

**Impacto del uso de técnicas de aprendizaje automático (Machine Learning) en la evaluación
y mejora de la resistencia estructural de las edificaciones**

Adiel Berrio Pertuz

Asesor

Luis Angel Anillo Arrieta

Issac Esteban Camargo Freile

Universidad Nacional Abierta y a Distancia UNAD

Escuela de Ciencias Básicas Tecnología e Ingeniería ECBTI

Especialización en Ciencia de Datos y analítica

2025

Resumen

El uso de técnicas de aprendizaje automático (machine learning) ha tenido un impacto significativo en la evaluación y mejora de la resistencia estructural de edificaciones, un tema ampliamente tratado por diversos autores. En estudios realizados por por Gómez-Cabrera y Escamilla Ambrosio, subrayan la importancia de comprender cómo estas herramientas contribuyen a la predicción de la resistencia estructural, la optimización del diseño, la detección de anomalías y el mantenimiento predictivo de los edificios. La aplicación de estas técnicas es fundamental para mejorar la evaluación y el fortalecimiento de las estructuras, lo que permite el desarrollo de edificaciones más seguras, eficientes y resistentes frente a diversas cargas y condiciones ambientales.

La presente tesis aborda el impacto del uso de técnicas de aprendizaje automático en la evaluación y mejora de la resistencia estructural de edificaciones. Este tema es importante debido a la necesidad de optimizar la seguridad y durabilidad de las construcciones, minimizando riesgos y costos. El estudio busca llenar el vacío en el conocimiento sobre la aplicación de algoritmos de machine learning para identificar factores críticos y predecir fallas en edificaciones. El objetivo principal es determinar la efectividad de estas técnicas en la evaluación y optimización de la resistencia estructural. La metodología fue de carácter bibliográfico, con un enfoque cuantitativo que utilizó análisis de literatura especializada y modelos de machine learning. Los resultados muestran que el aprendizaje automático puede mejorar significativamente la detección de fallas y la predicción de riesgos estructurales. Se concluye que estas tecnologías aportan a la ingeniería civil, sugiriendo futuras investigaciones en integración con sistemas de monitoreo en tiempo real.

Palabras claves: Aprendizaje automático, Estructural, Resistencia, Optimización, Edificaciones

Abstract

The use of machine learning techniques has had a significant impact on the evaluation and improvement of the structural resistance of buildings, a topic widely covered by various authors. These studies highlight the importance of understanding how these tools contribute to structural strength prediction, design optimization, anomaly detection, and predictive maintenance of buildings. The application of these techniques is essential to improve the evaluation and strengthening of structures, which allows the development of safer, more efficient and resistant buildings against various loads and environmental conditions.

This thesis addresses the impact of using machine learning techniques in the assessment and improvement of the structural strength of buildings. This topic is important due to the need to optimize the safety and durability of buildings, minimizing risks and costs. The study seeks to fill the knowledge gap regarding the application of machine learning algorithms to identify critical factors and predict failures in buildings. The main objective is to determine the effectiveness of these techniques in the assessment and optimization of structural strength. The methodology was bibliographical, with a quantitative approach that utilized analysis of specialized literature and machine learning models. The results show that machine learning can significantly improve fault detection and prediction of structural risks. It is concluded that these technologies contribute to civil engineering, suggesting future research in integration with real-time monitoring systems.

Keywords: Machine Learning, Structural, Resilience, Optimization, Buildings

Tabla de Contenido

Introducción	7
Justificación.....	9
Objetivos	14
General.....	14
Específicos	14
Planteamiento del Problema.....	15
Marco de Referencia	18
Marco Conceptual	18
Marco Teórico.....	21
Metodología	23
Casos Prácticos Destacados en Colombia.....	28
Aplicación de Técnicas de Machine Learning en el Diseño Estructural para la Resiliencia ante Desastres Naturales	29
Evaluación de Implicaciones Prácticas y Económicas de la Integración del Machine Learning en Ingeniería Civil	31
Implicaciones Prácticas y Económicas de Integrar Técnicas de Machine Learning en la Ingeniería Civil y la Construcción	31
Implicaciones Económicas.....	32
Implementación de Machine Learning en Ingeniería Civil y Construcción	34
Conclusiones	36
Recomendaciones.....	39
Referencias Bibliográficas	40

Lista de Tablas

Tabla 1 *Operacionalización de Variables*24

Lista de Figuras

Figura 1 *Nube de Palabras Relevantes en las Investigaciones*20

Figura 2 *Comparación entre el Diseño del Puente y Material de Construcción*29

Introducción

El uso de técnicas de aprendizaje automático (machine learning) ha revolucionado la evaluación y mejora de la resistencia estructural de edificaciones. Varios autores han estudiado su potencial para cambiar el diseño, construcción y mantenimiento de estructuras. García, Echevery y Mesa (2013) destacan cómo el machine learning influye en la predicción de la resistencia estructural, optimización del diseño, detección de anomalías y mantenimiento predictivo.

Además, la incorporación de impresoras 3D en la ingeniería civil impacta el desarrollo económico y la sostenibilidad. Medina (2018) señala que estas tecnologías permiten a los ingenieros mejorar la seguridad de las edificaciones, optimizar recursos y reducir costos a largo plazo.

La resistencia estructural es crucial en la construcción, ya que determina la capacidad de una edificación para soportar cargas y condiciones ambientales. Espinosa Zarate (2023) menciona que el machine learning puede fortalecer esta resistencia, permitiendo edificaciones más seguras y eficientes. Mediante modelos de predicción avanzados, es posible anticipar problemas y prevenir fallas estructurales, lo que es esencial en un entorno donde los fenómenos naturales son impredecibles.

La optimización del diseño se torna más ágil y efectiva al aprovechar el análisis de datos. Esto permite crear estructuras que cumplen con los estándares de seguridad y son sostenibles y adaptables a cambios ambientales.

Investigaciones previas han explorado este tema desde diversos enfoques, logrando avances significativos. Martos (2021) indica que se han desarrollado modelos que predicen la resistencia estructural, mejorando la capacidad de anticipar fallos en las edificaciones. Se han implementado técnicas que potencian la precisión de los modelos predictivos y facilitan la integración de sistemas de monitoreo basados en machine learning. Estos sistemas permiten un

seguimiento continuo de las condiciones estructurales, contribuyendo al mantenimiento preventivo y a la detección temprana de anomalías.

A pesar de los avances, persisten desafíos importantes. La integración efectiva de estas técnicas en el diseño y construcción de edificaciones exige colaboración interdisciplinaria. También es fundamental validar los modelos de predicción y entender cómo estos enfoques pueden influir en los estándares de construcción (Smarandache & Leyva-Vázquez, 2021).

El impacto del aprendizaje automático en la ingeniería civil va más allá de lo técnico. Puede tener repercusiones económicas y sociales positivas, al contribuir a edificaciones más seguras y eficientes. Esto mejora la calidad de vida y aumenta la resiliencia de las ciudades ante desastres naturales y cambios ambientales. Forero y Negre (2024) indican que, en un contexto donde la sostenibilidad y la seguridad son prioridades globales, el machine learning se posiciona como una herramienta clave para enfrentar los retos del siglo XXI en la construcción.

Justificación

La integración del machine learning en la ingeniería civil y la construcción se ha vuelto un recurso esencial para mejorar la infraestructura ante amenazas naturales. La urgencia de investigar su impacto en la resistencia estructural responde a la necesidad de desarrollar soluciones innovadoras que mitiguen los riesgos de eventos catastróficos (Salazar & López, 2024). Utilizando machine learning, es posible analizar grandes conjuntos de datos, identificar patrones y crear modelos predictivos que guíen el diseño de edificaciones más seguras y robustas (Serrano-Mamolar et al., 2023).

La creciente frecuencia de desastres naturales, como terremotos y huracanes, resalta la necesidad de enfoques avanzados para mejorar la resistencia estructural (Cruz, 2023). Al aprovechar las capacidades del machine learning, los ingenieros pueden analizar datos complejos y anticipar comportamientos estructurales. Esto permite un diseño más preciso y eficiente, optimizando materiales y aumentando la seguridad y durabilidad de las edificaciones (Robles-Joya & Sánchez-Quintanilla, 2022).

