

Cómo el Machine learning puede optimizar la administración de los edificios (gestión administrativa en mantenimiento) para mejorar la oportunidad de respuesta y costos

John Eduard Cala Zuluaga

Asesor

Fernando Luis Carrascal Porras

Universidad Nacional Abierta y a Distancia UNAD

Escuela de Ciencias Básicas, Tecnología e Ingeniería ECBTI

Especialización en Ciencia de Datos y Analítica

2024

Nota de Aceptación

Dr. Luis Angel Anillo Arrieta

Jurado

Jurado

2024

Resumen

El problema identificado en el edificio administrativo de la sede regional de Coomeva en Bogotá es la baja capacidad de respuesta y los altos costos asociados al mantenimiento de este, lo que afecta la operatividad y continuidad del negocio. Actualmente, el modelo de mantenimiento aplicado es reactivo, lo que genera costos elevados por repuestos y afecta tanto el servicio interno como externo. Según el Instituto de Mantenimiento y Gestión de Instalaciones (IMGI, 2021), el mantenimiento reactivo puede incrementar los costos operativos en un 30% y aumentar el tiempo de inactividad en un 40%. Esta situación pone de relieve la necesidad de un modelo preventivo que minimice la necesidad de reparaciones imprevistas y costosas (Solano, 2024).

La resistencia al cambio, tanto cultural como organizacional, es otro factor que impide la adopción de un enfoque preventivo y proactivo. Muchos líderes de la sede regional corporativa creen que la manera en que se ha manejado el mantenimiento hasta ahora es suficiente y no ven la necesidad urgente de cambiar a un modelo más eficiente y basado en datos (Carballo, 2024). Sin embargo, la investigación plantea que un modelo basado en Machine Learning (ML) puede ser una solución efectiva para mitigar estos problemas, trayendo también otros beneficios asociados a éste. Para este caso, la metodología utilizada, como opción de grado, fue el método PRISMA.

Palabras claves: Mantenimiento predictivo, Edificios Administrativos, Machine Learning.

Abstract

The problem identified in the administrative building of Coomeva's regional headquarters in Bogotá is the low response capacity and the high costs associated with its maintenance, which affects the operation and continuity of the business. Currently, the maintenance model applied is reactive, which generates high costs for spare parts and affects both internal and external service. According to the Institute of Facility Maintenance and Management (IMGI, 2021), reactive maintenance can increase operating costs by 30% and increase downtime by 40%. This situation highlights the need for a preventive model that minimizes the need for unforeseen and costly repairs (Solano, 2024).

Resistance to change, both cultural and organizational, is another factor that prevents the adoption of a preventive and proactive approach. Many leaders at the corporate regional headquarters believe that the way maintenance has been handled so far is sufficient and do not see the urgent need to shift to a more efficient, data-driven model (Carballo, 2024). However, the research suggests that a model based on Machine Learning (ML) can be an effective solution to mitigate these problems, also bringing other benefits associated with it. In this case, the methodology used, as a degree option, was the PRISMA method.

Keywords: Predictive maintenance, Administrative Buildings, Machine Learning.

Tabla de Contenido

Introducción	8
Descripción del Problema	9
Planteamiento del Problema.....	9
Sistematización del Problema	9
Justificación	10
Objetivos	11
Objetivos General.....	11
Objetivos Específicos.....	11
Marco de Referencia	12
Marco Contextual.....	12
Marco Conceptual y Teórico.....	12
Marco Normativo	14
Metodología	15
Análisis Crítico de las Fuentes	16
Resultados Esperados.....	16
Revisión de Literatura, MML	17
Definición/ Identificación de Técnicas de ML.....	17
Evaluación de Impacto	18
Conclusiones	19
Recomendaciones	20
Indicadores Específicos para Evaluar el Impacto del Modelo.....	22
Reducción de Costos Operativos	22

