



Año VII, vol. 1 2026 | Envío: 23/05/2026 | Aceptado: 26/05/2026 | Publicación: 29/05/2026

Aprendizaje automático aplicado a la ingeniería civil: análisis predictivo de la resistencia a la compresión del hormigón.

Aprendizaje automático aplicado a la ingeniería civil: modelado predictivo de la resistencia a la compresión del hormigón.

Aprendizaje automático aplicado a la ingeniería civil: análisis predictivo de la resistencia a la compresión del hormigón.

Luciana Andrade Villar¹

Milton Augusto Pinotti²

RESUMEN: Se ha observado un progreso significativo en la digitalización de la ingeniería civil, impulsado por el desarrollo de tecnologías computacionales y la mayor disponibilidad de datos técnicos de los procesos de producción. En este escenario, las técnicas de Inteligencia Artificial (IA), como el Aprendizaje Automático (ML) y el Aprendizaje Profundo (DL), se aplican a la ingeniería civil para analizar grandes volúmenes de datos e identificar patrones complejos en el diseño de mezclas y las variables de resistencia. En el área de la tecnología del hormigón, estas técnicas se han investigado como herramientas prometedoras para estimar las propiedades mecánicas del material, como la resistencia a la compresión, a partir de parámetros relacionados con el diseño de la mezcla y las condiciones de producción. Este artículo presenta la aplicación y evaluación de modelos de Aprendizaje Automático para el análisis predictivo de la resistencia a la compresión del hormigón (f_{ck}). El objetivo principal es aplicar algoritmos de regresión supervisada para estimar f_{ck} a partir de parámetros de diseño de mezcla, contribuyendo al control tecnológico y la toma de decisiones en proyectos estructurales. La metodología adoptada incluyó la recolección de 300 muestras de mezclas reales de una planta de hormigón ubicada en Brusque/SC, que cubren diez atributos relacionados con la composición del hormigón. Se realizó una selección preliminar de algoritmos, incluyendo regresión lineal, árbol de decisión, bosque aleatorio, SVR y k-vecinos más cercanos (KNN). SVR se seleccionó como el modelo con mejor desempeño en función de la similitud y proximidad de los datos. Se planificó la validación del modelo utilizando datos históricos y experimentales, empleando validación cruzada k-fold. Se concluye que el enfoque basado en SVR ofrece una herramienta prometedora para predecir f_{ck} , con potencial para su aplicación práctica en el control de calidad del concreto y la optimización de diseños de mezcla en plantas de dosificación.

Palabras clave: resistencia a la compresión del hormigón; aprendizaje automático aplicado a la resistencia del hormigón; k vecinos más cercanos; SVR; predicción.

1. INTRODUCCIÓN

Las innovaciones tecnológicas han calado hondo en diversos segmentos de la sociedad contemporánea. promover transformaciones significativas en los procesos de producción y la gestión de la información y en la toma de decisiones en diferentes campos del conocimiento. En el campo de la ingeniería civil, Este escenario no es diferente, dado el avance de las tecnologías informáticas y... Las herramientas de análisis de datos han contribuido a la mejora de los métodos tradicionales.

¹ Estudiante de Ingeniería Civil en UNIFEFE. Correo electrónico: luciana.villar@unifebe.edu.br

² Profesor supervisor. Máster en Ingeniería Eléctrica. Correo electrónico: pinotti@unifebe.edu.br



Año VII, vol. 1 2026 | Envío: 23/05/2026 | Aceptado: 26/05/2026 | Publicación: 29/05/2026

Diseño, ejecución y control de proyectos de obras de construcción.

Esta evolución digital permite un análisis más exhaustivo de las características de los materiales.

utilizado en la construcción. Entre las características mecánicas, la resistencia a la compresión (f_{ck} ,

La resistencia característica a los 28 días (NBR 5738) es un parámetro clave para el rendimiento.

Control estructural y de calidad, de acuerdo con las normas técnicas.

La resistencia a la compresión del hormigón (f_{ck}) está directamente relacionada con el diseño de la mezcla.

y a las condiciones de producción, incluyendo la relación cemento-agregado-agua, la relación

Relación agua/cemento (a/c), aditivos y las condiciones de mezcla, colocación, compactación y curado.

La influencia simultánea de estas variables genera complejidad, lo que dificulta realizar predicciones precisas.

con métodos tradicionales (Neville, 2011; Helene y Terzian, 1992).

En este contexto, el control tecnológico del hormigón juega un papel fundamental en

garantizar la calidad y el rendimiento estructural de los edificios. Este proceso implica...

verificación de las propiedades de los materiales constituyentes, seguimiento de las etapas de

producción y realización de ensayos de laboratorio, incluido el ensayo de resistencia a la compresión.

uno de los principales métodos utilizados para evaluar la calidad del hormigón producido.

Sin embargo, estos procedimientos se llevan a cabo después de que el material ha sido producido, lo que limita...

posibilidad de anticipar el comportamiento del hormigón antes de su aplicación en la construcción (Helene;

Terzian, 1992).

Paralelamente, se observa un progreso significativo en la digitalización de la ingeniería.

civil, impulsado por el desarrollo de las tecnologías informáticas y el aumento de

disponibilidad de datos técnicos de los procesos de producción. En este escenario,

Técnicas de Inteligencia Artificial (IA), como Aprendizaje Automático (ML) y Aprendizaje Profundo (DL),

Estas técnicas se aplican en la ingeniería civil para analizar grandes volúmenes de datos e identificar patrones.

complejos en variables de dosis y resistencia (Goodfellow; Bengio; Courville, 2016).

El aprendizaje automático, en particular, destaca por permitir...

desarrollo de modelos predictivos capaces de aprender de datos históricos,

Identificar relaciones entre variables y realizar predicciones basadas en patrones observados.

A diferencia de los sistemas informáticos tradicionales, que se basan en reglas preestablecidas...

Cuando se programan, los modelos de aprendizaje automático son capaces de extraer patrones.

directamente a partir de los datos, lo que permite la resolución de problemas complejos mediante procesos.

del aprendizaje automático (Goodfellow; Bengio; Courville, 2016).

En el campo de la tecnología del hormigón, estas técnicas se han investigado como herramientas.

prometedor para estimar las propiedades mecánicas del material, como la resistencia a



Año VII, vol. 1 2026 | Envío: 23/05/2026 | Aceptado: 26/05/2026 | Publicación: 29/05/2026

compresión, basada en parámetros relacionados con la dosificación y las condiciones de producción.