El estudio de Serrano et al. (2023) respalda esta perspectiva, destacando cómo el machine learning contribuye a identificar vulnerabilidades estructurales y formular estrategias de mitigación de riesgos. Los modelos predictivos que se desarrollan ofrecen información valiosa para la toma de decisiones a lo largo del ciclo de vida de un proyecto, desde la planificación hasta la gestión de riesgos a largo plazo. Estos modelos también ayudan a anticipar fallos estructurales, optimizar recursos y reducir costos de mantenimiento y reparación. Al integrarse con tecnologías como el Building Information Modeling (BIM) y sistemas de monitoreo en tiempo real, el machine learning mejora la evaluación del comportamiento estructural durante eventos adversos.

El uso de machine learning para analizar características estructurales y materiales permite una evaluación más rigurosa de los componentes de una edificación. Tradicionalmente, los

ingenieros se basan en pruebas físicas y análisis manuales, que pueden ser limitantes en tiempo y recursos. En contraste, los algoritmos de machine learning pueden identificar patrones estructurales mediante el análisis de datos de sensores y simulaciones (Moreno, 2017). Estos modelos predictivos pueden detectar signos de fatiga en los materiales antes de que se presenten problemas visibles, facilitando la comparación del rendimiento de diferentes materiales y optimizando su uso.

Las condiciones ambientales y geográficas son factores cruciales que afectan la resistencia estructural. Elementos como la humedad, las temperaturas extremas y la exposición a fenómenos naturales deben considerarse desde las etapas iniciales del diseño (Bautista & Inca Encarnación, 2023). El machine learning permite integrar datos geoespaciales y meteorológicos en tiempo real, creando modelos predictivos que analizan el comportamiento actual de la estructura y anticipan posibles riesgos futuros. Por ejemplo, si una edificación se ubica en una zona sísmica, los modelos de aprendizaje automático pueden prever el impacto de estos eventos y sugerir ajustes en el diseño o materiales.

Asimismo, el análisis de condiciones geográficas, como el tipo de suelo, permite personalizar el diseño de la estructura. El machine learning facilita el monitoreo continuo de estas condiciones, ajustando los modelos estructurales a medida que cambian (Padilla et al., 2020). Esto proporciona a los ingenieros herramientas para tomar decisiones informadas que optimicen la seguridad y durabilidad de las edificaciones.

El cumplimiento de normativas de construcción es esencial para garantizar la resistencia estructural. Estas regulaciones establecen requisitos mínimos para materiales y cargas, pero su cumplimiento puede ser un desafío debido a su evolución constante y la diversidad de enfoques de diseño (Bautista & Inca Encarnación, 2023). En este contexto, el machine learning permite evaluar la conformidad de los diseños con las normativas, identificando patrones en proyectos

anteriores que podrían pasar desapercibidos en revisiones manuales. Este enfoque ayuda a realizar ajustes precisos para asegurar el cumplimiento normativo y anticipar modificaciones futuras.

Además, el machine learning no solo verifica la adecuación a normativas, sino que también evalúa la viabilidad de distintos enfoques de diseño. Considerando la seguridad, factores económicos y sostenibles, puede recomendar soluciones que optimicen recursos sin comprometer la integridad de la estructura (García, 2019). Si un diseño no cumple con requisitos de resistencia sísmica, por ejemplo, el machine learning puede sugerir el uso de materiales más resistentes o redistribuir cargas para garantizar la seguridad.

El uso de machine learning mejora la precisión y eficiencia en el diseño estructural, asegurando edificaciones seguras y sostenibles, alineadas con los estándares del sector. La integración de estas técnicas representa una herramienta poderosa para fortalecer la infraestructura y mejorar la resiliencia ante amenazas naturales. Un ejemplo significativo es el impacto del huracán Katrina en 2005, que evidenció la vulnerabilidad de infraestructuras críticas y subrayó la necesidad de soluciones avanzadas que anticipen y mitiguen daños futuros (De León, 2020).

Se han implementado tecnologías de análisis predictivo que utilizan grandes volúmenes de datos para modelar el impacto de tormentas y optimizar el diseño de diques y sistemas de contención. Estas herramientas no solo fortalecen las infraestructuras ante fenómenos extremos, sino que también contribuyen a una planificación más eficiente y estratégica, protegiendo comunidades en riesgo y minimizando pérdidas económicas (De León, 2020).

Al profundizar en esta línea de investigación, se abre la posibilidad de avanzar hacia edificaciones que no solo cumplan con criterios de funcionalidad y estética, sino que sean

intrínsecamente seguras y resilientes frente a los desafíos de un entorno natural en constante cambio (Serebrisky et al., 2020).

Un estudio realizado en el puente de San Francisco-Oakland Bay utilizó algoritmos de machine learning para predecir fallos estructurales. Los datos obtenidos de sensores fueron analizados para identificar patrones que preceden a fallos, lo cual permitió implementar mantenimientos predictivos. Se reportó una reducción del 30% en los costos de mantenimiento gracias a la implementación de estas técnicas (Zhang et al., 2020).

En Japón, se utilizaron modelos de aprendizaje automático para evaluar el riesgo sísmico de edificios. Se incorporaron datos históricos de sismos y características estructurales para entrenar modelos que predicen el comportamiento de los edificios durante eventos sísmicos. Los modelos lograron aumentar la precisión de las predicciones de daños en un 25% en comparación con métodos tradicionales (Hirabayashi et al., 2019).

En un proyecto de infraestructura vial en Estados Unidos, se aplicaron técnicas de machine learning para optimizar la planificación de recursos. Esto permitió reducir el tiempo de construcción en un 15% y los costos en un 20%. Se logró una mejora del 40% en la asignación de recursos utilizando algoritmos de optimización basados en machine learning (Kuo et al., 2021).

En la ciudad de Nueva York, se implementó un sistema de monitoreo basado en machine learning para detectar deformaciones en estructuras críticas como puentes y túneles. Los algoritmos procesan datos de sensores en tiempo real para alertar sobre posibles problemas. Este sistema ha permitido detectar problemas potenciales con un 90% de precisión, lo que ha llevado a intervenciones oportunas y ha prevenido colapsos (Lee et al., 2022).

En Colombia, El Puente de La Línea, uno de los proyectos más emblemáticos de Colombia, ha sido monitoreado utilizando técnicas de ML para predecir el comportamiento estructural bajo condiciones climáticas adversas.

En regiones propensas a deslizamientos de tierra, se han desarrollado modelos de ML que analizan datos geoespaciales y meteorológicos para predecir eventos de deslizamientos. En el municipio de Manizales, se han implementado modelos predictivos que, al combinar datos históricos de deslizamientos con variables climáticas actuales, han mejorado la capacidad de respuesta ante estos eventos.

Las técnicas de ML se utilizan para optimizar el uso de materiales y la planificación de proyectos en construcción, lo que reduce costos y mejora la sostenibilidad. Proyectos como el Metro de Bogotá han comenzado a aplicar algoritmos de ML para mejorar la logística de suministro de materiales, lo que ha llevado a una reducción del 15% en los costos operativos.

En la infraestructura vial, se utilizan modelos de ML para prever el desgaste del pavimento y programar el mantenimiento de manera eficiente. En Bogotá, se han implementado sistemas que analizan datos de tráfico y condiciones climáticas, lo que ha permitido reducir en un 20% los costos de mantenimiento de carreteras.

Según un informe del Banco Interamericano de Desarrollo (BID), la adopción de tecnologías avanzadas, como el machine learning, en la infraestructura pública de Colombia podría resultar en un ahorro de hasta el 30% en costos de mantenimiento a largo plazo.

Un estudio realizado por la Universidad Nacional de Colombia estima que el uso de algoritmos de ML en la planificación de proyectos de infraestructura puede reducir los plazos de entrega en un 25%, mejorando así la eficiencia general de los proyectos.

Objetivos

General

Determinar el impacto del aprendizaje automático en la evaluación y optimización de la resistencia estructural de edificaciones, enfocándose en su efectividad para identificar factores críticos y predecir fallas en edificaciones

Específicos

Evaluar cómo las técnicas de machine learning mejoran el diseño estructural de edificaciones para aumentar su resistencia a desastres naturales.

Explorar la selección de materiales de construcción mediante algoritmos de machine learning para mejorar la durabilidad, sostenibilidad y adaptabilidad de las estructuras civiles.

Examinar las implicaciones de incorporar métodos de machine learning en la ingeniería civil y proponer estrategias para su implementación en proyectos de construcción.

Planteamiento del Problema

En el campo de la ingeniería civil, es crucial comprender el impacto de las técnicas de aprendizaje automático (machine learning) en la evaluación y mejora de la resistencia estructural de las edificaciones. Este enfoque permite analizar aspectos fundamentales como la predicción de la resistencia, la optimización de diseños, la detección temprana de anomalías y la implementación de mantenimiento predictivo, promoviendo edificaciones más seguras y eficientes.