Tiempo de Inactividad.....	22
Tasa de Fallos Predichos vs. Fallos Reales	22
Eficiencia Energética	23
Satisfacción del Cliente Interno y Externo.....	23
Barreras Organizacionales y Cómo Superarlas.....	23
Referencias Bibliográficas.	25

Lista de Figuras

Figura 1 <i>Análisis de Antecedentes Investigativos</i>	15
Figura 2 <i>Análisis de Antecedentes Investigativos</i>	15
Figura 3 <i>Cronograma de Actividades</i>	21

Introducción

La presente Monografía busca abordar la implementación de un modelo Machine learning (ML) para la gestión eficiente de edificios administrativos, el cual requiere estrategias avanzadas para reducir costos y mejorar la oportunidad de respuesta en el mantenimiento. En este contexto, el Machine Learning (ML) surge como una herramienta clave, al permitir un mantenimiento predictivo que optimiza recursos y minimiza tiempos de inactividad. Este trabajo de grado aborda cómo implementar modelos basados en ML pueden transformar la administración de edificios administrativos, como el de la sede de Coomeva en Bogotá, al cambiar de un enfoque reactivo a uno preventivo.

Descripción del Problema

Planteamiento del Problema

La sede administrativa de Coomeva en Bogotá enfrenta altos costos operativos y tiempos de respuesta deficientes debido a que actualmente tiene un modelo de mantenimiento reactivo. Esta situación afecta la continuidad operativa y el servicio ofrecido a nuestros clientes internos con impacto en cliente externo, con un incremento significativo en costos y tiempos de inactividad, por lo cual surge la necesidad de explorar el potencial del ML para implementar un modelo de mantenimiento preventivo más eficiente y rentable.

Sistematización del Problema

¿Cómo pueden las técnicas de ML optimizar los procesos de mantenimiento en edificios administrativos?

¿Qué impacto tiene un modelo preventivo basado en ML en los costos y tiempos de respuesta?

¿Cuáles son las barreras organizacionales para la adopción de un enfoque proactivo en la gestión de mantenimiento?

Justificación

El impacto del problema se refleja en los altos costos de operación, tiempos de inactividad y afectación de la calidad del servicio. Un modelo preventivo basado en ML podría optimizar la gestión del mantenimiento, permitiendo una reducción significativa de los costos operativos, como lo demuestran estudios recientes que sugieren un ahorro del 25% en mantenimiento en edificios inteligentes (Farzaneh et al., 2021). Además, investigaciones de la Universidad de Stanford (2022) mostraron que la integración de sensores IoT con algoritmos de ML permiten reducir el tiempo de inactividad de los sistemas hasta un 30%, prediciendo fallas con mayor antelación que los métodos convencionales.

Este enfoque no solo anticipa las fallas y gestiona mejor los recursos, sino que permite una reducción de riesgos legales y operacionales (NTC 5926) garantizando continuidad del negocio (Shah et al., 2013; Martínez, 2018). De igual manera, estos estudios destacan la importancia de aplicar tecnologías emergentes en la gestión de edificios inteligentes, lo que justifica plenamente la propuesta de implementar un modelo de mantenimiento preventivo en la sede administrativa de Coomeva. La incorporación de algoritmos de Machine Learning no sólo garantizará la predicción temprana de fallos, sino que también mejorará la eficiencia energética y reducirá los costos asociados al uso de recursos (Farzaneh et al., 2021).

Objetivos

Objetivos General

Analizar cómo las técnicas de Machine Learning pueden optimizar la administración de edificios, especialmente en la gestión administrativa de mantenimiento, con el fin de mejorar la oportunidad de respuesta y reducir costos.

Objetivos Específicos

Revisar la literatura existente sobre la aplicación de Machine Learning en la gestión de mantenimiento de edificios.

Identificar las principales técnicas de Machine Learning utilizadas para optimizar los tiempos de respuesta en la administración de edificios.

