualidades de ingeniería similares a las del hormigón creado con áridos naturales cuando estos agregados reciclados se añaden a hormigón nuevo. Sin embargo, varios factores intrínsecos como la resistencia y calidad del hormigón original, la cantidad de mortero adherido, la porosidad de las partículas recicladas y las propiedades de absorción de agua tienen un impacto significativo en la efectividad del RAC. (Chakradhara Rao et al., 2011) (Ajdukiewicz & Kliszczewicz, 2002; Khatib, 2005)

El hecho de que los áridos reciclados suelen tener más porosidad y absorción de agua que los áridos nativos es uno de los principales problemas al utilizar hormigón de áridos reciclados. Estas características provienen del mortero antiguo y adherido y de microgrietas que se desarrollan durante la trituración. La relación efectiva agua-cemento, la trabajabilidad, la resistencia y la durabilidad del RAC se ven afectadas por la alta absorción de agua de los RA. Además, el RAC fabricado con hormigón matriz de baja resistencia suele mostrar reducciones más significativas en la resistencia a la compresión que el RAC derivado de hormigón fuente de alta resistencia, probablemente porque las partículas recicladas contienen debilidades residuales (por ejemplo, microgrietas antiguas) en la nueva mezcla. (P. Zhang et al., 2023) (Khalil & AbouZeid, 2025) (Katz, 2003; Padmini et al., 2002)

Además de la absorción de agua y la calidad del hormigón original, otros parámetros de la mezcla como la relación de reposición (porcentaje de agregado reciclado), la relación aguacemento (p/c), la condición de humedad del agregado y la calidad mecánica (por ejemplo, resistencia a la abrasión) de los RAs también afectan a la resistencia del RAC. Debido a que estas variables suelen interactuar de forma no lineal, el comportamiento de la CAR es complejo e impredecible. Esta complejidad requiere pruebas de laboratorio exhaustivas como la colada de múltiples lotes de hormigón, su curado y la realización de pruebas de resistencia destructiva. Estos programas experimentales requieren muchos recursos, consumen mucho tiempo y son costosos. (Bai y otros, 2023; Huang & Yan, 2025)

La modelización predictiva se ha convertido en un sustituto potente de confiar únicamente en técnicas experimentales. En la investigación clásica del concreto, se han utilizado análisis de regresión (por ejemplo, regresión lineal múltiple o multivariante) para vincular parámetros de diseño de mezcla con resistencia y otras propiedades. Sin embargo, cuando los factores interactúan de manera no lineal o el conjunto de datos es de alta dimensión, estos enfoques frecuentemente fallan. (Dantas et al., 2013; Shin & Kim, 2013; Sí, 2007)

Las técnicas de inteligencia artificial (IA) y aprendizaje automático (ML) han demostrado un potencial significativo en los últimos diez años para predecir la resistencia a la compresión del hormigón, especialmente al manejar espacios de parámetros complejos e interacciones no lineales. Los modelos que pueden aprender de los datos y tener en cuenta los efectos complejos de los

Previsión impulsada por IA y evaluación en laboratorio de la resistencia a la compresión en hormigón agregado reciclado.

factores de diseño de mezcla incluyen Redes Neuronales Artificiales (ANN), Regresión de Vectores de Soporte (SVR), Bosques Aleatorios, Gradient Boosting y XGBoost. Estas técnicas de aprendizaje automático ya se han utilizado en el contexto del CRA para predecir la resistencia a la compresión teniendo en cuenta insumos como la densidad, la resistencia del hormigón principal, la absorción de agua, la relación aguacemento, la relación de reemplazo de áridos reciclados e incluso la resistencia a la abrasión de áridos. (Bilim, Koksai, et al., 2009; Farhangi et al., 2021; Jahangir & Eidgahee, 2020) (Khan y otros, 2022; X. Zhang et al., 2023)

A pesar de estos desarrollos, todavía existen varios vacíos. Muchos estudios existentes se basan en conjuntos de datos limitados en tamaño o diversidad, se centran solo en unos pocos parámetros de entrada o evalúan solo uno o dos modelos de aprendizaje automático. De manera crítica, pocos trabajos combinan un amplio programa experimental de laboratorio (con múltiples contenidos de agregados reciclados, resistencias del hormigón original y pruebas de calidad de áridos) con una comparación exhaustiva de modelos de aprendizaje automático. Sin dicha integración, sigue siendo difícil validar las predicciones del modelo en un amplio ámbito experimental y evaluar cómo los cambios reales en el diseño de la mezcla podrían influir en el rendimiento del modelo.

Las técnicas de inteligencia artificial (IA) y aprendizaje automático (ML) han demostrado un potencial considerable en los últimos años para predecir con precisión cualidades concretas. Redes Neuronales Artificiales (ANN), regresión de vectores de soporte (SVR), bosque aleatorio, aumento de gradiente y XGBoost son algunos de los métodos que pueden predecir rápida y asequiblemente correlaciones complejas entre parámetros de entrada y respuestas de salida. Estos modelos funcionan especialmente bien para RAC, donde la resistencia a la compresión está determinada por la interacción no lineal de varios componentes de la mezcla, las propiedades de agregados y las condiciones de curado. (Bilim, Ozbakkaloglu, et al., 2009; Farhangi et al., 2021; Jahangir & Eidgahee, 2020)

En este estudio, los agregados reciclados se procesaron cuidadosamente para asegurar una composición predominantemente basada en hormigón, minimizando la variabilidad asociada a los residuos mixtos C&D. Aunque las redes neuronales artificiales se han utilizado ampliamente en la predicción de resistencias concretas, el presente estudio se centra en enfoques alternativos de aprendizaje automático para asegurar la interpretabilidad y robustez con datos experimentales limitados. Abordamos estas carencias mediante una evaluación experimental sistemática y un modelado predictivo mejorado por IA para investigar la resistencia a compresión de 28 días del RAC. En un programa experimental se utilizaron mezclas de hormigón con diferentes cantidades de cemento, agregados finos y gruesos naturales y reciclados, agua, superplastificantes y proporciones agua-cemento. Las características importantes de la AR son la resistencia del hormigón principal, los valores de abrasión en Los Ángeles y la absorción de agua. Las resistencias de compresión de 28 días de las mezclas variaron entre aproximadamente 31,8 MPa y 45,2 MPa. Para mejorar el conjunto de datos con fines de modelado, cada instancia de datos se amplió mediante variación controlada ( $\pm 10\%$ ) aplicada a parámetros de mezcla seleccionados, dando lugar a 1.125 puntos de datos. Para la validación experimental, se preparó y probó una serie de muestras de hormigón correspondientes a cada modificación, generando 1.125 valores de resistencia medidos. Se implementaron varias técnicas de aprendizaje automático, incluyendo Regresión de Vectores de Soporte (SVR), Bosque Aleatorio (RF), K-Vecinos Más Cercanos (KNN), Aumento de Gradiente Extremo (XGBoost), Aumento de Gradiente (GB), Regresión Lineal (LR), Operador de Mínima Contracción Absoluta y Selección (Lazo), Regresión de Cresta (Cresta) y Red Elástica (EN), para predecir la resistencia a compresión a partir de parámetros de mezcla de entrada. Entre estos modelos, SVR logró la mayor precisión predictiva ( $R^2 = 0.998$ ) con errores mínimos (MAE = 0,008, RMSE = 0,011), demostrando la eficacia de los enfoques basados en IA para capturar relaciones complejas de fuerza de mezcla.

Este trabajo busca proporcionar un marco fiable para calcular la resistencia a compresión de los RAC, combinando predicciones impulsadas por IA con mediciones experimentales. El estudio

apoya el uso sostenible de áridos reciclados en la construcción de hormigón, reduce los costes experimentales e identifica los factores de mezcla más importantes.

## 2. MATERIALES Y MÉTODOS

Agua, plastificante, agregados naturales y reciclados, y cemento Portland ordinario (OPC) fueron los ingredientes empleados en esta investigación. El cemento cumplía con las especificaciones estándar, proporcionando un aglutinante consistente para todas las mezclas. De acuerdo con las normas ASTM C33 y C127, se obtuvieron localmente agregados naturales finos y gruesos y evaluados para absorber agua, gravedad específica y distribución del tamaño de las partículas, cuyos resultados se presentan en la Tabla 3. (Internacional, 2024) (Akbar & Liew, 2020a)

### 2.1 Propiedades físicas de los agregados

Las propiedades físicas de los áridos naturales finos y gruesos se determinaron de acuerdo con las normas ASTM pertinentes, incluyendo ASTM C127 y ASTM C128 para gravedad específica y absorción de agua, y ASTM C33 para distribución del tamaño de partículas. Estas propiedades son esenciales para evaluar la calidad de los áridos y su influencia en el rendimiento del hormigón. Los valores medidos experimentalmente de gravedad específica, absorción de agua y módulo de finura de los agregados naturales se presentan en la Tabla 1.

Tabla 1. Propiedades físicas de los agregados naturales utilizados en este estudio.

Propiedad	Agregado fino	Agregado grueso
Gravedad específica	2.62	2.68
Absorción de agua (%)	1.2	0.8
Módulo de finura	2.7	-
Tamaño máximo (mm)	4.75	20
Zona de Clasificación (según ASTM C33)	Zona II	-

### 2.2 Propiedades físicas y mecánicas de los áridos reciclados

Se determinaron las propiedades físicas y mecánicas del agregado fino reciclado (RFA) y del árido grueso reciclado (RCA) para evaluar su idoneidad para la producción de hormigón y su influencia en el desarrollo de resistencia. Se evaluaron propiedades clave como la gravedad específica, la absorción de agua, la densidad global y la porosidad conforme a las normas ASTM pertinentes. Los agregados reciclados generalmente presentaban una menor gravedad específica y mayor absorción de agua en comparación con los áridos naturales debido a la presencia de mortero adherido y microgrietas formadas durante el proceso de trituración. Se sabe que estas características influyen significativamente en la zona de transición interfacial (ITZ) entre el árido y la pasta de cemento, afectando así al rendimiento mecánico general del hormigón de áridos reciclados.

La Tabla 2 resume las propiedades físicas medidas de RCA y RFA utilizadas en este estudio. Los resultados indican un aumento de la porosidad y la absorción de agua, lo que contribuye a una reducción de la resistencia en niveles de reemplazo más altos.

Tabla 2. Propiedades físicas y mecánicas de los áridos reciclados.

Propiedad	RFA	RCA
Gravedad específica	2.4	2.55
Absorción de agua (%)	5.5	4.5
Densidad volumétrica (kg/m <sup>3</sup> )	1400	1500
Porosidad (%)	12	9
Abrasión en Los Ángeles (%)	-	25
Módulo de finura	2.6	-

*Nota:* Estos valores reflejan las características típicas de los áridos reciclados, donde una mayor porosidad y absorción de agua se asocian con mortero adherido y defectos microestructurales.

Los áridos reciclados (tanto finos como gruesos) se obtuvieron de residuos de construcción y demolición (C&D), compuestos principalmente por materiales de hormigón triturado recogidos de actividades locales de demolición dentro de la misma región geográfica. Aunque el material no procedía de un único lugar de demolición, se tuvo cuidado para garantizar la consistencia seleccionando principalmente residuos a base de hormigón.

Los residuos recogidos fueron sometidos a una cuidadosa clasificación manual para eliminar impurezas como madera, plásticos, refuerzo de acero y otros componentes no formigones. Durante el procesamiento se minimizaron los fragmentos visibles de mampostería y materiales indeseables para asegurar que los áridos reciclados fueran predominantemente de base de hormigón.

El material procesado se trituraba y tamizaba para obtener las fracciones de tamaño requeridas para el agregado fino reciclado (RFA) y el agregado grueso reciclado (RCA). Aunque en los agregados reciclados hay pequeñas huellas de mortero adherido, se hicieron esfuerzos para mantener la consistencia en la calidad de los materiales en todas las mezclas mediante condiciones de procesamiento uniformes.

La resistencia del hormigón original asociada a los áridos reciclados oscilaba entre 25 MPa y 45 MPa, según se consideró en el programa experimental. Este enfoque controlado de selección y procesamiento aseguró características agregadas relativamente consistentes, apoyando la fiabilidad tanto de los resultados experimentales como de las predicciones de modelos de aprendizaje automático.

Como se muestra en la Tabla 3, se utilizaron diferentes cantidades de cemento, agregados naturales y reciclados, agua, superplastificante y proporciones agua-cemento para fabricar mezclas de hormigón. Los niveles de reemplazo de áridos reciclados oscilaron entre 0% y 100% tanto para agregados finos como gruesos. Las proporciones agua-cemento variaron de 0,35 a 0,55, y las resistencias del hormigón original oscilaron entre 25 MPa y 45 MPa. El diseño de la mezcla también tuvo en cuenta la absorción de agua de los áridos reciclados y sus valores de abrasión en LA, que influyen en la resistencia a la compresión. Cada mezcla se preparó en un entorno controlado por laboratorio y curó bajo condiciones estándar. La resistencia a la compresión de las mezclas durante 28 días varió entre 31,8 MPa y 45,2 MPa, ilustrando los efectos del contenido de agregados reciclados, la absorción de agua y la calidad del hormigón principal en el rendimiento mecánico. (Katz, 2003; Padmini et al., 2002)

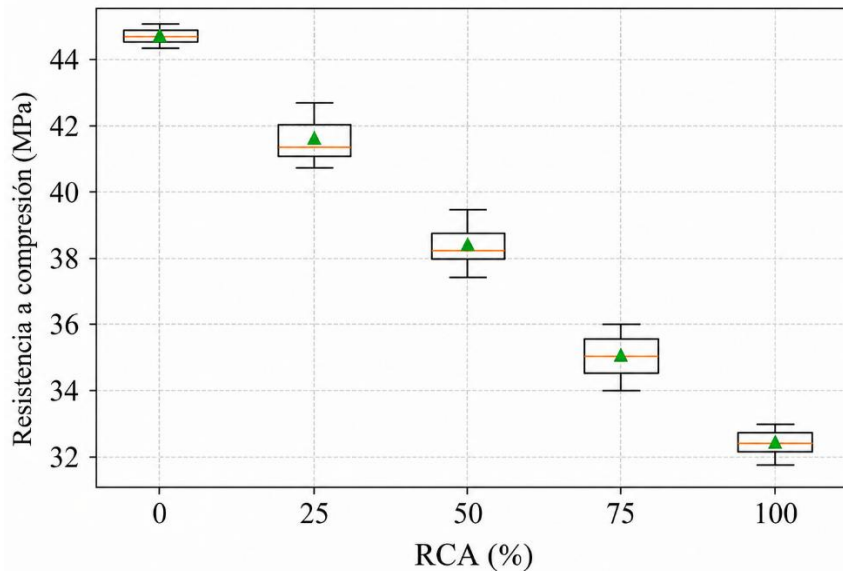
Tabla 3. Proporciones de mezcla y características de materiales de los hormigones probados.