Dado este contexto, el presente trabajo consiste en una revisión de la literatura sobre el tema.

aplicación de técnicas de aprendizaje automático para el análisis y predicción de la resistencia a

Compresión del hormigón. La investigación se centra en la base teórica de los principales...

Algoritmos de regresión utilizados en la literatura, con énfasis en los modelos SVR (Máquinas de Vectores de Soporte).

Regresión) y Regresor de Árbol de Decisión, así como una descripción de los procedimientos.

Métricas metodológicas y de evaluación empleadas en estudios relacionados. Las pruebas

experimentos con modelos predictivos, incluyendo el paso de optimización de hiperparámetros,

La validación con datos reales y el análisis comparativo de los resultados se llevarán a cabo en una fase posterior.

Posteriormente a la investigación, que establece la continuación natural de este estudio.

Por lo tanto, el objetivo general de este trabajo es realizar una revisión de la literatura sobre

Modelos predictivos basados en técnicas de aprendizaje automático orientados a la previsión

Resistencia a la compresión del hormigón, basada en los parámetros de diseño de la mezcla y en datos históricos.

métodos de producción. La relevancia de esta investigación radica en la posibilidad de integrar métodos

desde la tecnología tradicional del hormigón hasta las herramientas avanzadas de análisis de datos,

contribuyendo a la mejora de los procesos de previsión y control de calidad de

material en ingeniería civil.

2. FUNDAMENTOS TEÓRICOS

Este estudio abarca los principios de la tecnología del hormigón y los fundamentos computacionales de...

Aprendizaje automático, estableciendo la conexión entre las variables de dosificación y la capacidad.

Capacidades predictivas de los algoritmos supervisados.

2.1 Tecnología del hormigón

El hormigón es un material compuesto formado por una pasta aglutinante (cemento Portland y agua) y agregados (finos y gruesos), cuyo rendimiento resulta de la interacción química y física.

en la zona de transición interfacial entre la pasta y las partículas (Mehta; Monteiro, 2014).

La interacción determina propiedades cruciales, como la trabajabilidad en estado fresco y...

resistencia en estado endurecido. Su amplia aplicación en ingeniería civil se deriva de sus atributos.

tales como alta resistencia mecánica y durabilidad en diversas condiciones ambientales,

Su versatilidad en el moldeo y su coste relativamente económico consolidan su posición como materia prima.

esencial en obras de construcción e infraestructura (Neville, 2011).

La complejidad de las interacciones entre los componentes del hormigón y los factores ambientales. Esto introduce una variabilidad inherente al material. Para monitorear este comportamiento, utilizan: si los protocolos de prueba estandarizados: mientras que la prueba de hundimiento evalúa el Para garantizar la trabajabilidad y la consistencia en estado fresco, se emplea la compresión axial. para cuantificar la resistencia característica (fck) a los 28 días. En este escenario, la no- pronunciada linealidad de las interacciones entre las entradas, evidenciada por la correlación moderada entre las El consumo de cemento y fck (r=0,52) justifican la adopción de técnicas de aprendizaje automático para una predicción más sólida y asertiva (Hoefelmann, 2021).

2.1.1 COMPOSICIÓN

La composición del hormigón es el factor principal que define su rendimiento. Cemento El Portland, al reaccionar con agua en un proceso de hidratación, forma el gel CSH (silicato de calcio hidratado), que actúa como matriz de unión, aglutinando los agregados. La calidad y la cantidad de los áridos (finos y gruesos) son igualmente cruciales. influyendo en la trabajabilidad, la densidad y la resistencia final del hormigón, siendo la La distribución del tamaño de las partículas es un aspecto fundamental que debe controlarse (Carpinteiro, 2005). La relación La relación agua/cemento () es uno de los parámetros más críticos, ya que rige directamente la porosidad. de la pasta de cemento y, en consecuencia, la resistencia y durabilidad del material. En un contexto regional, Resner (2021) analizó rastros de hormigón en plantas de Santa Catarina, identificando patrones de dosificación que se ajustan a las directrices NBR 12655. (ABNT, 2015) para hormigón mezclado en obra. La Tabla 1 presenta un resumen de las proporciones de la mezcla. observaciones típicas, que resaltan el rango de variación de los componentes y su influencia en el resistencia a la compresión.

Tabla 1 – Rasgos típicos

Componente	Traza promedio (kg/m³)	Traza SC (kg/m³)	Influencia fck
Cemento	350	300-450	Alto (r=0,52)
Agua	175	150-200	Negativo (cociente 0,45-0,55)
Agregar Niño	700	650-750	Tamaño promedio de las partículas
Agregar Grande	1050	1000-1100	Mediana (forma y resistencia)
Curación del envejecimiento	28 días	7-28 días	Alto (r=0,48)

Fuente: Autor, basado en una adaptación de Resner (2021).



Año VII, vol. 1 2026 | Envío: 23/05/2026 | Aceptado: 26/05/2026 | Publicación: 29/05/2026

2.1.2 Factores influyentes y variabilidad

Las variables que influyen en la resistencia a compresión (f_{ck}) del hormigón son diversas, siendo

La relación agua/cemento es el factor determinante de la calidad de la mezcla. Según la

principios establecidos por Neville (2011), una proporción menor de agua en relación con

El volumen de cemento reduce la porosidad de la pasta endurecida, aumentando así su resistencia mecánica.

siempre que se garantice la hidratación completa de las partículas de cemento.

Para equilibrar esta relación sin comprometer la funcionalidad, se utilizan aditivos.

Superplastificantes, que permiten reducir el consumo de agua manteniendo el caudal necesario.

al espesamiento. El control de esta consistencia en estado fresco se lleva a cabo mediante

de la prueba de asentamiento, que garantiza el cumplimiento de

La mezcla se prepara antes del moldeo. Posteriormente, se controla el desarrollo de la resistencia durante el proceso.

Periodo de curado, bajo condiciones controladas de temperatura y humedad, a los 28 días de edad.

como marco normativo para validar los resultados de f_{ck} , siguiendo los criterios de

controles tecnológicos actuales.

2.2 RESISTENCIA A LA COMPRESIÓN DEL HORMIGÓN

La resistencia a compresión característica (f_{ck} , MPa) a los 28 días define el dimensionamiento.

estructural (NBR 6118:2023).

Esta propiedad se valida como lo demuestran las pruebas de cilindros, que calculan f_{ck} .

como el percentil 5 (95% de fiabilidad). En este contexto, para el hormigón premezclado en SC,

Una carga de 25-30 MPa equilibra el coste, la durabilidad y la productividad.

2.2.1 Dosis e influencias principales

La relación agua/cemento (a/c) es el factor determinante de la resistencia a la compresión (f_{ck}).

