

REVISIÓN DEL MANTENIMIENTO PREDICTIVO POTENCIADO POR MACHINE
LEARNING EN EL SECTOR INDUSTRIAL DE AMÉRICA LATINA: SITUACIÓN
ACTUAL, DESAFÍOS Y TENDENCIA



Por:

HENRY ESTEBAN ROMERO RAMÍREZ



UNIVERSIDAD SANTO TOMÁS
FACULTAD DE INGENIERÍA MECÁNICA
VILLAVICENCIO

2025

REVISIÓN DEL MANTENIMIENTO PREDICTIVO POTENCIADO POR MACHINE
LEARNING EN EL SECTOR INDUSTRIAL DE AMÉRICA LATINA: SITUACIÓN
ACTUAL, DESAFÍOS Y TENDENCIA

Por:

HENRY ESTEBAN ROMERO RAMIREZ

Trabajo de grado presentado como requisito para optar al título de Especialista en Gerencia de
Mantenimiento y Gestión de Activos

Asesor

Mg. MARLON YESID POVEDA PACHÓN

Magister en Ingeniería Mecánica

UNIVERSIDAD SANTO TOMÁS
FACULTAD DE INGENIERÍA MECÁNICA
VILLAVICENCIO

2025

Autoridades Académicas

P. Álvaro José ARANGO RESTREPO, O. P.

Rector General

P. Mauricio Antonio CORTÉS GALLEGO, O. P.

Vicerrector Académico General

P. José Antonio BALAGUERA CEPEDA, O. P.

Rector Seccional Villavicencio

P. Adrián Mauricio GARCÍA PEÑARANDA, O. P.

Vicerrector Académico Seccional Villavicencio

Mg. Julieth Andrea SIERRA TOBÓN

Secretaria General Seccional Villavicencio

PhD. Handel Andrés MARTÍNEZ SARACHE

Decano de la Facultad de Ingeniería Mecánica

Dedicatoria

A mis padres, quienes con su sacrificio y dedicación me han enseñado que no hay sueño inalcanzable cuando se tiene voluntad. A mis hermanos, por su apoyo incondicional en cada paso de este camino. A mi abuela, por ser el faro de sabiduría que siempre ha iluminado mi camino. Y a mi sobrino, cuya mirada llena de confianza me inspira a ser mejor cada día.

Agradecimientos

Agradezco a la Universidad Santo Tomás por brindarme acceso a las fuentes de información que hicieron posible la realización de este trabajo, así como al Ingeniero Marlon Yesid Poveda y al Ingeniero Jerson Fabian Maldonado por su colaboración en la redacción y revisión del documento, y por sus valiosas sugerencias y apoyo durante todo el proceso.

Contenido

	Pág.
Resumen	11
Abstract.....	12
Glosario.....	13
1. Introducción.....	14
2. Planteamiento del Problema.....	16
3. Justificación.....	18
4. Objetivos	20
4.1. Objetivo General.....	20
4.2. Objetivos Específicos.....	20
5. Marco Teórico	21
5.1. Industria 4.0	21
5.2. Mantenimiento Industrial.....	23
5.3. Machine Learning	23
5.3.1 Aprendizaje Supervisado	25
5.3.2 Aprendizaje No Supervisado	27
5.3.3 Aprendizaje Reforzado	28
5.3.4 Aprendizaje Profundo	29
5.4. Machine Learning en el Mantenimiento Predictivo.....	30
6. Metodología.....	32
6.1. Etapas de la Revisión	32
6.1.1 Fuentes de Información.....	33
6.1.2 Preguntas de la Revisión.....	34
6.1.3 Estrategia de Búsqueda.....	34
6.1.4 Selección de Documentos	35
6.1.5 Criterios de Inclusión y Exclusión.....	36
6.1.6 Evaluación de Calidad	37
7. Resultados de la Revisión Sistemática	39
7.1. Implementación de ML en el MP en el Sector Industrial de América Latina	40

- 7.1.1 Países Destacados en la Implementación de ML 40
- 7.1.2 Industrias con Mayor Aplicación de ML 41
- 7.1.3 Equipos y Sistemas Analizados con ML 42
- 7.1.4 Técnicas de ML Más Utilizadas en Industrias Latinoamericanas 44
- 7.1.5 Lenguajes de Programación Predominantes 45
- 7.1.6 Argentina..... 46
- 7.1.7 Brasil..... 47
- 7.1.8 Chile..... 50
- 7.1.9 Colombia..... 52
- 7.1.10 Ecuador..... 53
- 7.1.11 Honduras 55
- 7.1.12 México..... 56
- 7.1.13 Perú..... 56
- 7.2. Desafíos de Estas Tecnologías en América latina 57
 - 7.2.1 Falta de Talento Especializado 57
 - 7.2.2 Barreras Organizacionales y Culturales..... 58
 - 7.2.3 Barreras Económicas 59
 - 7.2.4 Infraestructura y Disponibilidad de Datos 60
 - 7.2.5 Ética, Regulación e Información..... 61
 - 7.2.6 Dependencia Tecnológica..... 62
- 7.3. Tendencias y Oportunidades..... 62
- Conclusiones..... 65
- Referencias 68
- Anexos 82

Lista de Tablas

	Pág.
Tabla 1 Tipos de tecnologías de la industria 4.0.....	22
Tabla 2 Tipos de mantenimiento más utilizados en empresas a nivel nacional e internacional ..	23
Tabla 3 Técnicas de aprendizaje supervisado en Machine Learning.....	25
Tabla 4 Técnicas de aprendizaje no supervisado en Machine Learning.....	27
Tabla 5 Técnicas de aprendizaje reforzado en Machine Learning.....	28
Tabla 6 Técnicas de aprendizaje profundo más utilizadas.....	29
Tabla 7 Casos de implementación del ML en el MP en América Latina	82

Lista de Figuras

	Pág.
Figura 1 Principales tecnologías de la industria 4.0	22
Figura 2 Niveles de la Inteligencia Artificial.....	24
Figura 3 Diagrama metodológico	32
Figura 4 Mapeo de áreas clave con relación al tema de revisión.	33
Figura 5 Ecuación de búsqueda con operadores booleanos utilizada en las bases de datos.....	35
Figura 6 Numero de documentos encontrados mediante la ecuación de búsqueda.....	36
Figura 7 Numero de documentos restantes del proceso de exclusión.	37
Figura 8 Numero de documentos seleccionados para la revisión.....	38
Figura 9 Cantidad de documentos por fuente de información consultada.....	39
Figura 10 Distribución de casos de aplicación de técnicas de ML en el MP por país.....	41
Figura 11 Distribución de estudios sobre ML en MP por industria en América Latina.....	42
Figura 12 Distribución de los equipos analizados con técnicas de ML.....	43
Figura 13 Técnicas de ML más utilizadas en MP según la revisión sistemática.....	45
Figura 14 Lenguajes de programación más utilizados en los estudios analizados.	46
Figura 15 Industrias brasileñas que registran casos de aplicación de ML en MP.	47
Figura 16 Industrias chilenas que registran casos de aplicación de ML en MP.	51
Figura 17 Industrias colombianas que registran casos de aplicación de ML en MP.	52
Figura 18 Industrias ecuatorianas que registran casos de aplicación de ML en MP.	54
Figura 19 Tendencia de publicaciones en Scopus sobre modelos de predicción.	63

Lista de Anexos

Pág.

Anexo 1 Matriz con los documentos encontrados 82

Resumen

Este estudio examina la situación actual, los desafíos y las tendencias del mantenimiento predictivo potenciado por Machine Learning en el sector industrial de América Latina, mediante una revisión sistemática que incluyó 60 casos de implementación identificados en Scopus, ScienceDirect y Google Scholar. Se seleccionaron únicamente documentos publicados a partir de 2014, en español, inglés o portugués, que aplicaran técnicas de Machine Learning para predecir fallas en equipos o sistemas industriales reales en empresas latinoamericanas. Los resultados muestran que Brasil concentra la mayor cantidad de publicaciones (48%), seguido por Ecuador (18%) y Colombia (15%), mientras que México, Argentina, Chile y Perú representan el 19% de los casos. La adopción de estas tecnologías se centra en las industrias manufacturera, energética y automotriz, donde los equipos críticos como turbinas, aerogeneradores y maquinaria pesada reciben mayor atención. Entre las técnicas de Machine Learning más utilizadas destacan los bosques aleatorios (RF), la máquina vectorial de soporte (SVM) y los árboles de decisión (DT), con Python como el lenguaje de programación predominante por su accesibilidad y versatilidad. Las principales barreras identificadas incluyen la falta de infraestructura tecnológica, el desconocimiento por parte de la gerencia, la resistencia al cambio y la confidencialidad de los datos. No obstante, se prevé que las futuras iniciativas apunten a soluciones enfocadas en la gestión de residuos, la optimización de recursos y el fortalecimiento de la sostenibilidad energética, ofreciendo oportunidades para transformar los procesos industriales y mejorar la competitividad regional.

Palabras Clave: América Latina, Barreras, Casos de implementación, Machine Learning, Mantenimiento predictivo, Sector industrial, Técnicas.

Abstract

This study examines the current situation, challenges, and trends of predictive maintenance powered by Machine Learning in the industrial sector of Latin America through a systematic review that included 60 implementation cases identified in Scopus, ScienceDirect, and Google Scholar. Only documents published from 2014 onward in Spanish, English, or Portuguese were selected, all applying Machine Learning techniques to predict failures in real industrial equipment or systems within Latin American companies. The results show that Brazil accounts for the largest number of publications (48%), followed by Ecuador (18%) and Colombia (15%), while Mexico, Argentina, Chile, and Peru represent 19% of the cases. The adoption of these technologies mainly focuses on the manufacturing, energy, and automotive industries, where critical equipment such as turbines, wind turbines, and heavy machinery receive the most attention. Among the most widely used Machine Learning techniques are Random Forests (RF), Support Vector Machines (SVM), and Decision Trees (DT), with Python as the predominant programming language due to its accessibility and versatility. The main barriers identified include the lack of technological infrastructure, managerial unawareness, resistance to change, and data confidentiality. Nevertheless, future initiatives are expected to prioritize solutions related to waste management, resource optimization, and enhanced energy sustainability, offering opportunities to transform industrial processes and improve regional competitiveness.

Key Word- Latin America, Barriers, Implementation Cases, Machine Learning, Predictive Maintenance, Industrial Sector, Techniques.

Glosario

Algoritmo: Secuencia de pasos lógicos y matemáticos diseñados para resolver problemas o realizar tareas específicas.

Aprendizaje Automático (Machine Learning, ML): Rama de la inteligencia artificial que permite a los sistemas aprender de datos y mejorar su desempeño sin ser programados.

Aprendizaje Profundo (Deep Learning, DL): Subcampo del aprendizaje automático que utiliza redes neuronales profundas para procesar grandes cantidades de datos y encontrar patrones complejos.

Big Data: Conjunto masivo de datos estructurados y no estructurados que requieren tecnologías avanzadas para su almacenamiento, procesamiento y análisis.

Industria 4.0: Cuarta revolución industrial caracterizada por la digitalización y la integración de tecnologías como el Internet de las Cosas (IoT) y la inteligencia artificial.

Inteligencia Artificial (IA): Rama de la computación que busca desarrollar sistemas capaces de realizar tareas que normalmente requieren inteligencia humana.

Mantenimiento Predictivo (MP): Técnica de mantenimiento que emplea datos y algoritmos para prever fallos antes de que ocurran.

Mipymes: Micro, pequeñas y medianas empresas.

Transformación Digital: Proceso de integración de tecnologías digitales en las operaciones de una organización para mejorar su eficiencia y competitividad.

Gestión de Activos: Práctica de mantener y optimizar los recursos de una empresa para maximizar su valor y vida útil.

1. Introducción

En América Latina, la industrialización ha sido un pilar fundamental del desarrollo económico, impulsando el avance tecnológico, la creación de empleo, la diversificación de la producción y la modernización de las estructuras económicas y sociales (Deutscher & Torres Rivas, 1986). Este proceso ha fortalecido la capacidad productiva de varios países de la región, facilitando su integración en la economía global a través de sectores clave como la manufactura, la minería, la energía y la agroindustria, los cuales son esenciales para sostener la competitividad y el crecimiento económico (Schmidtke et al., 2020).

Frente al dinamismo de los mercados internacionales, muchas empresas latinoamericanas han tenido que adoptar modelos de mantenimiento más eficientes y proactivos que les permitan optimizar la productividad, reducir costos y mejorar su capacidad de respuesta ante fallos para mantenerse competitiva (Marriaga Páez, 2024; OIT, 2013). Sin embargo, mientras que en otras regiones del mundo los enfoques avanzados de mantenimiento se han consolidado con mayor rapidez, en América Latina sigue predominando el mantenimiento correctivo en los procesos industriales (Pérez Rondón, 2021). Este modelo, centrado en la reparación de fallos una vez que ocurren, limita la capacidad de las organizaciones para anticiparse a problemas, incrementando los tiempos de inactividad y los costos operativos (Pérez Rondón, 2021).

Ante este panorama, el mantenimiento predictivo (MP) se presenta como una alternativa eficaz al permitir la detección temprana de fallas en equipos críticos mediante el monitoreo continuo de parámetros clave, lo que reduce paradas no programadas y optimiza el uso de recursos (Pérez Rondón, 2021). Al mismo tiempo, la adopción de tecnologías asociadas a la Industria 4.0, como el Internet de las Cosas (IoT), la Inteligencia Artificial (IA) y, en particular, el Machine Learning (ML), ha demostrado ser un factor determinante para potenciar estos esquemas de mantenimiento, gracias a su capacidad de recopilar y analizar grandes volúmenes de datos (Lee et al., 2019; Sanz Angulo & Maisueche Cuadrado, 2019; Shalev Shwartz & Ben David, 2014).

No obstante, la implementación de estas soluciones en América Latina enfrenta barreras significativas, como la limitada infraestructura tecnológica, la escasez de profesionales capacitados en análisis de datos y las dificultades de acceso a información de calidad que sustente la toma de decisiones (Calatayud & Katz, 2019). Esta brecha tecnológica no solo

impacta la competitividad de las empresas, sino que también limita el desarrollo industrial de la región. Por ello, es fundamental fomentar investigaciones que profundicen en el potencial del mantenimiento predictivo basado en ML, con el fin de identificar los factores que impulsan o dificultan su aplicación en distintos contextos industriales latinoamericanos.

En este contexto, el presente trabajo examina la situación actual, los desafíos y las tendencias del mantenimiento predictivo potenciado por Machine Learning en el sector industrial de América Latina. Para ello, se llevó a cabo una revisión sistemática de 60 casos de aplicación, identificados a través de fuentes académicas como Scopus, ScienceDirect y Google Scholar. La metodología empleada se estructuró en cuatro etapas: en primer lugar, se elaboró un marco teórico que integra los conceptos clave; en segundo lugar, se efectuó la búsqueda y selección de la información pertinente; posteriormente, se analizó la literatura seleccionada para responder las preguntas de investigación; y, finalmente, se sintetizaron los hallazgos, presentando conclusiones alineadas con los objetivos específicos planteados en este estudio.

2. Planteamiento del Problema

En el sector industrial, mantener altos niveles de producción y gestionar eficientemente los costos operativos ha llevado a las empresas a adoptar estrategias que optimicen la gestión del mantenimiento (Gasca et al., 2020). Esto es especialmente relevante en un contexto de competencia global cada vez más exigente, donde la inactividad de equipos críticos como motores, turbinas, compresores y sistemas automatizados puede ocasionar no solo pérdidas económicas significativas, sino también afectar la competitividad organizacional, aumentar los riesgos laborales e intensificar el impacto ambiental (Aguilar Otero et al., 2010; Caravedo et al., 2012).