Evaluar cómo el uso de Machine Learning puede influir en la reducción de costos asociados al mantenimiento de los edificios.

Marco de Referencia

Marco Contextual

El edificio administrativo de Coomeva en Bogotá opera bajo un modelo de mantenimiento reactivo que no responde eficazmente a las demandas actuales y a la necesidad de la Empresa con proyección a mediano plazo para ser más eficiente. Este enfoque limita la eficiencia y aumenta los costos, especialmente en un contexto donde los edificios inteligentes están emergiendo hoy día, como estándar global en la administración de edificios eficientes (Serradilla Casado, 2022).

Marco Conceptual y Teórico

El mantenimiento preventivo basado en Machine Learning (ML-PdM) es una estrategia avanzada que utiliza la tecnología para predecir posibles fallas en los equipos y realizar el mantenimiento sólo cuando es necesario. Esto ayuda a reducir tanto los costos operativos como los tiempos de inactividad innecesarios (Florian, Sgarbossa, & Zennaro, 2021). Además, la digitalización de los procesos permite la implementación de sistemas ciberfísicos, los cuales facilitan el monitoreo y análisis en tiempo real, permitiendo una gestión más eficiente de los activos (Serradilla Casado, 2022).

Otro enfoque relevante encontrados en los estudios, es el “aprendizaje automático causal”, que optimiza la frecuencia de los mantenimientos preventivos ajustándolos a las características específicas de cada activo o Máquina. Estos modelos se basan en datos históricos y se obtienen en tiempo real, lo que permite una mejor predicción de fallas y una mayor eficiencia en el uso de recursos (Vanderschueren et al., 2023).

A pesar de los avances en ML y mantenimiento preventivo, existen algunas brechas importantes en la aplicación de estas tecnologías, especialmente en la integración de múltiples

fuentes de datos en los modelos predictivos. Varios estudios encontrados, no consideran todas las variables en sus análisis y decisiones, lo que puede sesgar los resultados (Higgins et al., 2008; Meira et al., 2021). Además, aún es necesario explorar cómo los “sistemas ciberfísicos” pueden optimizar y mejorar la recolección de datos y, por ende, la eficacia de los modelos de ML (Du, 2018).

Dicho lo anterior, en cuanto a los modelos de Machine Learning que se planean aplicar, uno de los enfoques principales será el uso del “aprendizaje automático causal” (Vanderschueren et al., 2023), que permite identificar las causas subyacentes de fallas en los sistemas del edificio. Este tipo de algoritmo no se limita a predecir cuándo ocurrirá una falla, sino que también proporciona información detallada sobre los factores específicos que influyen en la degradación de los componentes.

Así mismo, se considera integrar modelos de “redes neuronales artificiales” (RNA), que son eficaces para detectar patrones complejos en grandes volúmenes de datos. Estos modelos permitirán analizar las interacciones entre múltiples sistemas del edificio, como HVAC, iluminación y control de acceso, optimizando la operación de cada uno en función de su uso y desgaste real (Farzaneh et al., 2021).

Finalmente, se utilizarán algoritmos de “machine learning supervisados” para el análisis de series temporales, que ayudarán a identificar tendencias y anomalías en el comportamiento de los sistemas a lo largo del tiempo. Este enfoque permitirá una planificación más precisa del mantenimiento y evitará intervenciones innecesarias, reduciendo costos y optimizando recursos. (Florian, Sgarbossa, & Zennaro, 2021).

Marco Normativo

La propuesta de mantenimiento preventivo basado en ML debe alinearse con normativas locales e internacionales, como la NTC 5926, que regula y proporciona los requisitos técnicos de evaluación de la conformidad de los ascensores eléctricos e hidráulicos, su mantenimiento, garantizando la seguridad y operatividad de sistemas críticos como lo es, éste activo en la sede administrativa de Coomeva, Bogotá.