El uso de índices reducidos (como el rango de 0,45 a 0,55) disminuye la porosidad de la pasta.

cemento endurecido, lo que resulta en una mayor resistencia mecánica según los principios de

Ley de Abrams (NEVILLE, 2011). Esta dosificación garantiza el equilibrio entre la hidratación.

separación completa de las partículas de cemento y la trabajabilidad necesaria para la compactación, que

Mitiga la formación de grietas iniciales y cumple con los requisitos de durabilidad estipulados en el NBR.

6118, artículo 7.4.2.

Año VII, vol. 1 2026 | Envío: 23/05/2026 | Aceptado: 26/05/2026 | Publicación: 29/05/2026

2.2.2 Factores específicos de resistencia a FCK y control de

VARIABILIDAD

Varios factores modulan la resistencia a la compresión máxima (f_{ck}). Además del agua-

En lo que respecta al cemento, los factores clave incluyen el tipo de cemento, la calidad de los áridos y la eficacia del proceso de curado.

(Neville, 2011). Además, variables ambientales, como la temperatura y la humedad relativa,

Juegan un papel fundamental en la cinética de hidratación del cemento. Según Mehta y

Monteiro (2014), el monitoreo continuo de estas condiciones es esencial y debe seguir el

directrices de NBR 14931, especialmente en elementos prefabricados, en los que control

El estricto control de la temperatura y la consistencia en estado fresco garantiza la integridad estructural.

Esta dependencia de múltiples factores se refleja en la variabilidad productiva del hormigón, que

Suele presentar dispersión, con coeficientes de variación entre el 10% y el 15% (NBR 12655).

Estas fluctuaciones son consecuencia de variaciones inevitables en las etapas de mezcla, transporte y curado.

Una limitación significativa del proceso convencional es que las pruebas destructivas, realizadas

Según la norma NBR 5739, los resultados a los 28 días se proporcionan con retraso, lo que limita las intervenciones.

inmediato. Por lo tanto, comprender esta variabilidad refuerza la importancia de los métodos de

Controles más ágiles y rigurosos, basados en los estándares técnicos actuales.

2.3 APRENDIZAJE AUTOMÁTICO Y MODELOS PREDICTIVOS

El aprendizaje automático (ML) es un campo de la inteligencia artificial que permite a los sistemas...

Aprende y mejora tu rendimiento a partir de los datos, sin ser explícitamente

programado para cada tarea específica (Goodfellow et al., 2016). Esta capacidad de

Identificar patrones complejos y hacer predicciones convierte al aprendizaje automático en una herramienta valiosa en

ingeniería civil, especialmente en el modelado de materiales como el hormigón.

Predecir la resistencia a la compresión (f_{ck}) del hormigón es un desafío notable, dada la naturaleza

no linealidad de las interacciones entre sus componentes, como la relación agua/cemento (), el tipo de

cemento, la proporción de agregados y el tiempo de curado.

Los métodos tradicionales suelen simplificar estas relaciones, mientras que el aprendizaje automático ofrece...

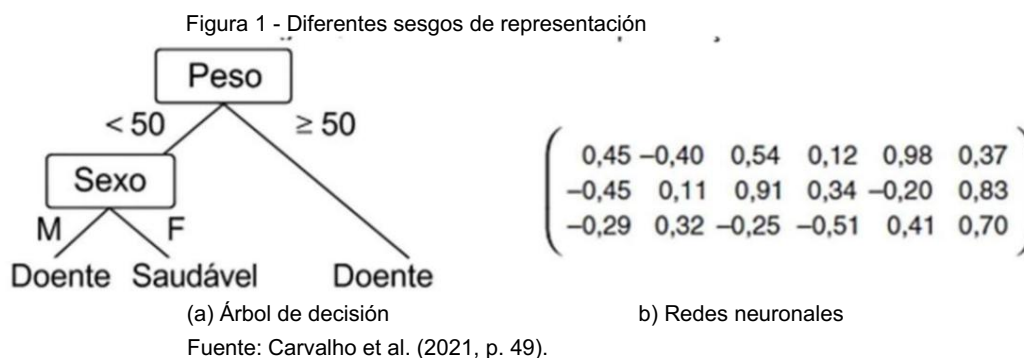
Un enfoque sólido para capturar esta complejidad y optimizar el control de calidad.

2.3.1 ALGORITMOS DE ML

Un algoritmo de aprendizaje automático es un conjunto de instrucciones para resolver problemas mediante...

Aprendizaje a partir de datos, sin programación explícita. En el contexto de la predicción de *fck* a partir de
 Específicamente, las hipótesis de atributos (, cura) se construyen para mapear relaciones no lineales, en
 que cada algoritmo utiliza un sesgo de representación específico, como los árboles de decisión.

(jerarquía) o redes neuronales (pesos), lo que limita las hipótesis para la generalización (Figura 1).




El ciclo de búsqueda explora modelos de forma eficaz. Elementos esenciales para las predicciones
 Sólido en datos concretos.

2.3.2 REGRESIÓN Y CLASIFICACIÓN

Un algoritmo de aprendizaje automático predictivo (ML) es una función que, basándose en un
 A partir de un conjunto de ejemplos etiquetados, se construye un estimador. El atributo toma valores dentro de
 un dominio previamente conocido y, cuando ese dominio está compuesto por valores nominales,
 El problema se clasifica como un problema de clasificación (o aprendizaje de conceptos), y el estimador
 El valor generado se llama clasificador. Por otro lado, si el dominio es un conjunto infinito y
 Conjunto ordenado de valores, este es un problema de regresión y el estimador se conoce como
 regresor. (Dietterich, 1998).

Tanto el clasificador como el regresor son funciones que reciben un no-ejemplo.
 etiqueta y produce una salida: en el caso del clasificador, asigna el ejemplo a una de las clases.
 posible; en el caso del regresor, estima un valor real correspondiente al ejemplo presentado.
 La figura 2 ilustra la definición de clasificación y regresión. (Carvalho et al., 2021).

Figura 2 – Gráfico que representa la clasificación y la regresión.



Fuente: Carvalho et al. (2021), pág. 49.

2.3.3 Algoritmos de regresión

El árbol de decisión CART (Árboles de Clasificación y Regresión) es un algoritmo de regresión.

que construye una estructura de decisión jerárquica basada en divisiones recursivas de los datos, utilizando criterios como Gini o Entropía para minimizar las impurezas, haciéndolo interpretable y robusto frente a valores atípicos (Breiman et al., 1984).