Para enfrentar estos desafíos, el mantenimiento predictivo potenciado por técnicas de Machine Learning ha emergido como una solución efectiva, capaz de anticipar fallas antes de que estas ocurran (Villano et al., 2024). Esta tecnología procesa grandes volúmenes de datos, detecta patrones en los equipos y aprovecha el historial de fallas para alimentar modelos de pronóstico, lo que permite programar intervenciones en el momento óptimo, reduciendo tiempos de inactividad y aumentando la eficiencia operativa y la vida útil de los activos industriales. No obstante, su adopción en América Latina presenta importantes desigualdades debido a diversos factores, entre los que se destacan la infraestructura tecnológica, la inestabilidad económica y el limitado conocimiento de estas herramientas por parte de los directivos empresariales (Calatayud & Katz, 2019). A esto se suma la escasa disponibilidad de estudios documentados y de acceso abierto, dificultando la generación de conocimiento aplicable y limitando la toma de decisiones informadas, lo que frena considerablemente la inversión en estas tecnologías.

Dado este contexto, resulta crucial contar con información detallada sobre la implementación del mantenimiento predictivo basado en Machine Learning en la región. Es necesario comprender qué países han avanzado significativamente, en qué industrias se han aplicado estas técnicas, qué tipos específicos de equipos han sido analizados, qué algoritmos son preferidos, cuáles son los lenguajes de programación predominantes y qué desafíos aún persisten. Particularmente, es importante ampliar el análisis para incluir no solo grandes industrias como la minería, la petroquímica y la manufactura avanzada, sino también a las micro, pequeñas y medianas empresas (Mipymes), que enfrentan mayores obstáculos relacionados con infraestructura, financiamiento y formación técnica (Carmona et al., 2020; Reyes Núñez, 2021).

Para abordar estos aspectos, se llevó a cabo una revisión sistemática de 60 casos de aplicación del mantenimiento predictivo potenciado por Machine Learning en diversos sectores industriales de América Latina. Este análisis permite identificar patrones de adopción de estas tecnologías y proporcionar un panorama integral sobre su estado actual en la región, generando información valiosa para la toma de decisiones estratégicas y contribuyendo a cerrar la brecha de conocimiento existente.

3. Justificación

En los últimos años, la transformación digital ha redefinido la dinámica del sector industrial en América Latina, impulsando la adopción de herramientas avanzadas que optimizan la gestión del mantenimiento y reducen los tiempos de inactividad de los equipos (ANDI, 2019; Rojas Bances, 2021). En este contexto, la recopilación y el análisis eficaz de datos se han convertido en recursos estratégicos fundamentales, permitiendo un seguimiento continuo del estado de los activos industriales, facilitando la detección temprana de anomalías potenciales y ofreciendo información clave para mejorar continuamente los procesos productivos (Braga & Andrade, 2023; Chung et al., 2023).

El mantenimiento predictivo potenciado por técnicas de Machine Learning representa una de las aplicaciones más prometedoras de la Industria 4.0, debido a su capacidad para procesar grandes volúmenes de datos en tiempo real y optimizar la toma de decisiones en contextos industriales complejos (Carrasco Vidal, 2020). La implementación de estas tecnologías no solo mejora la planificación del mantenimiento y reduce los tiempos de inactividad, sino que además permite a las empresas responder con mayor agilidad ante variaciones en la demanda y en la competencia del mercado (Aguilar Otero et al., 2010; Caravedo et al., 2012).

No obstante, la limitada infraestructura digital y la escasez de profesionales con formación en análisis de datos e inteligencia artificial constituyen importantes barreras para la integración efectiva de estas tecnologías en América Latina (Calatayud & Katz, 2019; Reyes Núñez, 2021). Adicionalmente, la falta de documentación sobre casos exitosos y estudios de implementación limita la capacidad de tomar decisiones informadas a nivel gerencial, generando incertidumbre sobre los beneficios reales del mantenimiento predictivo basado en Machine Learning. Por tanto, contar con información sistematizada sobre estas aplicaciones resulta esencial para comprender sus alcances, identificar oportunidades y promover su adopción en diversos sectores productivos (MIT, 2020).

En respuesta a esta necesidad, este estudio realiza una revisión sistemática de 60 casos documentados en América Latina, analizando específicamente en qué países e industrias se ha implementado el mantenimiento predictivo potenciado por Machine Learning, qué tipos de equipos y sistemas han sido evaluados, qué algoritmos y lenguajes de programación predominan, y qué desafíos se han presentado durante su implementación. Al destacar experiencias reales de

empresas que han adoptado estas tecnologías, este análisis pretende llenar un vacío existente en la literatura especializada y fomentar el intercambio de conocimientos para desarrollar estrategias más efectivas en la implementación del mantenimiento predictivo en la región.

En síntesis, esta investigación proporciona un panorama amplio y fundamentado del estado actual del mantenimiento predictivo basado en Machine Learning en América Latina, evaluando tanto el nivel de adopción como las barreras existentes. Se espera que los resultados obtenidos no solo reduzcan la brecha de conocimiento en la literatura actual, sino que también faciliten una mayor colaboración entre el sector industrial y la academia, sentando así las bases para futuras investigaciones e iniciativas innovadoras en el ámbito del mantenimiento industrial.

4. Objetivos

4.1. Objetivo General

Revisar la situación actual, desafíos y tendencias del mantenimiento predictivo potenciado por Machine Learning en el sector industrial de América Latina.

4.2. Objetivos Específicos

- Recopilar casos de implementación de Machine Learning para predecir fallas en la industria latinoamericana.
- Examinar la situación actual del mantenimiento predictivo basado en Machine Learning en los países de América Latina.
- Identificar los principales desafíos y barreras que dificultan la adopción de estas tecnologías en el sector industrial latinoamericano.
- Destacar las tendencias futuras de la aplicación de Machine Learning en el mantenimiento predictivo en Latinoamérica.

5. Marco Teórico

Para analizar la situación actual y los desafíos asociados a la adopción de estas tecnologías en el sector industrial de América Latina, es esencial establecer un marco conceptual que organice y explique los elementos fundamentales del tema. En este apartado, se abordan los conceptos de Industria 4.0, mantenimiento, ML y ML en el MP.

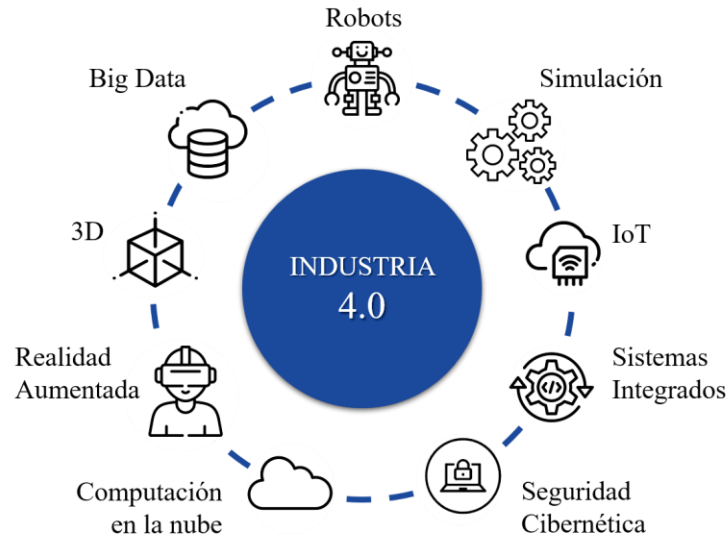
5.1. Industria 4.0

El concepto de Industria 4.0 o también llamada “Cuarta revolución industrial”, se enfoca en la digitalización y la adopción de tecnologías avanzadas capaces de transformar la manera en que las empresas realizan sus operaciones y administran su cadena de valor (Sanz Angulo & Maisueche Cuadrado, 2019). Este concepto surgió en Alemania en 2011 como una estrategia para modernizar la industria mediante la digitalización y el uso de tecnologías como el Internet de las Cosas (IoT), Big Data y sistemas ciberfísicos (Rojko, 2017). Estas tecnologías no solo facilitan la automatización de procesos y la toma de datos en tiempo real, sino que también promueven una mayor integración entre los sistemas físicos y digitales.

Otros países han desarrollado iniciativas similares, adaptando este enfoque a sus propios contextos industriales. Rojko (2017) en su artículo titulado *Industry 4.0 Concept: Background and Overview* menciona casos como el "Internet Industrial" en Estados Unidos, "Industrie du futur" en Francia, y "Made in China 2025", todos con el fin de potenciar la eficiencia y la sostenibilidad en la industria global. En la Figura 1 se presentan algunas de las tecnologías clave que forman parte del ecosistema de la Industria 4.0, las cuales desempeñan un papel crucial en la transformación de diversos sectores productivos.

Figura 1

Principales tecnologías de la industria 4.0



Nota. Adaptado de *Tecnologías de la industria 4.0*, por Elion S.A., 2024, Elion (<https://www.elion.es/tecnologias/industry40/>).

Para ampliar la comprensión de estas tecnologías, la Tabla 1 presenta una descripción detallada de cada una de ellas, lo que permite contextualizar su papel dentro del ecosistema de la Industria 4.0.

Tabla 1

Tipos de tecnologías de la industria 4.0

Tecnología	Definición
Robots	Robots que se adaptan y colaboran con humanos para mejorar la productividad.
Big Data	Análisis de grandes volúmenes de datos para identificar patrones y apoyar decisiones.
Impresión 3D	Creación de objetos tridimensionales a partir de modelos digitales.
Realidad Aumentada	Superpone información digital al entorno físico para mejorar la interacción
Computación en la Nube	Almacenamiento y procesamiento de datos en servidores remotos accesibles por Internet.
Seguridad Cibernética	Protección de sistemas y datos frente a amenazas digitales.
Sistemas integrados	Conexión de diferentes procesos y tecnologías para trabajar de forma coordinada y eficiente.
Internet de las cosas (IoT)	Conecta dispositivos y sistemas para recopilar y compartir datos en tiempo real.
Simulación	Modela digitalmente procesos para optimizar su rendimiento sin pruebas físicas.

Nota. Elaborado a partir de García (2021, pp 3-5).

5.2. Mantenimiento Industrial

El concepto de mantenimiento tiene múltiples enfoques, pero todos comparten un mismo objetivo. Como lo menciona Pérez Rondón (2021), el mantenimiento consta de una serie de acciones o actividades que deben llevarse a cabo en la industria por el personal responsable de cada área, con el fin de garantizar el correcto funcionamiento de los equipos, componentes e instalaciones. En la Tabla 2, el autor define los tipos de mantenimiento más utilizados en las empresas a nivel nacional e internacional.

Tabla 2

Tipos de mantenimiento más utilizados en empresas a nivel nacional e internacional

Tipo	Descripción
Correctivo	Es realizado cuando una máquina deja de funcionar debido a una falla. Su objetivo es reparar o reemplazar el componente dañado rápidamente para minimizar el impacto en la productividad.
Preventivo	Se basa en actividades planificadas en periodos definidos para asegurar el correcto funcionamiento de los equipos y prevenir fallas, incluyendo reemplazos, ajustes e inspecciones según un calendario o uso del equipo.
Predictivo	Se basa en el monitoreo y análisis de datos para anticipar el momento en que un componente de una máquina podría fallar, permitiendo su reemplazo justo antes de que ocurra una avería. Esto reduce el tiempo de inactividad del equipo y prolonga la vida útil de sus componentes.

Nota. Elaborado a partir de Pérez Rondón (2021, pp 37-48).

5.3. Machine Learning


El aprendizaje automático, conocido en inglés como Machine Learning, constituye una subrama de la inteligencia artificial orientada al desarrollo de algoritmos que aprenden a partir de datos (Mian et al., 2024). Al procesar grandes volúmenes de información durante su entrenamiento, estos algoritmos adquieren la capacidad de tomar decisiones de forma autónoma y mejorar progresivamente su precisión y capacidad de predicción (Shalev Shwartz & Ben David, 2014). Además de buscar un mayor acierto y velocidad en sus modelos, el ML pone énfasis en la eficiencia, optimizando el uso de espacio de almacenamiento y la cantidad de datos necesarios para su aprendizaje (Mohri et al., 2018).

Por su parte, el aprendizaje profundo o en inglés Deep Learning se considera una técnica más avanzada dentro del ML, ya que emplea redes neuronales profundas que simulan el

funcionamiento del cerebro humano. Esta estructura le permite identificar patrones complejos y analizar grandes volúmenes de datos con mayor exactitud (Mian et al., 2024). Como se ilustra en la Figura 2, el ML forma parte de la IA, mientras que el DL se encuentra dentro del ML como una rama especializada de mayor complejidad.

Figura 2

Niveles de la Inteligencia Artificial



Nota. Adaptado de *¿Qué es Machine Learning?*, por Universidad Complutense de Madrid, 2021, UCM (<https://www.masterdatascienceucm.com/que-es-machine-learning/>)

Como lo menciona Sanz Angulo & Maisueche Cuadrado (2019), citando otros autores, los tipos de aprendizaje en el ML se clasifican en tres categorías principales: aprendizaje supervisado, no supervisado y por refuerzo. Asimismo, el DL se integra como una subcategoría dentro de la familia del ML, destacándose por el uso de algoritmos avanzados diseñados para capturar representaciones complejas en los datos mediante arquitecturas de modelos sofisticados (Polamuri et al., 2022). A continuación, se describen en detalle cada uno de estos tipos de aprendizaje, así como las características que definen al aprendizaje profundo en el contexto del ML.

5.3.1 Aprendizaje Supervisado

El aprendizaje supervisado se define como el proceso de entrenar un modelo utilizando un conjunto de datos previamente etiquetados, en el cual cada entrada está asociada a una salida correcta (Russell & Norvig, 2007). Este enfoque permite que el algoritmo aprenda a predecir resultados y reconocer patrones a partir de la retroalimentación, lo que facilita la creación de una función capaz de relacionar las entradas con las salidas esperadas. En la Tabla 3 algunas de las técnicas más utilizadas de ML en el aprendizaje supervisado.

Tabla 3

Técnicas de aprendizaje supervisado en Machine Learning.

Técnica	Definición	Cita
Artificial Neuronal Network (ANN) Red Neuronal Artificial	Este modelo está formado por capas de neuronas conectadas que permiten que los datos ingresen por la capa de entrada, se procesen en las capas ocultas donde la red identifica patrones y finalmente, generen resultados en la capa de salida, utilizando datos con respuestas conocidas para aprender y ajustarse continuamente. Esa técnica mejora la precisión y estabilidad de los DT, mediante la creación de varios subconjuntos de datos al azar a partir del conjunto original y entrenando un modelo independiente con cada uno.	(Villano et al., 2024)
Bagged Tree (BG) Árboles ensamblados	Las predicciones finales se combinan, ya sea promediando los resultados (en regresión) o usando votación mayoritaria (en clasificación), ayudando a reducir errores en el proceso. Este modelo es utilizado para clasificar datos o realizar predicciones siguiendo la estructura de un árbol. Se construye dividiendo los datos en decisiones basadas en las características de entrada, donde cada punto de decisión es llamado nodo y representa una pregunta o condición sobre una característica. Dependiendo de la respuesta, se sigue un camino hacia otro nodo o hasta llegar a un nodo hoja, que da el resultado final (una clase o valor).	(Breiman, 1996)
Decision Tree (DT) Árbol de decisiones	Esta técnica se basa en el algoritmo de RF y fue diseñada específicamente para problemas de regresión, donde se busca mejorar la velocidad de procesamiento y la eficiencia computacional utilizando múltiples DT mejorando la precisión en comparación con modelos individuales.	(Chandramouli et al., 2018)
Fast Forest Regression (FFR) Regresión Rápida de Bosque	Este algoritmo combina de manera secuencial varios modelos débiles para construir un modelo más fuerte y preciso. El objetivo es minimizar iterativamente la función de pérdida pasando por cada modelo, donde el modelo siguiente se entrena para corregir los errores del modelo anterior.	(Yates & Islam, 2021)
Gradient Boosting (GB) Impulso por Gradiente	Este modelo es una aplicación específica de GB diseñada para problemas de regresión. Este algoritmo adapta la función de pérdida para predecir valores continuos en lugar de categorías.	(Bentéjac et al., 2021)
Gradient Boosted Regression (GBR) Regresión Mejorada por Gradiente	Esta técnica es una variante de GB en la que los modelos base utilizados son exclusivamente DT. Cada árbol se entrena secuencialmente para minimizar los errores de predicción y reducir los residuos del árbol anterior.	(Bentéjac et al., 2021)
Gradient Boosted Trees (GBT) Árboles Mejorados por Gradiente		