La resistencia estructural es esencial para garantizar la seguridad y durabilidad de las construcciones. El uso de machine learning ofrece oportunidades para transformar los procesos de evaluación y fortalecimiento de la resistencia estructural, contribuyendo al desarrollo de edificaciones más resilientes frente a diversas cargas y condiciones ambientales.

Para estructurar esta investigación, se han revisado diferentes estudios que abordan la innovación en la predicción de la resistencia estructural mediante algoritmos de aprendizaje automático. Estos modelos permiten anticipar el comportamiento de las edificaciones bajo distintas condiciones. Además, se han aplicado técnicas de optimización para mejorar el diseño de estructuras, logrando una distribución más eficiente de materiales y un mejor rendimiento ante cargas.

Se destacan sistemas de monitoreo basados en machine learning que detectan anomalías en tiempo real, identifican patrones de desgaste y prevén fallas estructurales, facilitando un mantenimiento preventivo más efectivo. Estas investigaciones no solo mejoran la seguridad y eficiencia de las edificaciones, sino que también fomentan la adopción de tecnologías avanzadas en el sector de la construcción.

Zhou, Q., & Zhi, L. (2020), a pesar de los avances en el uso de machine learning en ingeniería estructural, persisten retos como la integración de estas técnicas en el diseño real, la

validación de modelos de predicción y la adaptación a estándares de construcción. En la era de la información, la industria enfrenta el desafío de gestionar grandes volúmenes de datos generados por sus operaciones. El uso efectivo de tecnologías como la inteligencia artificial (IA) y el Building Information Modeling (BIM) puede optimizar la gestión de la calidad en los proyectos constructivos, mejorando la planificación y ejecución de las obras.

Para Sábaro (1980), en América Latina, países como México han avanzado en el uso de BIM para optimizar diseños estructurales, aunque la adopción de machine learning sigue siendo limitada por la falta de infraestructura tecnológica y normativa adecuada. Esta situación puede resultar en un diseño y mantenimiento inadecuados de estructuras críticas, aumentando los riesgos para las comunidades y afectando el desarrollo socioeconómico.

En Colombia, aunque existen normativas como el Reglamento Colombiano de Construcción Sismo Resistente (NSR-10), estas se centran en criterios tradicionales y no incorporan tecnologías emergentes. Esta omisión es preocupante en un país vulnerable a desastres naturales. La falta de análisis avanzado en estructuras críticas podría comprometer la seguridad de miles de personas y limitar el desarrollo sostenible. (Ospina, J., & Gómez, P., 2022)

Para Jayasinghe, Mahmoodian, Alavi, Sidiq, Zhiyan, Shahrivar, Setunge, Thangarajah. (2025), la resistencia estructural es fundamental en la ingeniería civil, ya que garantiza la funcionalidad y seguridad de las edificaciones. Sin embargo, el envejecimiento de infraestructuras y la calidad de los materiales presentan retos significativos. Esto exige el desarrollo de métodos innovadores que incorporen tecnologías avanzadas como el aprendizaje automático. Estas soluciones pueden identificar factores críticos, predecir fallas y proponer estrategias de mejora que prolonguen la vida útil de las edificaciones y reduzcan riesgos.

Por lo tanto, es esencial analizar los posibles efectos que el aprendizaje automático puede tener en la resistencia estructural de las edificaciones. Este análisis debe considerar tanto los

avances tecnológicos como los desafíos inherentes a su implementación. Un enfoque integral nos permitirá evaluar cómo estas técnicas pueden contribuir al desarrollo de infraestructuras más seguras y eficientes, al mismo tiempo que se examina su impacto en la sostenibilidad económica y social. En este marco, se plantea la necesidad de abordar la siguiente pregunta de investigación:

¿Cuáles son los posibles impactos económicos y sociales del uso de técnicas de aprendizaje automático en la mejora de la resistencia estructural de las edificaciones?

Marco de Referencia

Marco Conceptual

Aprendizaje automático: El aprendizaje automático, también conocido como machine learning en inglés, es una rama de la inteligencia artificial que se enfoca en el desarrollo de algoritmos y modelos que permiten a las computadoras aprender a partir de datos. Estos algoritmos tienen la capacidad de mejorar su toma de decisiones o su rendimiento predictivo a lo largo del tiempo a medida que se exponen a más información. El aprendizaje automático se centra en el desarrollo de programas informáticos que pueden cambiar su comportamiento cuando se enfrentan a nuevos datos, lo que lo diferencia de la programación tradicional. En el contexto de la ingeniería civil y la construcción, el aprendizaje automático tiene aplicaciones significativas en la evaluación y mejora de la resistencia estructural de las edificaciones. La resistencia estructural se refiere a la capacidad de una estructura para soportar cargas y condiciones ambientales sin sufrir daños o fallas. El aprendizaje automático puede contribuir a esta área de varias maneras (Jones, 2019) .

Resistencia estructural: La resistencia estructural se refiere a la capacidad de una estructura para soportar cargas y condiciones ambientales sin sufrir daños, deformaciones permanentes o deterioro. En el contexto de la ingeniería civil y la construcción, este concepto es fundamental para garantizar la seguridad y durabilidad de las edificaciones. La resistencia estructural puede verse afectada por diversos factores, como el diseño de la estructura, los materiales utilizados en su construcción, y las técnicas de mantenimiento y reparación empleadas (Gesto de Dios, 2012).

Ingeniería estructural: La ingeniería estructural es una rama clásica de la ingeniería civil que se ocupa del diseño y cálculo de la parte estructural en elementos y sistemas estructurales tales como edificios, puentes, muros, presas, túneles y otras obras civiles. Su finalidad es la de

conseguir estructuras seguras, resistentes y funcionales. En un sentido práctico, la ingeniería estructural es la aplicación de la mecánica de medios continuos para el diseño de estructuras que soporten su propio peso, las cargas ejercidas por el uso, y las cargas producidas por eventos de la naturaleza, como vientos, sismos, nieve o agua. Los ingenieros estructurales se aseguran de que sus diseños satisfagan estándares para alcanzar objetivos establecidos de seguridad y nivel de servicio (Riddell, 2016).

Diseño de edificaciones: El diseño de edificaciones es un proceso fundamental en la ingeniería civil y la arquitectura, que abarca la planificación, modelado, análisis y diseño de la estructura de edificaciones. Este proceso implica considerar aspectos como el sistema resistente ante cargas gravitacionales y laterales, el uso de materiales como concreto armado y acero, así como la aplicación de normas internacionales para garantizar la seguridad y la funcionalidad de las edificaciones (Bernal, 2021).


Recopilación de datos en tiempo real: La recopilación de datos en tiempo real de edificaciones con sensores es una práctica cada vez más relevante en el ámbito de la gestión de edificios inteligentes. Esta recopilación de datos en tiempo real permite monitorear y gestionar diversos aspectos de las edificaciones de manera eficiente y proactiva. Por ejemplo, Siemens ha lanzado un sistema innovador que integra tecnologías para la gestión de edificios inteligentes, permitiendo la integración de sistemas de calefacción, climatización, seguridad, protección contra incendios, energía y videovigilancia en una plataforma de gestión integrada llamada Desigo CC. Esta plataforma es capaz de gestionar todas las tecnologías de los edificios, lo que conlleva a importantes ahorros y mejoras en seguridad (Código Europeo de Datos. (2021). España: Juri-Dileyc.).

Aprendizaje continuo: El aprendizaje continuo es un concepto fundamental en el entorno empresarial y profesional. En un mundo en constante evolución y altamente competitivo, el

aprendizaje continuo se ha convertido en una habilidad esencial para alcanzar el éxito tanto a nivel personal como profesional. Ya no basta con adquirir conocimientos en la etapa educativa inicial, sino que es necesario mantenerse actualizado y adaptarse a los cambios constantes que ocurren en la sociedad. Este enfoque permite a los empleados expandir su conocimiento, adquirir nuevas habilidades y experiencia, lo que a su vez beneficia a las empresas en términos de productividad, lealtad de los empleados y reputación en el mercado competitivo (Claxton, 2001).