El Bosque Aleatorio (RF) extiende CART a través de un conjunto de

Múltiples árboles (bagging + aleatoriedad de características), reduciendo la varianza y el sobreajuste, con predicciones agregadas por el promedio (Breiman, 2001).

La robustez de este método respalda su viabilidad técnica en ingeniería civil, como lo demuestran los estudios.

Estudios recientes validan la aplicación de CART y Random Forest en la predicción de f_{ck} , según los estándares NBR. 6118 (2023) y NBR 12655 (2022), que enfatizan el control de variables como la razón f_{ct}/f_{ck} y la curar.

Silva et al. (2023) analizaron hormigones brasileños utilizando Random Forest, obteniendo $R^2 = 0,95$ y destacando f_{ct}/f_{ck} y f_{ct}/f_{ck} y f_{ct}/f_{ck} como principales predictores. Omotayo, Arum e Ikumapayi (2024),

A su vez, compararon los métodos de aprendizaje automático, con RF superando a CART (RMSE = 3,2 MPa).

vs. 4,8 MPa). Por otro lado, Xu et al. (2021) propusieron un modelo de conjunto para el hormigón.

listo, logrando $R^2 = 0,92$ en trazas variables.

El algoritmo de K-vecinos más cercanos (KNN) es un algoritmo de aprendizaje basado en instancias.

que realiza predicciones basadas en la similitud entre muestras en el espacio de atributos.

A diferencia de los modelos basados en árboles, KNN no construye una función de

Mapeo explícito durante el entrenamiento, pero almacena todo el conjunto de datos para

para hacer inferencias en el momento de la predicción.

2.4 Métricas para evaluar modelos de regresión

Evaluar el rendimiento de los modelos de aprendizaje automático, especialmente en Tareas de regresión, como predecir la resistencia a la compresión característica (f_{ck}) de

En concreto, estos aspectos son cruciales para determinar su exactitud y su capacidad de generalización.

Las métricas estadísticas nos permiten cuantificar la discrepancia entre los valores predichos por el modelo. y los valores observados reales, proporcionando una base objetiva para la comparación y selección de algoritmos (Harrison, 2020; Carvalho, 2021). Por lo tanto, la elección apropiada de métricas es fundamental para comprender las características de los errores del modelo y su adecuación a problema en cuestión.

2.4.1 Coeficiente de determinación (R^2)

El coeficiente de determinación, o R^2 , es una métrica ampliamente utilizada para evaluar la proporción de la varianza de la variable dependiente (f) explicada por las variables independientes del modelo. Su valor oscila entre 0 y 1, donde los valores más cercanos a 1 indican que el modelo explica una mayor porción de la variabilidad de los datos, es decir, presenta un mejor ajuste. Es calculado según la ecuación 1:

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

Dónde

R^2 = Coeficiente de determinación

\hat{y}_i = función predictiva y_i = Atributo objetivo conocido. Representa el valor real de f para la i -ésima muestra.

\bar{y} = valor predicho por el modelo para la i -ésima muestra.

\bar{y} = Promedio de los valores reales de f .

n = número total de muestras.

Para los modelos Random Forest aplicados a la predicción de f_{ck} , se espera un R^2 entre 0,92. y 0,98, lo que indica un alto poder explicativo.

2.4.2 ERROR CUADRADO MEDIO (MSE) Y RAÍZ DEL ERROR CUADRADO MEDIO (RMSE)

El error cuadrático medio (ECM) mide el promedio de los cuadrados de los errores, es decir, la diferencia

Año VII, vol. 1 2026 | Envío: 23/05/2026 | Aceptado: 26/05/2026 | Publicación: 29/05/2026

entre los valores previstos y los valores reales. Es una métrica que penaliza los errores de forma mayores. El factor más significativo es la elevación al cuadrado de la ecuación, lo que la hace sensible a los valores atípicos. El RMSE es el... misma métrica que MSE, pero normalizada a la misma unidad que la variable objetivo, lo que hace — El análisis e interpretación del error se vuelven más intuitivos. El MSE se define según la ecuación 2 y El RMSE según la ecuación 3:

$$() = - (- ()) \tag{2}$$

Dónde:

Error promedio

$$() = \sqrt{\quad} \tag{3}$$

Dónde:

= Error cuadrático medio

2.4.3 ERROR ABSOLUTO MEDIO (MAE)

El error absoluto medio (MAE) calcula el promedio de los valores absolutos de los errores. A diferencia de A diferencia del MSE/RMSE, el MAE no eleva al cuadrado los errores, lo que lo hace menos sensible a los valores atípicos. y más robusto en distribuciones de error con valores extremos. El MAE se expresa mediante

Ecuación 4:

$$() = - [-()] \tag{4}$$

Dónde:

Error absoluto medio



Año VII, vol. 1 2026 | Envío: 23/05/2026 | Aceptado: 26/05/2026 | Publicación: 29/05/2026

2.4.4 Flujo de análisis y evaluación de residuos

Además de las métricas cuantitativas, análisis gráfico de residuos (diferencias entre valores) (observado y predicho) es fundamental (Hoefelmann, 2021). Esta evaluación permite Identifique las características de un buen modelo: residuos distribuidos simétricamente alrededor de Partiendo de cero, sin patrones discernibles, lo que indica que los errores son aleatorios y que no existe sesgo. sistemático en las predicciones (Harrison, 2020).

Los gráficos de residuos frente a valores predichos o frente a variables independientes pueden revelar Problemas como la heterocedasticidad o las variables omitidas. Por lo tanto, el flujo de evaluación Los modelos de aprendizaje automático normalmente implican dividir el conjunto de datos en Subconjuntos de entrenamiento y prueba (train_test_split) para garantizar que el modelo sea Evaluado en base a datos no vistos durante el entrenamiento.

Para una evaluación más sólida y para mitigar la dependencia de la división específica de los datos, Se emplean técnicas como la validación cruzada k-fold. En ella, la El conjunto de datos se divide en 'k' partes, y el modelo se entrena y prueba 'k' veces, utilizando En cada iteración se prueba una parte diferente; luego, las métricas se calculan como el promedio. de los resultados 'k'.

Estas métricas de evaluación (R^2 , RMSE, MAE) se aplicaron en contextos del mundo real y se alinearon. a NBR 12655 para pruebas f_c . Los estudios de Hoefelmann (2021) y Chou et al. (2011) Confirman la robustez de RF para capturar no linealidades en el curado y los agregados, con Residuos aleatorios que indican una buena generalización.