Mezcla	Cemento (kg/m <sup>3</sup> )	Arena (kg/m <sup>3</sup> )	Bien, Agg. (kg/m <sup>3</sup> )	Reciclado Fino Agg. (kg/m <sup>3</sup> )	Groeso Agg. (kg/m <sup>3</sup> )	Groero reciclado Agg. (kg/m <sup>3</sup> )	Agua (kg/m <sup>3</sup> )	Plastificante (kg/m <sup>3</sup> )	w/c (-)	RCA %	PC	RCA WA %	LAA	CS
M1	300	650	700	0	900	0	105	1.50	0.35	0	45	2.00	18	45.20
M2	320	640	600	100	800	100	110	2.56	0.40	25	40	3.00	21	42.80
M3	340	630	550	150	750	150	115	3.40	0.40	25	35	3.50	22	41.30
M4	360	620	500	200	700	200	120	4.32	0.45	50	35	4.00	24	38.60
M5	380	610	450	250	650	250	125	5.32	0.45	50	30	4.20	25	37.90
M6	400	600	400	300	600	300	130	6.40	0.50	75	30	5.00	26	35.50
M7	420	590	350	350	550	350	135	7.56	0.50	75	28	5.50	27	34.70
M8	440	580	300	400	500	400	140	8.80	0.55	100	25	6.00	28	32.50
M9	460	570	250	450	450	450	145	8.28	0.55	100	25	6.50	29	31.80
M10	480	560	200	500	400	500	150	7.68	0.50	75	30	5.80	28	34.00
M11	500	550	150	550	350	550	155	7.00	0.45	50	35	4.50	26	37.40
M12	450	570	100	600	300	600	150	5.40	0.40	25	40	3.50	24	40.80
M13	430	580	50	650	250	650	145	4.30	0.40	25	40	3.00	23	41.20
M14	410	590	0	700	200	700	140	3.28	0.35	0	45	2.50	20	44.70
M15	390	600	100	600	250	650	130	3.90	0.40	25	38	3.00	22	42.10
M16	370	610	150	550	300	600	125	4.44	0.45	50	35	4.00	24	39.50
M17	350	620	200	500	350	550	120	4.90	0.45	50	30	4.50	26	38.20
M18	330	630	250	450	400	500	115	5.28	0.50	75	28	5.00	27	35.60
M19	310	640	300	400	450	450	110	5.58	0.55	100	25	6.00	29	33.00
M20	300	650	350	350	500	400	105	6.00	0.55	100	25	6.50	30	32.20
M21	420	600	400	300	550	350	130	5.04	0.45	50	35	4.00	25	38.80
M22	440	590	450	250	600	300	135	6.16	0.45	50	30	4.50	26	38.00
M23	460	580	500	200	650	250	140	7.36	0.50	75	30	5.00	27	36.00
M24	480	570	550	150	700	200	145	8.64	0.50	75	28	5.50	28	34.50
M25	500	560	600	100	750	150	150	10.00	0.55	100	25	6.00	29	32.80

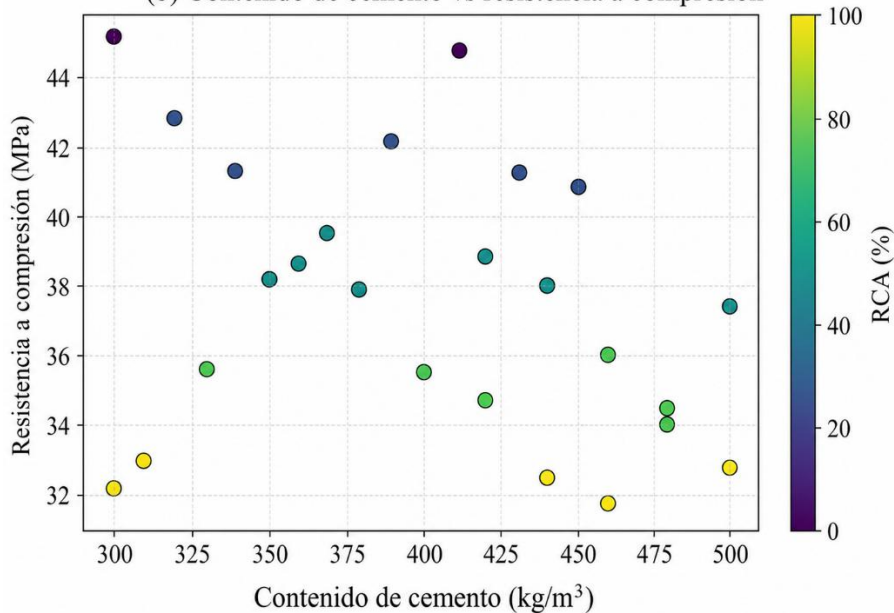
*Nota:* w/c = proporción agua-cemento; RCA = agregado grueso reciclado; RFA = agregado fino reciclado.

Para cada mezcla de hormigón, se prepararon muestras para evaluar la resistencia a compresión de 28 días siguiendo los estándares. Se fundieron cubos de dimensiones de  $150 \times 150 \times 150$  mm para cada mezcla, compactados con una mesa vibrante estándar para asegurar una densidad uniforme y cubiertos con arpillera húmeda para evitar la pérdida de humedad durante el curado inicial. Los ejemplares se sumergieron en agua a  $23 \pm 2^\circ\text{C}$  durante 28 días para lograr una hidratación completa. Los resultados demostraron una reducción gradual de la resistencia a la compresión con el aumento de la sustitución de áridos reciclados, especialmente en niveles más altos de absorción de agua, lo que pone de manifiesto la influencia de la calidad del hormigón original y las características de los áridos reciclados en el rendimiento de los RAC. (Internacional, 2024; Zain et al., 2002) (Ajdukiewicz & Kliszczewicz, 2002; Khatib, 2005) (Katz, 2003; Padmini et al., 2002)

(a) Variación de la resistencia a compresión según los niveles de RCA



(b) Contenido de cemento vs resistencia a compresión



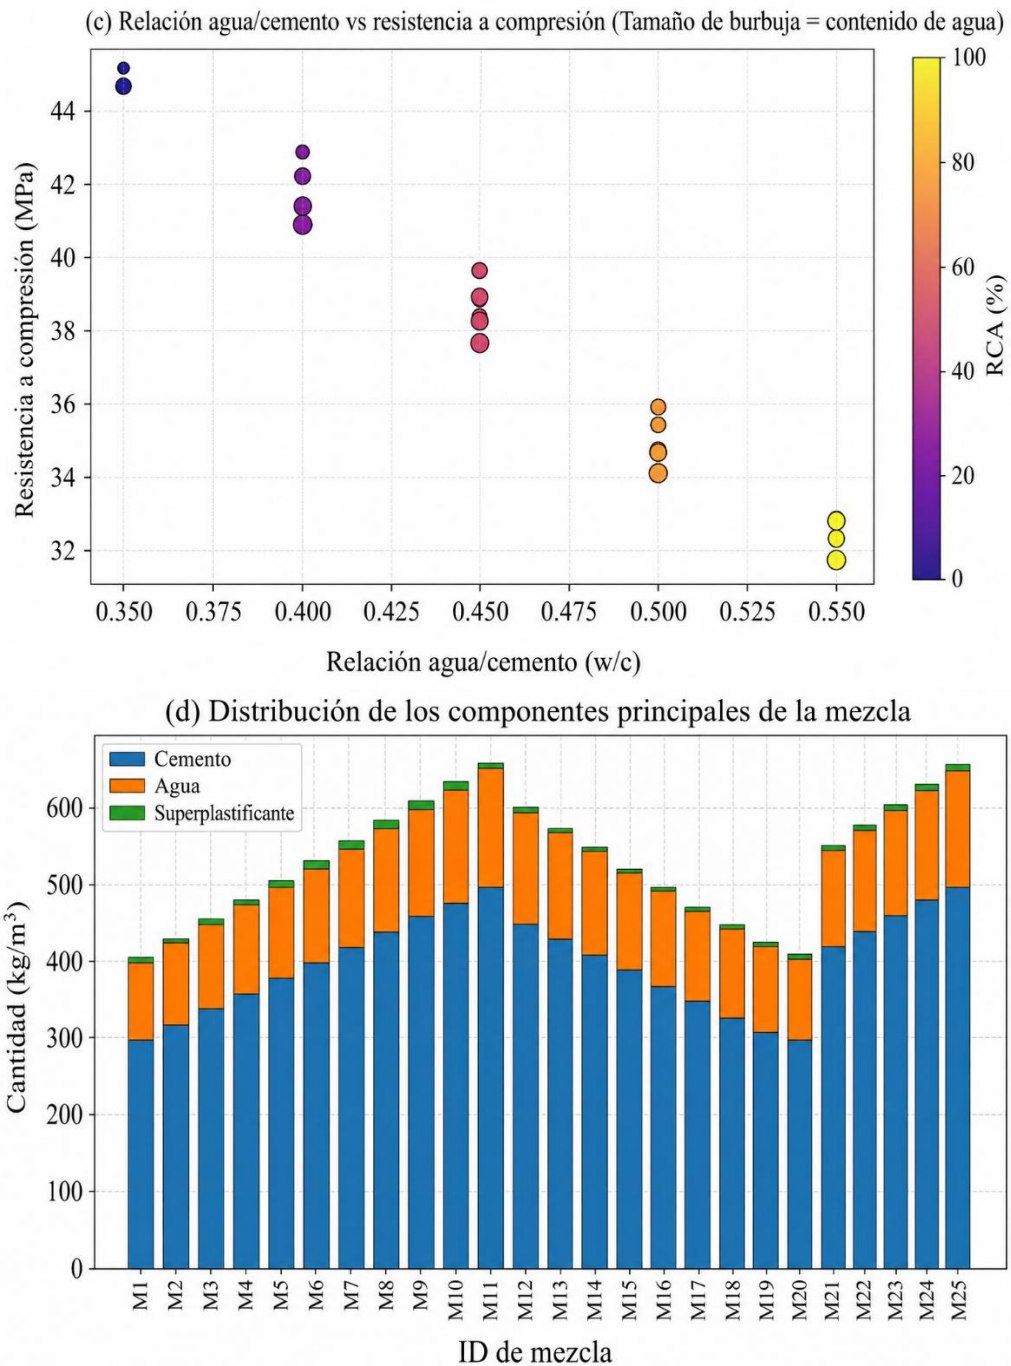


Figura 1. Visualización estadística del conjunto de datos RMC mostrando la distribución de los constituyentes clave de la mezcla y la resistencia a la compresión de los diseños de mezcla. (a) Variación de la intensidad entre niveles de RCA, (b) Contenido de cemento frente a resistencia, (c) peso y fuerza frente a resistencia, (d) Componentes de la mezcla de llaves Distribución.

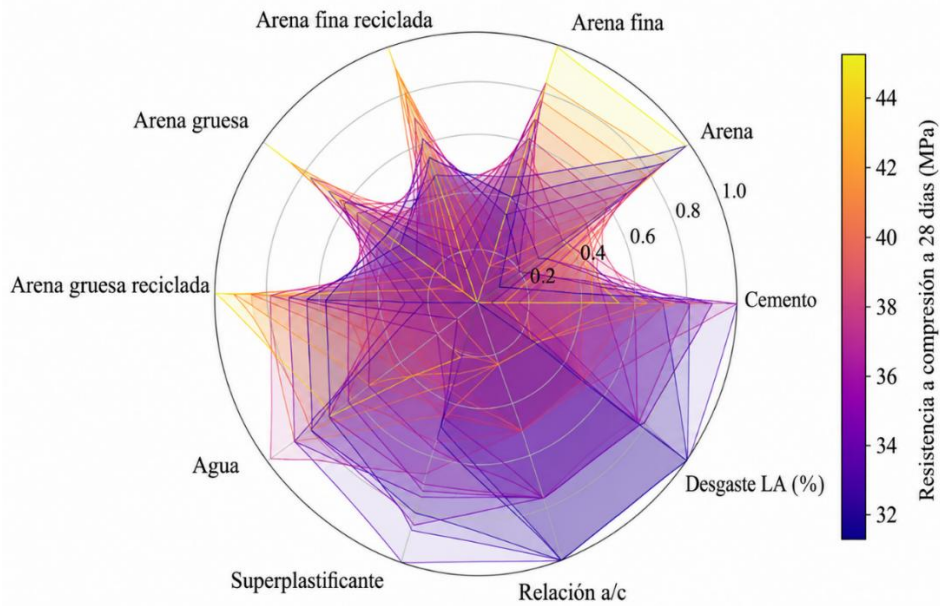


Figura 2. Gráfico radar de los parámetros normalizados de diseño de mezcla para las 25 mezclas experimentales de hormigón agregado reciclado (RAC).




Figura 3. Las coordenadas paralelas representan el conjunto de datos experimental RAC completo.

La distribución estadística de los principales componentes de la mezcla en el conjunto de datos RMC, que comprende mezclas de hormigón elaboradas con diferentes proporciones de agregados naturales y reciclados, se muestra en la Figura 1. Los diagramas de caja ilustran la variabilidad en el contenido de cemento, arena, agregados gruesos y finos, agregados reciclados, agua y plastificante, junto con las correspondientes resistencias a compresión de 28 días. La distribución de la resistencia entre los diferentes niveles de RCA muestra una reducción constante a medida que aumenta la proporción de áridos reciclados. Esta tendencia refleja la influencia del mortero adherido, una mayor porosidad y menor rigidez típicamente asociada a los áridos reciclados. La dispersión observada dentro de cada grupo RCA también indica la variabilidad introducida por los

cambios en la composición de la mezcla. La figura destaca la sensibilidad del rendimiento mecánico a la incorporación de RCA y proporciona una base estadística para la modelización predictiva posterior.

La Figura 2 muestra un gráfico de radar de las mezclas de hormigón, mostrando valores normalizados de todos los parámetros de diseño de la mezcla, incluyendo cemento, agregados naturales y reciclados, agua, plastificante, la proporción agua-cemento y contenido de RCA. Cada polígono representa una mezcla, mientras que la intensidad del color refleja la resistencia a compresión correspondiente. El gráfico ofrece una visión integrada de las interacciones multivariantes dentro del conjunto de datos y aclara cómo las variaciones en la composición agregada, la demanda de agua y el contenido de RCA se relacionan con el desarrollo de la resistencia. Antes de aplicar modelos de aprendizaje automático, esta pantalla ofrece una imagen clara de la variabilidad de los parámetros.

Un gráfico de coordenadas paralelas del conjunto de datos experimental se muestra en la Figura 3, donde una polilínea que conecta todos los parámetros de entrada representa cada mezcla. Este formato permite la comparación directa de las tendencias de los parámetros, especialmente el efecto del porcentaje de RCA, el contenido de agua y las proporciones agregadas sobre la resistencia a la compresión. La figura enfatiza las relaciones multivariantes dentro del conjunto de datos y apoya la identificación de patrones relevantes para el desarrollo del modelo y la evaluación del rendimiento.

La mayor porosidad y absorción de agua de los áridos reciclados afectan directamente a la zona de transición interfacial (ITZ), que suele ser la región más débil del hormigón. La presencia de mortero adherido y defectos microestructurales en RCA conduce a una ITZ más porosa, lo que reduce la resistencia a la unión entre el agregado y la pasta de cemento. Este fenómeno se vuelve más pronunciado en niveles de reemplazo más altos, contribuyendo a la reducción observada de la resistencia a la compresión.

### 3. MODELADO POR APRENDIZAJE AUTOMÁTICO

El conjunto de datos experimental de diseños de mezcla de hormigón se utilizó como entrada para modelado de aprendizaje automático para predecir la resistencia a la compresión a 28 días del hormigón agregado reciclado (RAC) tras el programa experimental. Se utilizaron la cantidad de cemento, las proporciones de áridos finos y gruesos naturales y reciclados, la proporción agua-cemento, la dosis de plastificante, la resistencia del hormigón principal, la absorción de agua de agregados reciclados y los valores de abrasión en Los Ángeles (LA) para definir cada mezcla. Para mejorar la robustez del conjunto de datos, se adoptó un enfoque de expansión controlada de datos introduciendo una variación limitada del  $\pm 10\%$  en parámetros seleccionados de la mezcla. Esta variación se aplicó dentro de límites realistas de ingeniería para simular pequeñas fluctuaciones que normalmente ocurren en las propiedades de los materiales y las condiciones del campo, en lugar de duplicar artificialmente puntos de datos idénticos.

A diferencia de los métodos puramente sintéticos de generación de datos, este enfoque preserva las relaciones físicas subyacentes entre variables y permite que los modelos de aprendizaje automático generalicen mejor dentro de un espacio de parámetros realista. Sin embargo, se reconoce que esta forma de aumento de datos puede introducir cierto grado de sesgo, por lo que los resultados deben interpretarse con la debida precaución. Este enfoque permitió una mejor generalización de los algoritmos de aprendizaje automático y redujo el riesgo de sobreajuste. (Farhangi et al., 2021; Jahangir et al., 2021)

Técnicas de aumento de datos más avanzadas, como la Técnica de Sobremuestreo de Minorías Sintéticas (SMOTE) o las Redes Generativas Adversariales (GANs), no se emplearon en este estudio, ya que el conjunto de datos no representa un problema de clasificación ni un escenario de datos desequilibrado. Además, el enfoque del presente trabajo está en preservar relaciones

físicamente interpretables en lugar de generar muestras completamente sintéticas. Futuros estudios podrían explorar técnicas avanzadas para mejorar aún más la generalización y robustez de los modelos.