Tabla 3*Continuación*

K-Nearest Neighbors (K-NN) K-Vecinos Más Cercanos	Este modelo se basa en la idea de que los elementos similares tienden a estar cerca unos de otros, por ende, cuando llega un nuevo dato sin etiquetar se compara con los datos del conjunto de entrenamiento para encontrar los elementos más cercanos "vecinos". La clase del nuevo dato se determina en función de las clases de sus vecinos más cercanos, si la mayoría de los vecinos pertenecen a una clase específica, esa será la clase asignada al nuevo dato.	(Chandramouli et al., 2018)
Logistic Regression (LogR) Regresión Logística	A diferencia de la Regresión Lineal, este modelo trabaja con una variable dependiente categórica, un "sí o no" o "1 y 0", utilizada para predecir probabilidades en problemas de clasificación. En lugar de ajustar una línea recta, utiliza una función logística que transforma las predicciones en probabilidades.	(Chandramouli et al., 2018)
Linear Regression (LR) Regresión Lineal	Este modelo se enfoca en predecir una variable dependiente a partir de una variable independiente, asumiendo una relación lineal entre ellas. En su forma más simple, traza la línea que mejor se ajusta a los datos para minimizar los errores en la predicción.	(Chandramouli et al., 2018)
Multilayer Perceptron (MLP) Perceptrón Multicapa	Esta técnica consta de una ANN que tiene varias capas: una de entrada para recibir los datos, capas ocultas para procesarlos y una de salida para entregar el resultado. Las neuronas de cada capa están conectadas a todas las de la siguiente, formando una red completamente conectada.	(Majidzadeh Gorjani et al., 2021)
Multiple Linear Regression (MLR) Regresión Lineal Múltiple	A diferencia de la regresión lineal simple, este modelo utiliza dos o más variables independientes para predecir el comportamiento de una variable dependiente. Se asume que existe una relación lineal entre la variable dependiente y las independientes, lo que permite analizar cómo cada predictor contribuye al resultado final.	(Chandramouli et al., 2018)
Naïve Bayes (NB)	Este método se usa para clasificar datos en diferentes categorías basándose en el Teorema de Bayes, que calcula la probabilidad de que algo pertenezca a una categoría específica después de observar ciertas características. Su principal suposición es que todas las características son independientes entre sí, lo que simplifica los cálculos.	(Chandramouli et al., 2018)
Nonlinear Autoregressive (NAR): Modelo Autorregresivo No Lineal	Este modelo predice valores futuros en series temporales usando únicamente valores pasados como entradas. Se entrena en un bucle abierto con datos reales para ajustar sus predicciones y, una vez entrenada, opera en un bucle cerrado, reutilizando sus propias predicciones como nuevas entradas.	(Benrhmach et al., 2020)
Random Forest (RF) Bosque Aleatorio	Esta técnica de clasificación combina múltiples DT para mejorar la precisión entrenando cada árbol con diferentes subconjuntos aleatorios de datos y características, la predicción final se determina mediante votación por mayoría en clasificación o por promedio en regresión, lo que permite reducir el sobreajuste y aumentar la capacidad en comparación con un único árbol de decisión.	(Chandramouli et al., 2018)
Extreme Gradient Boosting (XGBoost) Impulso por Gradiente Extremo	Este modelo es una implementación avanzada de GB que agrega optimizaciones para mejorar la velocidad y precisión del modelo como la regularización adicional para prevenir el sobreajuste, paralelización para acelerar el entrenamiento y enfoques eficientes para encontrar divisiones óptimas en los árboles de decisión.	(Bentéjac et al., 2021)
Support Vector Machine (SVM) Máquina de Vectores de Soporte	Este modelo se utiliza para clasificar datos y realizar regresiones. Su objetivo principal es encontrar una línea (hiperplano) que divida los datos en dos grupos distintos dentro de un espacio multidimensional, maximizando la distancia entre el hiperplano y los puntos más cercanos de cada grupo.	(Chandramouli et al., 2018)

5.3.2 *Aprendizaje No Supervisado*

El aprendizaje no supervisado se caracteriza por no depender de una ayuda externa ni de etiquetas o salidas predefinidas, permitiendo que el algoritmo analice de manera autónoma los datos de entrada para descubrir patrones ocultos, regularidades, correlaciones o categorías (Naeem et al., 2023). Este enfoque facilita el procesamiento de datos complejos, como la información sobre los viajes de un conductor, permitiendo reconocer tendencias en las condiciones del tráfico y desarrollar conceptos emergentes, como “buen tráfico” o “mal tráfico” (Russell & Norvig, 2007). Sin embargo, debido a la ausencia de retroalimentación correctiva, este modelo no puede aprender de sus acciones ni determinar qué estados son deseables. En la

Tabla 4 se presentan las principales técnicas de ML utilizadas en el aprendizaje no supervisado.

Tabla 4

Técnicas de aprendizaje no supervisado en Machine Learning.

Técnica	Definición	Cita
Autoencoder (AE)	Este modelo es una NN no supervisada diseñada para comprimir los datos y luego reconstruirlos. Está compuesto por un codificador que reduce los datos originales a una versión más simple y un decodificador que reconstruye los datos originales a partir de esa versión comprimida. Su objetivo principal es minimizar el error entre la entrada y la salida, capturando las características más importantes de los datos para reducir la dimensionalidad y eliminar el ruido.	(Alaghbari et al., 2023)
Dimensionality Reduction (DR) Reducción de Dimensionalidad	Esta técnica es utilizada en el aprendizaje automático para simplificar datos con muchas variables, manteniendo solo la información más importante. Este método ayuda a reducir la complejidad de los datos y a mejorar su calidad, eliminando características irrelevantes o redundantes, mejorando la precisión y eficiencia de los modelos.	(Rastogi et al., 2023)
Fuzzy K-Means (FK-Means) K-Medias Difuso	Este modelo es una versión más flexible del algoritmo K-Means que permite asignar los datos a diferentes grupos de manera más suave. En lugar de que cada dato pertenezca exclusivamente a un solo grupo, esta técnica permite que un objeto se asocie a varios grupos al mismo tiempo, con grados de pertenencia que varían entre 0 y 1. Es especialmente útil cuando los límites entre los grupos no están bien definidos.	(Ferraro, 2024)
Isolation Forest (IF) Bosque de Aislamiento	Este algoritmo está diseñado para detectar anomalías en los datos mediante la creación de varios árboles de aislamiento, que dividen los datos en partes más pequeñas de manera aleatoria. Esto permite que los árboles se concentren en identificar anomalías sin verse afectados por la mayoría de los datos normales, identificando como anomalías aquellos puntos que necesitan menos divisiones para quedar aislados, siendo diferentes o inusuales en comparación con el resto de los datos.	(Liu et al., 2008)
K-Means K-Medias	Esta técnica agrupa datos en un número de grupos (k) definido por el usuario, asignando cada punto al grupo más cercano. Su objetivo es que los puntos dentro de un grupo sean lo más similares posible y que los grupos sean distintos entre sí. Para lograrlo, utiliza distancias para medir la similitud o diferencia entre los puntos, facilitando la identificación de patrones o estructuras en los datos de manera eficiente.	(Chandramouli et al., 2018)

Tabla 4*Continuación*

Hidden Markov Model (HMM) Modelo de Markov Oculto	Este modelo se utiliza para analizar secuencias de datos donde solo se pueden observar los resultados visibles, pero no los estados internos que los generaron. Su objetivo principal es inferir la secuencia más probable de estos estados ocultos a partir de las observaciones, descubriendo patrones subyacentes en los datos sin necesidad de etiquetas.	(MathWorks, 2024b)
--	---	--------------------

5.3.3 Aprendizaje Reforzado

El aprendizaje por refuerzo se distingue del aprendizaje supervisado y no supervisado al no basarse en datos etiquetados ni en la búsqueda de patrones o asociaciones (Sutton & Barto, 2018). En su lugar, aprende de forma directa a través de la interacción con el entorno, evaluando las consecuencias de cada acción mediante recompensas o castigos establecidos por una función de recompensa. (Sutton & Barto, 2018). Retomando el ejemplo planteado por Russell & Norvig (2007), un algoritmo diseñado para simular el comportamiento de un conductor, entrenado mediante aprendizaje por refuerzo, podría aprender que realizar maniobras peligrosas o conducir mal incomoda a los pasajeros y reduce la probabilidad de recibir propinas, lo que lo llevaría a ajustar su comportamiento de manera autónoma para evitar dichas situaciones. En la

Tabla 5 se presentan algunas de las técnicas de ML utilizadas en el aprendizaje reforzado.

Tabla 5*Técnicas de aprendizaje reforzado en Machine Learning.*

Técnica	Definición	Cita
Q-Learning (QL)	Este algoritmo está basado en tablas que busca encontrar la política óptima para maximizar recompensas acumuladas. Utiliza una matriz Q que se actualiza iterativamente a medida que el agente interactúa con el entorno.	(Watkins, 1989)
Deep Reinforcement Learning (DRL) Aprendizaje de refuerzo profundo	Este método combina la técnica de Q-Learning con redes neuronales profundas para manejar problemas complejos de decisión, utilizando estas redes para aproximar funciones de valor. Este enfoque permite que el agente generalice mejor en entornos con estados continuos o de alta dimensionalidad.	(Mnih et al., 2013)
Proximal Policy Optimization (PPO) Optimización de políticas proximas	Este modelo se centra en la optimización de reglas, mejorando la estabilidad y eficiencia del entrenamiento al limitar las actualizaciones de estas reglas mediante una función objetivo que restringe cambios drásticos en la probabilidad de las acciones entre reglas consecutivas	(Schulman et al., 2017)

5.3.4 *Aprendizaje Profundo*

El aprendizaje profundo, conocido en inglés como Deep Learning, es un área especializada dentro del ML que se centra en el desarrollo de algoritmos capaces de aprender a partir de grandes volúmenes de datos. Para ello, emplea modelos con múltiples capas que procesan la información de manera jerárquica, permitiendo que las características relevantes se detecten automáticamente mediante transformaciones no lineales organizadas en distintos niveles. (Polamuri et al., 2022). Este aprendizaje es utilizado en áreas como el procesamiento de imágenes, texto y voz, gracias a su capacidad para procesar información y abstraer conceptos avanzados (MathWorks, 2024a). En la Tabla 6 se muestran algunas de las técnicas de DL más utilizadas.

Tabla 6

Técnicas de aprendizaje profundo más utilizadas

Técnica	Definición	Cita
Convolutional Neural Network (CNN) Red Neuronal Convocional Deep Neural Network (DNN) Red Neuronal Profunda	Este modelo de red neuronal analiza datos espaciales usando capas de convolución para detectar patrones básicos, capas de agrupamiento para simplificar los datos manteniendo la información importante y capas completamente conectadas para combinar esas características y clasificar o reconocer objetos.	(Villano et al., 2024)
Extreme Learning Machine (ELM) Máquina de Aprendizaje Extremo	En este modelo de redes neuronales se utiliza una sola capa oculta, los peso entre las capas de entrada y oculta se asignan aleatoriamente y los pesos de la capa oculta a la capa de salida se calculan matemáticamente.	(Huang et al., 2006)
Gated Recurrent Unit (GRU) Unidad Recurrente Condicionada	Esta técnica es una variante de las RNN que cuenta con “puertas” que deciden qué información recordar, olvidar o actualizar en cada paso, lo que le permite manejar dependencias largas en los datos.	(Cho et al., 2014)
Long Short-Term Memory (LSTM) Memoria a Largo Corto Plazo	Este modelo es una variante de las RNN diseñada para manejar secuencias de datos mejorando su capacidad para recordar información relevante durante largos periodos y descartar lo innecesario, lo que mejora significativamente su precisión en las predicciones en comparación a las RNN.	(Villano et al., 2024)
Neural Basis Expansion Analysis Time Series (N-BEATS) Análisis de Series Temporales Basado en Redes Neuronales	Este algoritmo avanzado de aprendizaje profundo es diseñado específicamente para la predicción de series temporales, su arquitectura está basada en bloques independientes que procesan datos históricos para producir predicciones. Una de sus configuraciones permite descomponer las series en componentes como tendencias y estacionalidad ofreciendo interpretaciones claras de los resultados.	(Oreshkin et al., 2020)

Tabla 6*Continuación*

Recurrent Neural Network (RNN) Red Neuronal Recurrente	Esta red está diseñada para trabajar con datos secuenciales como textos o reconocimiento de audios. Su principal característica es que pueden memorizar la información de pasos anteriores para influir en las predicciones futuras. Están compuestas por una entrada que recibe los datos, neuronas recurrentes que procesan los datos actuales junto con información previa, una célula de memoria que almacena la información relevante y una capa de salida que genera las predicciones.	(MathWorks, 2023; Villano et al., 2024)
Spatio-Temporal Neural Network (STNN) Red Neuronal Espacio-Temporal	Este modelo es utilizado para analizar datos que varían tanto en el tiempo como en el espacio. Funciona extrayendo patrones importantes en los datos mediante una representación interna que captura tanto las dinámicas temporales como las relaciones espaciales, transformando esta representación en predicciones concretas identificando relaciones relevantes entre las series temporales.	(Ziat et al., 2017)

5.4. Machine Learning en el Mantenimiento Predictivo

El MP se ha consolidado como una estrategia esencial en la gestión de activos industriales, debido a su capacidad para anticipar fallas antes de que ocurran y planificar intervenciones de manera oportuna, lo que deriva en una disminución de los costos operativos y un uso más eficiente de los recursos (Pérez Rondón, 2021). Para ello, la integración de modelos avanzados de análisis, como ML, ha demostrado ser fundamental, dado que permite procesar grandes volúmenes de datos históricos con el fin de identificar patrones complejos y detectar anomalías con mayor precisión, optimizando así la gestión del mantenimiento y prolongando la vida útil de los equipos (Rondon Chavez, 2022).

Diversos estudios resaltan que la adopción de estas tecnologías produce mejoras significativas en la eficiencia operativa y en la optimización de recursos (Rojas Bances, 2021). Entre los principales beneficios de su implementación se destacan:

- Reducción de costos operativos
- Mayor disponibilidad de los equipos
- Extensión de la vida útil de los activos

No obstante, la implementación efectiva de estas soluciones requiere un conocimiento profundo de las necesidades propias de cada sector industrial, así como la adaptación de las técnicas a las particularidades de cada proceso productivo. En este sentido, Soares (2015) propone que la integración de un sistema basado en ML suele seguir una estructura sistemática compuesta por las siguientes etapas:

- Selección de datos: Recolección de datos históricos provenientes de sensores, sistemas de monitoreo y registros operativos.
- Preprocesamiento de datos: Limpieza, normalización y transformación de los datos para garantizar su calidad.
- Selección, entrenamiento y validación del modelo: Elección del algoritmo adecuado y la evaluación de su desempeño en términos de precisión y confiabilidad.
- Monitoreo y actualización del modelo: Adaptación continua del modelo ante posibles cambios en las condiciones operativas y preservar su eficacia a lo largo del tiempo.

6. Metodología

En este apartado se describe la metodología aplicada para la revisión sistemática de la literatura sobre el MP potenciado por ML en el sector industrial de América Latina. La Figura 3 ilustra el diagrama metodológico empleado para llevar a cabo el proceso de revisión.

Figura 3

Diagrama metodológico



6.1. Etapas de la Revisión

Como lo mencionan Reyna et al. (2021), una revisión sistemática consta de varias etapas clave. En primer lugar, se seleccionan las bases de datos a utilizar, se formulan las preguntas de investigación y se implementa una estrategia de búsqueda mediante palabras clave y operadores booleanos. Posteriormente, se establecen criterios de inclusión y exclusión para asegurar la relevancia de los estudios. Los documentos seleccionados pasan por un proceso de extracción y organización, seguido de una evaluación de calidad para verificar la confiabilidad de la


información. Finalmente, los resultados se sintetizan y se organizan para facilitar su análisis y comprensión.