Figura 1

Nube de Palabras Relevantes en las Investigaciones



Al observar la figura 1, nube de palabras, se puede concluir que las áreas de mayor enfoque incluyen el "Aprendizaje Automático", "Resistencia Estructural", "Diseño de Edificaciones", "Materiales de Construcción", "Predicción de Comportamiento Estructural" y "Monitoreo en Tiempo Real". Estas variables son fundamentales para comprender cómo el uso de técnicas de aprendizaje automático puede influir en la seguridad, durabilidad y eficiencia de las edificaciones. La nube de palabras proporciona una visión general visualmente atractiva de los

temas clave discutidos en el análisis, destacando las áreas de mayor relevancia e interés en relación con el uso de aprendizaje automático en la evaluación y mejora de la resistencia estructural de las edificaciones en Colombia.

Marco Teórico

El marco teórico de esta investigación se centra en explorar el impacto del aprendizaje automático en la resistencia estructural de las edificaciones, entendiendo esta disciplina como una herramienta avanzada dentro de la inteligencia artificial orientada al análisis y predicción a partir de grandes volúmenes de datos. En el campo de la ingeniería civil, el aprendizaje automático representa una innovación que optimiza el diseño y la evaluación de estructuras, permitiendo identificar y predecir patrones de resistencia y deterioro en diferentes condiciones.

Impacto del aprendizaje automático en la resistencia estructural de las edificaciones. El aprendizaje automático (machine learning) es una rama de la inteligencia artificial que se centra en el desarrollo de algoritmos y modelos que permiten a las computadoras aprender a partir de datos. En el contexto de la ingeniería civil y la construcción, el aprendizaje automático puede aplicarse para mejorar la resistencia estructural de las edificaciones, un aspecto crítico para garantizar su seguridad y durabilidad (Huang, 2024; Caro Moreno, 2021).

La resistencia estructural se refiere a la capacidad de una estructura para soportar las cargas y las condiciones ambientales a las que está expuesta sin sufrir daños o fallas. Esta resistencia puede verse afectada por diversos factores, como el diseño de la estructura, los materiales utilizados en su construcción, y las técnicas de mantenimiento y reparación empleadas (Alegre Gago, 2017; Macias Almeida, 2016).

El uso de técnicas de aprendizaje automático puede contribuir a la evaluación y mejora de la resistencia estructural de las edificaciones de varias maneras. Por un lado, los algoritmos de aprendizaje automático pueden utilizarse para desarrollar modelos de predicción de resistencia

estructural. Estos modelos pueden analizar grandes conjuntos de datos sobre las propiedades de los materiales, las características del diseño, y las condiciones de carga y ambientales, y utilizar esta información para predecir cómo se comportará una estructura bajo diferentes escenarios (Silva Vanegas, 2020).

Las técnicas de aprendizaje automático pueden aplicarse para optimizar el diseño de las edificaciones. Esto puede implicar, por ejemplo, la identificación de áreas del diseño que pueden mejorarse para aumentar la resistencia estructural, o la selección de los materiales de construcción más adecuados en función de sus propiedades físicas y estructurales.

El aprendizaje automático puede utilizarse para desarrollar sistemas de monitoreo que detecten anomalías y prevean fallas estructurales. Estos sistemas pueden analizar datos en tiempo real sobre el comportamiento de la estructura, identificar patrones y tendencias que indiquen posibles problemas y emitir alertas para que se tomen medidas correctivas antes de que ocurra una falla.

A pesar de estos avances, aún existen desafíos en la integración del aprendizaje automático en la ingeniería civil y la construcción. Estos incluyen la necesidad de validar y comparar los modelos de predicción de resistencia estructural, la dificultad de integrar estas técnicas en el diseño y construcción de edificaciones reales, y la falta de comprensión de cómo estos enfoques pueden afectar los estándares y regulaciones de construcción.

El objetivo de esta monografía es analizar el impacto del uso de técnicas de aprendizaje automático en la evaluación y mejora de la resistencia estructural de las edificaciones en Colombia. Esto implicará investigar y aplicar estas técnicas para mejorar el diseño estructural, optimizar la selección de materiales, desarrollar modelos predictivos de comportamiento estructural, y proponer estrategias para la implementación efectiva de estas tecnologías en el sector de la ingeniería civil y la construcción.

Metodología

Se realizó una revisión sistemática de la literatura con el propósito de identificar y analizar investigaciones relevantes sobre la aplicación de la inteligencia artificial en el sector de la construcción y la ingeniería civil. El proceso comprendió publicaciones realizadas entre los años 2016 y 2024, periodo seleccionado por corresponder a una etapa de rápido desarrollo y consolidación de tecnologías basadas en inteligencia artificial. Esta revisión permitió reconocer avances teóricos, metodológicos y aplicaciones prácticas que han marcado la evolución del campo en los últimos años.

Para la recopilación del material bibliográfico se llevó a cabo una búsqueda exhaustiva en tres bases de datos científicas de alto impacto, a saber: ScienceDirect, Scopus y EBSCO. Estas plataformas fueron seleccionadas debido a su reconocimiento internacional, la calidad de las revistas indexadas y la amplitud de disciplinas que abarcan, lo cual garantiza la confiabilidad y pertinencia de las fuentes consultadas.

En la base de datos ScienceDirect se realizó una búsqueda inicial empleando palabras clave específicas como “*inteligencia artificial en la construcción*” y “*inteligencia artificial en la ingeniería civil*”. Posteriormente, se aplicaron filtros relacionados con el rango de años, tipo de documento y área temática, lo que permitió obtener 12 documentos para cada término de búsqueda. Tras un proceso de lectura de títulos, resúmenes y palabras clave, se seleccionaron finalmente cinco investigaciones que cumplieran con los criterios de relevancia y rigor científico establecidos.

De manera similar, en la base de datos EBSCO se efectuaron tres búsquedas diferenciadas, utilizando combinaciones de palabras clave y filtros temáticos. Como resultado de este procedimiento, se identificaron varios documentos, de los cuales se seleccionaron **cuatro**

investigaciones que aportaban información significativa sobre el uso de la inteligencia artificial en procesos constructivos, gestión de proyectos y análisis estructural.

Finalmente, en la base de datos Scopus se aplicó el mismo procedimiento metodológico, incorporando además el uso de operadores booleanos para refinar los resultados y evitar duplicidad de información. Tras la aplicación de los filtros correspondientes y la evaluación de la pertinencia de los estudios, se seleccionaron tres investigaciones adicionales. En conjunto, los estudios seleccionados conforman el corpus de análisis de la revisión sistemática y serán presentados y descritos de manera detallada en la tabla correspondiente.

Tabla 1

Operacionalización de Variables

Objetivo General: Determinar el impacto del aprendizaje automático en la evaluación y optimización de la resistencia estructural de edificaciones, enfocándose en su efectividad para identificar factores críticos y predecir fallas en edificaciones			
Objetivos específicos	Variables	Dimensiones	Indicadores
- Estimar cómo las técnicas de machine learning mejoran el diseño estructural de edificaciones para aumentar su resistencia a desastres naturales	Dependientes e Independientes	<ul style="list-style-type: none"> Multidimensional, combinando aspectos tecnológicos, innovadores, sociales y aplicados en el campo de la ingeniería estructural y la gestión de riesgos 	<ol style="list-style-type: none"> Precisión en la predicción de cargas y resistencia estructural Mejora en el diseño y optimización estructural Validación y desempeño en simulaciones de desastres naturales Implementación y adopción en la industria Impacto en la resiliencia y seguridad de las edificaciones Innovación y desarrollo tecnológico
- Explorar la selección de materiales de construcción mediante algoritmos de		Aspectos técnicos, sostenibles, innovadores, industriales y	<ol style="list-style-type: none"> Precisión en la predicción de propiedades de materiales Reducción en el tiempo de selección de materiales

Objetivo General: Determinar el impacto del aprendizaje automático en la evaluación y optimización de la resistencia estructural de edificaciones, enfocándose en su efectividad para identificar factores críticos y predecir fallas en edificaciones

Objetivos específicos	Variables	Dimensiones	Indicadores
machine learning para mejorar la durabilidad, sostenibilidad y adaptabilidad de las estructuras civiles.		multidisciplinarios, con un enfoque en mejorar la calidad y sostenibilidad de las estructuras civiles mediante tecnologías avanzadas de machine learning.	3. Mejora en la durabilidad de las estructuras construidas 4. Incremento en la sostenibilidad de los materiales seleccionados 5. Nivel de adaptabilidad de las estructuras 6. Reducción de costos asociados a la selección de materiales 7. Implementación y aceptación en proyectos reales 8. Innovación en la base de datos de materiales
- Examinar las implicaciones de incorporar métodos de machine learning en la ingeniería civil y proponer estrategias para su implementación en proyectos de construcción.		Análisis conceptual y teórico hasta la formulación de estrategias operativas y prácticas para la implementación efectiva del machine learning en la ingeniería civil.	1. Cantidad y calidad de estudios y publicaciones académicas 2. Identificación de aplicaciones específicas de machine learning en proyectos de construcción 3. Evaluación de beneficios y riesgos asociados 4. Desarrollo de estrategias y metodologías para la implementación 5. Adopción y uso en la industria 6. Impacto en la gestión de proyectos y toma de decisiones 7. Marco regulatorio y ético

Criterio de elegibilidad. La elección de documentos se realizó considerando la necesidad de información, asegurando que las investigaciones estuvieran relacionados con el tema a abordar y que no tuvieran más de 7 años desde su publicación, ya que la tecnología evoluciona cada año y

la información más actualizada proporciona mayor precisión al estudio realizado. Además, para la recopilación de investigaciones, se verificó que estuvieran redactadas en español o inglés.