Se implementaron nueve técnicas de aprendizaje automático para modelar la relación entre las variables de mezcla de entrada y la resistencia a la compresión. Estos incluían Regresión de Vectores de Soporte (SVR), Bosque Aleatorio (RF), K-Vecinos Más Cercanos (KNN), Aumento de Gradiente Extremo (XGBoost), Aumento de Gradiente (GB), Regresión Lineal (LR), Regresión de Lazo, Regresión de Crestas y Red Elástica (EN). Se seleccionaron modelos no lineales, como SVR, RF y métodos de conjunto (XGBoost y GB), por su capacidad para capturar interacciones complejas y no lineales entre múltiples variables, que son comunes en el RAC debido a la variabilidad en la calidad del agregado reciclado, la absorción de agua y la resistencia del hormigón principal. (Bilim, Atis, et al., 2009; Deng et al., 2018; Naderpour et al., 2018)

Aunque las propiedades físicas detalladas de agregados reciclados, como la absorción de agua y la abrasión de Los Ángeles, se incorporaron en el conjunto de datos otras características como la porosidad y la densidad, no se incluyeron explícitamente como variables de entrada independientes. Sin embargo, su influencia se refleja inherentemente en parámetros correlacionados como la absorción de agua y la resistencia del hormigón principal, que están fuertemente vinculados a la porosidad y calidad de los áridos.

Futuros estudios podrían incorporar un conjunto más amplio de propiedades físicas y microestructurales agregadas como características de entrada directa para mejorar aún más la interpretabilidad del modelo y la capacidad predictiva.

El conjunto de datos se dividió en subconjuntos de entrenamiento (80%) y de pruebas (20%) para evaluar el rendimiento predictivo. Las métricas de evaluación del modelo incluían el coeficiente de determinación ( $R^2$ ), el error absoluto medio (MAE), el error cuadrático medio (MSE), el error cuadrático medio raíz (RMSE), el error porcentual absoluto medio (MAPE) y el error de sesgo medio (MBE). SVR alcanzó la mayor precisión predictiva, con un valor  $R^2$  de 0,998, MAE de 0,008 y RMSE de 0,011, lo que indica una excelente concordancia entre los valores predichos y experimentales de resistencia a la compresión. El Bosque Aleatorio fue el segundo mejor modelo, logrando  $R^2 = 0,996$  y errores ligeramente superiores (MAE = 0,128, RMSE = 0,179). Los modelos KNN y XGBoost mostraron un rendimiento moderado con valores de  $R^2$  de 0,947 y 0,942, respectivamente, mientras que los modelos de gradiente y basados en líneas (LR, Lasso, Ridge, Elastic Net) mostraron menor precisión predictiva ( $R^2$  entre 0,842 y 0,904), lo que pone de manifiesto la superioridad de los algoritmos no lineales para este tipo de conjunto de datos. (Farhangi et al., 2021; Ghanizadeh et al., 2019)

Se realizó un análisis de importancia de características para comprender la influencia de cada variable de entrada en la resistencia a compresión del RAC. La proporción agua-cemento, el contenido de áridos gruesos reciclados y la resistencia del hormigón original fueron identificados como los parámetros más críticos que influyen en la resistencia a la compresión, mientras que la dosificación de plastificante y las proporciones de agregados finos tuvieron un efecto comparativamente menor. Este enfoque reduce la necesidad de experimentos de laboratorio prolongados guiando la optimización del diseño mixto para aplicaciones reales, además de validar los datos experimentales.

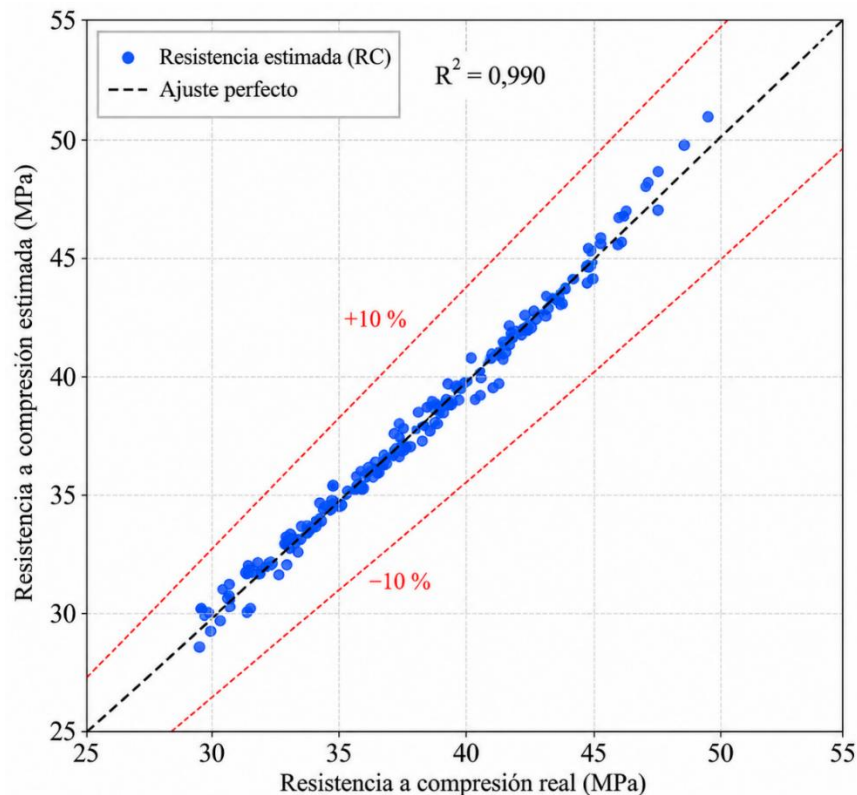


Figura 4. Resistencia a compresión predicha frente a la real de 28 días usando parámetros de entrada combinados.

La Figura 4 muestra la relación entre las resistencias de compresión predichas y medidas de 28 días obtenidas del modelo desarrollado utilizando todos los parámetros de entrada. Los puntos de datos muestran una alineación estrecha con la línea de predicción perfecta, lo que indica una fuerte concordancia entre los valores experimentales y estimados. Las bandas de desviación del  $\pm 10$  por ciento proporcionan una referencia visual clara para la precisión del modelo, con la mayoría de los puntos dentro de este rango. El alto coeficiente de determinación ( $R^2 = 0,990$ ) confirma además la fiabilidad del modelo y su capacidad para captar los factores clave que rigen el desarrollo de la resistencia.

Se crea una herramienta sólida para predecir eficazmente los atributos de los RAC combinando modelado por aprendizaje automático con datos experimentales. El enfoque minimiza el trabajo experimental intensivo en recursos, asegurando al mismo tiempo una estimación fiable y precisa de la resistencia. Estos resultados refuerzan el potencial de los métodos impulsados por IA en el diseño sostenible de hormigón, donde es necesario considerar simultáneamente múltiples niveles de áridos reciclados y cualidades variables de materiales. (Deng et al., 2018; Jahangir et al., 2021; Naderpour et al., 2018)




Figura 5. Mapa de calor de correlación que muestra las relaciones entre parámetros de mezcla de hormigón.

La Figura 5 presenta la matriz de correlación de Pearson para las variables de entrada utilizadas en el conjunto de datos de mezcla de hormigón. El mapa de calor destaca la intensidad y dirección de las relaciones lineales entre los parámetros. Se observan correlaciones positivas notables entre cemento y agua, así como entre el contenido de plastificante y la absorción de agua de RCA. En contraste, aparecen fuertes correlaciones negativas entre cemento y arena, y entre la proporción agua-cemento y el contenido de cemento. Estos patrones reflejan interacciones fundamentales dentro del diseño de la mezcla y proporcionan una guía útil para comprender las dependencias de los parámetros, mejorar las estrategias de optimización de la mezcla y apoyar la selección de características para el modelado predictivo de la resistencia a la compresión.

Este estudio utilizó una variedad de métodos de aprendizaje automático (ML) para predecir la resistencia a la compresión del hormigón de agregados reciclados (RAC). Se implementaron un total de nueve modelos, que abarcan regresión lineal, modelos lineales regularizados, modelos basados en núcleos, vecinos más cercanos, métodos basados en árboles de conjunto y enfoques de aumento de gradientes. El rendimiento predictivo de cada modelo se evaluó utilizando múltiples métricas estadísticas, incluyendo el coeficiente de determinación ( $R^2$ ), el error absoluto medio (MAE), el error cuadrático medio (MSE), el error cuadrático medio raíz (RMSE), el error porcentual absoluto medio (MAPE), el error de sesgo medio (MBE) y la estadística t. Para garantizar la comparabilidad, todos los modelos se entrenaron utilizando una división 80/20 en pruebas de tren con características numéricas estandarizadas. (Farhangi et al., 2021; Jahangir & Eidgahee, 2020)

Tabla 4. Rango de variables consideradas para la construcción del modelo.

Parámetro de entrada	Min	Max	Promedio	Desarrollo de Nivel de Edad	Varianza
Cemento (kg/m <sup>3</sup> )	300	500	401.27	61.9	3831.31
Arena (kg/m <sup>3</sup> )	550	650	599.75	28.88	834.16
Bien, Agg. (kg/m <sup>3</sup> )	0	700	337.95	187.92	35315.6
Argg fino reciclado. (kg/m <sup>3</sup> )	0	700	362.05	187.92	35315.6
Grueso Agg. (kg/m <sup>3</sup> )	200	900	515.86	188.2	35418.1
Agg grueso reciclado. (kg/m <sup>3</sup> )	0	700	384.14	188.2	35418.1
Agua (kg/m <sup>3</sup> )	105	155	130.73	14.94	223.16
Plastificante (kg/m <sup>3</sup> )	1.5	10	5.72	2.05	4.19
w/c (-)	0.3	0.35484	0.33	0.02	0
RCA (%)	0	100	56.97	30.49	929.64
Hormigón Principal (MPa)	25	45	32.49	6.09	37.07
Absorción de agua RCA (%)	2	6.5	4.52	1.25	1.56
Abrasión en Los Ángeles (%)	18	30	25.35	3.02	9.13
Resistencia a la compresión (MPa) de 28 días	28.74	49.45	37.53	4.35	18.9

El rango estadístico y la variabilidad de los parámetros de entrada utilizados para crear el modelo se resumen en la Tabla 4. Cemento, arena, áridos naturales y reciclados, agua, plastificante, relación agua-cemento, contenido RCA y características asociadas como la resistencia del hormigón principal, la absorción de agua RCA y la abrasión de Los Ángeles están todos listados en la tabla junto con su mínimo, máximo, medio, desviación estándar y varianza. Los datos destacan la amplia gama de valores considerados, reflejando la diversidad de las mezclas de hormigón. Esta caracterización exhaustiva apoya la evaluación del efecto de los parámetros y las interacciones, y ofrece una base sólida para la modelización predictiva de la resistencia a compresión a 28 días.

Aunque parámetros como la densidad y porosidad del agregado no se incluyeron explícitamente como variables de entrada independientes, su influencia se representa indirectamente mediante parámetros correlacionados como la absorción de agua de agregados reciclados, la abrasión de Los Ángeles y la resistencia del hormigón padre. Estos parámetros son ampliamente reconocidos como indicadores de la calidad del agregado, la porosidad y la integridad mecánica.

La absorción de agua refleja la estructura interna de los poros y la permeabilidad de los agregados reciclados, mientras que la abrasión en Los Ángeles ofrece una visión de su resistencia a la degradación mecánica. En conjunto, estas variables capturan las características intrínsecas de los áridos reciclados que gobiernan el comportamiento de la zona de transición interfacial (ITZ) y la resistencia general a la compresión del hormigón.

Sin embargo, se reconoce que la inclusión directa de propiedades físicas adicionales como la densidad volumétrica y la porosidad como variables de entrada independientes podría mejorar aún más la interpretabilidad y capacidad predictiva del modelo. Este aspecto se identifica como un ámbito para futuras investigaciones.

Tabla 5. Indicadores de rendimiento utilizados para evaluar los modelos de regresión.

Métrica	Fórmula	Descripción	Valor estándar/de referencia
Coefficiente de Determinación (R <sup>2</sup> )	$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2}$	Indica qué tan bien coinciden los valores predichos con los datos observados; mide el ajuste general.	0 a 1; valores más altos indican mejor ajuste (R <sup>2</sup> ≥ 0,8 considerado bueno)
Error cuadrático medio (MSE)	$MSE = \frac{1}{N} \sum (y_i - \hat{y}_i)^2$	Promedio de las diferencias al cuadrado entre valores predichos y reales.	Más cerca de 0 es mejor; No hay un estándar absoluto (depende de la escala de datos)
Error cuadrático medio raíz (RMSE)	$RMSE = \sqrt{\frac{1}{N} \sum (y_i - \hat{y}_i)^2}$	Raíz cuadrada de MSE; cuantifica la magnitud típica de los errores de predicción.	Más cerca de 0 es mejor; debe compararse en relación con el alcance del objetivo
Error absoluto medio (MAE)	$MAE = \frac{1}{N} \sum  y_i - \hat{y}_i $	Promedio de las diferencias absolutas entre valores predichos y observados.	Más cerca de 0 es mejor; Se recomienda la comparación relativa
Error porcentual absoluto medio (MAPE)	$MAPE = \frac{100}{N} \sum \left  \frac{y_i - \hat{y}_i}{y_i} \right $	Desviación porcentual media de las predicciones respecto a los valores reales.	<10% excelente, 10–20% bueno, 20–50% aceptable >50% pobre
Error de sesgo medio (MBE)	$MBE = \frac{1}{N} \sum (y_i - \hat{y}_i)$	Diferencia media con signos entre valores predichos y observados, indicando sesgo sistemático.	0 ideal; positivo indica subestimación, sobreestimación negativa
t-Estadística (t)	$t = \sqrt{\frac{(N-1)MBE^2}{RMSE^2 - MBE^2}}$	Estadística utilizada para evaluar si el sesgo medio es significativamente diferente de cero.	

*Aquí, denota el número de muestras en cada pliegue de validación cruzada. La estadística t se emplea para determinar si la diferencia media entre errores de predicción por pares es estadísticamente significativa. La notación N y  $y_i - \hat{y}_i$  se refiere a los valores observados y predichos, respectivamente.*

Las métricas estadísticas utilizadas para evaluar el rendimiento predictivo de los modelos de regresión se recopilan en la Tabla 5. Una medida global de la bondad del ajuste la proporciona el coeficiente de determinación (R<sup>2</sup>), que representa el porcentaje de varianza en la resistencia a la compresión medida capturado por las predicciones del modelo. Mientras que el error porcentual absoluto medio (MAPE) refleja desviaciones respecto a los valores observados, métricas basadas en errores como el error cuadrático medio (MSE), el error cuadrático medio (RMSE) y el error absoluto medio (MAE) miden el tamaño de los errores de predicción en términos absolutos y cuadráticos. El error de sesgo medio (MBE) se incluye para identificar tendencias sistemáticas a

la sobreestimación o subestimación. El estadístico t de muestras emparejadas se utiliza para evaluar si el sesgo medio es estadísticamente significativo. Estos indicadores son ampliamente adoptados en aplicaciones de regresión y aprendizaje automático para modelado de comportamiento de materiales y rendimiento estructural, asegurando una evaluación rigurosa e interpretable de la precisión predictiva. (Chicco & Warrens, 2021; Emmert-Streib & Dehmer, 2019; Miller y otros, 2024; Plevris et al., 2022; Steurer et al., 2021)

El proceso de aprendizaje automático utilizado para predecir la resistencia a la compresión del hormigón agregado reciclado se muestra en la Figura 6. Los parámetros de entrada y los procedimientos de preprocesamiento de datos, como la normalización y la división del conjunto de datos en subconjuntos de entrenamiento y prueba, se describen en la primera etapa. La creación de modelos predictivos y la optimización de hiperparámetros para algoritmos como regresión de vectores de soporte, bosque aleatorio, XGBoost y variaciones de regresión lineal se abordan en la segunda etapa. En el tercer paso, se utilizan métricas estadísticas como el coeficiente de determinación, el error absoluto medio y el error cuadrático medio raíz para evaluar el rendimiento del modelo, y la influencia de las características se interpreta mediante análisis basado en SHAP. La etapa final informa de la resistencia a la compresión prevista, completando un marco estructurado y transparente para la evaluación e interpretación del modelo.