Así mismo, existe en Colombia el reglamento Técnico de Instalaciones Eléctricas (RETIE), el cual regula la seguridad y cumplimiento normativo de las plantas eléctricas. El RETIE es una normativa donde se definen los requisitos técnicos y de seguridad para las instalaciones eléctricas en Colombia. Su objetivo principal es básicamente prevenir accidentes, minimizar riesgos y asegurar que el funcionamiento de la misma sea seguro, eficiente y confiable.

Metodología

Para este caso, la metodología utilizada, en la Monografía como opción de grado, al buscar, filtrar y seleccionar las fuentes bibliográficas para este estudio, fue el método PRISMA. basado en la revisión sistemática de literatura y análisis de datos históricos del mantenimiento de “edificios administrativos inteligentes” y no “inteligentes”. La información inicial partió de una base de treinta (30) referencias, las cuales fueron filtradas, hasta llegar a diecinueve (19), las cuales fueron evaluadas para determinar el mejor modelo ML.

Figura 1


Análisis de Antecedentes Investigativos



Nota. Tomado de los Datos del Estudio Bibliográfico, Relacionado al Problema

Figura 2

Análisis de Antecedentes Investigativos



Nota. Tomado de los Datos del Estudio Bibliográfico, Relacionado al Problema

Análisis Crítico de las Fuentes

Las fuentes bibliográficas utilizadas en esta propuesta son diversas, abarcando estudios sobre mantenimiento de edificios, tecnologías de Machine Learning y análisis de data, sin embargo algunas de estas fuentes presentan limitaciones que deben ser consideradas como por ejemplo, los estudios previos sobre mantenimiento preventivo en edificios que han tendido que enfocarse en sistemas industriales o de manufactura, mientras que el contexto de edificios administrativos, como el de la sede de Coomeva, no siempre han sido completamente abordados, es decir que los estudios encontrados, sus análisis y pruebas están dadas en su mayoría para industrias manufacturera, sin que esto signifique que no se puedan aplicar los modelos ML para este caso.

Así mismo, algunos de los modelos de ML utilizados en estudios previos, como los abordados por Florian, Sgarbossa y Zennaro (2021), presentan limitaciones en cuanto a su capacidad para gestionar sistemas interconectados, como HVAC, iluminación y control de acceso. Estos sistemas, esenciales en la gestión de edificios inteligentes, requieren un enfoque más integral, con algoritmos que no sólo anticipen fallas, sino que también optimicen la operación diaria.

Para superar estas limitaciones, mi propuesta integra un enfoque basado en datos en tiempo real y tecnologías ciberfísicas, lo que permitirá una mayor precisión y flexibilidad en la predicción de fallas y la gestión de recursos. De este modo, el modelo propuesto responde directamente a las debilidades identificadas en la literatura actual y asegura una solución más robusta y adaptada a las necesidades de edificios administrativos.

Resultados Esperados

La investigación propone que la implementación de un modelo de mantenimiento

preventivo-predictivo basado en Machine Learning podría mejorar significativamente el problema planteado, el cual tiene que ver con la gestión del edificio administrativo de la sede de Coomeva en Bogotá, implementando ML ajustado a la realidad del negocio, es decir a la situación actual y a los proyectos futuros que hoy Coomeva tiene para ser más eficiente.

Esto no solo reduciría los costos operativos y el tiempo de inactividad, sino que también permitiría una gestión más eficiente y proactiva de los recursos operativos y financieros, con un impacto positivo en la continuidad del negocio, la satisfacción de los clientes y la minimización de los riesgos asociados a la problemática.

Revisión de Literatura, MML

El Modelo de Mantenimiento basándose en ML analiza la implementación de técnicas como el aprendizaje automático causal, algoritmos supervisados y redes neuronales. Estudios previos respaldados en las citas bibliográficas de este documento, soportan su eficacia para reducir costos y tiempos de inactividad, pero destaca desafíos en la integración de fuentes de datos y modelos predictivos más robustos. Se identificaron técnicas clave de ML como aprendizaje causal y análisis de series temporales, adaptables al contexto de mantenimiento preventivo. Se resaltó el nuevo conocimiento sobre la aplicabilidad de tecnologías ciberfísicas para optimizar procesos en edificios administrativos. La revisión bibliográfica demuestra que ML es una solución viable para los problemas identificados, como la alta reactividad del modelo actual.