6.1.1 Fuentes de Información

En esta fase, se definieron las fuentes de información que se emplearon para la revisión del tema, entre las cuales se incluyeron Scopus, ScienceDirect y Google Scholar. Estas plataformas ofrecen un amplio volumen de documentos relacionados con investigaciones en ingeniería y ciencias computacionales, áreas clave para este análisis. Además, bases de datos como Scopus permiten extraer documentos para mapear los temas de mayor profundidad en VOSviewer, lo cual brinda una visión integral de la relevancia del tema, como se muestra en la Figura 4.

Figura 4

Mapeo de áreas clave con relación al tema de revisión.



Nota. La figura representa un mapa de densidad generado con VOSviewer a partir de documentos de la base de datos Scopus, recuperados mediante las palabras clave “mantenimiento predictivo” y “Machine Learning”. El tamaño y la posición de los términos reflejan su frecuencia de aparición y la relación entre ellos en la literatura especializada. En las zonas con mayor densidad de color (color amarillo), se identifican conceptos como “Machine Learning”, “Artificial Intelligence” e “Industry 4.0”, resaltando la tendencia actual hacia la integración de soluciones tecnológicas para optimizar el monitoreo y la gestión de fallas.

Este mapeo permitió identificar la concentración de términos relacionados con ML y mantenimiento predictivo, destacando por su frecuencia conceptos como “Industria 4.0”, “Artificial Intelligence”, “Life Cycle”, “Fault Detection” y “Condition Monitoring”. En el contexto de esta revisión, la presencia de “Fault Detection” y “Condition Monitoring” fue determinante para la selección de los documentos y la definición de la estructura general del artículo. Asimismo, estos términos se establecieron como elementos clave en la estrategia de búsqueda, facilitando la identificación de estudios enfocados en la aplicación de técnicas de ML para la detección de fallas y la mejora en el monitoreo de condiciones operativas.

6.1.2 Preguntas de la Revisión

Como se planteó en la sección de planteamiento del problema, se definieron preguntas clave que orientaron el enfoque de la investigación y facilitaron la selección de los estudios más relevantes. Las preguntas formuladas para esta revisión fueron:

- ¿Qué países de América Latina se destacan por publicar casos de en la aplicación de Machine Learning en el mantenimiento predictivo en el sector industrial?
- ¿En qué industrias de América Latina se han aplicado técnicas de Machine Learning para el mantenimiento predictivo?
- ¿A qué equipos o sistemas se les ha aplicado técnicas de Machine Learning para su mantenimiento predictivo o predicción de fallas en Latinoamérica?
- ¿Cuáles son las técnicas de Machine Learning más utilizadas en las empresas de América Latina?
- ¿Qué lenguajes de programación son los más empleados por las empresas de América Latina para desarrollar modelos de Machine Learning?
- ¿Cuáles son los principales desafíos y barreras que enfrentan las empresas latinoamericanas para adoptar estas tecnologías en sus prácticas de mantenimiento?

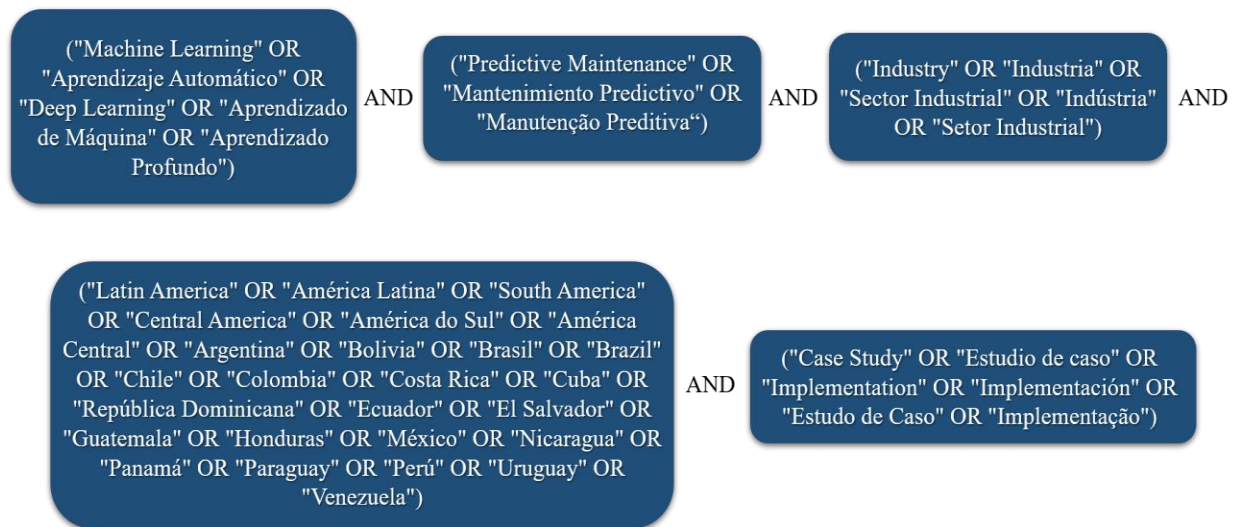
6.1.3 Estrategia de Búsqueda

Para lograr una búsqueda precisa en las fuentes de información, se diseñó una ecuación que permitió identificar documentos relacionados con la aplicación de técnicas de Machine

Learning en el mantenimiento predictivo o en la predicción de fallas dentro de empresas de América Latina. Para ello, se utilizaron palabras clave como “Machine Learning”, “Mantenimiento Predictivo”, “Industria”, “América Latina”, nombres específicos de países de la región y términos como “Caso de Estudio” o “Implementación”. La ecuación de búsqueda incluyó términos en inglés, español y portugués, así como operadores booleanos para ampliar y precisar los resultados. Esta ecuación se detalla en la Figura 5.

Figura 5

Ecuación de búsqueda con operadores booleanos utilizada en las bases de datos.

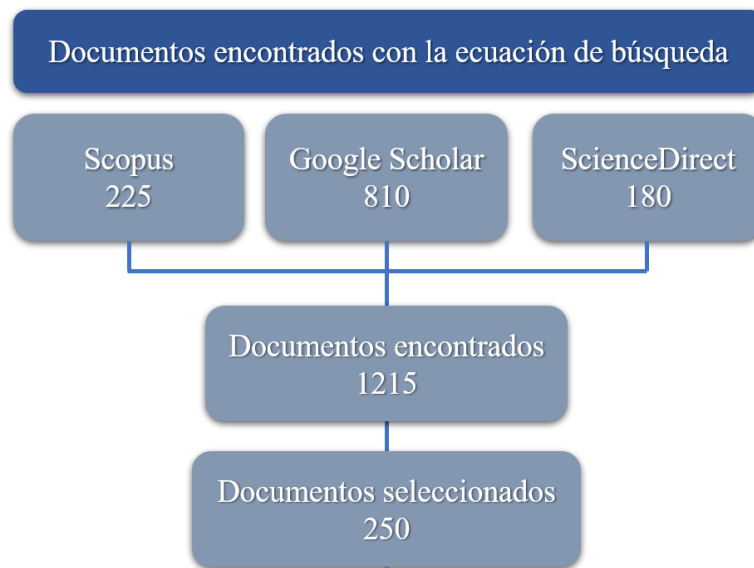


6.1.4 Selección de Documentos

La selección de documentos se llevó a cabo en dos fases. Primero, se revisaron los títulos y resúmenes de las publicaciones obtenidas a través de la ecuación de búsqueda. Después, se examinó el texto completo para asegurar que cada documento aportara información útil y específica para la revisión. Con este proceso se buscó minimizar sesgos y asegurar que los estudios coincidieran con los objetivos de la investigación. En la Figura 6 se presenta el número de documentos encontrados en cada fuente de información, así como la cantidad finalmente seleccionada.

Figura 6

Numero de documentos encontrados mediante la ecuación de búsqueda.



6.1.5 Criterios de Inclusión y Exclusión

La literatura gris, también conocida como literatura no convencional, hace referencia a documentos elaborados en ámbitos gubernamentales, académicos, empresariales e industriales que no se encuentran controlados por editoriales comerciales (Paez, 2017). En esta revisión, se consideraron documentos de literatura gris (tesis institucionales y estudios técnicos), debido a que pueden aportar casos relevantes de aplicación de ML para la predicción de fallas que no suelen estar disponibles en publicaciones científicas tradicionales.

Se incluyeron documentos publicados entre 2014 y 2024, redactados en inglés, español o portugués, que reportaran la implementación de técnicas de ML orientadas a la detección de fallos en sistemas o procesos industriales. Asimismo, se contemplaron estudios que, pese a no centrarse exclusivamente en MP, abordaran barreras o desafíos relacionados con la adopción de tecnologías avanzadas en América Latina, ya que proporcionan un contexto valioso sobre las limitaciones que enfrentan las organizaciones de la región.

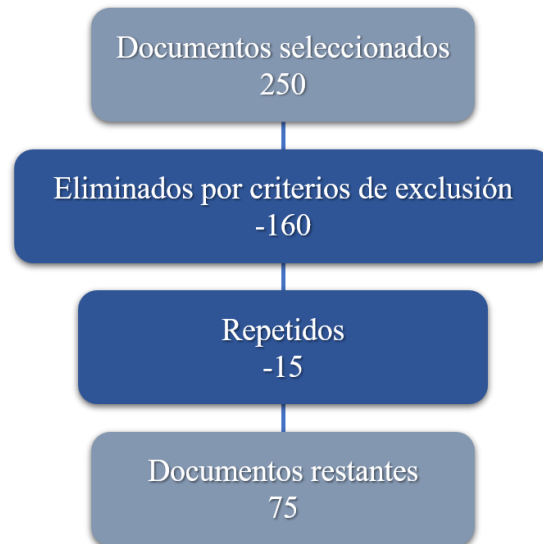
Respecto a la exclusión, se descartaron estudios que utilizaran datos sintéticos, investigaciones desarrolladas únicamente en entornos de laboratorio, documentos que no presentaran resultados específicos de implementación o aquellos redactados en idiomas distintos al inglés, español o portugués. Estos criterios garantizaron la pertinencia de los estudios

seleccionados y su coherencia con el propósito de examinar aplicaciones reales, así como los retos que implica su implementación en el contexto latinoamericano.

En la Figura 7 se muestra la cantidad de documentos restantes tras aplicar los criterios de exclusión y eliminar duplicados, a partir de la selección previa.

Figura 7

Numero de documentos restantes del proceso de exclusión.



6.1.6 Evaluación de Calidad

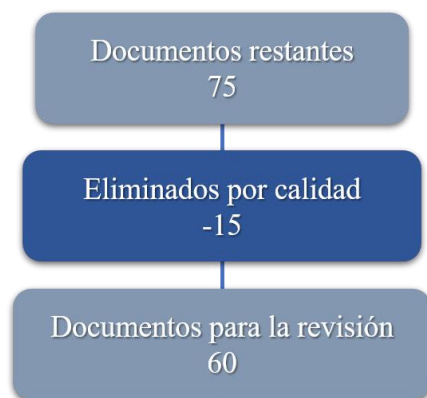
La evaluación de los documentos se basó en un análisis detallado de los estudios seleccionados durante la fase anterior, con el fin de extraer datos relevantes y construir una matriz de análisis de información en Excel. En ella, se integraron aspectos clave como el título del documento, el país de origen, el tipo de industria, el equipo o sistema analizado, el tipo de datos empleados, el objetivo de predicción, la técnica de ML utilizada, el lenguaje de programación y la base de datos de origen. Para completar rigurosamente los campos de esta matriz, se revisó en detalle cada publicación, priorizando aquellas que ofrecieran datos claros y completos, lo que aseguró la calidad y coherencia de la información recopilada.

Por otro lado, los documentos que carecían de información esencial (por ejemplo, contexto industrial definido, especificaciones sobre los equipos analizados o una descripción suficiente de las técnicas de ML y sus resultados) se consideraron de forma secundaria o fueron

excluidos si no cumplían con los criterios mínimos establecidos. Esta estrategia contribuyó a que la matriz de análisis se conformara únicamente por estudios con información relevante y detallada, mejorando así la calidad del análisis comparativo y la utilidad de los resultados obtenidos. En la Figura 8 se presenta el número de documentos finales que sirvieron de base para la revisión sistemática, ofreciendo una visión clara del alcance del estudio.

Figura 8

Numero de documentos seleccionados para la revisión.



Nota. El diagrama representa la cantidad de documentos restantes tras el proceso de revisión, los cuales se detallan en el Anexo 1.

7. Resultados de la Revisión Sistemática

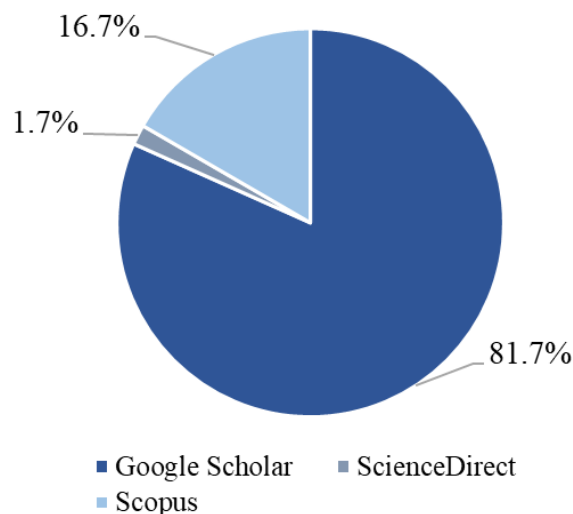
A continuación, se presentan los resultados derivados del análisis de los documentos que cumplieron con los criterios establecidos en esta revisión. La información se organizó de manera sistemática, con el propósito de responder las preguntas formuladas en la metodología.

En relación con la procedencia de los documentos, la Figura 9 muestra que el 81.7% fueron extraídos de Google Scholar, el 16.7% de Scopus y el 1.7% de ScienceDirect. Esta distribución evidencia la predominancia de fuentes de acceso abierto como Google Scholar frente a bases de datos indexadas, donde el acceso puede estar limitado por suscripciones o restricciones institucionales.

Figura 9

Cantidad de documentos por fuente de información consultada.

Distribución de documentos por fuente de información



Nota. Porcentaje de documentos seleccionados en cada base de datos para la revisión sistemática.

Asimismo, se observó que gran parte de los documentos provenientes de Google Scholar corresponde a trabajos de grado publicados en repositorios institucionales, lo cual demuestra que la literatura gris identificada en esta revisión está compuesta principalmente por informes técnicos y tesis universitarias. Dichas investigaciones resultan especialmente valiosas, pues

abordan casos reales y desarrollan modelos basados en datos proporcionados directamente por empresas, convirtiéndose así en recursos útiles para diversos tipos de análisis. En este sentido, el presente estudio no solo amplía la visibilidad de estas fuentes, sino que también resalta su contribución tanto en el ámbito académico como en el industrial.

7.1. Implementación de ML en el MP en el Sector Industrial de América Latina

En una región donde resulta fundamental aumentar la competitividad y adaptarse a cambios constantes, el uso de técnicas de ML en el mantenimiento predictivo se ha convertido en una alternativa cada vez más relevante para optimizar la gestión de activos en las empresas, despertando un creciente interés en los últimos años.

Con el propósito de evidenciar las tendencias y aportes más significativos, se exponen a continuación los principales hallazgos obtenidos a partir del análisis de los documentos que cumplieron con los criterios de esta revisión, organizados de forma sistemática para responder las preguntas de investigación previamente formuladas.

7.1.1 Países Destacados en la Implementación de ML


Como se observa en la Figura 10, la distribución de casos publicados sobre la implementación de técnicas de ML en el mantenimiento predictivo (MP) del sector industrial de América Latina está liderada por Brasil, con 29 casos documentados. Este liderazgo responde a su sólida base industrial y académica, que facilita la adopción de este tipo de tecnologías. En segundo lugar se ubica Ecuador, con 11 casos, seguido de Colombia, con 9, lo que refleja un creciente interés en la modernización de los procesos industriales mediante herramientas avanzadas de análisis de datos. Chile, por su parte, registra 5 casos de implementación, mientras que Perú y Argentina presentan solo dos casos cada uno. En el otro extremo, Honduras y México reportan un único caso documentado.