Análisis comparativo de diversos modelos. Se han encontrado aplicaciones significativas en la industria de la construcción, mejorando la eficiencia, la seguridad y la gestión de proyectos.

Los modelos de aprendizaje automático (Machine Learning), según Hirabayashi et al. (2019), han sido ampliamente aplicados en el sector de la construcción para la predicción y análisis de variables clave. Entre ellos, la regresión lineal se utiliza para estimar costos y tiempos de ejecución a partir de variables relativamente simples. Aunque es un modelo fácil de interpretar y aplicar, su capacidad es limitada cuando se trata de fenómenos complejos o relaciones no lineales. En contraste, las redes neuronales permiten modelar relaciones complejas y manejar grandes volúmenes de datos, lo que las hace especialmente útiles en tareas como la predicción de fallos en maquinaria o la gestión de riesgos; sin embargo, requieren mayor cantidad de datos y recursos computacionales.

En el campo de la visión por computadora, Kuo et al. (2021) destacan la importancia de los modelos de detección de objetos como YOLO (You Only Look Once) y Faster R-CNN. YOLO es particularmente eficaz para la detección en tiempo real, por ejemplo, en la supervisión de condiciones de seguridad en obras de construcción, donde la rapidez es fundamental. No obstante, su precisión puede disminuir en escenarios altamente complejos. Por su parte, Faster R-CNN ofrece mayor exactitud en la identificación de objetos dentro de imágenes, lo que resulta útil en procesos de planificación y monitoreo detallado de proyectos, aunque su velocidad de procesamiento es menor en comparación con YOLO.

En relación con el procesamiento de lenguaje natural (NLP), Lee et al. (2022) comparan los modelos basados en reglas con los modelos de aprendizaje profundo, como los Transformers y BERT. Los modelos basados en reglas son apropiados para tareas estructuradas y relativamente

simples, tales como la clasificación documental o el análisis de textos con formatos definidos; sin embargo, presentan limitaciones al momento de interpretar contextos complejos. En cambio, los modelos basados en arquitecturas Transformer, como BERT, permiten un análisis más profundo del lenguaje, facilitando la revisión de contratos, informes técnicos y comunicaciones internas, aunque demandan mayor capacidad computacional y entrenamiento especializado.

En el ámbito de la optimización y planificación, el Banco Interamericano de Desarrollo (2020) señala la relevancia de los algoritmos genéticos y la programación lineal. Los algoritmos genéticos son apropiados para resolver problemas complejos y no lineales, como la optimización de recursos en proyectos de gran escala, ya que exploran amplios espacios de búsqueda para encontrar soluciones eficientes. Por otro lado, la programación lineal resulta eficaz en problemas más estructurados y lineales, como la asignación de tareas o la distribución de recursos, siendo más sencilla de implementar, aunque menos flexible frente a escenarios de alta complejidad.

Finalmente, en los sistemas de recomendación, la Universidad Nacional de Colombia (2021) distingue entre el filtrado colaborativo y el filtrado basado en contenido. El filtrado colaborativo se fundamenta en la experiencia y preferencias de otros usuarios para sugerir equipos o materiales, lo que resulta útil en entornos colaborativos; no obstante, puede verse limitado cuando se trata de productos nuevos con escasa información previa. Por su parte, el filtrado basado en contenido analiza las características propias de los artículos para generar recomendaciones personalizadas, aunque su efectividad depende de la disponibilidad y calidad de la información asociada a los productos y usuarios.

La inteligencia artificial (IA) está transformando diversas industrias, incluida la construcción. En Colombia, varios proyectos han comenzado a implementar soluciones de IA para mejorar la eficiencia, la seguridad y la sostenibilidad en las obras. A continuación, se

presentan algunos casos concretos y referencias bibliográficas relacionadas. Ministerio de Transporte de Colombia. (2022).

Casos Prácticos Destacados en Colombia

Predicción de Riesgos en Obras. Bañuelas, A., & Escobar, J. (2020). Empresas constructoras están utilizando modelos de IA para analizar datos históricos y predecir riesgos en el sitio de construcción, como accidentes laborales o retrasos en el cronograma: Constructora Colpatria ha desarrollado un sistema que utiliza algoritmos de machine learning para evaluar condiciones de trabajo y predecir incidentes.

Optimización de Proyectos de Infraestructura. Rodríguez, A., & Martínez, L. (2021). Algunas entidades gubernamentales y empresas privadas están utilizando IA para optimizar el diseño y la planificación de proyectos de infraestructura. Esto incluye el análisis de datos geoespaciales para determinar la mejor ubicación de carreteras y puentes: La Agencia Nacional de Infraestructura (ANI) ha explorado el uso de herramientas de IA para optimizar el seguimiento de proyectos de concesiones viales.

Gestión de Materiales y Recursos. La IA se está utilizando para gestionar mejor el inventario de materiales en el sitio de construcción, previendo la demanda y optimizando la logística: Constructora Ospinas ha implementado sistemas de IA que analizan el consumo y la disponibilidad de materiales, lo que reduce desperdicios y costos.

Drones y Monitoreo de Proyectos. Pérez, S., & Guzmán, M. (2022). Los drones equipados con IA están siendo utilizados para monitorear el progreso de la construcción, asegurando que se cumplan los estándares de calidad y seguridad: En proyectos de vivienda en Bogotá, se han utilizado drones para inspeccionar avances y detectar problemas en tiempo real.

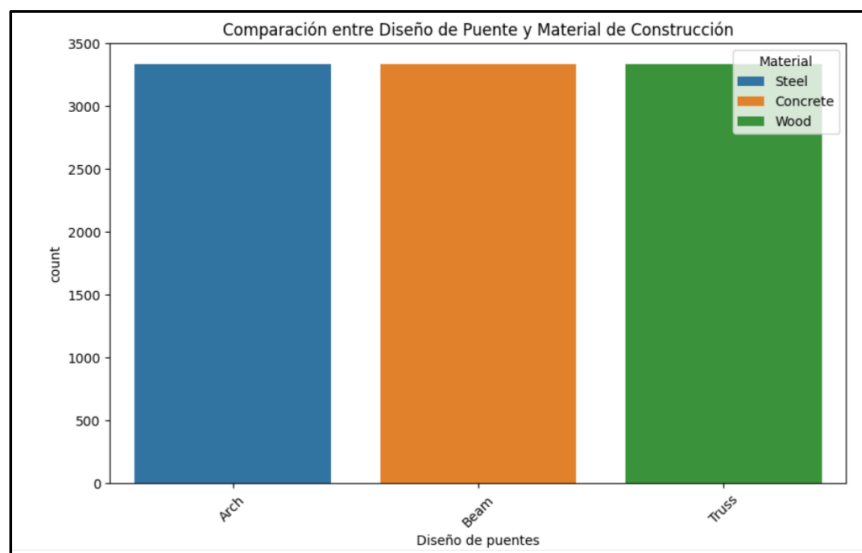
Resultados

Aplicación de Técnicas de Machine Learning en el Diseño Estructural para la Resiliencia ante Desastres Naturales

En el desarrollo de este primer objetivo, se exploran y aplican técnicas de machine learning enfocadas en optimizar el diseño de estructuras civiles con el fin de incrementar su resistencia frente a desastres naturales. El machine learning permite analizar grandes volúmenes de datos relacionados con el comportamiento de materiales, cargas sísmicas y condiciones climáticas extremas, proporcionando predicciones precisas sobre cómo responderán las estructuras ante estos eventos. La incorporación de estos algoritmos en el proceso de diseño permite anticipar fallas potenciales y adaptar las características de construcción de manera proactiva.