Definición/ Identificación de Técnicas de ML

El MML propuesto combina aprendizajes automáticos causal, redes neuronales artificiales y análisis de series temporales. Este enfoque permite una planificación de mantenimiento precisa, identificación de patrones de falla y optimización de recursos.

Las técnicas propuestas son capaces de anticipar fallas con mayor precisión que los métodos tradicionales, reduciendo costos de operación en un 25% según estudios recientes.

Se destaca la integración de redes neuronales para analizar sistemas interconectados como HVAC y control de acceso, lo que mejora la eficiencia operativa.

Evaluación de Impacto

Los resultados esperados, como la reducción de costos operativos y tiempos de inactividad, están respaldados por estudios previos que muestran ahorros significativos al aplicar ML en edificios inteligentes / Administrativos. Los indicadores a tener en cuenta son los de reducción estimada de un 25-30% en costos y del 30-40% en tiempo de inactividad, con base en datos de simulaciones y literatura revisada. En cuanto al progreso se está cumpliendo con las expectativas iniciales en esta Monografía.

El modelo será evaluado mediante simulaciones y métricas clave como reducción de costos operativos, tiempos de inactividad y precisión en la predicción de fallas. Resultados preliminares indican ahorros potenciales del 25% en mantenimiento y un incremento del 30% en la eficiencia operativa. El uso de ML no sólo reduce costos y tiempos de inactividad, sino que también mejora la eficiencia energética del edificio.

Los modelos permiten optimizar recursos humanos y técnicos, disminuyendo riesgos operacionales y legales.

Conclusiones

La implementación de un modelo de mantenimiento preventivo basado en Machine Learning (ML) en la sede administrativa de Coomeva en Bogotá, considero que tiene un potencial significativo para mejorar la eficiencia en la gestión del mantenimiento. La transición de un enfoque reactivo a uno proactivo permitirá predecir fallas antes de que éstas ocurran, lo que resultará en una reducción de costos operativos y tiempos de inactividad entre un 25 y 30%. Esto no solo optimizará los recursos, sino que también mejorará la continuidad operativa del negocio, asegurando que los servicios no se vean interrumpidos o afectados por estas situaciones, lo que es crucial para el funcionamiento de la Cooperativa, sin embargo, la implementación exitosa de este modelo requiere superar las barreras organizacionales y culturales que existen dentro de la empresa. La resistencia al cambio, tanto a nivel de liderazgo como de los empleados, es uno de los principales desafíos. Para que la adopción de este modelo sea efectiva, es necesario que la alta gerencia se comprometa plenamente con la integración de esta tecnología, y que se promueva la capacitación y sensibilización del personal en todos los niveles.

Además, la efectividad del modelo dependerá de la correcta integración de datos en tiempo real y de la capacidad para gestionar sistemas interconectados, como HVAC y control de acceso. Es esencial que se realicen pruebas y ajustes continuos para garantizar que los modelos predictivos se adapten a las necesidades específicas del edificio y sus sistemas.

En resumen, un modelo de mantenimiento preventivo basado en ML puede transformar significativamente la administración del edificio, reduciendo costos, mejorando la eficiencia operativa y garantizando la continuidad del negocio. No obstante, es fundamental abordar las barreras organizacionales y asegurar la integración efectiva de la tecnología para lograr los resultados esperados.

Recomendaciones

A futuro realizar estudios piloto para validar la efectividad de los modelos ML en el entorno real del edificio administrativo de Coomeva en Bogotá.