Esta disparidad en el número de publicaciones está influenciada por factores como la confidencialidad de las empresas, que optan por no divulgar información estratégica, y la limitada difusión de investigaciones académicas en bases de datos indexadas. Esto pone de

manifiesto la necesidad de fomentar la difusión de estas iniciativas en toda la región, con el objetivo de impulsar su adopción y desarrollo.

Figura 10

Distribución de casos de aplicación de técnicas de ML en el MP por país.



Nota. Número de documentos publicados por cada país, con base en los documentos analizados de Scopus, Google Scholar y ScienceDirect.

7.1.2 Industrias con Mayor Aplicación de ML

La distribución de casos encontrados en diversas industrias de América Latina está liderada por el sector energético, con 19 casos documentados, como se muestra en la Figura 11. Este enfoque se centra principalmente en la predicción de fallas en equipos de generación de energía y otros sistemas críticos empleados en los procesos de producción.


En segundo lugar se ubica la industria manufacturera, con 9 casos, mientras que la automotriz reporta 4 estudios centrados en el mantenimiento de motores de combustión interna y sus componentes. Los sectores de petróleo y gas (Oil & Gas), alimentos, servicios, transporte y logística, y siderurgia cuentan con 3 casos cada uno, reflejando un interés creciente en la aplicación de técnicas de ML para optimizar el mantenimiento de activos críticos.

Por su parte, las industrias de minería, naval y construcción registran 2 casos cada una, con enfoques en la optimización del mantenimiento de excavadoras, componentes de vehículos pesados, sistemas de propulsión y motores diésel en embarcaciones. Finalmente, los sectores de

telecomunicaciones, petroquímica, agrícola, aeronáutica, reciclaje y gestión de residuos, bienes de consumo, y papel y celulosa presentan un caso documentado cada uno, evidenciando la diversidad de aplicaciones de ML en el MP a lo largo de la región.

Figura 11

Distribución de estudios sobre ML en MP por industria en América Latina.



Nota. Número de documentos publicados por cada industria, con base en los documentos analizados de Scopus, Google Scholar y ScienceDirect.

7.1.3 Equipos y Sistemas Analizados con ML

Dada la diversidad de componentes y sistemas evaluados en los estudios, se agruparon los elementos específicos en categorías generales para facilitar su representación gráfica. Tal como se muestra en la Figura 12, el grupo de aerogeneradores y turbinas resulta el más representativo, con 12 estudios documentados. Estos dispositivos aprovechan el movimiento de un fluido para generar potencia mecánica o eléctrica, dada su relevancia en la industria sus fallas pueden ocasionar pérdidas económicas considerables (Çengel, 2012).


En segundo lugar, el grupo de vehículos y maquinaria pesada registra 9 casos, reflejando su importancia estratégica en sectores como la construcción, la manufactura y la industria

automotriz. Por su parte, los motores fueron objeto de análisis en 8 estudios, mientras que los sistemas de producción alcanzaron 6 estudios, centrados en líneas de producción equipadas con sensores inteligentes. Los sistemas eléctricos se evaluaron en 5 estudios, en tanto que los sistemas de telecomunicaciones y los equipos de refrigeración y aire acondicionado se documentaron en 3 estudios cada uno.

Aunque con menor presencia, las bombas, las válvulas y los hornos aparecieron en 2 estudios cada uno, reflejando su relevancia en ámbitos industriales más especializados. Finalmente, con una sola mención cada uno, se incluyeron equipos como prensas, laminadores, maquinaria rotativa, brazos robóticos, fresadoras, calderas y digestores, todos reunidos en la categoría “otros”. En estos casos, las técnicas de ML se aplicaron para anticipar fallas y facilitar la planificación de mantenimientos con mayor antelación, contribuyendo a reducir el tiempo de inactividad y los costos asociados.

Figura 12

Distribución de los equipos analizados con técnicas de ML.



Nota. Número de equipos a los que se aplicaron técnicas de ML para predecir fallas en las industrias de América Latina según los documentos recopilados.

7.1.4 Técnicas de ML Más Utilizadas en Industrias Latinoamericanas


Como se observa en la Figura 13, los bosques aleatorios (RF) y la máquina de soporte vectorial (SVM) surgieron como las técnicas más utilizadas, con 16 estudios en empresas latinoamericanas. Esto evidencia su capacidad para manejar conjuntos de datos complejos y modelar relaciones no lineales (Chandramouli et al., 2018). En segundo lugar, el árbol de decisiones (DT) aparece en 11 estudios, demostrando su utilidad para identificar patrones claros y facilitar la interpretación de resultados (Chandramouli et al., 2018).

Otras técnicas como LSTM y ANN aparecen en 9 casos, mientras que K-NN suma 8 menciones. La regresión lineal (LR) y XGBoost se aplicaron en 7, seguidos de Naïve Bayes (NB), regresión logística (LogR) y perceptrón multicapa (MLP), cada uno con 6 menciones. Modelos como K-Means y RNN se registraron en 5 aplicaciones cada uno, mientras que las redes neuronales profunda (DNN) y convolucional (CNN), reconocidas por su capacidad para procesar grandes volúmenes de datos y detectar patrones complejos, se reportaron en 4 casos (Alfian et al., 2020; Villano et al., 2024).

Entre los algoritmos menos frecuentes destacan bosque de aislamiento (IF), Autoencoder (AE) e impulso por gradiente (GB), con 2 documentos cada uno. Por último, se encontró un grupo de métodos mencionados solo una vez: GBT, BT, NAR, ELM, FFR, GRU, HMM, GBR, FK-Means, MLR, DR, N-Beats y STNN. Conviene subrayar que algunos estudios evaluaron varias técnicas de manera simultánea, aunque RF y SVM sobresalen por su versatilidad en distintos contextos industriales de América Latina.

Figura 13

Técnicas de ML más utilizadas en MP según la revisión sistemática.



Nota. Frecuencia de uso de cada técnica en los estudios analizados, según los criterios de esta revisión.

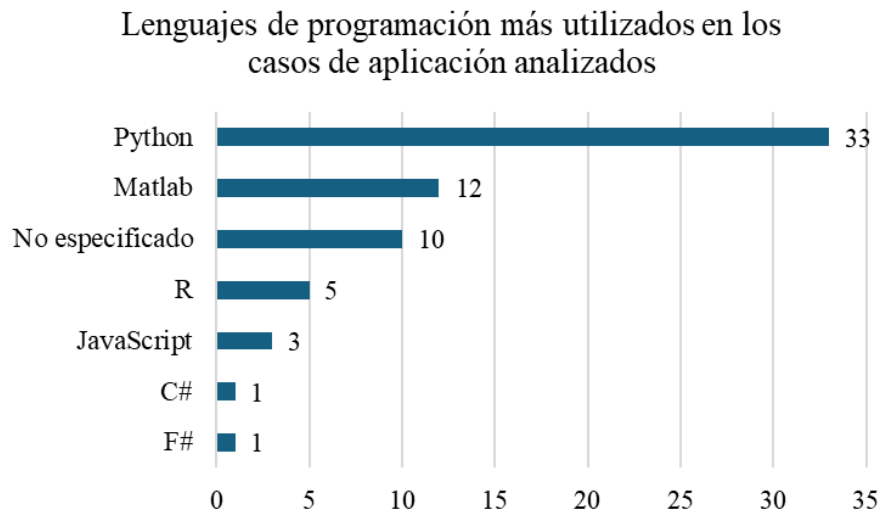
7.1.5 Lenguajes de Programación Predominantes

De los casos analizados, Python se consolida como el lenguaje de programación más empleado en empresas de América Latina para desarrollar modelos de Machine Learning, registrando 33 casos, tal como se muestra en la Figura 14. Su carácter gratuito y de código abierto, sumado a la amplia comunidad de apoyo y su facilidad de uso, lo convierte en la opción preferida (Zelle, 2004). En segundo lugar se ubica Matlab, identificado en 12 documentos de esta revisión relacionados con la implementación de técnicas en equipos industriales; no obstante, su costo de licencia supone una barrera para algunas organizaciones (MathWorks, 2024c).

Por su parte, R aparece en 5 documentos gracias a su fortaleza en análisis estadístico y minería de datos, mientras que JavaScript se menciona en 3 casos. C# y F# solo surgen en un documento cada uno, y en 10 estudios no se precisó el lenguaje utilizado. Aun así, el dominio de Python, que representa más del 50% de los casos, confirma su posición como el lenguaje más utilizado para desarrollar modelos de ML enfocados en la predicción de fallas en equipos.

Figura 14

Lenguajes de programación más utilizados en los estudios analizados.



Nota. Frecuencia de uso de los lenguajes de programación en los casos encontrados en la revisión.

7.1.6 Argentina

En el caso de Argentina, se identificaron dos estudios que aplicaron ML al MP en los sectores de servicios y energía. El primero fue la tesis de pregrado de Vázquez (2024), titulada *“Diseño e implementación de tablero de mantenimiento y predicción de fallas con Machine Learning en una empresa de saneamiento urbano”*. Esta investigación analizó la flota de camiones de saneamiento en la ciudad de Olavarría, empleando datos de temperatura, presión y vibración del motor, el sistema hidráulico y la transmisión. Con el respaldo de redes neuronales recurrentes (RNN) y perceptrón multicapa (MLP), el objetivo consistió en anticipar fallas, reducir paradas imprevistas y optimizar los recursos de mantenimiento. Los resultados indicaron que la implementación de un tablero digital en JavaScript condujo a una gestión de activos más dinámica, facilitó la toma de decisiones y reforzó la colaboración entre equipos, generando un enfoque de mantenimiento más proactivo y una mayor confiabilidad del servicio.

El segundo estudio correspondió a la tesis de especialización de Carrizo (2022), titulada *“Modelo de pronóstico como soporte para el mantenimiento predictivo en filtros de aire de una turbina de gas”*. Este trabajo evaluó el nivel de contaminación en los filtros de aire de una turbina de gas, a partir de mediciones de presión y tiempos de operación. Con el apoyo de LSTM y N-


Beats en Python, se determinó el momento más adecuado para sustituir los filtros y así evitar paradas inesperadas. Los hallazgos mostraron que N-Beats proporcionó mejores predicciones sobre la calidad del aire, permitiendo llevar a cabo el mantenimiento del sistema de filtración sin detener la turbina.

7.1.7 Brasil

Brasil reúne el 48% de los documentos revisados, lo que lo posiciona como el país con más casos de implementación de mantenimiento predictivo (MP) basados en Machine Learning (ML) en esta revisión. En la Figura 15 se observa que la industria energética ocupa el primer lugar con 11 estudios, seguida de la manufacturera con 3. Las industrias de alimentos, automotriz y logística registran 2 documentos cada una, mientras que el resto de los sectores únicamente cuenta con un caso en la muestra.

Figura 15

Industrias brasileñas que registran casos de aplicación de ML en MP.



En el ámbito energético de Brasil, se identificaron 11 investigaciones centradas en mejorar el mantenimiento y la optimización de procesos. Carvalho Chrysostomo et al. (2020)

propusieron el marco BAProm en una planta hidroeléctrica, sirviéndose de DT y ANN para detectar variables críticas y disminuir costos operativos. De Farias & Coelho (2022) emplearon AE en turbinas hidráulicas para identificar patrones de falla a partir de datos de sensores y alarmas, lo que permitió anticipar mantenimientos y reducir interrupciones en la generación. Fantin et al. (2020) aplicaron SVM en acoplamientos flexibles de turbinas eólicas de GE Renewable Energy, logrando una precisión del 97.3% en turbinas saludables y 100% en las defectuosas. Por su parte, Righetto et al. (2021) combinaron NB, DNN, DT, GBT y RF para predecir fallas en reconectores automáticos, alcanzando un desempeño de 82.47% en precisión y recuperación, con una mejora notable en la operación de redes inteligentes. Vallim Filho et al. (2022) diseñaron un modelo con DT, ANN, LogR y RF para turbinas hidroeléctricas, alcanzando un 98% de acierto en la detección de fallas. Bezerra et al. (2023) utilizaron Wavelets, LSTM, MLP y XGBoost para estimar la presión del gas SF₆ en interruptores de alta tensión, optimizando la planificación del mantenimiento al reducir el error absoluto medio. Deon et al. (2022) integraron un gemelo digital con LR, GBR y MLP en plantas termoeléctricas, mejorando la toma de decisiones y reduciendo costos. Alonso (2023) propuso un modelo basado en ANN para prever fallas en plantas de biogás con hasta 20 horas de antelación, aumentando la eficiencia operativa. Nascimento (2023) sugirió predecir fallas en aerogeneradores mediante AE, SVM e IF, destacando AE por su eficacia en la detección de anomalías a partir de datos de vibración y potencia. Xavier (2024) empleó MLR, LSTM y XGBoost en datos SCADA de aerogeneradores para anticipar variaciones de temperatura en componentes críticos, con alta precisión en la optimización de la operación y el mantenimiento de turbinas. Por último, Bellinello et al. (2022) desarrollaron una herramienta para priorizar componentes en unidades hidroeléctricas tipo Kaplan, recurriendo a FK-Means con el fin de agrupar datos operativos y de mantenimiento, e identificar de manera eficaz los puntos más críticos del sistema energético.

La industria manufacturera de Brasil reporta 3 casos. Rocha (2022) desarrolló un modelo predictivo basado en RF para detectar fallas mecánicas en máquinas rotativas, observando que los datos de forma de onda arrojaban mejores resultados que la telemetría. Pinto (2021) diseñó un sistema predictivo para identificar fallas en válvulas de procesos industriales, utilizando K-Means y LR en una plataforma de inteligencia artificial; obtuvo alta precisión y redujo costos operativos al mejorar la planificación del mantenimiento. Resner & Pinotti (2023) emplearon LogR para predecir la vida útil de herramientas de fresado en acero VP Atlas, consiguiendo

100% de efectividad en métricas de precisión y recuperación, lo que optimizó los procesos de manufactura y evitó desgastes que propiciarán fallas.

En la industria de alimentos, Leites (2023) implementó un modelo basado en XGBoost, RF y LR para calderas dedicadas a la producción de arroz parbolizado, con lo cual redujo paradas no previstas y optimizó la gestión de recursos. De igual forma, Filho et al. (2023) desarrollaron un modelo con RF para predecir fallas en una centrífuga industrial, estableciendo una línea base confiable que orientó las inspecciones técnicas.

En el sector de transporte y logística, Sepulvene (2019) creó un sistema que diagnostica fallas en módulos rastreadores de flotas vehiculares, integrando RF, NB, SVM, MLP y CNN, logrando 99.76% de precisión en la detección de errores. Cabreira (2022) presentó un modelo para descubrir anomalías en sistemas neumáticos de camiones mediante RF, NB y LogR, alcanzando 99.4% de exactitud con RF y mejorando la seguridad operativa de los vehículos.

La industria automotriz brasileña cuenta con dos estudios destacados. Lima (2021) desarrolló el sistema MOMENT para diagnosticar fallos en filtros de aire de vehículos con datos en tiempo real, valiéndose de SVM, K-NN y RF para obtener alta precisión, reducir costos operativos y mejorar la confiabilidad. En tanto, Lemos & Zelaquett de Souza (2022) aplicaron ANN y MLP al análisis de robots industriales con 400 registros de fallas; el modelo anticipó problemas y perfeccionó la gestión de mantenimiento.

En el ámbito petrolero, Abdalla et al. (2022) diseñaron un sistema que prevé anomalías en bombas de extracción de crudo con ayuda de XGBoost, emitiendo alertas hasta 7 días antes de la falla real. En la industria aeronáutica, Coelho (2020) empleó GB para estimar la vida útil de componentes neumáticos en aeronaves, logrando 64.65% de precisión y una desviación estándar de 5.89%, lo que contribuyó a mejorar la planificación del mantenimiento.

La industria de servicios está presente en el trabajo de Gouveia (2022), quien gestionó datos operativos, físicos y ambientales de la red de distribución de agua de CAESB para predecir fugas en tuberías. Al combinar LogR, SVM, K-NN, DT, NB, RF, GB y XGBoost, alcanzó una precisión del 63.6%, agilizando la detección de fugas y la priorización de reparaciones. Por su parte, Mine (2024) aplicó LSTM y RNN en el sector papero para identificar fallas en equipos industriales, con una especificidad de 84.48% y la posibilidad de anticiparse hasta con 96 horas de antelación.