3 PROCEDIMIENTOS METODOLÓGICOS

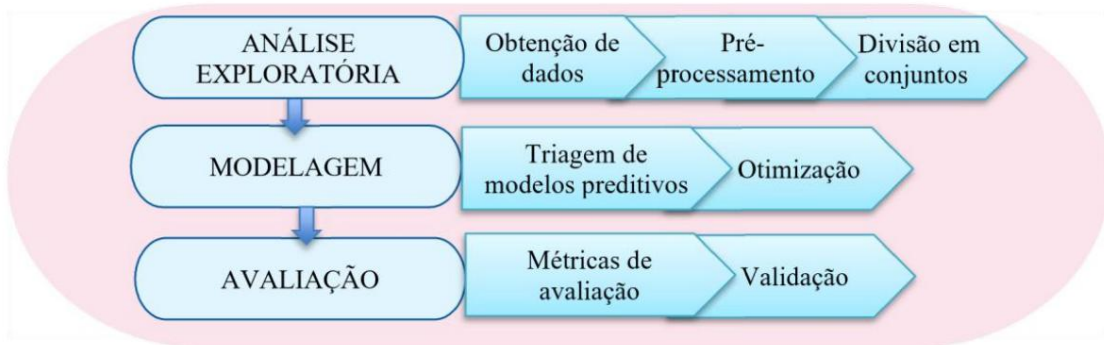
Este capítulo presenta el enfoque metodológico establecido para llevar a cabo el trabajo. comprender las fases desde la recopilación de datos hasta la verificación del modelo predictivo, dado el propósito de crear un sistema de aprendizaje automático capaz de estimar el resistencia a la compresión (f_{ck}) del hormigón en función de su composición.

El estudio comienza con una revisión bibliográfica para proporcionar una base técnica para la investigación. seguido del uso de una base de datos de una planta de hormigón local.

Una vez definido el conjunto de datos, comenzó la fase de análisis, que consistió en extraer los... variables, su preprocesamiento y su posterior partición en muestras de entrenamiento y de prueba. Durante la fase de modelado, se realizó una selección inicial entre varios algoritmos de regresión.

Para comparar, avanzando hacia la optimización de aquel con el mejor rendimiento. Finalmente, la etapa de evaluación describe los indicadores de desempeño y el proceso de validación de la herramienta desarrollada. La Figura 3 presenta el diagrama de flujo metodológico que resume el proceso de trabajo.

Figura 3 – Fluxograma metodológico



Fonte: Os autores (2026).

El procesamiento de datos y el desarrollo de algoritmos se llevaron a cabo en el lenguaje Python, utilizando la distribución Anaconda y la aplicación Jupyter.

3.1 CONJUNTO DE DATOS

Para garantizar la integridad, relevancia y conformidad de la información con el alcance establecido. Para esta investigación, se eligió un conjunto de datos que abarca parámetros de dosificación y resultados de las pruebas de resistencia a la compresión. Este conjunto de datos se compone de registros reales recopilados directamente en una planta de dosificación de concreto ubicada en el municipio de Brusque/SC. Los datos se extrajeron de informes técnicos de producción y pruebas de laboratorio, incluyendo: un muestreo riguroso que refleje las condiciones prácticas de fabricación y el control tecnológico de la región.

Tabla 2 – Parámetros de traza

Componente de cemento	Arena Artificial	Arena natural	Brita 1	Brita 0	Agua, aditivo superplastificante
Línea 1	277	522	352	655 276 185 2.2	488 320 195 0.0
Línea 2	360	449 454 Fuente:	1.08		1.08

Los autores (2026).

Con base en la composición de los rasgos presentados en la Tabla 2, se llevaron a cabo los siguientes pasos:



Año VII, vol. 1 2026 | Envío: 23/05/2026 | Aceptado: 26/05/2026 | Publicación: 29/05/2026

Procedimientos de moldeo y curado para probetas cilíndricas de ensayo para cada diseño de mezcla experimental. Para asegurar la representatividad de la muestra y la fiabilidad de los resultados, se realizaron moldes en serie para cada dosis, siguiendo estrictamente los criterios de compactación y curado húmedo. Las lecturas de resistencia a la compresión se obtuvieron mediante a partir de la rotura de las muestras de prueba en una prensa hidráulica debidamente calibrada, con registros realizado a los 28 días de edad. El conjunto de datos resultante, consolidado a partir de los informes técnicos de la planta regional sirvieron de base para la capacitación y validación de modelos predictivos.

3.1 PREPROCESAMIENTO

3.1.1 INTEGRACIÓN

El conjunto de datos utilizado en esta investigación fue compilado a partir de... Registros técnicos de la planta regional, que integran variables de dosificación y resultados de resistencia en una base de datos unificada. Esta base de datos está compuesta por 10 columnas de atributos, que abarca los componentes de la mezcla (cemento, arena artificial, arena natural, piedra triturada 1, piedra triturada 0, Agua, aditivo y superplastificante) y los resultados de rendimiento mecánico (R7 y R28). En total, se procesaron 300 registros de muestras de prueba reales. Después de la integración y... Después de la estructuración, los datos se exportaron al entorno Jupyter en formato .csv, lo que permitió Inicio de los procedimientos de preprocesamiento y análisis predictivo.

3.1.2 EVALUACIÓN DE ATRIBUTOS

La fase de evaluación de atributos se llevó a cabo con el objetivo de seleccionar las variables de mayor poder predictivo y garantía de la integridad estadística del modelo. Se eliminaron los siguientes elementos: registros de identificación de los especímenes de prueba (ID CP), así como las columnas que se presentaron valores constantes o valores que no presentaban variabilidad relevante para el aprendizaje algoritmo. A diferencia de los identificadores, el resultado de resistencia de 7 días (R7) se mantuvo en conjunto de datos. La persistencia de este atributo permite que el modelo capture la cinética de endurecimiento inicial del hormigón, que sirve como un valioso indicador técnico para la predicción desde la resistencia hasta los 28 días (R28). Esta integración permite que el algoritmo identifique patrones de ganancia de resistencia que dependen de la interacción química entre el cemento y los aditivos para

con el tiempo.

La exclusión de estas variables se realizó utilizando la función `.drop` de la biblioteca Pandas, que

Esto nos permitió optimizar el conjunto de datos. Con este procedimiento, la estructura del conjunto de datos fue...

refinado, conservando solo los atributos esenciales para el modelado, lo que reduce la

complejidad computacional y mitiga el riesgo de sobreajuste. La figura 4 muestra

el resumen estadístico del conjunto de datos

Figura 4 – Datos estadísticos de los atributos.