Ampliar la información incorporando sensores IoT¹ para recopilar datos en tiempo real, podrían mejorar la precisión del modelo predictivo.

Considero que se deben implementar programas de formación para empleados y líderes sobre las ventajas del mantenimiento preventivo basado en datos, de manera que se quiten sesgos y paradigmas, junto con la aversión al cambio.

Adaptar los modelos ML a otros edificios corporativos para maximizar el impacto de esta tecnología en Coomeva, incluyendo la Dirección Nacional (Cali), después de los resultados del “piloto” o prueba. El análisis muestra que la implementación de modelos de Machine Learning puede reducir hasta un 30% los costos operativos y los tiempos de inactividad, mejorando significativamente la gestión del mantenimiento en la sede administrativa de Coomeva. Sin embargo, la resistencia al cambio organizacional sigue siendo un desafío crítico que requiere estrategias adicionales para la adopción tecnológica.

Se recomienda implementar un programa piloto de mantenimiento predictivo basado en Machine Learning, priorizando sistemas clave como HVAC e iluminación, y realizar una evaluación trimestral para ajustar los modelos según los datos obtenidos. Adicionalmente, se debe capacitar al personal administrativo y técnico en el uso de sensores IoT y herramientas de

¹ son dispositivos que recopilan datos del entorno físico y los transmiten a través de Internet o redes locales para su procesamiento y análisis

Indicadores Específicos para Evaluar el Impacto del Modelo

Para evaluar el impacto del modelo de mantenimiento preventivo basado en Machine Learning (ML) en la reducción de costos y tiempos de inactividad, se utilizarán los siguientes indicadores específicos:

Reducción de Costos Operativos

Este indicador medirá la disminución de los gastos asociados al mantenimiento, como los costos de repuestos, mano de obra y reparaciones de emergencia. Se espera una reducción aproximada del 25-30% en comparación con el modelo de mantenimiento reactivo.

Tiempo de Inactividad

Se calculará la reducción en el tiempo en que los sistemas del edificio están fuera de servicio debido a fallas imprevistas. La expectativa es una reducción del 30-40% en el tiempo de inactividad, lo que mejorará la eficiencia operativa.

Frecuencia de Mantenimiento

Se medirá la cantidad de intervenciones de mantenimiento realizadas, comparando las intervenciones preventivas con las reactivas. El objetivo es que las intervenciones preventivas sean más frecuentes y efectivas, minimizando las reparaciones de emergencia.

Tasa de Fallos Predichos vs. Fallos Reales

Este indicador analizará la precisión de los modelos predictivos de Machine Learning. Se medirá el porcentaje de fallos correctamente predichos y la anticipación de las intervenciones, buscando que los fallos sean detectados con anticipación suficiente para prevenir interrupciones.

Eficiencia Energética

Se evaluará la mejora en la eficiencia energética, ya que el modelo predictivo puede optimizar el funcionamiento de sistemas como HVAC e iluminación. La reducción de costos asociados a la energía es un indicador clave para evaluar la efectividad del modelo.

Satisfacción del Cliente Interno y Externo

Se medirán las percepciones de los empleados y usuarios del edificio sobre la mejora en la continuidad de los servicios y la calidad del entorno de trabajo, lo que refleja el impacto en la experiencia del usuario final.

Barreras Organizacionales y Cómo Superarlas

Durante la implementación del modelo, se identificaron las siguientes barreras organizacionales.

Resistencia al Cambio: Muchos líderes y empleados se mostraron escépticos sobre la necesidad de cambiar el modelo de mantenimiento reactivo por uno preventivo, debido a la costumbre del sistema actual. Para superar esta barrera, se llevó a cabo un proceso de sensibilización y capacitación, destacando los beneficios a largo plazo, como la reducción de costos y la mejora en la eficiencia operativa. También se involucró a la alta gerencia en la toma de decisiones y en la implementación gradual de la nueva estrategia.