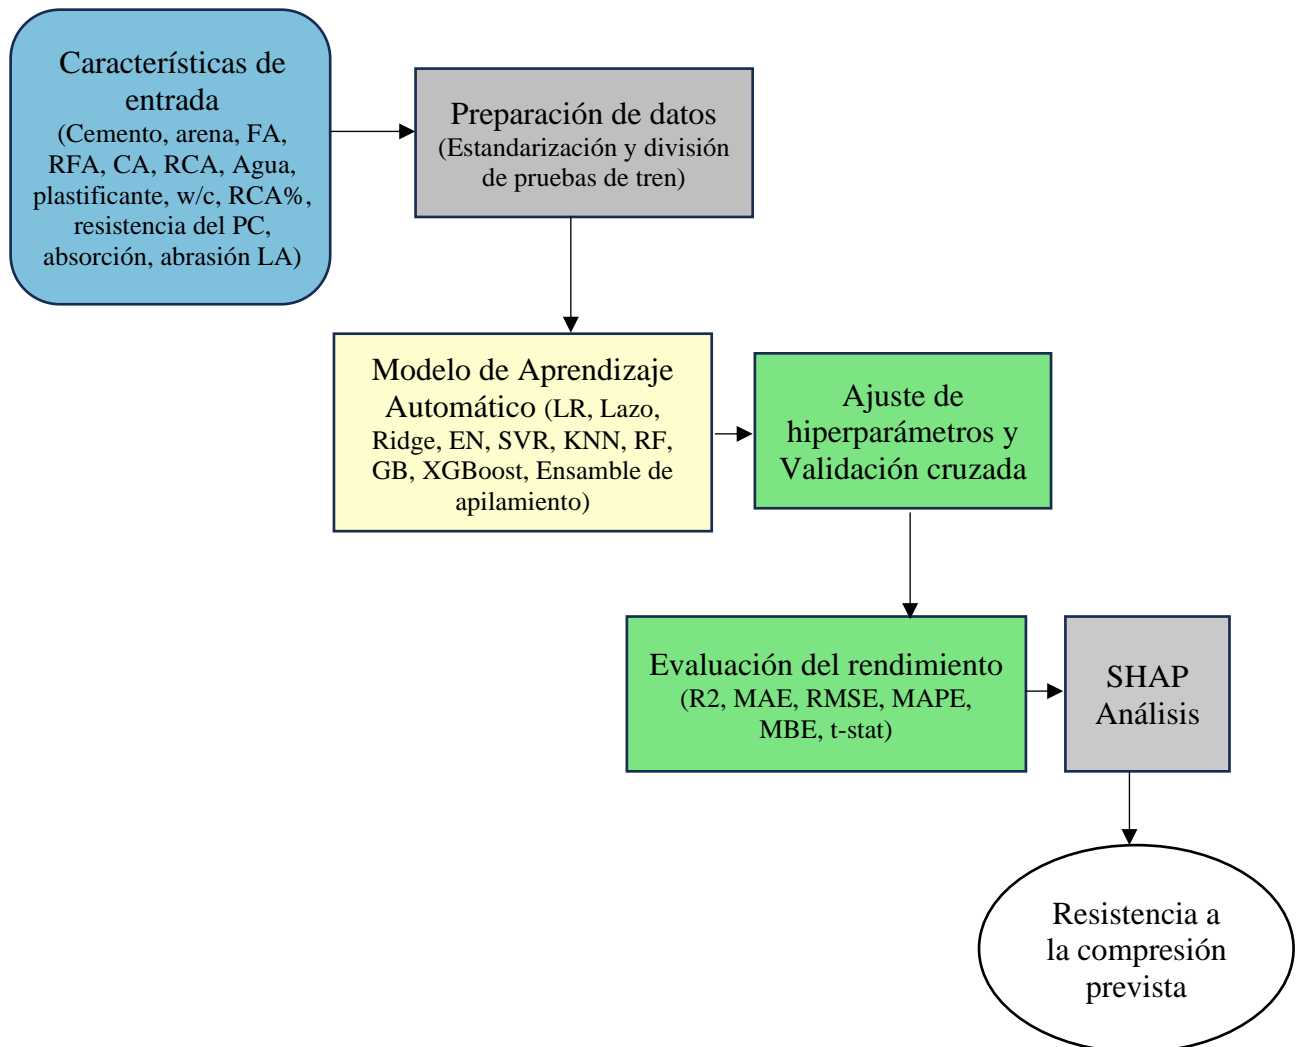


Figura 6. El flujo de trabajo del marco de aprendizaje automático para predecir la resistencia a la compresión de la resistencia a la compresión de hormigón de áridos reciclados.

### 3.1 Modelos de aprendizaje automático utilizados en este estudio

#### 3.1.1 Regresión de vectores de soporte (SVR)

La Regresión Vectorial de Soporte (SVR) se implementó utilizando un núcleo de función de base radial (RBF) para modelar dependencias no lineales entre características de entrada y resistencia a la compresión. Los hiperparámetros, incluyendo el parámetro de penalización C y la función de pérdida insensible a  $\epsilon$ , se ajustaron para minimizar el error de predicción. SVR alcanzó la mayor precisión predictiva entre los modelos individuales ( $R^2 = 0,998$ ), con errores mínimos (MAE = 0,008, RMSE = 0,011). Esto demuestra lo bien que las técnicas basadas en núcleo capturan interacciones intrincadas entre objetivos de características en RAC. (Smola & Scholkopf, 2004)

#### 3.1.2 Bosque Aleatorio

El algoritmo de Bosque Aleatorio (RF) es un método de conjunto no lineal que construye múltiples árboles de decisión sobre muestras bootstrap y predicciones agregadas para reducir la varianza y mejorar la robustez. RF utiliza muestreo bootstrap con aleatoriedad de características, con RF logrando  $R^2 = 0,996$ . Hiperparámetros, como la profundidad máxima del árbol (12) y el número de estimadores (400), se ajustaron para equilibrar sesgo y varianza. Estos conjuntos basados en árboles son muy efectivos para conjuntos de datos tabulares con características de entrada heterogéneas. (Breiman, 2001; Geurts et al., 2006)

#### 3.1.3 k-Vecinos más cercanos (KNN)

El regresor KNN estima el valor objetivo como una relación con la media de k instancias de entrenamiento más cercanas en el espacio de características. En este estudio, k se estableció en 5 y se utilizó la distancia euclidiana para identificar a los vecinos. KNN tuvo un rendimiento moderadamente bueno ( $R^2 = 0,947$ ), pero es sensible a la escalado de características y a los valores atípicos, lo que destaca la importancia del preprocesamiento y la estandarización. Su enfoque de aproximación local puede modelar eficazmente no linealidades a pequeña escala, pero tiene dificultades con datos de alta dimensión en comparación con los modelos globales de conjunto. (Altman, 1992)

#### 3.1.4 Gradient Boosting y XGBoost

El aumento de gradiente (GB) y el aumento extremo de gradiente (XGBoost) construyen árboles de decisión secuencialmente, corrigiendo cada uno los errores del anterior, para minimizar una función de pérdida especificada. GB se implementó con 400 árboles, tasa de aprendizaje 0,05 y profundidad máxima 4, mientras que XGBoost usó 600 árboles, tasa de aprendizaje 0,03, profundidad máxima 5 y submuestreo de 0,9. Se aplicaron un ajuste extensivo de hiperparámetros y una validación cruzada de 5 veces para evitar el sobreajuste y mejorar la generalización. Ambos modelos demostraron fuertes capacidades de modelado no lineal, alcanzando valores de  $R^2$  de 0,904 (GB) y 0,942 (XGBoost). (Chen & Guestrin, 2016; Friedman, 2001)

#### 3.1.5 Modelos de regresión lineal

Se asume que la variable objetivo, la resistencia a la compresión y las características de entrada tienen una relación lineal por regresión lineal (LR). Se usaron mínimos cuadrados ordinarios (OLS) para minimizar la diferencia entre los valores observados y los predichos, proporcionando una línea base sencilla para la comparación. La Regresión de Crestas, el Lazo y la Red Elástica son ejemplos de modelos lineales regularizados que se utilizaron para reducir el sobreajuste y mejorar la generalización. Lasso utiliza regularización L1 para elegir características, Ridge usa regularización L2 para penalizar coeficientes altos, y Elastic Net combina ambas penalizaciones. Estos modelos alcanzaron valores de  $R^2$  que iban de 0,842 a 0,893, lo que indica un rendimiento razonable pero una capacidad limitada para capturar interacciones no lineales inherentes a los

conjuntos de datos RAC. (Bhanja & Sengupta, 2005) (Hastie et al., 2009)

### **3.1.6 Red elástica**

La regresión Elastic Net (EN) incorpora tanto términos de regularización L1 (Lazo) como L2 (Ridge), puede elegir características mientras permanece estable cuando existe multicolinealidad entre las variables de entrada. Ajustando el parámetro de mezcla, Elastic Net puede desplazar el equilibrio entre la esparsidad L1 y la contracción L2, lo que lo hace especialmente útil cuando existen predictores correlacionados, como es común en conjuntos de datos de mezcla de hormigón donde interactúan múltiples propiedades de materiales. Para maximizar la generalización, se utilizó Elastic Net en esta investigación con una relación L1 moderada y una escala estándar de características de entrada. El modelo produjo un  $R^2$  de 0,846, ligeramente inferior al de Ridge o Lazo, lo que indica que, aunque capturó parcialmente tendencias lineales en los datos, tuvo dificultades para modelar completamente los efectos no lineales de las propiedades de los agregados reciclados, la absorción de agua y la resistencia del hormigón principal. (Zou & Hastie, 2005)  $\alpha$  (Hastie et al., 2009; Zou & Hastie, 2005)

### **3.1.7 Regresión de la dorsal**

La regresión de crestas (RR) es un método de regresión lineal regularizada que reduce los coeficientes de regresión para evitar sobreajustes y mejorar la generalización añadiendo un componente de penalización L2 a la función de coste estándar de mínimos cuadrados. Este enfoque funciona bien cuando los predictores muestran una fuerte correlación, porque ayuda a controlar la varianza manteniendo todas las variables en el modelo. En el presente estudio, se utilizó la regresión de crestas para estimar la resistencia a la compresión de 28 días del hormigón de agregados reciclados, y todas las características de entrada se estandarizaron para mantener una influencia uniforme entre las variables. El modelo alcanzó un  $R^2$  de 0,842, lo que indica un rendimiento predictivo moderado. Aunque Ridge gestionó eficazmente la multicolinealidad entre parámetros de mezcla, como la relación agua-cemento, el contenido de agregados reciclados y las propiedades del agregado, estuvo limitado a la hora de capturar las interacciones no lineales inherentes a los conjuntos de datos RAC, en comparación con modelos basados en conjunto o núcleo. (Hoerl & Kennard, 1970) (Hastie et al., 2009; Hoerl & Kennard, 1970)

### **3.1.8 Modelo de Conjunto de Apilamiento**

Para aprovechar las fortalezas complementarias de los modelos individuales, se implementó un conjunto de apilamiento, combinando los regresores de mejor rendimiento. En el apilamiento, los aprendices base generan predicciones que sirven como entradas para un meta-aprendiz, optimizando la precisión de la salida final. El conjunto de apilamiento logró una precisión predictiva casi perfecta ( $R^2 = 0,999$ ), superando significativamente a los modelos individuales en todas las métricas. Esto sugiere que las interacciones complejas entre los factores de mezcla y la resistencia a la compresión pueden capturarse eficientemente integrando modelos heterogéneos. (Wolpert, 1992; J. Zhang et al., 2022)

### **3.1.9 Ajuste de hiperparámetros y validación cruzada**

Se usó la búsqueda en cuadrícula para optimizar hiperparámetros en todos los modelos de aprendizaje automático, y se empleó la validación cruzada para asegurar la robustez del modelo. Parámetros como la tasa de aprendizaje, el número de estimadores, la profundidad máxima, los coeficientes de regularización y el número de vecinos se ajustaron sistemáticamente para minimizar los errores de validación. La validación cruzada permitió identificar comportamientos de subajuste o sobreajuste, asegurando predicciones generalizables. Para equilibrar con éxito el sesgo y la varianza, se utilizaron criterios de parada temprana para los modelos de impulso y así detener el entrenamiento cuando no se observaba mejora. (Chen & Guestrin, 2016; Hastie et al.,

2009)

Aunque las redes neuronales artificiales (RNA) y otras arquitecturas de aprendizaje profundo, como las redes de función de base radial, han demostrado un fuerte rendimiento en la predicción de propiedades concretas, no se priorizaron en el presente estudio debido al tamaño relativamente limitado y la naturaleza estructurada del conjunto de datos experimental.

Los modelos de aprendizaje profundo generalmente requieren conjuntos de datos grandes y diversos para lograr una generalización fiable y evitar el sobreajuste. En cambio, el estudio actual se centra en un conjunto de datos experimental controlado con parámetros de entrada bien definidos, donde se sabe que modelos clásicos de aprendizaje automático como la regresión de vectores de soporte y métodos de conjunto (Random Forest, Gradient Boosting) funcionan eficazmente.

Además, los modelos seleccionados ofrecen mejor interpretabilidad y eficiencia computacional, permitiendo una visión más clara de la influencia de los parámetros de diseño en mezcla en la resistencia a la compresión. Esto está alineado con el objetivo del estudio no solo de lograr predicciones precisas, sino también de comprender el comportamiento subyacente del material.

No obstante, se reconoce el potencial de los enfoques de RNA y aprendizaje profundo, y futuros trabajos podrían explorar su aplicación utilizando conjuntos de datos más grandes y diversos.

#### 4. DESCRIPCIÓN Y ANÁLISIS DEL CONJUNTO DE DATOS

Para el estudio actual, se utilizó un conjunto de datos completo que comprende 1.125 muestras, combinando 25 mezclas experimentales de hormigón replicadas 45 veces con una variación aleatoria del  $\pm 10\%$  para capturar la variabilidad en los parámetros de mezcla y las condiciones de medición. Este método garantiza un conjunto de datos robusto y diverso adecuado para usos en aprendizaje automático. El conjunto de datos incluye 13 características de entrada: cemento, arena natural, agregado fino (FA), agregado fino reciclado (RFA), agregado grueso (CA), agregado grueso reciclado (RCA), agua, superplastificante, relación agua/cemento (p/c), porcentaje de reemplazo de RCA, resistencia del hormigón principal, absorción de agua RCA y valores de abrasión en Los Ángeles (LA). La variable objetivo es la resistencia a la compresión (CS) de 28 días del hormigón de agregados reciclados. (Goodfellow et al., 2016; Naderpour et al., 2018) Para describir el conjunto de datos, se calcularon estadísticas descriptivas para cada parámetro, incluyendo mínimo, máximo, media, desviación estándar, asimetría y kurtosis. El cemento, los agregados finos y gruesos, y el agua mostraron una variación moderada entre mezclas, mientras que el contenido de RCA, la absorción de agua de RCA y la abrasión de LA mostraron una mayor variabilidad debido a diferencias en las propiedades de materiales reciclados. La asimetría de cada variable indicaba la asimetría en la distribución de los datos: se detectó un sesgo positivo para la absorción de agua y el contenido de RFA de RCA, lo que sugiere una frecuencia más alta de valores más bajos, mientras que el sesgo negativo apareció en agregados gruesos naturales y contenido de cemento, reflejando un agrupamiento en valores más altos. El análisis de kurtosis reveló valores picos relativamente altos para superplastificantes y RCA, destacando la distribución concentrada de aditivos específicos en mezclas seleccionadas. Estos datos estadísticos confirman que el conjunto de datos captura adecuadamente variaciones tanto en materiales naturales como reciclados, permitiendo un modelado fiable por aprendizaje automático. (Field, 2013) (Jahangir & Eidgahee, 2020)

El conjunto de datos muestra suficiente variabilidad, tamaño de muestra adecuado y una proporción equilibrada de características de entrada respecto a observaciones, lo que lo hace adecuado para la predicción basada en aprendizaje automático de la resistencia a compresión del RAC. Para proporcionar tanto rigor experimental como relevancia práctica para el diseño sostenible del hormigón, la combinación de estadística descriptiva, visualizaciones y análisis de correlación proporciona una base sólida para futuros procedimientos de modelado y selección de

características. (Bilim, Ozbakkaloglu, et al., 2009; Naderpour et al., 2018)

#### 4.1 Evaluación del rendimiento de los modelos

Utilizando el conjunto de datos experimental de mezclas de hormigón y sus réplicas ampliadas, el trabajo actual empleó aprendizaje automático y modelos de regresión múltiple para predecir la resistencia a la compresión de 28 días del hormigón agregado reciclado (RAC). Los modelos evaluados incluyen LR, Ridge, Lasso, EN, SVR, KNN, RF, GB y XG Boost. Se utilizaron varios indicadores para evaluar el rendimiento del modelo, incluyendo el coeficiente de determinación ( $R^2$ ), el error absoluto medio (MAE), el error cuadrático medio (MSE), el error cuadrático medio (RMSE), el error porcentual absoluto medio (MAPE), el error de sesgo medio (MBE) y la estadística t, proporcionando una comprensión completa de la precisión predictiva y el sesgo. (Farhangi et al., 2021; Jahangir & Eidgahee, 2020)

La regresión lineal (LR) asume que las variables de entrada tienen una relación lineal con la resistencia a la compresión. Aunque es fácil de entender y aplicar, LR no representa el comportamiento no lineal observado en el hormigón de áridos reciclados, donde factores como la proporción de reemplazo, la absorción de agua y la resistencia del hormigón original interactúan de formas más complejas. En este estudio, LR logró un  $R^2$  de 0,893 con un MAE de 0,346, lo que indica un rendimiento predictivo moderado, pero limitaciones en el manejo de patrones no lineales complejos. (Bhanja & Sengupta, 2005)

La Figura 7 presenta la fuerte capacidad del modelo de regresión lineal para predecir la resistencia a la compresión de 28 días del hormigón de agregados reciclados. Alcanza un valor  $R^2$  de 0,893, junto con un bajo error absoluto medio y un error de sesgo medio, demostrando una coincidencia cercana entre los valores reales y predichos de fuerza. El panel (a) muestra la comparación entre valores reales y predichos, con la mayoría de los datos dentro de los límites de desviación del  $\pm 20\%$  por ciento. El panel (b) muestra la superficie de error de predicción tridimensional, que ofrece una visión general de la distribución de los residuos en el conjunto de datos y ayuda a identificar posibles patrones o desviaciones respecto a las suposiciones del modelo.