	Cemento	Areia Artificial	Areia Natural	Brita 1	Brita 0	Água	Aditivo	Superplastificante	R7 (Mpa)	R28 (Mpa)
count	300.000000	300.000000	300.000000	300.000000	300.000000	300.000000	300.000000	300.000000	300.000000	300.000000
mean	304.666667	497.666667	386.000000	599.333333	290.666667	188.333333	2.140000	0.360000	27.845667	33.617667
std	39.191950	34.470028	48.163601	78.856091	20.776455	4.721922	0.113326	0.509968	3.249906	2.726052
min	277.000000	449.000000	352.000000	488.000000	276.000000	185.000000	1.980000	0.000000	20.100000	25.800000
25%	277.000000	449.000000	352.000000	488.000000	276.000000	185.000000	1.980000	0.000000	25.675000	31.600000
50%	277.000000	522.000000	352.000000	655.000000	276.000000	185.000000	2.220000	0.000000	27.600000	34.000000
75%	360.000000	522.000000	454.000000	655.000000	320.000000	195.000000	2.220000	1.080000	30.000000	35.500000
max	360.000000	522.000000	454.000000	655.000000	320.000000	195.000000	2.220000	1.080000	35.000000	41.200000

Fuente: Los autores (2026).

3.1.3 ESTANDARIZACIÓN

La estandarización de datos es un paso previo al procesamiento que tiene como objetivo normalizar las escalas.

de las variables, asegurando que todas tengan una media de cero y una desviación estándar de uno.

Este procedimiento es fundamental para el rendimiento de los algoritmos de aprendizaje automático.

porque impide que los atributos de mayor magnitud ejerzan influencia.

desproporcionado durante el entrenamiento del modelo.

En el contexto de esta investigación, la aplicación de la estandarización se justifica por la disparidad numérica.

Entre las variables de entrada se encuentran el consumo de cemento (en kg/m^3) y el contenido de aditivos.

Para realizar esta tarea, se utilizó la función `StandardScaler`, disponible en el módulo.

preprocesamiento de la biblioteca Scikit-learn.

3.2 DIVISIÓN DE LOS CONJUNTOS DE DATOS

La etapa inicial en la construcción de una arquitectura predictiva consiste en entrenar el algoritmo.

con la base de datos consolidada. Para ello, se utilizó la biblioteca `scikit-learn`.

(`sklearn`), específicamente a través de la función `train_test_split`. Esta característica permite dividir

La información se distribuyó aleatoriamente en dos grupos distintos: uno centrado en el aprendizaje y el otro...

Año VII, vol. 1 2026 | Envío: 23/05/2026 | Aceptado: 26/05/2026 | Publicación: 29/05/2026

dedicado a validar los resultados. En esta investigación, se definió que el 80% de los registros serían El 20% restante se destinó a la formación y el 20% restante a la fase de pruebas.

Para garantizar una evaluación imparcial del rendimiento del sistema, los datos se dividieron en conjuntos de entrenamiento y prueba. Esta distribución garantiza que la efectividad del modelo sea Validado con datos no vistos durante la fase de aprendizaje. La organización de las variables.

(los atributos) se estructuraron de la siguiente manera:

- X_{train} : incluye los atributos predictores (dosis) utilizados para el aprender del modelo;
- y_{train} : almacena la variable objetivo correspondiente a la resistencia a la compresión. (fck) para entrenamiento;
- X_{test} : incluye las variables de entrada que se utilizarán para probar la precisión de modelo;
- y_{test} : contiene los valores de resistencia reales asociados con X_{test} , lo que permite Verificación estadística de las previsiones.

Esta metodología de partición de datos es esencial para verificar el potencial de Generalización del modelo ante nuevas dosis, mitigando el riesgo de sobreajuste de los datos originales.

3.3 Evaluación preliminar de algoritmos de regresión

Con el objetivo de identificar el algoritmo con la mayor capacidad de generalización para el Para estimar la resistencia del hormigón, se realizó una evaluación comparativa inicial entre los Los modelos de regresión están disponibles en la biblioteca scikit-learn. Para garantizar la selección de Se evaluaron los siguientes algoritmos para determinar el modelo más eficiente y robusto:

- Regresión lineal (`sklearn.linear_model`): modelo estadístico clásico para análisis de relaciones lineales;
- Regresor de árbol de decisión — CART (`sklearn.tree`): algoritmo que subdivide los datos en estructuras jerárquicas;
- Regresor de bosque aleatorio (`sklearn.ensemble`): técnica de un conjunto que combina múltiples árboles de decisión;
- Regresor de vectores de soporte (SVR) (`sklearn.svm`): un algoritmo que busca Encuentra el mejor hiperplano para la regresión.

- K vecinos más cercanos — KNN (sklearn.neighbors): un modelo basado en similitud y proximidad de los datos;

El entrenamiento de cada modelo se realizó utilizando la función `fit(X_train, y_train)`, que envía los parámetros de dosificación y sus respectivos resultados de resistencia a procesamiento de algoritmos. Este procedimiento permite a los algoritmos identificar patrones e interdependencias presentes en el conjunto de datos. Después de la fase de entrenamiento, se utilizó lo siguiente: Se utilizó la función `predict(X_test)` para que los modelos pudieran procesar las variables del conjunto de prueba, generando el vector `y_pred`. Este conjunto almacena las estimaciones producidas por cada algoritmo. regresión (enumerada anteriormente), lo que permite un análisis estadístico posterior en relación con Valores reales medidos en el laboratorio.

3.4 EVALUACIÓN DE LOS MODELOS

La evaluación de la efectividad de los modelos detallados en la sección anterior se llevó a cabo con base en Cuatro indicadores de regresión estadística: R^2 , MAE, MSE y RMSE. Estas métricas permiten Compare los resultados reales obtenidos en el conjunto de prueba (`y_test`) con las estimaciones generadas, a través de algoritmos (`y_pred`), que permiten cuantificar la precisión de las predicciones. La implementación de estos indicadores se llevó a cabo a través de funciones específicas de La biblioteca scikit-learn. El coeficiente R^2 nos permitió verificar el porcentaje de varianza explicada, por el modelo, mientras que MAE y RMSE proporcionaron la magnitud del error medio y el sensibilidad a desviaciones mayores, respectivamente.

3.5 Optimización de algoritmos

El rendimiento del modelo predictivo mejoró a través de la configuración de hiperparámetros, ajustando los parámetros internos de los algoritmos para aumentar la precisión y robustez de las estimaciones. Para ello, se utilizó la técnica de búsqueda aleatoria, con Se realizó una validación cruzada utilizando la función `RandomizedSearchCV` de la biblioteca scikit-learn. Este enfoque permitió explorar de manera eficiente diversas combinaciones de parámetros previos, definido.