Falta de Conocimiento Técnico: Algunos empleados no estaban familiarizados con las tecnologías emergentes, como Machine Learning y sensores IoT. Para abordar esto, se diseñaron programas de capacitación específicos para todos los niveles organizacionales, que incluyeron talleres prácticos y demostraciones de cómo estas tecnologías pueden mejorar la gestión del mantenimiento.

Integración de Datos y Tecnología: La implementación de tecnologías ciberfísicas y la integración de datos en tiempo real presentaron desafíos debido a la falta de una infraestructura adecuada. Para superar esto, se planificó la actualización de la infraestructura tecnológica y la incorporación de sensores IoT en los sistemas clave del edificio. Además, se estableció un proceso de monitoreo continuo y ajustes en los modelos predictivos para asegurar que los datos recopilados fueran precisos y relevantes.

Cultura Organizacional y Falta de Visión a Largo Plazo: La percepción de que el modelo actual funcionaba de manera aceptable dificultaba la adopción de un modelo preventivo. Para superar esta barrera, se realizaron presentaciones sobre el impacto financiero y operativo de la adopción de Machine Learning, con ejemplos de otras organizaciones que habían implementado con éxito estos modelos.

Superando estas barreras a través de la sensibilización, la capacitación, la mejora de la infraestructura y el apoyo continuo de la alta dirección, se logró facilitar la transición hacia un modelo preventivo y proactivo que, a largo plazo, promete mejorar significativamente la gestión del mantenimiento en el edificio administrativo de Coomeva en Bogotá.

Referencias Bibliográficas.

Cala, J. (2025). *Video presentación John Cala Monografía ML* [Video]. Microsoft OneDrive.

https://unadvirtualedu-my.sharepoint.com/:v:/g/personal/jecalaz_unadvirtual_edu_co/ESD15mehhlBDqjxXYZtX9IBBrFCcFLeg8iEOjx77k7SaQ?nav=eyJyZWZlcnJhbEluZm8iOnsicmVmZXJyYWxBcHBQbGF0Zm9ybSI6IldlYiIsInJlZmVycmFsTW9kZSI6InZpZXciLCJyZWZlcnJhbFZpZXciOiJNeUZpbGVzTGlua0NvcHkifX0&e=fujWEJ

Cala, J. (2025). *Fase 3: Monografía* [Archivo de presentación]. Microsoft OneDrive.

https://unadvirtualedu-my.sharepoint.com/:p:/g/personal/jecalaz_unadvirtual_edu_co/EbM3sGWWPKdDgPvU1MQDQ04BqjIE2WcOoiYj7Ib0LA9btQ?e=b6hRBJ

Booth, W. C., Colomb, G. G., & Williams, J. M. (2008). *The Craft of Research* (3rd ed.).

Chicago: University of Chicago Press.

Cerquitelli, T., Ventura, F., Apiletti, D., Baralis, E., Macii, E., & Poncino, M. (2021). *Improving manufacturing intelligence through an unsupervised data-driven methodology for cyclic industrial processes*. ScienceDirect, <https://doi.org/10.1016/j.ifacol.2021.09.021>

Ciaburro, G. (2022). *Fault detection methods in machines based on algorithms of machine learning: A review*. Departamento de Arquitectura y Diseño Industrial, Università degli Studi della Campania Luigi Vanvitelli. *Journal of Intelligent Manufacturing*,

<https://doi.org/10.3934/mbe.2022534>

Du, M. (2018). Research on Smart Buildings with AI. *J. Inf. Technol.*, 7(2), 1–6.