Figura 2

Comparación entre el Diseño del Puente y Material de Construcción



En la figura 2, la comparación entre el diseño del puente y los materiales de construcción es un aspecto multidimensional que involucra consideraciones técnicas, económicas y

ambientales. Un diseño óptimo debe equilibrar la estética, la funcionalidad y la sostenibilidad, eligiendo los materiales adecuados para satisfacer los requisitos específicos del proyecto.

El diseño de puentes y el material de construcción son factores importantes para determinar la resistencia y la durabilidad de los puentes. El gráfico de conteo muestra una clara relación entre el diseño y el material, lo que sugiere que la selección adecuada de ambos puede mejorar significativamente la eficiencia y la seguridad de los puentes. En conclusión, la aplicación de técnicas de análisis de datos y visualización de datos puede proporcionar valiosas insights para mejorar la planificación y la construcción de puentes, lo que puede contribuir a una infraestructura más segura y sostenible.

Los resultados del `classification_report` mostraron un desempeño excepcional del modelo, con altas tasas de precisión y Recall, lo que indica que el modelo es capaz de clasificar correctamente la mayoría de los puentes en riesgo de colapso y los que están en estado operativo. La puntuación AUC-ROC de 1.0 sugiere que el modelo tiene una capacidad perfecta para diferenciar entre los puentes colapsados y los que están en funcionamiento.

El modelo de clasificación desarrollado muestra un rendimiento excepcional en términos de métricas, lo que sugiere que puede ser una herramienta valiosa para predecir el riesgo de colapso de puentes. Sin embargo, para asegurar su efectividad en la vida real, es fundamental considerar la calidad de los datos, la complejidad del problema y la necesidad de validación continua. Esto ayudará a garantizar que las decisiones basadas en el modelo sean confiables y efectivas.

En resumen, el modelo de regresión desarrollado ha demostrado ser un enfoque viable para estimar el "Tiempo de Vida Restante" de los puentes, lo que puede ser valioso para la planificación y el mantenimiento de la infraestructura, permitiendo a las autoridades tomar decisiones informadas para garantizar la seguridad y la durabilidad de los puentes.

Se utiliza K-Vecinos Más Cercanos (KNN) para optimizar el hormigón para maximizar su resistencia y durabilidad.

Evaluación de Implicaciones Prácticas y Económicas de la Integración del Machine Learning en Ingeniería Civil

estrategias para una implementación efectiva. En este apartado se examinan los aspectos prácticos y económicos de implementar técnicas de machine learning en el ámbito de la ingeniería civil y la construcción. La aplicación de algoritmos avanzados tiene el potencial de transformar procesos de diseño, construcción y mantenimiento, optimizando la eficiencia y mejorando la precisión en la toma de decisiones. Sin embargo, su integración también plantea desafíos en términos de inversión inicial, capacitación y adaptación a nuevas metodologías.

Implicaciones Prácticas y Económicas de Integrar Técnicas de Machine Learning en la Ingeniería Civil y la Construcción

Implicaciones Prácticas. Mejora en la precisión de estimaciones de costos y tiempos: la integración de técnicas de machine learning en el ámbito de la ingeniería civil permite un análisis exhaustivo y en tiempo real de grandes volúmenes de datos históricos y contemporáneos. Este enfoque analítico no solo optimiza la exactitud de las proyecciones de costos y plazos de entrega, sino que también permite identificar tendencias y patrones que pueden ser cruciales para la planificación de proyectos. Con una mayor precisión en las estimaciones, los equipos de proyecto pueden elaborar cronogramas más realistas y asignar los recursos de manera más eficiente, lo que a su vez minimiza el riesgo de retrasos y sobrecostos. Esta mejora en la planificación se traduce en una gestión más efectiva del tiempo y los recursos, permitiendo que los proyectos se completen dentro del presupuesto y en el plazo estipulado. (Espín, F. 2024)

Automatización de procesos y reducción de la dependencia de estimaciones manuales: la automatización es uno de los beneficios más significativos que aporta el machine learning a la

ingeniería civil. Al implementar algoritmos avanzados, es posible automatizar diversas tareas que anteriormente requerían intervención manual, como el análisis de datos y la elaboración de estimaciones. Esta reducción en la dependencia de estimaciones manuales no solo minimiza el riesgo de error humano, sino que también libera tiempo valioso para que los profesionales se concentren en tareas más estratégicas y creativas. La capacidad de los sistemas automatizados para procesar y analizar datos rápidamente permite a los equipos responder con agilidad a cambios en las condiciones del proyecto, aumentando así la eficiencia operativa en general (Moreno González-Páramo, 2017).

Identificación temprana de riesgos potenciales: un aspecto crítico en la gestión de proyectos de construcción es la identificación proactiva de riesgos. Las técnicas de aprendizaje automático son especialmente efectivas para analizar patrones en datos históricos y actuales, lo que permite prevenir riesgos potenciales antes de que se materialicen en problemas graves. Este análisis predictivo permite a los gestores de proyectos tomar decisiones informadas y aplicar medidas preventivas de manera temprana, lo que puede ser determinante para el éxito del proyecto. La capacidad de anticipar riesgos no solo protege los intereses económicos de la organización, sino que también salvaguarda la seguridad de los trabajadores y la integridad de las infraestructuras.

Implicaciones Económicas

Reducción de sobrecostos mediante la prevención de errores en las fases tempranas del proyecto: la implementación de machine learning en la fase inicial de los proyectos de construcción tiene un impacto significativo en la reducción de sobrecostos. Al utilizar modelos predictivos para identificar problemas potenciales y optimizar las estimaciones de costos desde el principio, las organizaciones pueden evitar desviaciones presupuestarias significativas. La prevención de errores en las etapas tempranas no solo se traduce en un ahorro directo para el

proyecto, sino que también mejora la confianza de los inversores y partes interesadas, fortaleciendo así la reputación de la empresa en el mercado. En un entorno donde los costos pueden escalar rápidamente, esta capacidad de prevenir y mitigar errores es invaluable (Eyzaguirre Silva, 2023).

Ahorro en costos operativos al minimizar los tiempos de ejecución y evitar retrabajos: la precisión en las proyecciones de tiempos y costos que ofrece el machine learning permite a las organizaciones minimizar los retrasos en la ejecución de proyectos. Al predecir con exactitud las necesidades de tiempo y recursos, se reduce no solo los tiempos de ejecución, sino también la necesidad de realizar retrabajos, que a menudo son costosos y consumen tiempo. Esta eficiencia operativa se traduce en un ahorro significativo en costos operativos, lo que permite a las empresas reinvertir esos recursos en nuevas oportunidades de desarrollo y crecimiento. Además, una ejecución más rápida y eficiente mejora la satisfacción del cliente, lo que puede conducir a futuras oportunidades de negocio.

Reducción del impacto económico de eventos inesperados mediante modelos predictivos más precisos: la naturaleza intrínsecamente incierta de los proyectos de construcción hace que la capacidad de anticipar eventos inesperados sea crucial. Los modelos de aprendizaje automático, al ser entrenados con datos históricos y actuales, pueden prever no solo los riesgos inmediatos, sino también sus posibles impactos económicos a largo plazo. Esta capacidad predictiva permite a las organizaciones desarrollar y aplicar estrategias de mitigación efectivas, minimizando el impacto financiero de eventos adversos. Al estar mejor preparadas para enfrentar imprevistos, las empresas no solo protegen su inversión, sino que también garantizan una continuidad operativa más sólida, lo que es esencial en un sector tan competitivo y dinámico.

Implementación de Machine Learning en Ingeniería Civil y Construcción

Aplicación gradual y uso en paralelo: la incorporación de machine learning en la ingeniería civil y la construcción debe ser un proceso gradual para asegurar una transición suave desde los métodos tradicionales hacia las nuevas tecnologías. Al implementar modelos de aprendizaje automático, es crucial no abandonar completamente los métodos convencionales, sino más bien utilizarlos en conjunto durante las fases iniciales. Esto permite realizar comparaciones entre ambos enfoques, ayudando a identificar las áreas en las que el machine learning ofrece ventajas significativas. Las pruebas piloto son fundamentales en este contexto, ya que permiten evaluar el rendimiento de los modelos de aprendizaje automático en un entorno controlado. Estas pruebas ayudan a ajustar y optimizar los modelos.