Los hiperparámetros y sus respectivos rangos de variación se definieron de acuerdo con la Detalles del modelo K-Vecinos más cercanos (KNN). La búsqueda se configuró para procesar un número determinado de combinaciones aleatorias y, al final del procedimiento,



Año VII, vol. 1 2026 | Envío: 23/05/2026 | Aceptado: 26/05/2026 | Publicación: 29/05/2026

Se seleccionó la configuración que mostró el mejor rendimiento promedio en la validación.

elaborar la versión final del modelo predictivo.

3.6 VALIDACIÓN DEL MODELO

Para validar el algoritmo desarrollado en esta investigación, se adoptaron dos procedimientos.

distinto. El primero consistió en la validación cruzada de datos históricos de la planta de Brusque,

integrado en el proceso de entrenamiento estándar de aprendizaje automático. El segundo procedimiento

Esto implicó una validación utilizando datos experimentales recopilados en la propia planta, con el propósito de

para verificar la capacidad del modelo para generalizar a dosis sin precedentes que no fueron

presentado durante la fase de aprendizaje.

3.6.1 Validación con datos experimentales

Para validar el algoritmo desarrollado, se realizó un paso de verificación utilizando datos.

Los experimentos se realizaron directamente en la planta de dosificación. El objetivo de este procedimiento era...

para probar la capacidad del modelo para generalizar a dosis del mundo real que no incluían la

conjunto de entrenamiento inicial. Los rasgos se seleccionaron para replicar las condiciones

aspectos operativos de la base de datos, manteniendo las mismas especificaciones de entrada y relaciones.

Las relaciones agua/cemento se presentan en la Tabla 2.

La recopilación de datos siguió los estándares del laboratorio de la planta, en los que los resultados de

La resistencia a la compresión se midió utilizando prensas hidráulicas calibradas, según

las normas NBR 5738 y NBR 5739. A diferencia del método de mecanizado y medición de

rugosidad propuesta por Canal (2022), esta validación se basó en el control tecnológico.

del hormigón endurecido a los 28 días. Los nuevos valores fueron debidamente tabulados y

importado al entorno Jupyter, donde, utilizando la función `predict(X_valid)`, se generó

el conjunto de predicciones `y_pred_valid`.

Finalmente, los resultados reales de las dosis experimentales se compararon con los

Estimaciones generadas por el algoritmo. El rendimiento se evaluó utilizando la métrica R^2 .

Los valores de MAE, MSE y RMSE, además del análisis de residuos, dan fe de la fiabilidad de la herramienta.

para aplicaciones prácticas en el control de la resistencia del hormigón regional.

4. ANÁLISIS DE RESULTADOS

Esta sección presenta los principales hallazgos resultantes de la aplicación de los modelos de regresión a datos experimentales, con énfasis en la variable dependiente resistencia a Compresión del hormigón (f_{ck}). En primer lugar, se describen las métricas de rendimiento obtenidos en la etapa de evaluación preliminar de los modelos, seguidos de una comparación entre los Se probaron diferentes algoritmos, destacando el SVR y el árbol de decisión de regresor, que En esta fase inicial mostraron un rendimiento similar y los mejores resultados. Posteriormente, se examina el impacto de los hiperparámetros en el comportamiento del modelo. Se realiza la interpretación de las métricas de error y la distribución residual, lo que hace posible una evaluación fiable de los resultados. Finalmente, se presentan las pruebas realizadas. datos del experimento, con el objetivo de evaluar la capacidad del modelo para generalizar el Datos no observados durante el entrenamiento.

4.1 RESULTADOS DE LA EVALUACIÓN PRELIMINAR DE LOS ALGORITMOS

La Tabla 3 presenta los indicadores de rendimiento de los algoritmos evaluados en la etapa. Resultados preliminares. El algoritmo SVR (Regresión de Vectores de Soporte) destacó en esta fase. presentando el coeficiente de determinación (R^2) más alto.

Tabla 3 – Resultados de la evaluación preliminar

Algoritmo	R2	MADRE	MSE	RMSE
SVR	0,76	0,48	0,63	0,76 0,75 0,48
Árbol de decisión	0,65	0,81	0,70	0,61 0,79 0,89
KNNighbors	0,63	0,69	0,96	0,98 0,63 0,69
Bosque aleatorio	0,96	0,98		
Regresión				

lineal. Fuente: Los autores (2026).

4.2 OPTIMIZACIÓN DEL ALGORITMO SVR

Los algoritmos SVR (Regresión de Vectores de Soporte) y de Regresor de Árbol de Decisión fueron sometido a un proceso de ajuste de hiperparámetros utilizando la función RandomizedSearchCV, con el propósito de identificar la mejor configuración para el conjunto de datos de los datos en cuestión. La búsqueda se parametrizó para probar 50 combinaciones aleatorias de hiperparámetros dentro de

intervalos preestablecidos para cada algoritmo. Una vez completada la ejecución, Se seleccionó la combinación que mostró el mejor rendimiento en el conjunto de validación, como la configuración final de cada modelo. Los hiperparámetros sometidos a esta búsqueda, En las tablas se muestran sus respectivos rangos de variación y los valores óptimos identificados. 4 y 5.

Tabla 4 – Selección de hiperparámetros - Intervalos del kernel del algoritmo SVR

kernel del algoritmo SVR	Mejor parámetro
[lineal, sigmoide] [0,1, 1, 10, 100] rbf, escala polinomial.	Por definir
W	Por definir
Épsilon [0.01, 0.1, 0.2, 0.5]	Por definir
Gamma [escala, automático, 0.01, 0.1] TBD	Grado [2, 3, 4]
determinar Tol [1e-3, 1e-4, 1e-5]	Por definir

Fuente: Los autores (2026).

Tabla 5 – Selección de hiperparámetros – Regresor de árbol de decisión Mejor

Algoritmo	Intervalos	parámetro
Criterio	[squared_error, friedman_mse, absolute_error, poisson]	Por definir
[Ninguno, 10, 20, 30]		max_depth
min_samples_split [2, 5, 10]		TBD
min_samples_leaf [1, 2, 4]		Por definir
max_features [sqrt, log2, None]	ccp_alpha [0.0, 0.01, 0.1]	Por definir
		Por definir

Fuente: Los autores (2026).

4.3 Importancia de las características

Análisis de importancia de atributos, que cuantifica la contribución de cada variable en Las predicciones del modelo mostraron que R7 y R28 (resistencias del hormigón a los 7 y 28 días) son... los factores más determinantes para la predicción. Estos resultados son consistentes, ya que el La resistencia inicial y final del hormigón refleja directamente la calidad de la mezcla y su capacidad para desarrollar resistencia. Los otros parámetros del rasgo también mostraron contribuciones significativas. Sin embargo, se identificó que el rasgo 2 generaba valores atípicos. (valores atípicos) que afectaron el rendimiento del modelo.