En cuanto a reciclaje y gestión de residuos, F. M. J. de Almeida (2023) trabajó con digestores comerciales, utilizando K-Means para detectar patrones anómalos y optimizar la disposición de residuos orgánicos, lo que redujo la acumulación en vertederos y limitó fallas en los equipos. En la industria de bienes de consumo, Oliveira et al. (2023) desarrollaron un modelo basado en RF y LR para la línea de ensamblaje de refrigeradores, disminuyendo en 15% los órdenes de servicio por desperfectos y mejorando la eficiencia general.


La industria de la construcción se ve representada por el estudio de C. A. Almeida (2024) quien elaboró un modelo con SVM, K-NN y RF para predecir el estado de salud de transmisiones Powershift en maquinaria pesada de ZF Friedrichshafen, destacando que RF ofreció los resultados más confiables para la prevención de fallas. Por su parte, la industria siderúrgica cuenta con el aporte de Santos Dutra (2023), que recurrió a K-Means y DT en motores industriales para anticipar problemas eléctricos con 80% de precisión, incrementando la eficiencia operativa. Finalmente, la industria naval se ilustra con la investigación de Saraiva (2023), quien empleó SVM y RF en motores diésel marítimos para monitorear la calidad del aceite lubricante, evitando fallas costosas y fortaleciendo la confiabilidad de los equipos.

7.1.8 Chile

En Chile se encontraron estudios que aplicaron técnicas de ML al mantenimiento predictivo en las industrias de alimentos, manufactura, naval y siderurgia, tal como lo muestra la Figura 16. La industria manufacturera concentró dos casos, mientras que el resto de los sectores registró un solo estudio documentado.

Figura 16

Industrias chilenas que registran casos de aplicación de ML en MP.



En el ámbito manufacturero, Galdames Sepúlveda et al. (2020) emplearon RNN, MLP y SVR para predecir el comportamiento de máquinas de aserrío, lo que permitió optimizar la velocidad de alimentación y reducir el desgaste del equipo. El modelo basado en RNN registró una precisión del 93.21% al estimar dicha velocidad, disminuyendo fallas, prolongando la vida útil de los componentes y, en general, mejorando la eficiencia operativa. Por su parte, Urra González & Ramos Maldonado (2023) utilizaron ANN y SVM para estimar la calidad de tableros contrachapados, considerando variables como temperatura, adhesivo y tiempos operativos; los resultados indicaron una precisión superior al 66%, evidenciando el potencial de ML en procesos productivos complejos para prevenir defectos.


En la industria siderúrgica, Burgos Tapia (2023) desarrolló un modelo predictivo de fallas mediante DT y XGBoost para el laminador de acero de la empresa AZA, alcanzando un 70% de predicción de interrupciones mecánicas. Este logro se tradujo en 111 horas adicionales de producción al año y en una reducción de pérdidas económicas cercana a los 334,152 dólares. En el sector naval, Carrasco Vidal (2020) creó un sistema de mantenimiento predictivo para turbinas a gas con K-NN, logrando un 94.8% de eficiencia al determinar los momentos óptimos de mantenimiento, lo que disminuyó costos y fortaleció la confiabilidad de la operación. Finalmente, en la industria de alimentos, Vargas et al. (2024) implementaron un modelo Lean/Six Sigma híbrido con STNN para mejorar la producción de sal de ajo, obteniendo un 97.31% de precisión al clasificar parámetros críticos y reduciendo desperdicios en un 3.15%.

7.1.9 Colombia

En Colombia se identificaron 9 documentos como se muestra en la Figura 17. Las industrias de energía y Oil & Gas lideran con 3 estudios cada una, mientras que sectores como la minería, manufactura y servicios cuentan con un documento que aplica estas herramientas para optimizar su mantenimiento y anticipar fallas en los equipos.

Figura 17

Industrias colombianas que registran casos de aplicación de ML en MP.



En el sector energético colombiano, Sánchez et al. (2024) implementaron una estrategia de mantenimiento en plantas hidroeléctricas de Enel Colombia, utilizando datos de temperatura en cojinetes de turbinas y registros de generación de energía activa. El modelo, basado en ANN y HMM, mejoró la planificación del mantenimiento, redujo los costos operativos y elevó la confiabilidad del sistema. Por otro lado, Quiñones Álvarez et al. (2022) propusieron una metodología predictiva para transformadores de distribución en el departamento del Cauca, aplicando SVM para clasificar e identificar aquellos con mayor riesgo de fallas, lo que facilitó la programación del mantenimiento y mejoró la calidad del servicio eléctrico. Asimismo, Rodríguez Amaya & Pérez Aponte (2023) diseñaron un modelo de detección de fallas en los generadores hidroeléctricos de Enel Colombia, utilizando RF, SVM y XGBoost, lo que optimizó la detección de anomalías, acortó los tiempos de inactividad y aumentó la eficiencia operativa.

La industria de Oil & Gas presentó tres estudios relevantes. Calderón Gasca & Franco Niño (2023) aplicaron CNN y LSTM para detectar anomalías en bombas electrosumergibles (BES) en un campo del Valle Medio del Magdalena, anticipando fallas con 7 a 55 días de antelación y reduciendo de 75,000 a 26,000 los barriles perdidos por fallas, lo que se tradujo en un ahorro de 1.925 millones de dólares. En otro caso, Alvarado Beltrán & Longo Meneses (2024) diseñaron un modelo predictivo para activos críticos mediante LR y RF, logrando disminuir notablemente los tiempos de inactividad y mejorar la confiabilidad de los equipos. Finalmente, Quiroga Niño (2023) desarrolló una aplicación centrada en el mantenimiento predictivo de sistemas de aire acondicionado industrial en la refinería de Ecopetrol en Barrancabermeja. Con un algoritmo basado en FFR, el modelo detectó fallas recurrentes, optimizó la logística de recursos y disminuyó los costos relacionados con el mantenimiento.

Dentro de la industria minera, Gómez Mercado (2021) creó un modelo predictivo para planificar el cambio de bastidores y orugas en la flota de tractores de Cerrejón. Con algoritmos SVM y datos históricos de desgaste, el modelo alcanzó un 98% de precisión para orugas y 100% en bastidores, reduciendo fallos no programados y perfeccionando la organización de los recursos de mantenimiento.

En el sector manufacturero, Correa Mira et al. (2023) emplearon analítica de datos y algoritmos LogR y DT en Python para establecer un sistema de mantenimiento predictivo en motores eléctricos, logrando detectar anomalías en etapas tempranas y reduciendo los costos derivados de paradas imprevistas.

Por último, en la industria de servicios, López Restrepo & Acevedo Vanegas (2022) propusieron un modelo de ML para prevenir fallas en la infraestructura tecnológica de una compañía de bienes y servicios. Con técnicas como IF, LR y LogR, se consiguió acortar los tiempos de inactividad y asegurar la disponibilidad continua de sistemas críticos.


7.1.10 Ecuador

Ecuador se posiciona como el segundo país con mayor número de casos identificados en esta revisión, representando el 18 % de los documentos recopilados. Como se muestra en la Figura 18, las industrias automotriz, energética y manufacturera destacan con 2 casos de implementación cada una. Sectores como la construcción, telecomunicaciones, transporte y

logística, siderurgia y agrícola registran únicamente 1 caso aplicado, evidenciando un menor nivel de adopción en estas áreas.

Figura 18

Industrias ecuatorianas que registran casos de aplicación de ML en MP.



En la industria automotriz, la tesis de Guartazaca Uyaguari (2024) propuso un modelo de predicción de fallas en motores mediante Matlab, utilizando DT y K-NN, y alcanzó una precisión del 77.6% en la identificación de fallas críticas. Asimismo, destacó el trabajo de Cabrera Palacios & Chiliza Luna (2018), en el que, mediante SVM y K-Means, se detectaron fallas en motores con encendido provocado, lo que redujo el consumo de combustible y las emisiones en vehículos pequeños.

En el sector energético, Segarra López & Andrade Veloz (2017) diseñaron un modelo basado en LSTM para anticipar interrupciones no programadas en alimentadores primarios de la empresa CENTROSUR, logrando identificar patrones de fallas recurrentes y mejorar la planificación de los mantenimientos. En otra investigación, Reino Chérrez & Cochancela Araujo (2022) implementaron LSTM, LR y RNN para predecir fallas en cojinetes de turbinas hidráulicas en la central Saymirín III-IV, alcanzando alta precisión y optimizando la confiabilidad operativa.

Dentro de la industria manufacturera, Jaramillo Alcázar et al. (2023) demostraron que el uso de IoT y algoritmos como SVM, RF y CNN en una planta inteligente mejoró la detección de

anomalías en un 13% y redujo los falsos positivos en un 3%. Asimismo, Villegas Ch et al. (2024) desarrollaron una metodología que combinó CNN, DNN, RNN, LSTM y GRU en un entorno de sensores y actuadores, alcanzando un 92% de acierto en la detección de anomalías y elevando la eficiencia operativa de 70% a 85%, lo que evidenció los beneficios de la fusión de datos en entornos industriales.

En el área de transporte y logística, el estudio de Vega Álvarez (2023) aplicó NB, DT, SVM, ANN, DR y K-Means para predecir fallas en motores de combustión interna de la empresa OCP Ecuador, logrando precisiones entre 98% y 99% y reduciendo los costos de mantenimiento. Por su parte, en el campo agrícola, Mafla Yépez et al. (2023) emplearon DT para detectar fallas en motores de tractores, obteniendo un desempeño superior al 90% en la predicción basada en datos de vibración.

En la construcción, Ortiz Reyes (2023) planteó un modelo con NAR para estimar el consumo de lubricantes en maquinaria pesada del GAD de La Maná, logrando alta precisión y optimizando la planeación del mantenimiento. En el sector de telecomunicaciones, Haro Velasco (2023) utilizó Zabbix para recopilar datos y, tras probar varios algoritmos, encontró que K-NN ofrecía la mayor exactitud y el menor costo de validación para la detección temprana de fallas en equipos inalámbricos, lo que aseguró mejores tiempos de respuesta.

Por último, en la industria siderúrgica, Cifuentes Simbaña (2023) implementó un enfoque de mantenimiento predictivo y proactivo con diversas técnicas de la Industria 4.0 en Acería del Ecuador C.A. (ADELCA). Al utilizar DNN, DT, NB, RF y K-NN con datos históricos de la planta, redujo las paradas no planificadas y prolongó la vida útil de los equipos, consolidando la eficiencia operativa.

7.1.11 Honduras

En el caso de Honduras se encontró el estudio de Velasquez & Flores (2022), titulado “Machine Learning Approach for Predictive Maintenance in Hydroelectric Power Plants”, el cual se centró en la planta hidroeléctrica de Peña Blanca. Mediante datos históricos de sensores en turbinas, unidades hidráulicas y generadores, los autores aplicaron DNN y LSTM para clasificar y predecir comportamientos anómalos. El modelo basado en LSTM logró una exactitud del 99% en la identificación de fallas relacionadas con temperaturas elevadas en los cojinetes del

generador, lo que permitió la detección temprana de incidencias, optimizó los plazos de mantenimiento y redujo costos. El autor del estudio resaltó la importancia de robustecer la confiabilidad de las operaciones de generación eléctrica en el país.

7.1.12 México

En la industria energética de México se destaca el trabajo de Riego Martínez (2018), una tesis de maestría en la que se desarrolló un modelo predictivo para la gestión de mantenimiento en subestaciones de distribución de energía eléctrica de media tensión. El autor aplicó una ANN para estimar en tiempo real la temperatura del aceite de transformadores, utilizando datos del sistema SCADA. Los resultados indicaron que el algoritmo detectó anomalías tempranas en el funcionamiento, disminuyendo así la probabilidad de fallas imprevistas. Esta metodología no solo prolongó la vida útil de los activos, sino que también reforzó la confiabilidad del sistema eléctrico y optimizó los programas de mantenimiento.

7.1.13 Perú

En Perú se encontraron dos estudios relevantes que aplicaron ML a las industrias minera y manufacturera. En primer lugar, la tesis de Cabanillas Flores (2022), titulada “*Desarrollo de modelo predictivo de desgaste basado en datos de ensayos según ASTM G-65 utilizando algoritmos de Machine Learning*”, analizó el desgaste abrasivo en recargues duros sometidos a condiciones extremas en procesos de manufactura. Se emplearon ANN, K-NN y ELM, y se encontró que ANN alcanzó una precisión del 85.75% en la predicción de la pérdida de masa, lo que evidenció su utilidad para optimizar el mantenimiento y reducir costos operativos.

El segundo documento, un artículo de Castro Puma et al. (2023) titulado “*Automatic learning algorithm for troubleshooting in hydraulic machinery*”, se enfocó en la predicción de fallas en excavadoras Caterpillar de 75 toneladas empleadas en minería. El modelo, basado en BT, logró una precisión del 97.15% al identificar fallos en sistemas críticos como lubricación y refrigeración, contribuyendo así a optimizar la planificación de recursos y asegurar la continuidad operativa en el sector minero.

7.2. Desafíos de Estas Tecnologías en América latina

Para obtener una visión integral de los desafíos que enfrentan estas tecnologías en América Latina, se analizaron las dificultades reportadas en cada uno de los estudios incluidos en esta revisión. Sin embargo, de los 60 estudios recopilados, únicamente 13 abordaron de manera específica los obstáculos encontrados durante su implementación. Por esta razón, se incorporaron 5 estudios adicionales que exploraron de forma detallada las barreras que enfrentan estas tecnologías en la región, lo que permitió enriquecer el análisis y profundizar en la comprensión de la situación regional.

A partir del análisis de los documentos recopilados y de los desafíos identificados en los casos de implementación, se estableció un panorama general sobre las principales barreras para la adopción de tecnologías emergentes en América Latina. Estas barreras reflejan tanto limitaciones estructurales como factores organizacionales y sociales que dificultan el aprovechamiento de dichas tecnologías en la región. Entre los principales desafíos mencionados en los estudios se encuentran:

7.2.1 Falta de Talento Especializado

En América Latina, uno de los desafíos más significativos para la implementación de tecnologías avanzadas es la escasez de talento especializado. El informe del Instituto Tecnológico de Massachusetts, basado en entrevistas con altos directivos de América Latina reveló que la falta de profesionales con habilidades técnicas específicas, junto con la dificultad para retenerlos, representa un obstáculo clave en la ejecución de proyectos tecnológicos ambiciosos (MIT, 2020). Este problema también fue analizado, en colaboración con el Banco Interamericano de Desarrollo (BID) y el Foro Económico Mundial, destacando la escasez de personal capacitado en liderazgo y manejo de nuevas tecnologías, especialmente en pequeñas y medianas empresas (PYMEs). En este estudio, se mostró el caso de Argentina, donde el nivel de preparación laboral resultó insuficiente, mientras que, en Brasil, sectores como el automotriz enfrentaron carencias significativas en la formación de supervisores y operarios para adoptar tecnologías 4.0.

El contexto colombiano ofrece un panorama similar. El informe de transformación digital de la Asociación Nacional de Industriales (ANDI), señala que menos de la mitad de las empresas en manufactura y servicios capacitan a su personal en aspectos de digitalización, lo cual restringe el uso no solo de la inteligencia artificial, sino también de herramientas clave que hacen parte del concepto de industria 4.0 (ANDI, 2019). Esta situación se ve reforzada por el estudio de Vera Otálvaro (2023), donde, a partir de la Encuesta Pulso Empresarial (EPE) del DANE, se determinó que 30.7% de las compañías no emplean IA debido a la falta de experiencia técnica. Ejemplos específicos aparecen en la industria manufacturera, tal como menciona Correa Mira et al. (2023), cuyos autores recalcan la necesidad de contar con personal capaz de administrar e interpretar los datos introducidos en el sistema, y también en la industria de Oil & Gas, donde Calderón Gasca & Franco Niño (2023) resaltan que la adopción tecnológica debe ir acompañada de una estrategia que considere tanto la pericia humana como la precisión técnica.