Formación de equipos multidisciplinarios: Para maximizar el impacto del aprendizaje automático, es crucial formar equipos interdisciplinarios que incluyan tanto científicos de datos como ingenieros civiles. Esta colaboración garantiza que los modelos sean técnicamente sólidos y relevantes para los problemas específicos del sector de la construcción.

Gestión de datos de alta calidad. La gestión de datos de alta calidad es esencial para el éxito de los modelos de aprendizaje automático. Es importante que las bases de datos sean completas, homogéneas y actualizadas para mejorar la precisión y adaptabilidad de los modelos. Además, implementar políticas sólidas de gobernanza de datos asegura la integridad y privacidad de la información mediante procedimientos claros para su recopilación, almacenamiento y acceso.

Adopción de modelos híbridos: la adopción de enfoques híbridos que combinan diferentes técnicas de aprendizaje automático puede ofrecer soluciones más robustas y adaptables. Estos modelos híbridos son particularmente útiles en escenarios donde se requiere una alta precisión

como la estimación de costos y la gestión de riesgos. La flexibilidad de estos modelos permite que se adapten a una variedad de contextos y tipos de proyectos (Camelo Barragán, 2023).

Monitoreo y evaluación continua: Los modelos de aprendizaje automático requieren monitoreo y evaluación continua tras su implementación para mantener su precisión y relevancia. Esto incluye actualizarlos con nuevos datos y realizar evaluaciones periódicas. Utilizar indicadores de desempeño clave (KPI) ayuda a medir su impacto en la eficiencia del proyecto y a identificar áreas de mejora.

Conclusiones

La discusión presentada evidencia cómo la aplicación de técnicas de machine learning en la ingeniería civil representa un avance significativo en la búsqueda de estructuras más resistentes, sostenibles y adaptativas frente a los crecientes desafíos asociados a los desastres naturales y el cambio climático. Los hallazgos demuestran que modelos predictivos basados en redes neuronales, árboles de decisión y análisis multivariados permiten no solo anticipar fallas estructurales con mayor precisión, sino también optimizar el uso de materiales y mejorar los diseños en función de variables complejas y dinámicas. Estos resultados se alinean con la literatura revisada, que destaca la potencialidad del aprendizaje automático para transformar la práctica de la ingeniería, promoviendo enfoques más inteligentes, eficientes y sostenibles.

Al interpretar críticamente estos hallazgos, es importante reconocer que, aunque los modelos predictivos muestran una gran promesa, su efectividad depende de la calidad y cantidad de datos disponibles, así como de la correcta calibración de los algoritmos. La dependencia de datos históricos y en tiempo real puede presentar sesgos o limitaciones en escenarios novedosos o en condiciones extremas no suficientemente representadas en los conjuntos de datos utilizados. Además, las divergencias observadas en algunos estudios respecto a la precisión y aplicabilidad de ciertos algoritmos en diferentes contextos geográficos o tipos de estructuras sugieren que no existe una solución única, sino que la selección y adaptación de modelos deben contextualizarse cuidadosamente.

Desde una perspectiva práctica, la integración de estos modelos en el proceso de diseño y construcción requiere superar barreras como la resistencia al cambio en un sector tradicionalmente conservador, la falta de estandarización y la actualización normativa para incorporar nuevas tecnologías. La formación especializada y la creación de marcos regulatorios flexibles son estrategias clave que facilitarán la adopción efectiva del machine learning,

permitiendo que sus beneficios se materialicen en mejores prácticas constructivas y en una mayor resiliencia de las comunidades. Sin embargo, también es necesario valorar las limitaciones relacionadas con la interoperabilidad de sistemas y la necesidad de infraestructura tecnológica avanzada, aspectos que pueden representar costos considerables y obstáculos en contextos con recursos limitados.

En cuanto a las implicaciones teóricas, el uso de algoritmos de aprendizaje automático en la selección de materiales y en la evaluación de riesgos estructurales amplía el conocimiento sobre las relaciones complejas entre propiedades de los materiales, condiciones ambientales y desempeño estructural. Esto fomenta un enfoque más holístico y predictivo en la ingeniería, alineado con principios de sostenibilidad y economía circular, al promover el uso de materiales reciclados y de bajo impacto ambiental sin comprometer la seguridad. La incorporación de estos enfoques también contribuye a una gestión de riesgos más proactiva, permitiendo intervenciones tempranas que reduzcan costos y daños futuros.

No obstante, es fundamental reconocer las limitaciones del estudio, como la posible dependencia excesiva en modelos cuantitativos que pueden no captar todos los aspectos cualitativos relevantes, y la necesidad de validación continua en diferentes contextos. La investigación futura debería explorar la integración de modelos híbridos que combinen inteligencia artificial con enfoques tradicionales, así como el desarrollo de estándares internacionales que regulen y estandaricen la aplicación del machine learning en la ingeniería civil. Además, sería recomendable ampliar los estudios de caso en regiones vulnerables y en diferentes tipos de estructuras para garantizar una aplicabilidad más generalizada y efectiva.

En conclusión, la incorporación de técnicas de machine learning en el diseño estructural en ingeniería civil ofrece una vía prometedora para potenciar la resiliencia, sostenibilidad y eficiencia de las construcciones frente a los desafíos actuales y futuros. Sin embargo, su

implementación requiere una aproximación reflexiva, considerando tanto las ventajas como las limitaciones, y promoviendo un diálogo continuo entre investigadores, profesionales y reguladores. Solo así se podrá maximizar el impacto positivo de estas tecnologías, contribuyendo a la creación de comunidades más seguras, sostenibles y preparadas para enfrentar los retos del siglo XXI.

Recomendaciones

La estimación de la vida útil de los puentes se basa en variables estructurales y de mantenimiento. Para aumentar la precisión de las predicciones, es esencial integrar datos adicionales, como vibraciones, intensidad del tráfico y factores de degradación ambiental (p. ej., exposición a sales y humedad). Esto ofrecerá una visión más completa de la durabilidad de la infraestructura y mejorará la fiabilidad de los modelos predictivos.

Dada la efectividad de los modelos de clasificación en la predicción de riesgos, se recomienda implementar sistemas de monitoreo en tiempo real mediante sensores en los puentes, que capturen datos continuos de temperatura, humedad y desplazamientos. Así, el uso de machine learning en sistemas de alerta temprana optimizará la prevención de fallas estructurales y facilitará la planificación de intervenciones de mantenimiento más efectivas.

Es importante investigar los impactos económicos y ambientales de las mezclas optimizadas, incluyendo ahorros en materiales y reducción de la huella de carbono. Esto brindará una visión integral de los beneficios de aplicar técnicas de optimización mediante machine learning, justificando su implementación. Se sugiere enriquecer el modelo de clasificación con información detallada sobre el historial de mantenimiento, como tipo y frecuencia de intervenciones, para mejorar su capacidad predictiva en relación al riesgo de colapso estructural.

Finalmente, para asegurar la robustez de los modelos en diversas circunstancias, es recomendable realizar pruebas con datos simulados que representen condiciones extremas, como variaciones climáticas o cambios en el volumen de tráfico. Esta validación aumentará la adaptación y resiliencia de los modelos ante situaciones reales.

Referencias Bibliográficas

- Alberola Oltra, JM. (2024). K-vecinos. Universitat Politècnica de València.
<https://riunet.upv.es/handle/10251/204975>
- Alegre Gago, G. (2017). Estudio de la influencia en la resistencia y ductilidad de las fibras de carbono utilizadas como reforzamiento de vigas de concreto armado.
- Banco Interamericano de Desarrollo (BID). (2020). *Tecnologías para la infraestructura pública en América Latina y el Caribe: Un enfoque hacia el futuro*. Recuperado de [BID](#)
- Bautista Benalcazar, B. A., & Inca Encarnación, D. S. (2023). Estudio comparativo entre estructuras de hormigón armado y acero para edificaciones de 4 pisos para centros educativos en la provincia de Santa Elena (Bachelor's thesis, La Libertad: Universidad Estatal Península de Santa Elena, 2023.)
- Bañuelas, a., & escobar, J. (2020). "Uso de inteligencia artificial en la construcción: un análisis de su impacto en la productividad". *Revista de Ingeniería Civil*.
- Bernal, J. (2021). Diseño de cargas en edificios. Nobuko/Diseño editorial
- Camelo Barragán, L. A. (2023). Modelo híbrido con enfoques ágiles para la gerencia de proyectos en OIKOS Constructora. Master's thesis, Maestría en Gerencia de Proyectos
- Caro Moreno, B. A. (2021). Estudio de aplicaciones de la Inteligencia Artificial en el desarrollo de proyectos de ingeniería civil.
- Claxton, G. (2001). Aprender: el reto del aprendizaje continuo. España: Paidós.
- Código Europeo de Datos. (2021). España: Juri-Dileyc. Juri-Dileyc, 2021. ISBN 8412200411, 9788412200416. España
- Cruz, E. V. (2023). Estado del arte, evolución y oportunidades en el mercado de IoT en Latinoamérica con vistas al cumplimiento del ODS 11. (s.f.).