Año VII, vol. 1 2026 | Envío: 23/05/2026 | Aceptado: 26/05/2026 | Publicación: 29/05/2026

4.4 TRABAJO FUTURO: PRUEBAS EXPERIMENTALES CON SVR Y DECISIÓN

ÁRBOL

Este trabajo consistió en una revisión bibliográfica sobre la aplicación de algoritmos.

Aprendizaje automático para predecir la resistencia a la compresión del hormigón (f_{ck}), con énfasis

en los modelos SVR (Regresión de Vectores de Soporte) y de Regresor de Árbol de Decisión. La justificación

El marco teórico presentado, junto con una descripción de los procedimientos metodológicos y...

Las métricas de evaluación proporcionaron la base conceptual necesaria para la continuación de investigación.

Como paso futuro, se planean pruebas experimentales con los algoritmos SVR y

Regresor de árbol de decisión, utilizando el conjunto de datos descrito en la sección 3.1. Ambos

Los modelos se someterán a un proceso de optimización de hiperparámetros utilizando la función.

Búsqueda aleatoria CV, dentro de intervalos preestablecidos, con el objetivo de

Identificar la configuración con el mejor rendimiento predictivo.

Tras la fase de optimización, los modelos serán validados con datos experimentales y evaluados.

Basado en las métricas R^2 , MAE, MSE y RMSE. Análisis comparativo de los resultados.

Esto nos permitirá identificar cuál de los dos algoritmos ofrece el mejor equilibrio entre precisión y...

capacidad de generalización para predecir f_{ck} , contribuyendo a la mejora de

Control tecnológico del hormigón en ingeniería civil.

CONSIDERACIONES FINALES

Este artículo presenta una revisión de la literatura sobre la aplicación de técnicas de

Aprendizaje automático para predecir la resistencia a la compresión del hormigón (f_{ck}), con énfasis

en los algoritmos SVR (Regresión de Vectores de Soporte) y de Regresor de Árbol de Decisión. A

La base teórica abordó los conceptos principales relacionados con la tecnología del hormigón.

a los factores que influyen en su resistencia y a los fundamentos de los modelos predictivos, así como

como las métricas de evaluación utilizadas en la literatura especializada.

Con base en la revisión realizada, fue posible determinar que el uso de algoritmos de regresión

Esto ha demostrado ser un enfoque prometedor para estimar f_{ck} en función de los parámetros de

dosis y datos históricos de producción. La bibliografía consultada indica que tanto SVR como el árbol de

decisión tienen el potencial de capturar relaciones no lineales entre variables.

entrada y resistencia del hormigón, que pueden ayudar en el control tecnológico y en

Año VII, vol. 1 2026 | Envío: 23/05/2026 | Aceptado: 26/05/2026 | Publicación: 29/05/2026

Optimización de funcionalidades.

El análisis de los procedimientos metodológicos descritos en estudios relacionados permitió identificar los pasos fundamentales para el desarrollo de modelos predictivos, incluyendo los preprocesamiento de datos, división de conjuntos de entrenamiento y prueba, evaluación Algoritmos preliminares y optimización de hiperparámetros. Las métricas R^2 , MAE, MSE y Las mediciones de RMSE resultaron adecuadas para la evaluación comparativa del rendimiento del modelo. Cabe señalar que este trabajo constituye una etapa inicial de investigación, cuyos objetivos principales son... contribuciones a la sistematización del marco teórico y a la definición de la metodología a utilizar aplicado. Pruebas experimentales con los algoritmos SVR y Decision Tree Regressor, incluyendo Optimización de hiperparámetros mediante RandomizedSearchCV y validación con datos reales. Estas se llevarán a cabo en una fase posterior, lo que representa la continuación natural de esta investigación. Se espera que los resultados futuros contribuyan a la mejora del control tecnológico. El hormigón en la ingeniería civil, integrando métodos tradicionales con herramientas avanzadas. análisis de datos y permitir estimaciones de resistencia más rápidas y eficientes material incluso antes de que se realizaran las pruebas a los 28 días.

REFERENCIAS

- Asociación Brasileña de Normas Técnicas. NBR 5738: Hormigón — Procedimiento para el moldeo y curado de probetas. Río de Janeiro, 2015.
- Asociación Brasileña de Normas Técnicas. NBR 5739: Hormigón — Ensayo de compresión de probetas cilíndricas. Río de Janeiro, 2018.
- Asociación Brasileña de Normas Técnicas. NBR 6118: Diseño de estructuras de hormigón — Procedimiento. Río de Janeiro, 2023.
- Asociación Brasileña de Normas Técnicas. NBR 12655: Hormigón de cemento Portland — Preparación, control, recepción y aceptación — Procedimiento. Río de Janeiro, 2022.
- BISHOP, CM. Reconocimiento de patrones y aprendizaje automático. Nueva York: Springer, 2006.
- BREIMAN, L. Bosques aleatorios. Aprendizaje automático, vol. 45, n.º 1, págs. 5-32, 2001.
- BREIMAN, L. et al. Árboles de clasificación y regresión. Nueva York: Chapman & Hall, 1984.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. Aprendizaje profundo. Cambridge: MIT Press, 2016.
- HÉLENE, P.; TERZIAN, P. Manual de diseño y control de mezclas de concreto. São Paulo: Pini, 1992.

Año VII, vol. 1 2026 | Envío: 23/05/2026 | Aceptado: 26/05/2026 | Publicación: 29/05/2026

MEHTA, PK; MONTEIRO, PJM Concreto: microestructura, propiedades y materiales. 2da ed. São Paulo: IBRACON, 2014.

NEVILLE, AM Propiedades del hormigón. 5.^a ed. Londres: Pearson, 2011.

OMOTAYO, T.S.; ARUM, C.; IKUMAFAYI, CM Análisis comparativo de modelos de aprendizaje automático para predecir la resistencia a la compresión del hormigón. Revista Asiática de Ingeniería Civil, vol. 25, págs. 1-12, 2024.

SILVA, R. et al. Predicción de la resistencia a compresión del hormigón mediante el algoritmo Random Forest. Revista Ibracon de Estructuras y Materiales, vol. 16, n.º 2, págs. 1-15, 2023.

XU, J. et al. Modelos de aprendizaje conjunto para predecir la resistencia a la compresión del hormigón— Construcción y materiales de construcción, vol. 303, págs. 124-132, 2021.