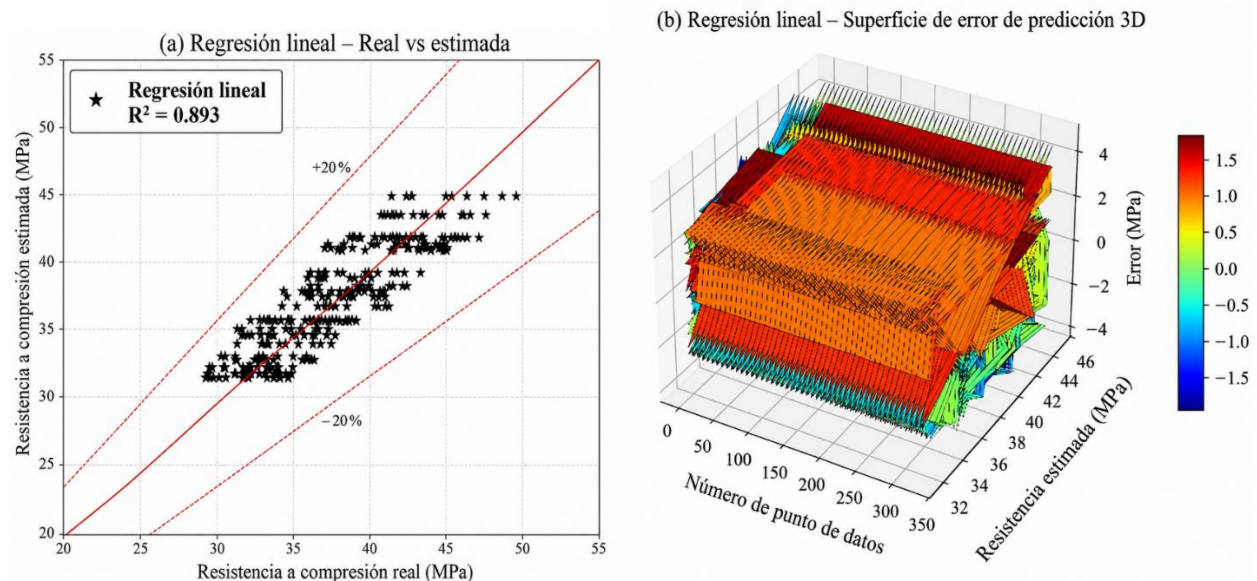


Figura 7. Rendimiento del modelo de regresión lineal para predecir la resistencia a la compresión de hormigón a 28 días. (a) Gráfico de dispersión de la resistencia a compresión real frente a la predicha, (b) gráfico de superficie 3D que muestre la distribución de los errores de predicción entre todos los puntos de datos.

La regresión de crestas amplía la LR incorporando regularización L2, que penaliza los coeficientes

altos para reducir el sobreajuste y mejorar la generalización. Ridge logró un  $R^2$  de 0,842 y un RMSE de 0,575. Aunque es ligeramente mejor manejando la multicolinealidad que LR, Ridge aún tuvo dificultades para modelar las dependencias no lineales entre las propiedades de agregados reciclados y la resistencia a la compresión. (Hoerl & Kennard, 1970)

La Figura 8 muestra cómo se comportó el modelo de regresión de crestas en la previsión de la resistencia a la compresión a 28 días del hormigón agregado reciclado. El modelo alcanza un coeficiente de determinación de 0,842, lo que indica un nivel fiable de precisión predictiva. El panel (a) compara las fortalezas previstas y medidas, con la mayoría de los puntos de datos situados dentro de la banda de desviación del  $\pm 20$  por ciento. El panel (b) ilustra la superficie de error tridimensional, proporcionando una visión clara de la distribución residual a lo largo del conjunto de datos y demostrando el comportamiento consistente del modelo bajo condiciones de entrada variables.

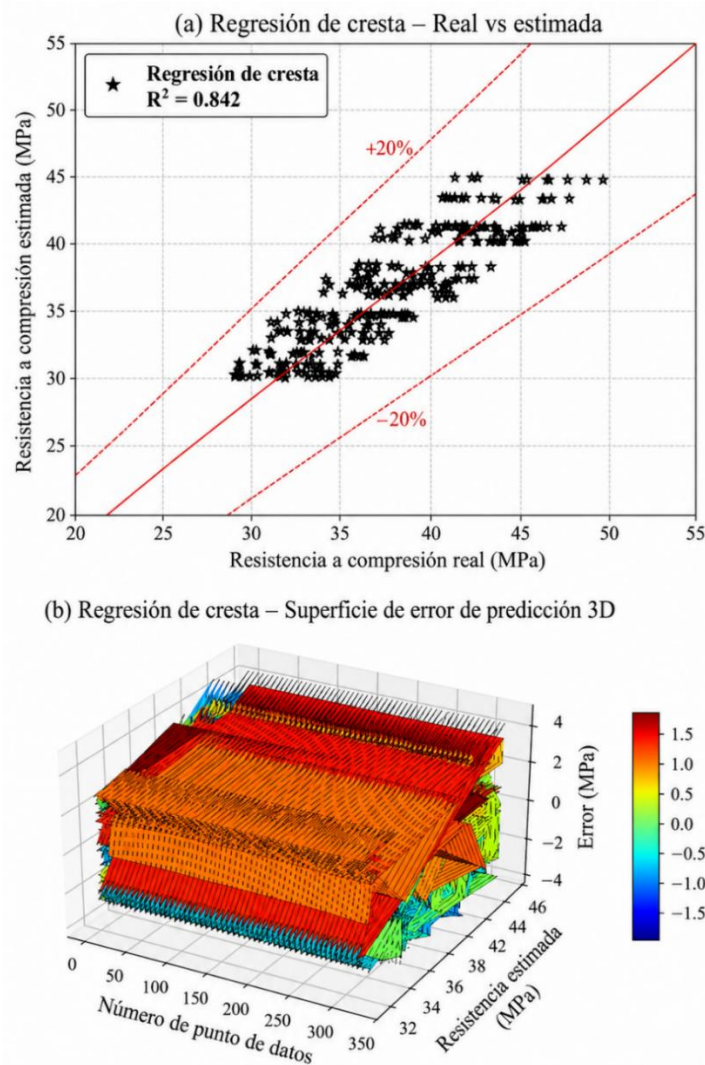


Figura 8. Rendimiento del modelo de regresión de crestas para predecir la resistencia a la compresión del hormigón a 28 días. (a) Gráfico de dispersión de la resistencia a compresión real frente a la predicha, (b) gráfico de superficie 3D que muestre la distribución de los errores de predicción entre todos los puntos de datos.

La regresión de lazo utiliza regularización L1 para imponer la esparsidad, realizando eficazmente la selección de características. Lasso produjo un  $R^2$  de 0,879 y un EMA inferior de 0,364, lo que

destaca su capacidad para enfatizar las variables más influyentes, como la proporción agua-cemento, el contenido de RCA y la abrasión de LA. Sin embargo, el marco lineal limita su capacidad para capturar completamente interacciones complejas entre parámetros de mezcla. (Hastie et al., 2009)

La Figura 9 presenta los resultados de predicción del modelo de regresión de Lasso para evaluar la resistencia a la compresión a 28 días del hormigón agregado reciclado. El panel (a) muestra la comparación entre los valores medidos y los predichos, con la mayoría de los puntos de datos situándose dentro del  $\pm 20$  por ciento de las fortalezas reales, lo que indica un fuerte acuerdo. El panel (b) presenta la superficie de error tridimensional, destacando la distribución de los residuos y confirmando un sesgo sistemático mínimo en las predicciones del modelo. El modelo alcanza un coeficiente de determinación de 0,879, junto con métricas de error bajas (MAE = 0,364 MPa, MSE = 0,218 MPa<sup>2</sup>, RMSE = 0,467 MPa, MAPE = 0,987%, MBE = 0,018), demostrando su fiabilidad para una estimación precisa de la resistencia a la compresión.

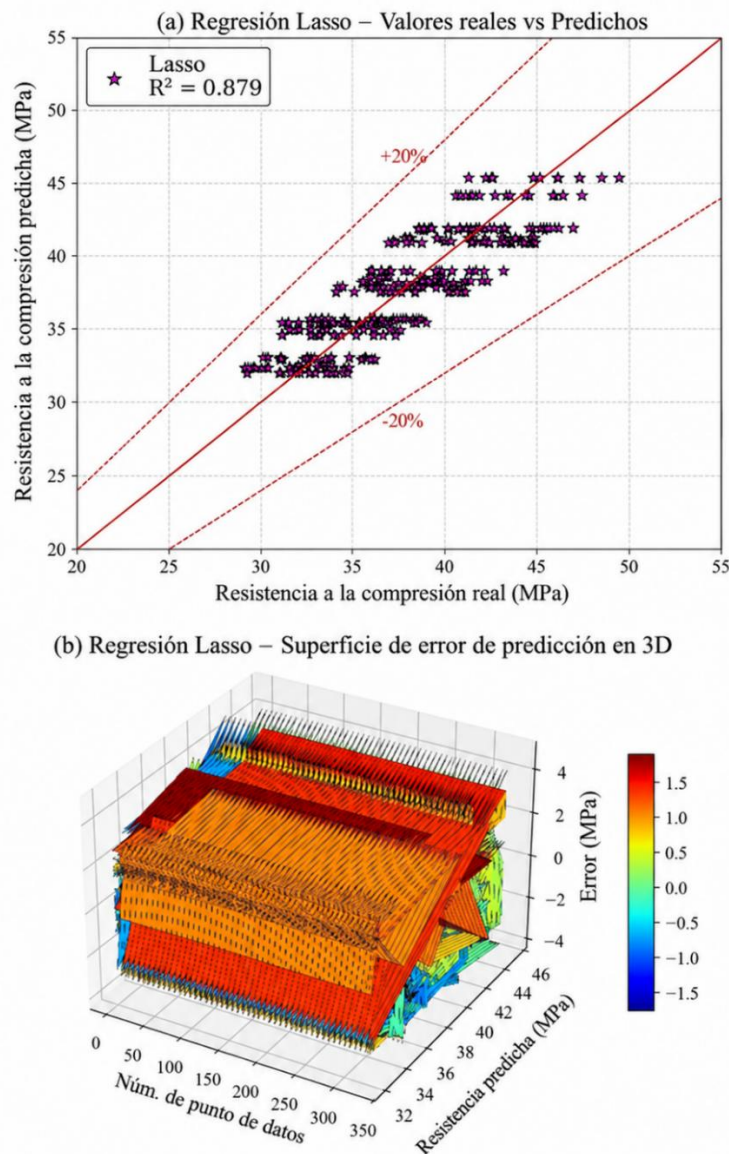


Figura 9. Rendimiento del modelo de regresión de lazo para predecir la resistencia a la compresión de hormigón a 28 días. (a) Gráfico de dispersión de la resistencia a compresión real frente a la predicha, (b) gráfico de superficie 3D que muestre la distribución de los errores de predicción entre todos los puntos de datos.

La Red Elástica (EN) combina penalizaciones de L1 y L2, selección de características y contracción de coeficientes. EN logró un  $R^2$  de 0,846, ofreciendo una generalización ligeramente mejorada en comparación con Ridge pero con un rendimiento inferior en comparación con enfoques de conjunto y no lineales. Su rendimiento sugiere que, aunque la regularización lineal puede mejorar la estabilidad, las interacciones no lineales aún requieren un modelado más sofisticado. (Zou & Hastie, 2005)

La Figura 10 muestra qué tan bien predice el modelo de regresión neta elástica la resistencia a la compresión a 28 días del hormigón de agregados reciclados. El panel (a) muestra la relación entre las fortalezas medidas y predichas, con la mayoría de los datos situados dentro del rango de desviación del  $\pm 20$  por ciento, lo que indica un fuerte nivel de concordancia. El panel (b) representa la superficie de error tridimensional, proporcionando una visión detallada de la distribución residual entre las muestras de prueba. El modelo proporciona un coeficiente de determinación de 0,846 y un bajo error medio de sesgo, demostrando una precisión predictiva sustancial y una desviación sistemática mínima. Estos resultados respaldan la idoneidad del enfoque de red elástica para conjuntos de datos que involucran múltiples variables de entrada correlacionadas.

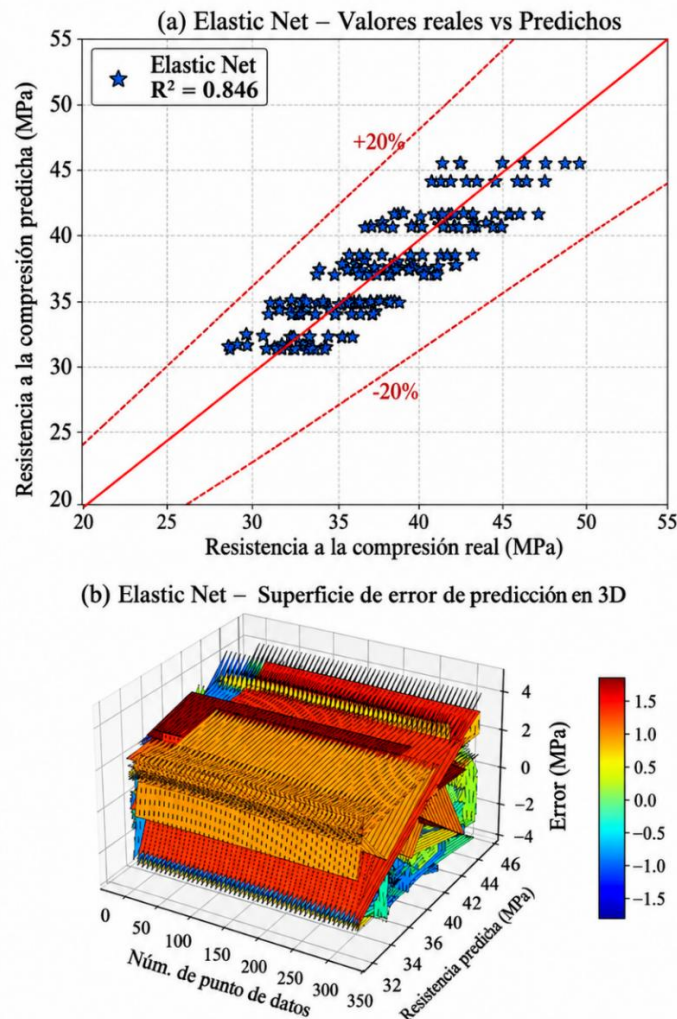


Figura 10. Rendimiento del modelo Elastic Net para predecir la resistencia a la compresión del hormigón a 28 días. (a) Gráfico de dispersión de la resistencia a compresión real frente a la predicha, (b) gráfico de superficie 3D que muestre la distribución de los errores de predicción entre todos los puntos de datos.