En Brasil, Xavier (2024) observó en el ámbito energético que, para garantizar resultados confiables, es esencial tener un conocimiento sólido de los fundamentos matemáticos de los algoritmos y asegurar una adecuada parametrización. Por su parte, Sepulvene (2019), trabajando en transporte y logística, hizo hincapié en la importancia de contar con personal especializado para llevar a cabo la extracción manual de características, superando así las limitaciones de precisión en los modelos automáticos. Estas evidencias, provenientes de distintos países y sectores, reafirman que la falta de formación y actualización profesional es uno de los principales obstáculos para la adopción de tecnologías avanzadas en el mantenimiento predictivo dentro de América Latina.

7.2.2 Barreras Organizacionales y Culturales

Calatayud & Katz (2019) señalan que una de las grandes dificultades en América Latina radica en el desconocimiento y la falta de prioridad que los mandos medios y gerenciales otorgan a las tecnologías avanzadas. A esto se suma el temor a la pérdida de empleos y la resistencia generacional, factores que ralentizan la adopción de soluciones tecnológicas en diferentes sectores. De forma similar, MIT (2020) encontró que, pese al gran potencial transformador de estas herramientas, muchas empresas consideran que la alta dirección carece de una visión definida para su implementación. Además, la reticencia al cambio no solo está presente en el

personal, sino también entre los clientes, quienes a veces desconfían de sistemas completamente digitales.

En países concretos, estas barreras adquieren matices particulares. En Argentina, la integración digital se ve obstaculizada por la escasa adopción tecnológica de proveedores logísticos y transportistas (Calatayud & Katz, 2019). En Brasil, la dirección, mayoritariamente de generaciones anteriores, tiene dificultades para asumir iniciativas de transformación digital, lo que se complica aún más por la resistencia sindical (Calatayud & Katz, 2019). Por su parte, en Colombia, entrevistas realizadas por la ANDI (2019) revelaron que el 42.5% de las compañías que no usan IA la consideran innecesaria. El estudio de Quiroga Niño (2023) en la industria de Oil & Gas subraya que la falta de información sobre el uso de aprendizaje automático dificulta la adopción del mantenimiento predictivo en sistemas de refrigeración y aire acondicionado, mientras que Quiñones Álvarez et al. (2022) evidencian cómo las conexiones no autorizadas en zonas rurales incrementan la sobrecarga de transformadores y aceleran su deterioro. Además, Vargas et al. (2024) subrayan, en la industria alimentaria chilena, la necesidad de una mayor colaboración entre gobierno, academia e industria, pues la insuficiencia de apoyo estructural representa un obstáculo primordial para el avance tecnológico en este sector.

7.2.3 Barreras Económicas

A nivel regional, Calatayud & Katz (2019) señalan que los bajos costos laborales en algunos países de América Latina pueden competir con los beneficios de la adopción de tecnologías digitales, lo que desincentiva la inversión en infraestructura tecnológica. Asimismo, Reyes Núñez (2021) destaca que el limitado gasto en investigación y desarrollo en la región no se debe únicamente a problemas de coordinación en las instituciones, sino también a la forma en que se organiza el capital en Latinoamérica. Según el autor, empresarios locales consideran innecesaria la inversión en investigación científica y desarrollo, optando por adquirir tecnologías extranjeras en lugar de fomentar la innovación local.

En Colombia, el estudio de Vera Otálvaro (2023) reveló que el 33% de las empresas consideran que los costos de adopción de tecnologías de IA son demasiado altos, lo que evidencia barreras económicas significativas que dificultan la integración de tecnologías avanzadas en sus procesos productivos. De manera similar, el informe de MIT (2020), señala que

nueve de cada diez directivos consideran insuficientes las inversiones actuales en estas tecnologías, reflejando una percepción empresarial que ve estas tecnologías más como un gasto que como una inversión estratégica con un retorno financiero claro.

Esta barrera también es destacada en el trabajo de Vargas et al. (2024), enfocado en la industria de alimentos en Chile. El autor concluye que las Pymes realizan una baja inversión en tecnologías y resalta la necesidad de implementar políticas que aborden los altos costos de inversión para fomentar su adopción.

7.2.4 Infraestructura y Disponibilidad de Datos

América Latina enfrenta diversos desafíos que dificultan la adopción de tecnologías avanzadas, los cuales están estrechamente ligados a la infraestructura digital y la gestión de datos. Según Reyes Núñez (2021), quien analizó datos de otros autores, la región enfrenta un notable atraso en infraestructura tecnológica caracterizado por redes de banda ancha de baja calidad y velocidad, así como una capacidad limitada de procesamiento en la nube, controlada en su mayoría por corporaciones transnacionales. Además, señaló que este problema afecta especialmente a las poblaciones más vulnerables, ya que en muchos países de América Latina menos del 50% de la población tiene acceso a internet, evidenciando profundas desigualdades vinculadas a factores como ingresos, edad y ubicación geográfica.

En relación con los datos, el documento del Instituto Tecnológico de Massachusetts destaca que esta barrera afecta directamente la calidad de las soluciones tecnológicas y su efectividad en los procesos empresariales (MIT, 2020). Complementando esta perspectiva, Calatayud & Katz (2019) menciona que muchas empresas latinoamericanas dependen de soluciones tecnológicas externas debido a la falta de opciones adaptadas a las necesidades locales. Esta dependencia no solo incrementa los costos de adquisición, sino que también reduce el retorno de inversión, afectando particularmente a sectores clave como la manufactura y los servicios.

En Colombia, el trabajo de Gómez Mercado (2021) destacó la importancia de mantener un registro correcto y constante de los datos a lo largo del tiempo para utilizar indicadores y desarrollar modelos de aprendizaje efectivos en la industria minera. De manera similar, Quiñones Álvarez et al. (2022) en su estudio enfocado en la industria energética colombiana, señalaron que

la ubicación de los equipos en zonas de difícil acceso dificulta el monitoreo, los análisis y la recopilación de datos necesarios para implementar tecnologías avanzadas.

En Argentina, Vázquez (2024) en la industria de servicios, enfatizó que la falta de procesos eficientes en la gestión de información y la ausencia de análisis de fallas en la flota de vehículos representan barreras significativas para la adopción de este tipo de tecnologías en las empresas.

En Brasil, Xavier (2024) en la industria energética, subrayó la importancia de realizar una limpieza y organización exhaustiva de los datos SCADA antes de aplicar los modelos predictivos. De manera similar, Carvalho Chrysostomo et al. (2020) señalaron que el proceso de extracción, transformación y carga de datos depende de la transferencia manual por parte de los empleados, lo que ralentiza el proceso y aumenta el riesgo de errores. En la industria manufacturera, Rocha (2022) destacó la necesidad de comprobar los datos antes de subirlos a la plataforma Dynamox, pero al ser una tarea manual, esta etapa puede introducir fallos que afectan la precisión del modelo. Asimismo, en el sector de alimentos, Leites (2023) señaló que las inconsistencias en los datos utilizados hicieron que el algoritmo aplicado no lograra resultados satisfactorios.

7.2.5 Ética, Regulación e Información

La incorporación de tecnologías avanzadas en Latinoamérica también enfrenta obstáculos de carácter ético, regulatorio y relacionados con la información. De acuerdo con MIT (2020), son pocas las empresas que han implementado políticas explícitas para garantizar la privacidad y la transparencia en la transformación digital, lo que refleja un enfoque ético todavía incipiente. Complementariamente, el estudio de Calatayud & Katz (2019) señala que, si bien se observan avances tecnológicos en la región, subsiste una brecha entre grandes empresas y Pymes debido a la falta de marcos regulatorios que impulsen la adopción de estas innovaciones. Esta carencia se ve agravada por la fragmentación de la información en torno al uso de la inteligencia artificial, tal como enfatiza Reyes Núñez (2021), para quien dicha dispersión dificulta el desarrollo de análisis confiables y la elaboración de normativas alineadas con las necesidades locales. En Colombia, Vera Otálvaro (2023) estima que las principales barreras incluyen la incertidumbre

legal y las inquietudes respecto a la privacidad, impactando al 3.5% de las organizaciones y restringiendo la implementación de tecnologías emergentes.

7.2.6 Dependencia Tecnológica

Otro obstáculo relevante es la gran dependencia tecnológica de la región, tal como describe Reyes Núñez (2021). La preferencia por importar soluciones eleva los costos y limita los beneficios, además de frenar la inversión en investigación y desarrollo que permitiría crear productos y servicios propios. Este fenómeno se refuerza, por una estructura económica que prioriza la adquisición de tecnología extranjera y desalienta la generación local de valor, profundizando la dependencia de proveedores internacionales (MIT, 2020). Asimismo, Calatayud & Katz (2019) documentan la limitada disponibilidad de soluciones autóctonas, que obliga a las empresas a optar por sistemas foráneos, encareciendo la adopción de tecnologías en sectores estratégicos como la industria automotriz y la manufactura. En Argentina, estos autores evidencian la baja integración digital en la cadena de valor de la industria manufacturera, con efectos adversos sobre ámbitos como la logística y el transporte, donde la necesidad de adquirir tecnologías importadas se hace aún más notoria.

7.3. Tendencias y Oportunidades


Los documentos analizados en esta revisión evidencian un creciente interés en el desarrollo de modelos predictivos para equipos que aprovechan recursos renovables, como el aire o fluidos residuales de procesos. Tal y como se muestra en la Figura 19 los aerogeneradores y las turbinas destacan por su número de estudios orientados a pronosticar posibles fallas, lo que permite planificar cambios y evitar interrupciones imprevistas o daños adicionales en otros componentes.

Una búsqueda en Scopus con las palabras clave “Turbine” OR “Wind Turbine” AND “Prediction model” confirmó el aumento sostenido en la publicación de documentos sobre este tipo de equipos, tal como se evidencia en la Figura 19. Este incremento señala el interés por optimizar el rendimiento y la fiabilidad de dichos sistemas a través de metodologías avanzadas de predicción y monitoreo, y sugiere que la tendencia continuará creciendo de la mano de

iniciativas gubernamentales y empresariales que promueven sistemas con menor impacto ambiental.

Figura 19

Tendencia de publicaciones en Scopus sobre modelos de predicción.



Nota. Elaboración a partir de datos de Scopus sobre la tendencia de publicaciones relacionadas con modelos predictivos aplicados a turbinas y aerogeneradores.

En cuanto a las técnicas de aprendizaje automático, Wen et al. (2022), en su revisión sistemática “*Recent advances and trends of predictive maintenance from data-driven machine prognostics perspective*”, resaltaron el uso cada vez mayor de redes neuronales profundas como CNN, RNN y LSTM para abordar la predicción de la vida útil remanente (RUL) en equipos críticos. Su estudio anticipa que futuras investigaciones integrarán la heterogeneidad y la incertidumbre de los datos en escenarios de predicción en tiempo real. No obstante, los métodos tradicionales de Machine Learning (RF, SVM y DT) se mantienen como referentes muy efectivos en aplicaciones de mantenimiento predictivo como se observa en la Figura 13 y en las conclusiones de Carvalho et al. (2019). En esta última, se destacó que los bosques aleatorios (RF) eran la técnica más empleada, seguidos por métodos basados en redes neuronales (ANN, CNN, LSTM) y la máquina de soporte vectorial (SVM), lo cual refleja la preferencia de la

comunidad investigadora por enfoques probados en distintos contextos industriales, así como el interés continuo en perfeccionarlos (Yates & Islam, 2021).

Además de los casos estudiados en esta revisión, hay ejemplos internacionales que apuntan a oportunidades relevantes para América Latina. Ejaz et al. (2024), demostraron en Pakistán la utilidad de modelos de aprendizaje automático para monitorear la calidad del agua, una aplicación que puede ser adoptada localmente por empresas que buscan reducir el riesgo ambiental o maximizar la gestión sostenible de recursos. Por otro lado, McLaughlin & Choi (2023) ilustraron el uso de técnicas de ML para predecir ahorros energéticos tras la reparación de fugas en sistemas de aire comprimido, con un margen de error del 17 %. Este tipo de soluciones resulta de particular interés para industrias latinoamericanas que requieren optimizar el uso de la energía de la red, puesto que la reducción de costes, el recorte de emisiones y la mejora de la eficiencia siguen siendo prioridades esenciales en la región.

En el ámbito de la gestión empresarial, Yato Flores & Zamudio Navarro (2024) presentaron un modelo de ML para la gestión de inventarios de repuestos en una mina subterránea en Perú. Su propuesta predijo de manera precisa la demanda de insumos críticos y permitió una clasificación óptima mediante el método ABC, lo que pone de relieve los beneficios de adoptar herramientas de la Industria 4.0 para optimizar la disponibilidad de recursos, abaratar costes y perfeccionar la eficiencia en sectores como la minería, manufactura y logística.

En definitiva, estas aplicaciones evidencian un panorama prometedor para la adopción de tecnologías de ML en América Latina, especialmente en áreas donde el ahorro de energía, el manejo de recursos naturales y la gestión estratégica de inventarios constituyen ventajas competitivas. Con la superación de las barreras identificadas tanto tecnológicas como organizacionales y económicas, se vislumbra un escenario de mayor incorporación de modelos de mantenimiento predictivo y soluciones de Industria 4.0 en la región, orientando a las empresas hacia una transformación digital más sostenible y eficiente.

Conclusiones

El mantenimiento predictivo potenciado por Machine Learning en el sector industrial de América Latina se ha consolidado como una herramienta clave para optimizar procesos, reducir costos operativos y mejorar la confiabilidad de los equipos. A partir del análisis de los estudios recopilados, se identificó que su aplicación no se limita únicamente a sectores tradicionalmente intensivos en maquinaria, como la industria energética, manufacturera, automotriz y Oil & Gas, sino que también ha comenzado a expandirse hacia ámbitos como la construcción, la logística, el sector de alimentos, la aeronáutica y la industria naval. Esta diversidad de aplicaciones evidencia el potencial del ML para abordar problemáticas específicas en cada industria, aprovechando el análisis de datos históricos para anticipar fallas y optimizar estrategias de mantenimiento.

El análisis de los 60 casos de implementación en América Latina revela que Brasil lidera la adopción con el 48% de los estudios registrados, destacándose por su capacidad de innovación y desarrollo tecnológico en esta área. Ecuador (18%) y Colombia (15%) muestran avances significativos en la integración de técnicas de ML en sus procesos industriales, mientras que países como México, Argentina, Chile y Perú, en conjunto, representan el 19% de los casos documentados. Sin embargo, la escasez de estudios publicados en revistas científicas y bases de datos indexadas, sumada a la confidencialidad de la información en algunas empresas, dificulta el acceso a conocimientos clave sobre estas implementaciones. Esto no solo limita la posibilidad de realizar análisis más amplios y comparativos, sino que también reduce la visibilidad de los esfuerzos de modernización en distintos países de la región. Ante esta situación, resulta fundamental fomentar una mayor producción y difusión de investigaciones que permitan compartir experiencias, validar resultados y acelerar la adopción de estas tecnologías en el sector industrial latinoamericano.

En términos sectoriales, la industria energética encabeza la implementación de modelos de ML con 19 casos documentados, seguida por la manufacturera con 9 y la automotriz con 4 estudios enfocados en la predicción de fallas en motores de combustión interna. Sectores como Oil & Gas, alimentos, servicios, transporte y logística, y siderurgia presentan un menor número de implementaciones, con tres casos cada uno. Esta distribución sugiere que las industrias con procesos altamente dependientes de la operatividad de sus equipos y con costos elevados derivados de fallas imprevistas han priorizado el uso de estas tecnologías para optimizar sus

estrategias de mantenimiento. Sin embargo, la efectividad del mantenimiento predictivo no radica únicamente en la sofisticación de los modelos empleados, sino también en la capacidad de las organizaciones para interpretar, gestionar y mejorar continuamente estos sistemas. La formación de profesionales con habilidades en análisis de datos y aprendizaje automático se vuelve un factor determinante para garantizar una implementación exitosa y escalable en todos los sectores industriales.