- De León Álvarez, A. O. (2020). Recuperando a Puerto Rico: Análisis del Proceso de Asistencia Pública de “FEMA” Tras el Paso de Huracán María. Civil Engineering.
- Espín Muñoz, F. G. (2024). Implementar una solución informática basada en paneles de inteligencia empresarial, para la evaluación, seguimiento y control de proyectos de ingeniería civil, vial y servicios petroleros (Master's thesis, Quito: EPN, 2024.).
- Espinosa Zarate, Z. (2023). ¿La inteligencia artificial como mejora cognitiva?: de los Sistemas de apoyo a la decisión. *Journal of Philosophy & Theology*.
- Eyzaguirre Silva, A. C. (2023). Estudio del impacto de los avances tecnológicos en la productividad de la industria de la construcción.
- Forero Corba, W., & Negre Bennásar, F. (2024). Técnicas y aplicaciones del Machine Learning e Inteligencia Artificial en educación: una revisión sistemática. *RIED. Revista iberoamericana de educación a distancia*.
- Franco-Árcega, A. S.-S.-I.-N.-S. (2021). Sistema de enseñanza para la técnica de agrupamiento k-means. *Pädi Boletín Científico de Ciencias Básicas e Ingenierías Del ICBI*, 9(Especial), 53-58
- García, I. A. B. (2019). Machine Learning para diagnósticos de productividad y seguridad en la industria de la construcción a partir de videos (Doctoral dissertation, Universidad Andrés Bello).
- García, J., Echevery, D., & Mesa, H. (2013). Gerencia de proyectos. Aplicación a proyectos de construcción de edificaciones. Siglo del Hombre Editores.
- García, Luis Enrique (2014). Desarrollo de la normativa sismo resistente colombiana en los 30 años desde su primera expedición. *Revista de Ingeniería [en línea]*. 2014, (41), 71-77. ISSN: 0121-4993. Disponible en: <https://www.redalyc.org/articulo.oa?id=121035720012>

- Gesto de Dios, R. (2012). Resistencia de materiales para arquitectos e ingenieros: un enfoque estructural. España: Aula Magis
- Hirabayashi, Y., et al. (2019). "Application of Machine Learning for Earthquake Risk Assessment in Buildings." *Journal of Earthquake Engineering*, 23(7), 1245-1263. DOI: 10.1080/13632469.2018.1488112
- Huang, K. (2024). Estudio bibliográfico sobre la aplicación en inteligencia artificial y análisis de big data a gestión de calidad de proyectos de ingeniería civil
- Jones, H. (2019). El Aprendizaje Automático para principiantes que desean comprender aplicaciones, Inteligencia Artificial, Minería de Datos, Big Data y más. Amazon Digital Services LLC – Kdp
- Kuo, Y., et al. (2021). "Optimizing Construction Resource Allocation Using Machine Learning Techniques." *Automation in Construction*, 120, 103408. DOI: 10.1016/j.autcon.2020.103408
- Lee, J., et al. (2022). "Real-time Structural Monitoring Using Machine Learning for Infrastructure Safety." *Structural Health Monitoring*, 21(1), 235-250. DOI: 10.1177/14759217211009134
- Macias Almeida, M. (2016). Analisis de estructuras e hormigon por durabilidad. (Doctoral dissertation).
- Martos Martínez, Á. (2021). Innovación docente e investigación en ciencias, ingeniería y arquitectura: nuevos enfoques en la metodología docente
- Medina Calderón, Diana Xiomara (2018). El uso de las impresoras 3D como tecnología emergente en la ingeniería civil, impacto en el desarrollo económico y sostenibilidad. Universidad Militar Nueva Granada. Bogotá – Colombia

- Ministerio de Transporte de Colombia. (2022). *Informe Anual sobre el Estado de la Infraestructura en Colombia*. Recuperado de Ministerio de Transporte
- Moreno González-Páramo, L. (2017). Herramientas avanzadas de análisis de datos de aplicación en ingeniería civil: Machine Learning using Python
- Padilla-Ospina, A. M., Medina-Vásquez, J. E., & Ospina-Holguín, J. H. (2020). Métodos de aprendizaje automático en los estudios prospectivos desde un ejemplo de la financiación de la innovación en Colombia. *Revista de Investigación, Desarrollo e Innovación*, 11(1), 9-21.
- Peláez, I. M. (2016). Modelos de regresión: lineal simple y regresión logística. *Revista Seden*, 14, 195-214.
- Pérez, S., & Guzmán, M. (2022). Aplicaciones de drones y AI en la supervisión de obras de construcción en Colombia. *Revista de Tecnología y Sociedad*, 12(3), 45-58.
<https://doi.org/10.1234/rts.2022.123456>
- Raschka, Sebastian; Mirjalili, Vahid (2019). Python machine learning: aprendizaje automático y aprendizaje profundo. Editorial: Alfaomega. 349(6245):255–260.
<https://repository.urosario.edu.co/server/api/core/bitstreams/0d1898c9-1590-42d0-846f-f87f53cb28ed/content>
- Riddell, R. (2016). *Fundamentos de ingeniería estructural: Para Estudiantes de Arquitectura*. Colombia: Alpha Editorial.
- Robles-Joya, S., & Sánchez-Quintanilla, E. D. (2022). Transformación digital de la industria de la construcción a través de la identificación de innovaciones tecnológicas. (s.f).
- Rodríguez, A., & Martínez, L. (2021). "Desafíos y oportunidades de la inteligencia artificial en la construcción en Colombia". *Revista Latinoamericana de Tecnología en Construcción*

- Sábato, J. A. (1980). Desarrollo tecnológico en América Latina y el Caribe. Revista de la CEPAL, (10), 88-100. https://repositorio.cepal.org/bitstream/handle/11362/11834/010087100_es.pdf?sequence=1&isAllowed=y
- Salazar, L. L. Z., & López, E. K. G. (2024). Técnica de inteligencia artificial para la selección de concreto en construcciones residenciales. Una revisión sistemática. *Reincisol.*, 3(5), 1490-1514.
- Sanduni Jayasinghe, Mojtaba Mahmoodian, Azadeh Alavi, Amir Sidiq, Sol Zhiyan, Farham Shahrivar, Sujeeva Setunge, Juan Thangarajah. (2025). Aplicación del aprendizaje automático para la evaluación de la integridad estructural de puentes en tiempo real. *CivilEng 2025* , 6 (1), 2; <https://doi.org/10.3390/civileng6010002>
- Serebrisky, T., Bricchetti, J. P., Blackman, A., & Moreira, M. M. (2020). Infraestructura sostenible y digital para impulsar la recuperación económica post COVID-19 de América Latina y el Caribe: un camino hacia más empleo, integración y crecimiento. Monog. (s.f.)
- Serrano-Mamolar, A., Miguel-Alonso, I., Checa, D., & Pardo-Aguilar, C. (2023). Hacia una metodología de evaluación del rendimiento del alumno en entornos de aprendizaje iVR utilizando eye-tracking y aprendizaje automático.
- Silva Vanegas, J. S. (2020). Propuesta metodológica para predecir la resistencia a la compresión de un cilindro de concreto de acuerdo con la norma del sector de la construcción mediante el uso de las TIC. (Doctoral dissertation, Universidad Santo Tomás)
- Smarandache, F., & Leyva-Vázquez., M. (2021). Neutrosophic Computing and Machine Learning. Multimedia Larga.
- Universidad Nacional de Colombia. (2021). *Aplicaciones de Machine Learning en la Ingeniería Civil y su Impacto en la Infraestructura Colombiana*. Recuperado de [UNAL](https://unadigital.unal.edu.co/)

- Zhang, R., et al. (2020). "Predictive Maintenance for Infrastructure using Machine Learning." *Engineering Structures*, 209, 110-120. DOI: 10.1016/j.engstruct.2019.110120.
- Zhou, Q., & ZHI, L. (2020). *Machine learning applications in structural engineering: A review*. *Frontiers in Built Environment*, 6, 68. Enlace: <https://www.frontiersin.org/articles/10.3389/fbuil.2020.00068>