La regresión de vectores de soporte (SVR) emplea un enfoque basado en núcleos para capturar relaciones no lineales entre variables de entrada y resistencia a la compresión del hormigón. Con un valor  $R^2$  de 0,998, MAE de 0,008 y RMSE de 0,011, SVR superó a todos los modelos lineales, reflejando con precisión los efectos del reemplazo de RCA, la absorción de agua y la resistencia del hormigón padre. La optimización de hiperparámetros del tipo kernel, el parámetro de penalización (C) y el margen épsilon fue fundamental para optimizar el rendimiento SVR. (Smola & Scholkopf, 2004)

La Figura 11 muestra qué tan bien predice el modelo de regresión de vectores de soporte la resistencia a compresión a 28 días del hormigón de agregados reciclados. El panel (a) muestra una correspondencia estrecha entre los valores medidos y los predichos, con los puntos de datos concentrados dentro de los límites de desviación del  $\pm 20$  por ciento, lo que indica un alto nivel de precisión predictiva. El panel (b) muestra la superficie de error tridimensional, que ilustra los residuos uniformes y mínimos en todo el conjunto de datos. El modelo alcanza un coeficiente de determinación de 0,998 y presenta un error de sesgo medio despreciable, junto con errores cuadráticos absolutos y cuadráticos medios de raíz muy bajos, lo que confirma su capacidad para capturar de forma fiable la variación en la resistencia a la compresión.

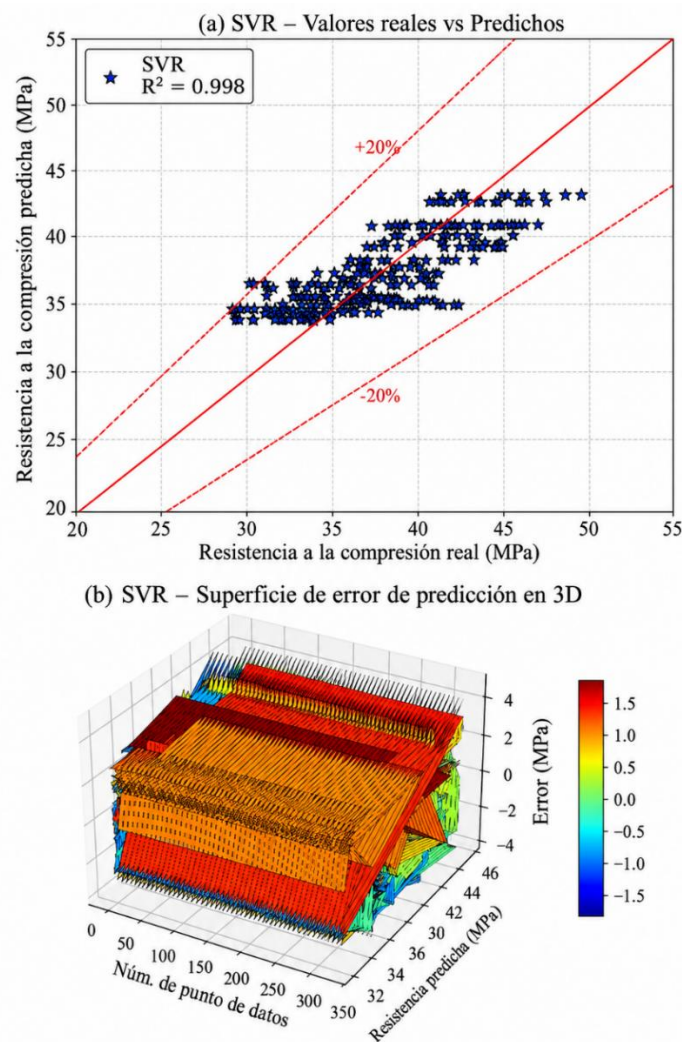


Figura 11. Soporte el rendimiento del modelo de regresión vectorial para predecir la resistencia a la compresión del hormigón a 28 días. (a) Gráfico de dispersión de la resistencia a compresión real frente a la predicha, (b) gráfico de superficie 3D que muestra la distribución de los errores de predicción entre todos los puntos de datos.

K-Nearest Neighbors (KNN) es un enfoque no paramétrico que predice los valores objetivo basándose en la similitud con puntos de datos cercanos. KNN logró un  $R^2$  de 0,947, demostrando un rendimiento sólido, pero ligeramente inferior al SVR. El modelo capturó eficazmente patrones locales en el conjunto de datos, particularmente variaciones en los porcentajes de RCA y en las proporciones de cemento agua, aunque es sensible a los valores atípicos y a los espacios de alta dimensión. (Altman, 1992)

La Figura 12 muestra cómo el modelo de los k vecinos más cercanos se desempeñó al predecir la resistencia a la compresión a 28 días del hormigón agregado reciclado. El panel (a) muestra la relación entre los valores medidos y los predichos, con la mayoría de los puntos de datos situados dentro de los límites de desviación del  $\pm 20$  por ciento, lo que indica un acuerdo fiable. El panel (b) presenta la superficie de error tridimensional, proporcionando una visión general de la distribución residual a lo largo del conjunto de datos y demostrando el comportamiento predictivo robusto del modelo con desviación mínima.

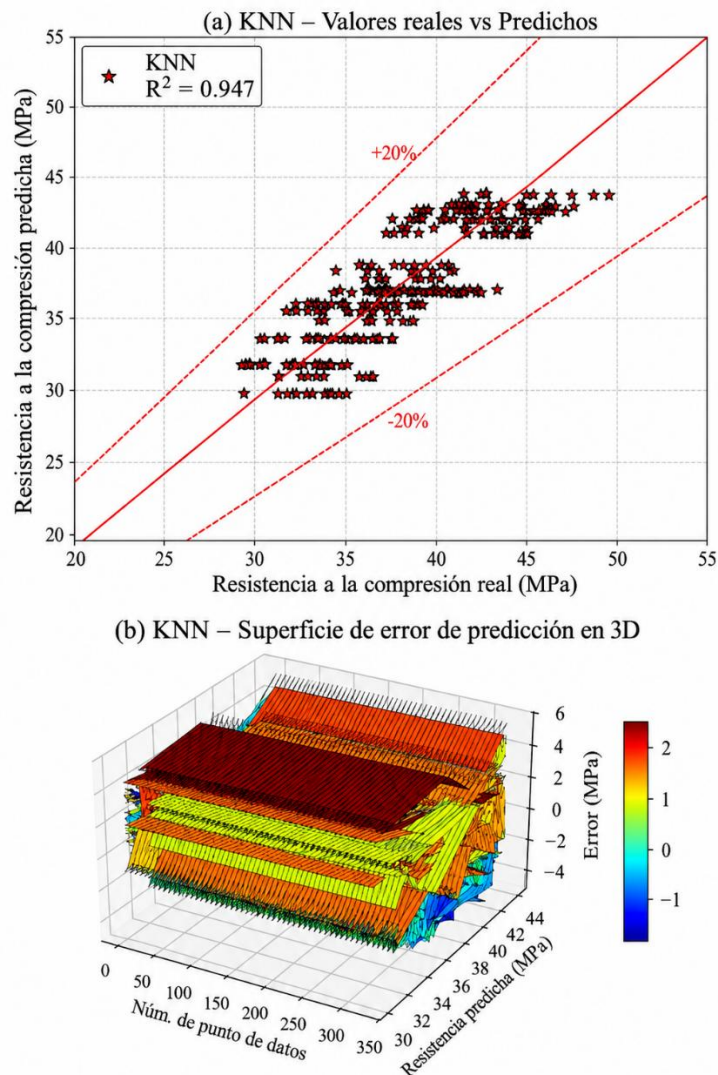


Figura 12. El rendimiento del modelo K-Nearest Neighbors para predecir la resistencia a la compresión del hormigón a 28 días. (a) Gráfico de dispersión de la resistencia a compresión real frente a la predicha, (b) gráfico de superficie 3D que muestre la distribución de los errores de predicción entre todos los puntos de datos.

El Bosque Aleatorio (RF) es un método basado en árboles de conjunto que promedia varios árboles

de decisión para reducir la varianza y mejorar la generalización. RF logró un  $R^2$  de 0,996 con MAE y MSE bajas, demostrando robustez en el manejo de multicolinealidad e interacciones no lineales entre parámetros de mezcla. (Breiman, 2001)

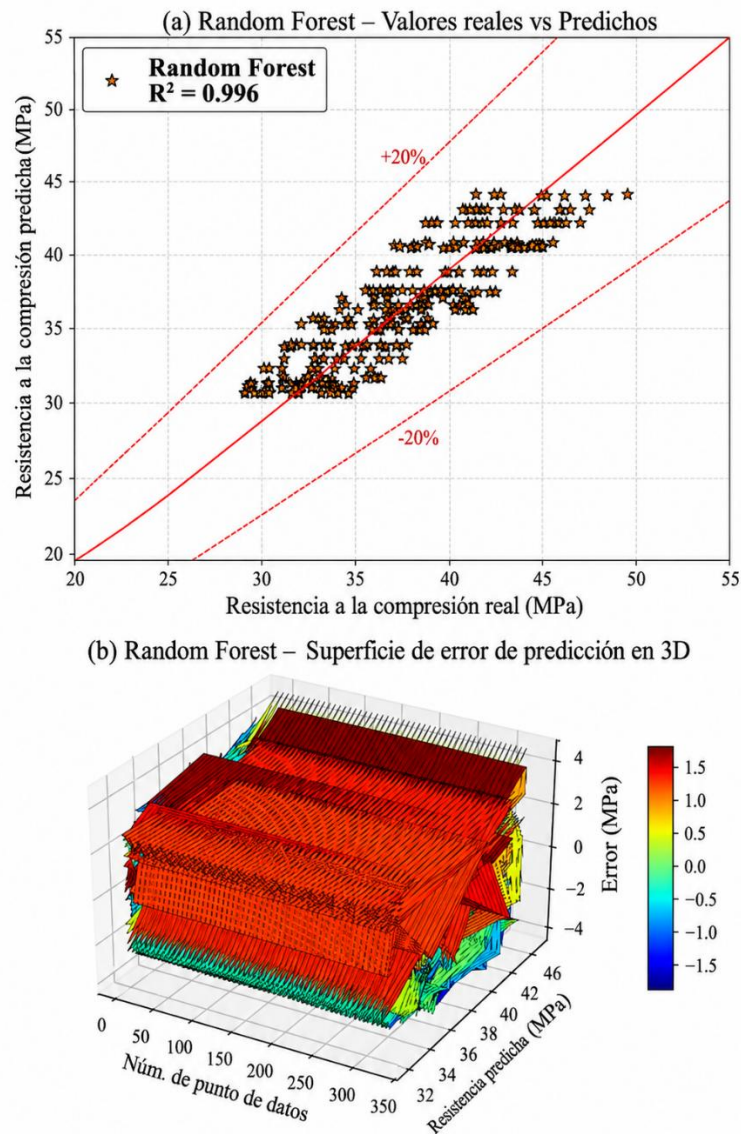


Figura 13. Rendimiento del modelo Random Forest para predecir la resistencia a la compresión del hormigón a 28 días. (a) Gráfico de dispersión de la resistencia a compresión real frente a la predicha, (b) gráfico de superficie 3D que muestre la distribución de los errores de predicción entre todos los puntos de datos.

La capacidad predictiva del modelo de bosque aleatorio para predecir la resistencia a la compresión a 28 días del hormigón de agregados reciclados se ilustra en la Figura 13. El panel (a) muestra la comparación entre los valores medidos y los predichos, con la mayoría de los puntos situados dentro del rango de desviación del  $\pm 20$  por ciento, lo que indica una fuerte precisión predictiva. El panel (b) muestra la superficie de error tridimensional, destacando los residuos consistentemente bajos en todo el conjunto de datos. El modelo alcanza un coeficiente de determinación de 0,996 y métricas de error bajas, lo que confirma su fiabilidad y idoneidad para una predicción robusta de la resistencia a la compresión del hormigón.

El aumento de gradiente (GB) construye árboles secuencialmente sobre errores residuales de árboles previos para minimizar el sesgo de forma iterativa. GB proporcionó un  $R^2$  de 0,904,

Previsión impulsada por IA y evaluación en laboratorio de la resistencia a la compresión en hormigón agregado reciclado.

mostrando buena capacidad predictiva, pero el rendimiento fue ligeramente inferior al RF debido a la sensibilidad a ajustes de hiperparámetros como la tasa de aprendizaje, la profundidad del árbol y el número de estimadores. (Friedman, 2001)

La Figura 14 muestra qué tan bien predice el modelo de aumento de gradiente la resistencia a la compresión de 28 días del hormigón agregado reciclado. El panel (a) muestra la comparación entre los valores medidos y los predichos, con la mayoría de los puntos situados dentro del rango de desviación del  $\pm 20$  por ciento, lo que indica una fuerte coincidencia. El panel (b) representa la superficie de error tridimensional, destacando la magnitud y distribución de los residuos, que son predominantemente bajos y distribuidos uniformemente en todo el conjunto de datos de prueba. Estas observaciones confirman la fiabilidad y precisión del modelo para predecir la resistencia a la compresión del hormigón.

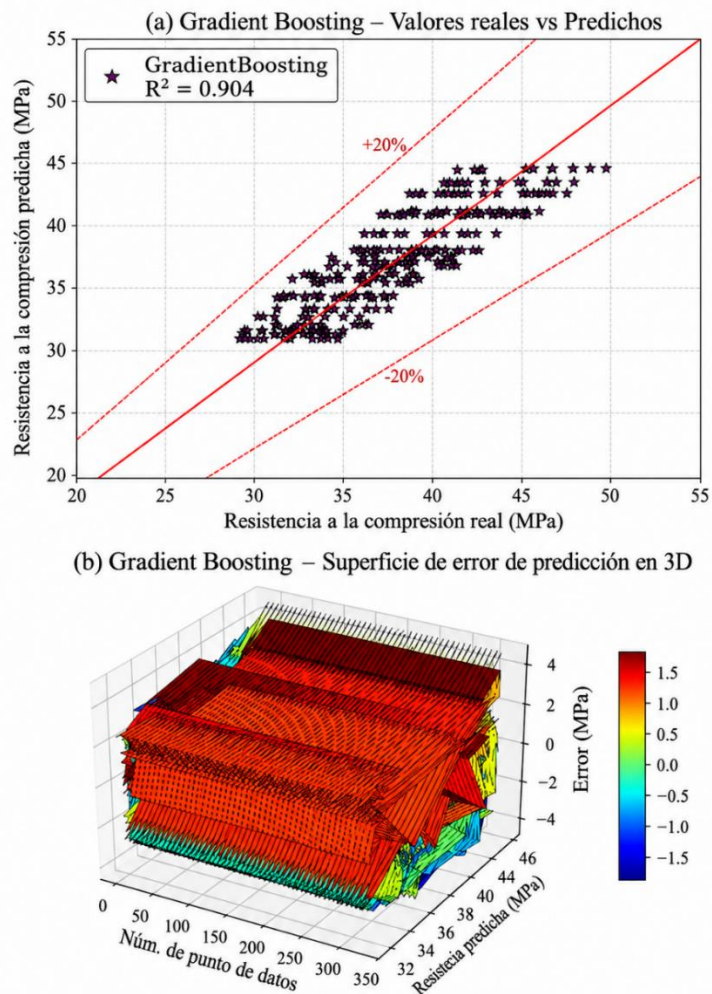


Figura 14. Rendimiento del modelo de aumento de gradiente para predecir la resistencia a compresión de hormigón a 28 días. (a) Gráfico de dispersión de la resistencia a compresión real frente a la predicha, (b) gráfico de superficie 3D que muestre la distribución de los errores de predicción entre todos los puntos de datos.