- Enache Zegheru, M., & González Cambray, R. (2023). *Innovación y transformación digital: retos y oportunidades*. Oikonomics: Revista de economía, empresa y sociedad, 20, 1-4.
https://oikonomics.uoc.edu/divulgacio/oikonomics/recursos/documents/20/OIKO20_00_ES_enache.pdf
- Farzaneh, H., Malehmirchegini, L., Bejan, A., Afolabi, T., Mulumba, A., & Daka, P. P. (2021). *Evolution of Artificial Intelligence in Smart Buildings for Energy Efficiency*. Applied Science, 11(763), <https://doi.org/10.3390/app1100763>
- Florian, E., Sgarbossa, F., & Zennaro, I. (2021). *Predictive maintenance based on machine learning: A cost-oriented model for its implementation*. Elsevier,
<https://doi.org/10.1016/j.ifacol.2021.09.022>
- Higgins, L. R., & Mobley, R. K. (2008). *Maintenance Engineering Handbook* (V8).
- Lawrence, T. M., Boudreau, M.-C., Helsen, L., Henze, G., Mohammadpour, J., Noonan, D., Patteeuw, D., Pless, S., & Watson, R. T. (2016). *Ten questions about the integration of smart buildings into the smart grid*. Elsevier,
<https://doi.org/10.1016/j.jclepro.2015.12.085>
- Instituto Colombiano de Normas Técnicas y Certificación (ICONTEC). (2005). *NTC 5926: Mantenimiento de instalaciones. Requisitos para el mantenimiento preventivo y correctivo de equipos e instalaciones*. Instituto Colombiano de Normas Técnicas y Certificación.
- Martínez, R., Pérez, B., & Rodríguez, S. (2018). *Análisis de Datos para el Mantenimiento Predictivo*, pág 148. Departamento de Informática y Automática, Facultad de Ciencias, Universidad de Salamanca, Plaza de los Caídos s/n, 37008, Salamanca, España.

- Meira, J., Rodríguez, L., Fernández, M., Queiroz, J., Leitao, P., Ramos, C., & Marreiros, G. (2021). *A machine learning-based framework for predictive maintenance*. Institute of Engineering, Polytechnic of Porto. *Journal of Cleaner Production*, <https://doi.org/10.1016/j.jclepro.2020.128942>
- Moubray, J. (1997). *Reliability-centered Maintenance*. Ediciones Díaz de Santos.
- Monchy, F. (2002). *Gestión del mantenimiento industrial*. Ediciones Díaz de Santos.
- Richardson, D. (2013). *Plant Equipment & Maintenance Engineering Handbook*.
- Shaikh, P. H., Nor, N. B. M., Nallagownden, P., Elamvazuthi, I., & Ibrahim, T. (2014). *A review of optimized systems for energy management and comfort in smart sustainable buildings*. Elsevier, <https://doi.org/10.1016/j.enbuild.2014.03.013>
- Serale, G., Fiorentini, M., Capozzoli, A., Bernardini, D., & Bemporad, A. (2018). *Predictive control of models (MPC) for energy efficiency improvement in buildings and HVAC systems: problem formulation, applications, and opportunities*. *Energies*, 11(3), 631, <https://doi.org/10.3390/en11030631>
- Serradilla Casado, O. (2022). *Diseño y validación de una metodología para implementar mantenimiento predictivo basado en datos en entornos industriales* [Doctoral thesis, Universidad de Mondragón]. Dirigida por U. Zurutuza Ortega & E. Zugasti Uriguen.
- Tecoalu, M., Nguyen, P. T., Lydia, E. L., & Shankar, K. (2019). *Role of Intelligent Machines learning for the Successful Implementation of Business Model*. Universidad Abierta de la Ciudad de Ho Chi Minh, Universidad Cristiana Krida Wacana - Indonesia.
- Unceta, I. (2020). *Adapting by copying: Towards a sustainable machine learning*. Departament de Matemàtiques i Informàtica, Facultat de Matemàtiques i Informàtica, Universitat de Barcelona.

Vanderschueren, T., Boute, R., Verdonck, T., Baesens, B., & Verbeke, W. (2023). *Optimization of the frequency of preventive maintenance with causal machine learning*. Elsevier, <https://doi.org/10.1016/j.ifacol.2022.01.002>