XGBoost, una implementación de aumento de gradiente altamente eficiente, obtuvo un R<sup>2</sup> de 0,942, un MAE de 0,186 y un RMSE de 0,248. XGBoost gestionaba eficazmente dependencias no lineales y características de entrada de alta dimensión como la absorción de agua RCA, la abrasión de LA y el contenido de cemento, manteniendo la eficiencia computacional. (Chen & Guestrin, 2016)

La Figura 15 muestra cómo se desempeñó el modelo XGBoost en la estimación de la resistencia a

Previsión impulsada por IA y evaluación en laboratorio de la resistencia a la compresión en hormigón agregado reciclado.

la compresión a 28 días del hormigón agregado reciclado. En el panel (a), los valores predichos siguen de cerca las fortalezas medidas, con la mayoría de los puntos situándose dentro del  $\pm 20$  por ciento de la línea ideal, lo que indica una alta precisión predictiva. El panel (b) presenta la superficie de error tridimensional, mostrando la distribución de los residuos a lo largo del conjunto de datos y destacando las desviaciones generalmente pequeñas. El modelo logra un alto coeficiente de determinación ( $R^2 = 0,942$ ) y métricas de error bajas (MAE = 0,186 MPa, RMSE = 0,248 MPa), lo que confirma su fiabilidad y efectividad para la predicción de la resistencia.

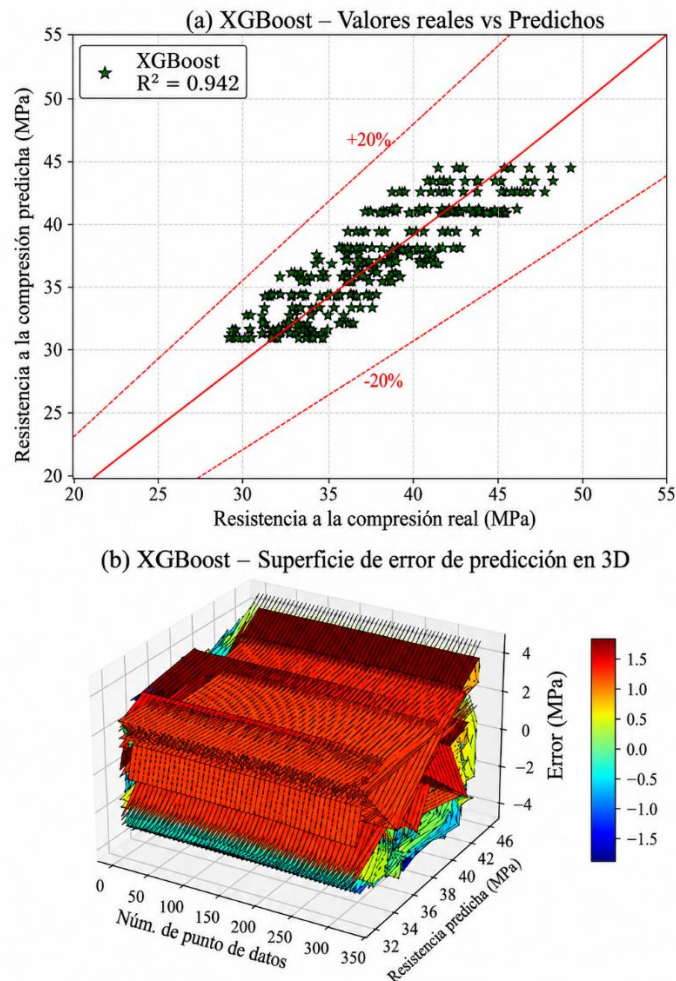


Figura 15. Rendimiento del modelo XGBoost para predecir la resistencia a la compresión del hormigón a 28 días. (a) Gráfico de dispersión de la resistencia a compresión real frente a la predicha, (b) gráfico de superficie 3D que muestre la distribución de los errores de predicción entre todos los puntos de datos.

Los hallazgos muestran que los algoritmos no lineales y de conjunto proporcionan predicciones más precisas de la resistencia a la compresión del RAC en comparación con las técnicas lineales. Las fuertes puntuaciones  $R^2$  logradas por SVR y Random Forest demuestran su fiabilidad para uso real, mientras que los modelos lineales siguen siendo útiles como referencias base o en situaciones donde la interpretabilidad es importante.




Figura 16. Análisis por límite de error que muestra la distribución de los residuos absolutos para todos los modelos de regresión.

La Figura 16 muestra la evaluación limitada por error de cada modelo de regresión basada en la dispersión de los valores absolutos residuales. El modelo SVR muestra la dispersión residual más estrecha, lo que se alinea con su baja MAE de 0,008 y confirma su fuerte consistencia en la predicción de la resistencia a la compresión. Random Forest (MAE 0,128), KNN (MAE 0,164) y XGBoost (MAE 0,186) también muestran distribuciones de error compactas, lo que indica un rendimiento estable dentro de límites de error restringidos. En contraste, el aumento de gradiente (MAE 0,189), la regresión lineal (MAE 0,346), el lazo (MAE 0,364), la red elástica (MAE 0,425) y la cresta (MAE 0,450) muestran rangos de error más amplios, lo que sugiere un control comparativamente más débil sobre las desviaciones de predicción. Los modelos con MAE más bajos muestran rangos de error más compactos, mientras que los métodos lineales y regularizados suelen mostrar una mayor dispersión en sus residuos.

#### 4.2 Diagnósticos de regresión y evaluación de modelos

Se llevó a cabo un procedimiento exhaustivo de optimización de hiperparámetros para cada modelo para mejorar el rendimiento global de la predicción. La afinación de hiperparámetros implicaba ajustar sistemáticamente parámetros clave del modelo como el tipo de núcleo, C y epsilon para la Regresión de Vectores de Soporte (SVR); el número de estimadores, la profundidad máxima y las muestras mínimas divididas para el Bosque Aleatorio (RF); el número de vecinos para K-Vecinos Más Cercanos (KNN); tasa de aprendizaje y profundidad máxima para XGBoost y Gradient Boosting; y parámetros de regularización para Lazo, Cresta y Red Elástica. Se emplearon métodos de búsqueda en cuadrícula y búsqueda aleatoria junto con la validación cruzada k-fold ( $k=10$ ) para asegurar una selección robusta de parámetros y evitar el sobreajuste. La validación cruzada permitió entrenar y validar los modelos en múltiples subconjuntos del conjunto de datos, proporcionando una estimación imparcial del rendimiento de la generalización. (Farhangi et al., 2021; Naderpour et al., 2018) (Deng et al., 2018; Jahangir & Eidgahee, 2020) (Ghanizadeh et al., 2019)

La precisión del modelo se evaluó utilizando múltiples indicadores, como el coeficiente de determinación ( $R^2$ ), el error absoluto medio (MAE), el error cuadrático medio (MSE), el error cuadrático medio de raíz (RMSE), el error porcentual absoluto medio (MAPE), el error de sesgo

medio (MBE) y la estadística t. Entre los modelos individuales, el SVR logró la mayor precisión predictiva con un valor de  $R^2$  (Bilim, Koksal, et al., 2009; Farhangiet al., 2021) de 0,998, un MAE mínimo (0,008) y un RMSE de 0,011, seguido de cerca por el Bosque Aleatorio ( $R^2 = 0,996$ ). Los modelos no lineales como KNN, XGBoost y Gradient Boosting superaron a los modelos lineales (Regresión Lineal, Lazo, Cresta, Red Elástica), lo que indica las fuertes relaciones no lineales entre los parámetros de mezcla y la resistencia a la compresión. KNN y XGBoost registraron valores de  $R^2$  de 0,947 y 0,942, respectivamente, mientras que el Gradient Boosting alcanzó 0,904. La regresión lineal y los modelos lineales regularizados mostraron valores de  $R^2$  comparativamente más bajos, que iban de 0,842 a 0,893, lo que pone de manifiesto sus limitaciones para capturar interacciones complejas. (Deng et al., 2018; Naderpour et al., 2018) (Bilim, Ozbakkaloglu, et al., 2009; Jahangir & Eidgahee, 2020)

Para mejorar la precisión de las predicciones, se creó un modelo de ensamble apilado, integrando las capacidades de los algoritmos con mejor rendimiento. El método de conjunto combina varios modelos base junto con un modelo de nivel superior que aprende de sus resultados para mejorar la precisión global de las predicciones. El modelo de apilamiento demostró un rendimiento superior con valores  $R^2$  de 0,999 para el conjunto de entrenamiento y 0,998 para el conjunto de pruebas, acompañados de errores insignificantes (MAE  $\approx$  0,0099, RMSE  $\approx$  0,0137), Tabla 6. Estos resultados confirman que el aprendizaje en conjunto puede explotar eficazmente las capacidades complementarias de modelos individuales, logrando una predicción casi perfecta de la resistencia a la compresión a 28 días a lo largo del diverso conjunto de datos experimentales. Este método pone de manifiesto cómo los modelos modernos de aprendizaje automático pueden ofrecer predicciones precisas y basadas en datos sobre el rendimiento del hormigón de agregados reciclados, ayudando a minimizar la necesidad de grandes cantidades de pruebas de laboratorio y asegurando resultados fiables. (J. Zhang et al., 2022) (Farhangi et al., 2021; Jahangir & Eidgahee, 2020) (Ghanizadeh et al., 2019; Naderpour et al., 2018)

Tabla 6. Rendimiento comparativo de modelos de regresión para predecir la resistencia a la compresión a 28 días de hormigón agregado reciclado.

Modelo	Valor R2	MAE	MSE	RMSE	MAPE (%)	MBE	T-stat
Regresión de vectores de soporte	0.998	0.008	0	0.011	0.022	0	-0.309
Bosque Aleatorio	0.996	0.128	0.032	0.179	0.346	0.017	1.373
K-Vecinos más cercanos	0.947	0.164	0.052	0.227	0.441	0.029	1.913
XGBoost	0.942	0.186	0.061	0.248	0.494	-0.01	-0.282
Aumento de gradiente	0.904	0.189	0.063	0.251	0.505	0.006	0.353
Regresión lineal	0.893	0.346	0.209	0.457	0.94	0.009	0.284
Regresión de lazo	0.879	0.364	0.218	0.467	0.987	0.018	0.556
Red elástica	0.846	0.425	0.291	0.539	1.148	0.024	0.646
Regresión de la dorsal	0.842	0.45	0.331	0.575	1.209	0.026	0.672

**Nota:** Los valores representan la media de la validación cruzada de cinco veces promediada sobre tres semillas aleatorias. Los hiperparámetros se optimizaron mediante validación cruzada 10 veces con cuadrícula y búsqueda aleatoria para asegurar una selección robusta del modelo. Las métricas de rendimiento incluyen  $R^2$ , MAE, MSE, RMSE, MAPE, MBE y estadísticas t pareadas, destacando la superior precisión de los modelos no lineales y en conjunto.

Aunque se obtuvieron valores muy altos de  $R^2$  para ciertos modelos, estos resultados deben interpretarse en el contexto del conjunto de datos controlado y la fuerte correlación entre los parámetros de diseño de mezcla y la resistencia a la compresión. Se utilizaron métricas de validación cruzada y de error para evaluar el rendimiento del modelo; sin embargo, se reconoce el potencial de sobreajuste debido a la expansión del conjunto de datos como una limitación del estudio.

### 4.3 Interpretabilidad del modelo e importancia de las características

Para entender el efecto de cada parámetro de mezcla en la predicción de la resistencia a compresión a 28 días para hormigón de agregados reciclados del modelo de Regresión de Vectores de Apoyo, se realizó un análisis SHAPapley Aditivive ExPlanations (SHAP). SHAP proporciona una interpretación transparente de los resultados del aprendizaje automático al atribuir un valor de contribución a cada característica en función de su influencia en la predicción final. Este enfoque permite una comprensión detallada de los efectos no lineales e interactivos que no son visibles mediante el análisis tradicional de sensibilidad. (Lundberg & Lee, 2017; Molnar, 2020)

La Figura 17 muestra cómo cada característica de entrada contribuye a la salida del modelo según el análisis SHAP. Los valores medios de SHAP para el modelo SVR se muestran en la Figura 17(a). Entre todas las variables, el porcentaje de RCA tuvo el mayor impacto, con un valor medio de SHAP de 0,638, demostrando que la cantidad de agregado grueso reciclado desempeñó el papel más significativo en la predicción de la resistencia a la compresión. La absorción de agua de RCA (0,584) y el valor de abrasión de LA (0,459) también fueron muy influyentes, reflejando el papel crítico de la condición superficial de los agregados y la integridad mecánica en la determinación del rendimiento del hormigón. Siguió la resistencia del hormigón principal (0,351), el contenido de plastificante (0,346) y la proporción agua-cemento (0,168), mostrando una influencia moderada pero significativa en el desarrollo de resistencia.

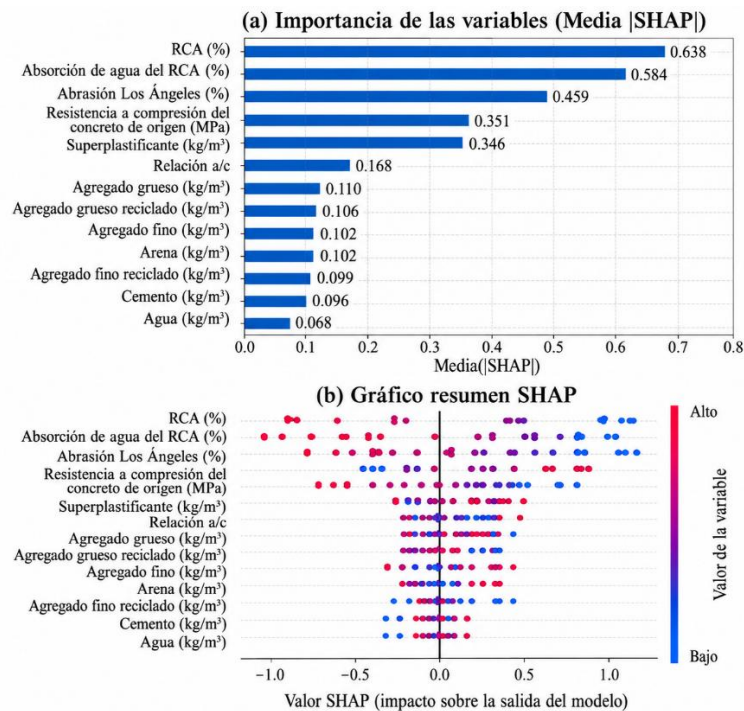


Figura 17. Análisis SHAP, (a) valores absolutos medios de SHAP que indican la influencia relativa de las variables de entrada en las predicciones del modelo SVR sobre la resistencia a compresión a 28 días, (b) gráfico resumen SHAP que muestra la distribución, dirección y magnitud de los efectos de las características en todas las muestras.

Otros componentes como el agregado grueso total (0,110), el agregado grueso reciclado (0,106), el agregado fino (0,102), la arena (0,102) y el agregado fino reciclado (0,099) mostraron contribuciones menores pero fueron consistentes en su papel en el control de la trabajabilidad, la densidad interna de empaquetado y la calidad de la zona de transición interfacial. El cemento (0,096) y el contenido de agua (0,068) tenían los valores SHAP más bajos, lo que sugiere una variabilidad limitada en sus rangos dentro del conjunto de datos en lugar de una influencia de ingeniería reducida.

La Figura 17(b) muestra cómo se distribuyen los valores SHAP para cada muestra. La mayor dispersión horizontal observada para el porcentaje de RCA, absorción y abrasión muestra que estas entradas contribuyen más a la variabilidad de la predicción dentro del conjunto de datos. En cambio, el cemento y el agua presentan dispersiones mucho más compactas, lo que indica que el modelo es menos sensible a los cambios en estas características. Los gradientes de color rojo y azul muestran cómo los valores de características altos o bajos desplazan las predicciones positiva o negativamente, ayudando a visualizar la dirección e influencia de cada entrada en el rendimiento del modelo.

En conjunto, las Figuras 17(a) y 17(b) demuestran que las propiedades de los agregados reciclados gobiernan la predicción de la fuerza en el CRA de forma más fuerte que las proporciones de mezcla por sí solas. Estos resultados proporcionan una orientación basada en datos para la optimización de RAC, destacando que mejorar la calidad de los áridos, controlar la absorción y seleccionar hormigón fuente duradero puede mejorar significativamente los resultados de resistencia predichos por el modelo.

La alta importancia de la absorción de agua y los parámetros relacionados con RCA observados en el análisis SHAP confirman aún más que la calidad de los agregados y las características relacionadas con la porosidad juegan un papel dominante en la predicción de resistencia.

Estas ideas permiten un enfoque basado en datos para optimizar la mezcla: aumentar la eficiencia del aglutinante y controlar la calidad del RCA puede maximizar la resistencia, mientras que pequeños ajustes en el contenido de agua, arena y plastificante mejoran la trabajabilidad y la integridad estructural sin comprometer la resistencia a la compresión. Los valores SHAP proporcionan tanto interpretabilidad como orientación accionable para el diseño de mezclas RAC sostenibles, reduciendo los ensayos experimentales mientras mantienen una alta confianza en las predicciones del modelo. (Lundberg & Lee, 2017; Molnar, 2020)

## 5. CONCLUSIÓN

Este trabajo explora la resistencia a la compresión del hormigón de agregados reciclados (RAC) utilizando tanto pruebas de laboratorio como técnicas de aprendizaje automático. Se prepararon un total de 25 mezclas de hormigón con diferentes combinaciones de áridos gruesos y finos naturales y reciclados, proporciones variables-aguacemento y diferentes resistencias del hormigón original. Los resultados de resistencia a la compresión a 28 días oscilaron entre 31,8 MPa para mezclas que contenían solo agregados reciclados hasta 45,2 MPa para mezclas hechas íntegramente con agregados naturales. A continuación, se desarrollaron modelos de aprendizaje automático para predecir la resistencia a la compresión a partir de los parámetros de la mezcla. La regresión de vectores de soporte (SVR) ofreció los resultados más precisos, logrando un valor  $R^2$  de 0,998 con errores de predicción muy pequeños (MAE = 0,008 MPa, RMSE = 0,011 MPa). Métodos de conjunto como Random Forest y KNN también tuvieron buenos resultados, mientras que enfoques tradicionales como Linear Regression, Lasso y Ridge registraron menor precisión en comparación.

Las observaciones clave del estudio incluyen:

- Aumentar el contenido de áridos reciclados generalmente reduce la resistencia a la compresión. Las mezclas con RCA entre 75 y 100% mostraron los valores de concentración más bajos, mientras que las mezclas sin RCA alcanzaron las más altas.
- La relación aguacemento, la resistencia del hormigón principal y la absorción de agua por RCA estuvieron entre los factores más influyentes que afectaron la resistencia a la compresión. Relaciones de peso y peso más altas combinadas con altos niveles de RCA provocaron reducciones significativas en la fuerza.
- Los modelos de aprendizaje automático demostraron una fuerte capacidad para predecir la resistencia a la compresión a partir de parámetros de mezcla. Los modelos SVR y RF proporcionaban una precisión predictiva muy alta dentro del rango de parámetros estudiados, lo que los hacía muy adecuados para la optimización de diseño en mezcla.
- Los modelos no lineales en conjunto y otros ofrecieron mejores resultados que la regresión lineal tradicional, mostrando que es importante tener en cuenta relaciones complejas entre las variables de entrada al predecir el comportamiento del hormigón de agregado reciclado.

Los resultados indican que sustituir los áridos naturales por áridos reciclados en un rango de 25% a 75% es factible para la producción de hormigón cuando la mezcla está bien diseñada. Aunque se observa cierta reducción en la resistencia, esta se mantiene dentro de los límites aceptables y el hormigón resultante mantiene el rendimiento estructural. En cambio, la sustitución completa (100%) conduce consistentemente a la menor resistencia, en gran parte debido a la mayor absorción de agua de los áridos reciclados y a la menor calidad de la fuente original de hormigón. Integrar pruebas de laboratorio con aprendizaje automático mejora la precisión en la predicción del rendimiento del hormigón y minimiza la necesidad de ensayos físicos repetidos, facilitando la determinación del contenido de agregados reciclados más adecuado para aplicaciones sostenibles de hormigón.

Los estudios futuros deberían considerar incorporar variables adicionales de entrada como características químicas, indicadores de durabilidad, variables de curación y comportamiento a largo plazo para reforzar la fiabilidad y la profundidad predictiva del modelo. Estos modelos también pueden ampliarse para predecir otros parámetros mecánicos y de durabilidad, ayudando en el desarrollo de materiales de hormigón ambientalmente conscientes y de alto rendimiento y con conciencia ambiental.

## 6. REFERENCIAS

- Ajdkiewicz, A., & Kliszczewicz, A. (2002). Influencia de los áridos reciclados en las propiedades mecánicas del hormigón de alta resistencia. *Compuestos de cemento y hormigón*, 24(2), 269–279. [https://doi.org/10.1016/S0958-9465\(01\)00012-9](https://doi.org/10.1016/S0958-9465(01)00012-9)
- Akbar, A., & Liew, J. Y. R. (2020a). Impacto ambiental de la producción de cemento y sostenibilidad del hormigón. *Journal of Cleaner Production*, 258, 120543. <https://doi.org/10.1016/j.jclepro.2020.120543>
- Akbar, A., & Liew, K. M. (2020b). Evaluación del potencial de reciclaje de residuos plásticos reforzados con fibra de carbono en materiales de cemento ecoeficientes. *Journal of Cleaner Production*, 274, 123001. <https://doi.org/10.1016/j.jclepro.2020.123001>
- Altman, N. S. (1992). Una introducción a la regresión no paramétrica del núcleo y del vecino más cercano. *The American Statistician*, 46(3), 175–185. <https://doi.org/10.1080/00031305.1992.10475879>
- Bai, X. y otros. (2023). Estudio experimental sobre propiedades mecánicas y modelo constitutivo compresivo de hormigón reciclado bajo ataque de sulfatos considerando los efectos de múltiples factores. *Edificios*, 14(9), 2761. <https://doi.org/10.3390/buildings14092761>

- Bhanja, S., & Sengupta, B. (2005). Predicción de la resistencia a la compresión del hormigón mediante análisis de regresión. *Investigación sobre cemento y hormigón*, 35(9), 1848–1855. <https://doi.org/10.1016/j.cemconres.2005.03.003>
- Bilim, C., Atis, C. D., Tanyildizi, H., & Karahan, O. (2009). Predicción de la resistencia a la compresión del hormigón GGBS usando ANN. *Avances en el software de ingeniería*, 40(5), 334–340. <https://doi.org/10.1016/j.advengsoft.2008.05.005>
- Bilim, C., Koksal, F., & Tosun, T. (2009). Predicción de la resistencia del hormigón usando RNA. *Sistemas Expertos con Aplicaciones*, 36(2), 3736–3742. <https://doi.org/10.1016/j.eswa.2008.03.011>
- Bilim, C., Ozbakkaloglu, T., & Tanyu, B. F. (2009). Redes neuronales artificiales para predecir la resistencia a la compresión del hormigón. *ACI Materials Journal*, 106(3), 203–211.
- Breiman, L. (2001). Bosques aleatorios. *Aprendizaje automático*, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>
- Cakiroglu, M., Pal, S., & Sharma, R. (2023). Desafíos medioambientales de los residuos de construcción: una revisión. *Journal of Environmental Management*, 335, 117142. <https://doi.org/10.1016/j.jenvman.2023.117142>
- Chakradhara Rao, M., Bhattacharyya, S. K., & Barai, S. V. (2011). Influencia del árido grueso reciclado en campo en las propiedades del hormigón. *Materiales y Estructuras*, 44(1), 205–220. <https://doi.org/10.1617/s11527-010-9620-x>
- Chen, T., & Guestrin, C. (2016). XGBoost: Un sistema escalable de potenciación de árboles. *Procedimientos KDD*, 785–794. <https://doi.org/10.1145/2939672.2939785>
- Chicco, D., & Warrens, M. J. (2021). El coeficiente de determinación R-cuadrado es más informativo que el de SMAPE, MAE, MSE y RMSE en la evaluación del análisis de regresión. *PeerJ Computer Science*, 7, e623. <https://doi.org/10.7717/peerj-cs.623>
- Dantas, A. T., Leite, M., & Nagahama, K. (2013). Predicción de resistencia basada en RNA para hormigón con residuos. *Materiales de construcción y construcción*, 38, 717–722.
- Deng, A., Naderpour, H., & Ghanizadeh, A. (2018). Predicción de la resistencia del hormigón reciclado usando ML. *Materiales de hoy: Actas*, 5(11), 24091–24099. <https://doi.org/10.1016/j.matpr.2018.10.091>
- Emmert-Streib, F., & Dehmer, M. (2019). Evaluación de modelos de regresión: evaluación de modelos, selección de modelos y error de generalización. *Aprendizaje automático y extracción de conocimiento*, 1(1), 521–551. <https://doi.org/10.3390/make1010032>
- Farhangi, V., Jahangir, H., & Ghafari, E. (2021). Predicción basada en aprendizaje automático de hormigón agregado reciclado. *Materiales Comunicaciones Hoy*, 28 de 102633. <https://doi.org/10.1016/j.mtcomm.2021.102633>
- Field, A. (2013). *Descubriendo estadísticas usando IBM SPSS* (4ª ed.). Sabio.
- Friedman, J. (2001). Aproximación de función codiciosa: aumento de gradiente. *Anales de Estadística*, 29(5), 1189–1232.
- Geurts, P., Ernst, D., & Wehenkel, L. (2006). Árboles extremadamente aleatorios. *Aprendizaje automático*, 63, 3–42.
- Ghanizadeh, A., Naderpour, H., & Deng, Q. (2019). Predicción de resistencia basada en IA para hormigón reciclado. *Revista de Producción Más Limpia*, 215, 376–385.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Aprendizaje profundo*. MIT Press.
- Hansen, T. C., & Narud, H. (1983). Resistencia del hormigón reciclado con áridos triturados. *Concrete International*, 5(1), 79–83.
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *Elementos del aprendizaje estadístico*. Springer.
- Hoerl, A. E., & Kennard, R. W. (1970). Regresión de crestas: Estimación sesgada para problemas no ortogonales. *Tecnometría*, 12(1), 55–67. <https://doi.org/10.1080/00401706.1970.10488634>

- Huang, B., & Yan, Q. (2025). Evaluación de las propiedades mecánicas del hormigón de agregados reciclados con reemplazos variables de áridos gruesos y finos. *Descubre la ingeniería civil*. <https://doi.org/10.1007/s44290-025-00336-3>
- International, A. (2024). *ASTM C150/C150M-24: Especificación estándar para cemento Portland*.
- Jahangir, H., & Eidgahee, D. (2020). Modelado híbrido de IA para la resistencia de unión FRP–hormigón. *Estructuras compuestas*, 257, 113160.
- Jahangir, H., Farhangi, H., & Ghodrati, B. (2021). Predicción conjunta de la fuerza del RAC. *Materiales de construcción y construcción*, 271, 121654.
- Katz, A. (2003). Hormigón hecho de árido reciclado parcialmente hidratado. *Investigación sobre cemento y hormigón*, 33(5), 703–711.
- Khalil, E., & AbouZeid, M. (2025). Marco para la evaluación de plantas de cemento mediante medidas de mejora de la producción de cemento para reducir las emisiones de CO<sub>2</sub> hacia emisiones netas cero. *Materiales de construcción*, 5(2), 20. <https://doi.org/10.3390/constrmater5020020>
- Khan, K. y otros. (2022). Comparación de métodos de aprendizaje automático para la predicción de la resistencia del hormigón de áridos reciclados. *Materiales*, 15(10), 3430. <https://doi.org/10.3390/ma15103430>
- Khatib, J. M. (2005). Hormigón con áridos reciclados finos. *Investigación sobre cemento y hormigón*, 35(4), 763–769.
- Lundberg, S. M., & Lee, S. I. (2017). Un enfoque unificado para interpretar las predicciones de modelos. *Avances en sistemas de procesamiento de información neuronal*, 30, 4765–4774.
- Miller, C., y otros. (2024). Revisión de métricas de evaluación de modelos para aprendizaje automático en regresión, clasificación y agrupamiento. *PeerJ Informática*, 10, eXXXX.
- Molnar, C. (2020). *Aprendizaje automático interpretable: una guía para explicar los modelos de caja negra*. Lulu.com.
- Naderpour, H., Ghanizadeh, M., & Behnood, A. (2018). Predicción de la resistencia a compresión del RAC mediante ANN. *Journal of Cleaner Production*, 184, 640–650.
- Padmini, A. K., Ramamurthy, K., & Mathew, M. (2002). Influencia del hormigón padre en las propiedades del RAC. *Investigación sobre cemento y hormigón*, 32(12), 1893–1901.
- Pal, R., & Singh, S. (2024). Papel de la trituración por impacto y compresión en las características físicas, químicas y morfológicas de los áridos de hormigón reciclados. *Revista de Materiales en Ingeniería Civil*. <https://doi.org/10.1061/JMCEE7.MTENG-17400>
- Plevris, V., Solórzano, G., Bakas, N. P., & Ben Seghier, M. E. (2022). Investigación de métricas de rendimiento en análisis de regresión y modelos de predicción basados en aprendizaje automático. *Actas del 8º Congreso Europeo de Métodos Computacionales en Ciencias Aplicadas e Ingeniería (ECCOMAS 2022)*. <https://doi.org/10.23967/eccomas.2022.155>
- Ryu, G. S. (2002). Resistencia y durabilidad del hormigón agregado reciclado. *Materiales de construcción y construcción*, 16(1), 95–101.
- Shin, Y. S., & Kim, G. H. (2013). Predicción de la resistencia a la compresión de hormigón agregado reciclado mediante análisis de regresión múltiple. *Mecánica y Materiales Aplicados*, 253–255, 546–549. <https://doi.org/10.4028/www.scientific.net/AMM.253-255.546>
- Smola, A., & Scholkopf, B. (2004). Tutorial sobre regresión de vectores de soporte. *Estadística e Informática*, 14(3), 199–222.
- Steurer, M., Schulz, W., & Werwatz, A. (2021). Métricas para evaluar el rendimiento de modelos de predicción por aprendizaje automático. *International Journal of Forecasting*, 36(6), 812–828. <https://doi.org/10.1080/09599916.2020.1858937>
- Tu, C., Belarbi, R., Pigeon, M., & Tam, V. (2006). Propiedades del hormigón con áridos reciclados. *Investigación sobre cemento y hormigón*, 36(1), 153–159.
- Wolpert, D. (1992). Generalización apilada. *Redes neuronales*, 5(2), 241–259.

- Sí, I.C. (2007). Predicción de propiedades del hormigón en aprendizaje automático. *Investigación sobre cemento y hormigón*, 37(5), 676–685.
- Zain, M. F. M., Safiuddin, M., & Mahmud, H. B. (2002). Desarrollo de hormigón de alto rendimiento utilizando humo de sílice y superplastificante. *Investigación sobre cemento y hormigón*, 32(1), 115–122. [https://doi.org/10.1016/S0008-8846\(01\)00643-1](https://doi.org/10.1016/S0008-8846(01)00643-1)
- Zhang, J., Li, X., & Chen, Y. (2022). Conjunto de apilamiento para la predicción de resistencia concreta. *Aplicaciones de ingeniería de la inteligencia artificial*, 109, 104617.
- Zhang, P., Sun, X., Wang, F., & Wang, J. (2023). Propiedades mecánicas y durabilidad del hormigón de agregados reciclados de geopolímeros: una revisión. *Polímeros*, 15(3), 615. <https://doi.org/10.3390/polym15030615>
- Zhang, X., Sun, X., Wang, F., & Wang, J. (2023). Predicción de la resistencia a la compresión de hormigón agregado reciclado mediante aprendizaje automático y técnicas de optimización de hiperparámetros. *Fronteras en Ciencias de la Tierra*, 11, 1112105. <https://doi.org/10.3389/feart.2023.1112105>
- Zou, H., & Hastie, T. (2005). Regularización y selección de variables mediante la red elástica. *Journal of the Royal Statistical Society: Serie B*, 67(2), 301–320. <https://doi.org/10.1111/j.1467-9868.2005.00503.x>