En cuanto a las técnicas de ML utilizadas, se observa una clara preferencia por algoritmos como bosques aleatorios (RF), máquina de soporte vectorial (SVM) y árboles de decisión (DT), debido a su capacidad para manejar grandes volúmenes de datos y generar modelos interpretables. Paralelamente, ha crecido el uso de enfoques más avanzados basados en redes neuronales como LSTM, ANN y CNN, especialmente en aplicaciones que requieren modelar secuencias de datos y detectar patrones complejos. Python a su vez, se consolida como el lenguaje de programación predominante en estas implementaciones, gracias a su flexibilidad, código abierto y una comunidad de desarrolladores activa que facilita la creación y mejora de modelos de inteligencia artificial. En este sentido, fomentar el aprendizaje de este lenguaje en programas académicos y de formación profesional es esencial para dotar a la región de especialistas con las competencias necesarias para integrarse en el mercado laboral y contribuir al desarrollo de soluciones innovadoras.

A pesar del potencial de estas tecnologías, esta revisión identificó diversas barreras que dificultan su adopción generalizada en América Latina. La falta de talento especializado, la resistencia organizacional al cambio, las limitaciones económicas y de infraestructura, la escasa disponibilidad de datos y la dependencia de tecnología extranjera se destacan como los principales obstáculos para su implementación. Estos factores no solo ralentizan la transformación digital de las industrias, sino que también impiden que las empresas aprovechen plenamente los beneficios del mantenimiento predictivo. Ante esta realidad, es fundamental un cambio de mentalidad en la región, donde los altos directivos y el personal encargado de la toma de decisiones no solo reconozcan la importancia de estas tecnologías, sino que se involucren activamente en su aprendizaje y en la capacitación de sus equipos, asegurando así una transición efectiva hacia modelos de mantenimiento más inteligentes y eficientes.

Finalmente, las tendencias observadas en esta revisión destacan el creciente interés en el uso de ML para mejorar la sostenibilidad y la eficiencia energética en la industria. La

implementación de modelos para el monitoreo de aerogeneradores, turbinas y sistemas de energía renovable refleja un esfuerzo por desarrollar soluciones más ecológicas y optimizar el consumo de recursos. Asimismo, el avance en redes neuronales y algoritmos cada vez más sofisticados marca una evolución en las estrategias de mantenimiento predictivo, orientadas hacia la automatización y la detección temprana de fallas en tiempo real. Con estos avances, queda en evidencia que el mantenimiento predictivo basado en Machine Learning ya es una realidad en América Latina, pero su consolidación definitiva dependerá de la superación de las barreras identificadas y del fortalecimiento del conocimiento técnico, garantizando que la región pueda capitalizar plenamente las oportunidades que ofrecen estas tecnologías.

Referencias

- Abdalla, R., Samara, H., Perozo, N., Paz, C., & Jaeger, P. (2022). Machine Learning Approach for Predictive Maintenance of the Electrical Submersible Pumps (ESPs). *ACS Omega*, 7. <https://doi.org/10.1021/acsomega.1c05881>
- Aguilar Otero, J. R., Torre Arcique, R., & Magaña Jiménez, D. (2010). Análisis de modos de falla, efectos y criticidad (AMFEC) para la planeación del mantenimiento empleando criterios de riesgo y confiabilidad. *Tecnología, Ciencia Edición (IMIQ)*, 1(25), Article 25. <http://www.redalyc.org/articulo.oa?id=48215094003>
- Alaghbari, K. A., Lim, H.-S., Saad, M. H. M., & Yong, Y. S. (2023). Deep Autoencoder-Based Integrated Model for Anomaly Detection and Efficient Feature Extraction in IoT Networks. *IoT*, 4(3), Article 3. <https://doi.org/10.3390/iot4030016>
- Alfian, G., Syafrudin, M., Fitriyani, N. L., Anshari, M., Stasa, P., Svub, J., & Rhee, J. (2020). Deep Neural Network for Predicting Diabetic Retinopathy from Risk Factors. *Mathematics*, 8(9), Article 9. <https://doi.org/10.3390/math8091620>
- Almeida, C. A. (2024). *Development of a machine learning model to predict construction machinery gearboxes' health status* [Tesis de pregrado, Universidad Federal de Uberlândia]. Repositorio Institucional. <https://repositorio.ufu.br/handle/123456789/41976>
- Almeida, F. M. J. de. (2023). *Utilização de aprendizado de máquina em sistemas digestores comerciais* [Trabalho de Conclusão de Curso (MBA), Universidad de São Paulo]. Repositorio Institucional. <https://bdta.abcd.usp.br/directbitstream/863f3827-983b-46fe-be65-74d479968796/Fernanda%20Almeida.pdf>
- Alonso, M. E. (2023). *Proposta de aplicação de métodos de machine learning em manutenção preditiva* [Tesis de grado, Universidade Federal Fluminense]. Repositorio Institucional. <https://app.uff.br/riuff/handle/1/27463>
- Alvarado Beltrán, D. S., & Longo Meneses, F. E. (2024). *Mantenimiento 4.0: Diseño de modelo predictivo para la definición de estrategias de mantenimiento en la industria oíl & gas* [Proyecto aplicado, Universidad Nacional Abierta y a Distancia (UNAD)]. Repositorio Institucional. <http://repository.unad.edu.co/handle/10596/62826>
- ANDI. (2019). *Informe de la encuesta de encuesta de transformación digital 2019* (pp. 1-25) [Informe técnico]. Asociación Nacional de Empresarios de Colombia.

- <https://www.andi.com.co/Uploads/Analisis%20-%20encuesta%20de%20transformaci%C3%93n%20digital%202019%20-%20andi.Pdf>
- Bellinello, M. M., Antomarioni, S., Souza, G. F. M. de, Bevilacqua, M., & Ciarapica, F. E. (2022). Entropy-MAUT integrated approach supported by Fuzzy K-means: A robust tool for determining critical components for maintenance monitoring and a case study of Kaplan hydro generator unit. *Production*, 32, 24. <https://doi.org/10.1590/0103-6513.20210066>
- Benrhmach, G., Namir, K., Namir, A., & Bouyaghroumni, J. (2020). Nonlinear Autoregressive Neural Network and Extended Kalman Filters for Prediction of Financial Time Series. *Journal of Applied Mathematics*. <https://doi.org/10.1155/2020/5057801>
- Bentéjac, C., Csörgő, A., & Martínez-Muñoz, G. (2021). A comparative analysis of gradient boosting algorithms. *Artificial Intelligence Review*, 54(3), 1937-1967. <https://doi.org/10.1007/s10462-020-09896-5>
- Bezerra, F. E., Di Santo, S. G., & Junior, G. M. (2023). An approach based on wavelets and machine learning to build a prediction model for SF6 filling pressure of high-voltage circuit breakers. *Electric Power Systems Research*, 216, 108974. <https://doi.org/10.1016/j.epsr.2022.108974>
- Braga, J. A. P., & Andrade, A. R. (2023). Data-driven decision support system for degrading assets and its application under the perspective of a railway component. *Transportation Engineering*, 12, 100180. <https://doi.org/10.1016/j.treng.2023.100180>
- Breiman, L. (1996). Bagging Predictors. *Machine Learning*, 24(2), 123-140. <https://doi.org/10.1023/A:1018054314350>
- Burgos Tapia, D. A. (2023). *Rediseño al proceso de laminado del acero para aumentar la producción, incorporando un modelo predictivo de fallas para el mantenimiento del laminador en la acerera AZA* [Tesis de maestría, Universidad de Chile]. Repositorio Institucional. <https://repositorio.uchile.cl/handle/2250/192883>
- Cabanillas Flores, R. (2022). *Desarrollo de modelo predictivo de desgaste basado en datos de ensayos según ASTM G-65 utilizando algoritmos de Machine Learning* [Tesis de grado, Pontificia Universidad Católica Del Perú]. Repositorio Institucional. <https://tesis.pucp.edu.pe/repositorio/handle/20.500.12404/24085>

- Cabreira, G. R. (2022). *Detecção de anomalias por meio de machine learning: Estudo de caso de sistemas pneumáticos em caminhões* [Tesis de grado, Universidade Tecnológica Federal do Paraná]. Repositorio Institucional. <http://repositorio.utfpr.edu.br:8080/jspui/handle/1/31287>
- Cabrera Palacios, A. P., & Chiluiza Luna, B. M. (2018). *Desarrollo de un algoritmo mediante análisis de aprendizaje automático para la detección de fallos en vehículos M1 con motores de encendido provocado* [Tesis de grado, Universidad Politécnica Salesiana]. Repositorio Institucional. <http://dspace.ups.edu.ec/handle/123456789/16584>
- Calatayud, A., & Katz, R. (2019). *Cadena de suministro 4.0: Mejores prácticas internacionales y hoja de ruta para América Latina*. Banco Interamericano de Desarrollo (BID). <http://hdl.handle.net/11520/26208>
- Calderón Gasca, A. F., & Franco Niño, K. Y. (2023). *Detección de anomalías en series de tiempo del funcionamiento de bombas electrosumergibles (BES) de producción en un campo de petróleo en Colombia* [Tesis de maestría, Universidad de los Andes]. Repositorio Institucional. <https://hdl.handle.net/1992/73121>
- Caravedo, B., Casanova, L., Correa, M. E., Castillo, E. D., Estévez, R., Korin, M., González, L., Gutiérrez, R., Leguizamón, F. A., Nowalski, J., Peinado-Vara, E., Aldama, L. R. P., Schwalb, M. M., & Vives, A. (2012). *La responsabilidad social de la empresa en América Latina: Manual de Gestión* (Caribe). <http://dx.doi.org/10.18235/0009873>
- Carmona, R., Amato Neto, J., & Ascúa, R. (2020). *Industria 4.0 en empresas manufactureras del Brasil* (p. 53). Comisión Económica para América Latina y el Caribe (CEPAL). <https://www.cepal.org/es/publicaciones/46389-industria-40-empresas-manufactureras-brasil>
- Carrasco Vidal, E. (2020). Data science: Herramientas de machine learning para implementar mantenimiento predictivo en una planta propulsora | Revista de Marina. *Revista de Marina Año, 137*(974), <https://revistamarina.cl/es/articulo/data-science-herramientas-de-machine-learning-para-implementar-mantenimiento-predictivo-en-una-planta-propulsora>
- Carrizo, J. J. A. (2022). *Modelo de pronóstico como soporte para el mantenimiento predictivo en filtros de aire de una turbina de gas* [Tesis de especialización, Instituto tecnológico de Buenos Aires]. Repositorio Institucional. <https://ri.itba.edu.ar/handle/123456789/4100>

- Carvalho, T. P., Soares, F. A. A. M. N., Vita, R., Francisco, R. da P., Basto, J. P., & Alcalá, S. G. S. (2019). A systematic literature review of machine learning methods applied to predictive maintenance. *Computers & Industrial Engineering*, *137*, 106024. <https://doi.org/10.1016/j.cie.2019.106024>
- Castro Puma, J., Castro Puma, M., More Sánchez, V., Marcos Romero, J., Huamán Flores, E., Poma Garcia, C., & Alejos Ipanaque, R. (2023). Automatic learning algorithm for troubleshooting in hydraulic machinery. *Indonesian Journal of Electrical Engineering and Computer Science*, *29*(1), Article 1. <https://doi.org/10.11591/ijeecs.v29.i1.pp535-544>
- Çengel, Y. A. (2012). *TERMODINAMICA* (7.^a ed.). McGraw-Hill Interamericana.
- Chandramouli, S., Dutt, S., & Dāsa, A. (2018). *Machine Learning*. Pearson Education.
- Cho, K., Merriënboer, B. van, Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. (2014). Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation. *En Actas de la Conferencia sobre Métodos Empíricos en el Procesamiento del Lenguaje Natural*, 1724-1734. <https://doi.org/10.48550/arXiv.1406.1078>
- Chung, E., Park, K., & Kang, P. (2023). Fault classification and timing prediction based on shipment inspection data and maintenance reports for semiconductor manufacturing equipment. *Computers & Industrial Engineering*, *176*, 108972. <https://doi.org/10.1016/j.cie.2022.108972>
- Cifuentes Simbaña, D. I. (2023). *Modelo de mantenimiento predictivo y proactivo para el funcionamiento de las maquinarias de la empresa Acería del Ecuador C.A. ADELCA*. [Tesis de maestría, Universidad de las Fuerzas Armadas ESPE]. Repositorio Institucional. <https://repositorio.espe.edu.ec/items/93d6a5fc-4d8f-4b16-831d-abe9378382f5>
- Coelho, M. H. (2020). *Mineração de dados e aprendizado de máquina aplicados ao prognóstico de falhas em componentes aeronáuticos* [Tesis de grado, Universidade Federal de Santa Catarina.]. Repositorio Institucional. <https://repositorio.ufsc.br/handle/123456789/218423?show=full>
- Correa Mira, C. A., Escobar Galvis, J. A., & Mena Perea, J. I. (2023). *Implementación de analítica de datos para el mantenimiento predictivo de motores eléctricos*. [Tesis de grado, Institución Universitaria Pascual Bravo]. Repositorio Institucional. <https://repositorio.pascualbravo.edu.co/handle/pascualbravo/2303>

- de Carvalho Chrysostomo, G. G., de Aguiar Vallim, M. V. B., da Silva, L. S., Silva, L. A., & de Aguiar Vallim Filho, A. R. (2020). A Framework for Big Data Analytical Process and Mapping—BAProm: Description of an Application in an Industrial Environment. *Energies*, 13(22), Article 22. <https://doi.org/10.3390/en13226014>
- de Farias, K., & Coelho, O. B. (2022, noviembre 7). Investigando Uma Solução Para Previsão De Falhas Em Turbinas Hidráulicas Por Meio De Detecção De Anomalia, Deep Learning E A Arquitetura Autoencoder. *Jornada de Iniciação Científica y Exposición de Iniciação Tecnológica*. <http://eventoscopq.mackenzie.br/index.php/jornada/xviii/paper/view/2852>
- Deon, B., Cotta, K. P., Silva, R. F. V., Batista, C. B., Justino, G. T., Freitas, G. C., Cordeiro, A. M., Barbosa, A. S., Loução, F. L., Simioni, T., Morais, A. M., Medeiros, I. E. A., Almeida, R. J. S., Araújo Jr., C. A. A., Soares, C., & Padoin, N. (2022). Digital twin and machine learning for decision support in thermal power plant with combustion engines. *Knowledge-Based Systems*, 253, 109578. <https://doi.org/10.1016/j.knosys.2022.109578>
- Deutscher, E., & Torres Rivas, E. (1986). *Industrialización en América Latina: Crisis y perspectivas*. FLACSO Ecuador. <https://biblio.flacsoandes.edu.ec/libros/7713-opac>
- Ejaz, U., Khan, S. M., Jehangir, S., Ahmad, Z., Abdullah, A., Iqbal, M., Khalid, N., Nazir, A., & Svenning, J.-C. (2024). Monitoring the Industrial waste polluted stream—Integrated analytics and machine learning for water quality index assessment. *Journal of Cleaner Production*, 450, 141877. <https://doi.org/10.1016/j.jclepro.2024.141877>
- Elion. (2024). *Tecnologías de la industria 4.0*. Elion. <https://www.elion.es/tecnologias/industry40/>
- Fantin, T. H., Rocha, H. G., & Scodiero, G. U. de A. (2020). *Manutenção Preditiva do Acoplamento Flexível de Turbinas Eólicas (GE Renewable Energy)* [Tesis de grado, Instituto de ensino e pesquisa]. Repositorio Institucional. <https://repositorio.insper.edu.br/handle/11224/3320>
- Ferraro, M. B. (2024). Fuzzy K-Means: History and applications. *Econometrics and Statistics*, 30, 110-123. <https://doi.org/10.1016/j.ecosta.2021.11.008>
- Filho, L. F. M., Monteiro, R. de P., Pinheiro, D., Endo, P. T., & Ribeiro, A. M. N. C. (2023). Forecasting Imminent Failures in Electrical Industrial Centrifuge using Machine

- Learning. 2023 *IEEE Latin American Conference on Computational Intelligence (LA-CCI)*, 1-6. <https://doi.org/10.1109/LA-CCI58595.2023.10409489>
- Galdames Sepúlveda, P. A., Ramos Maldonado, M. A., & Reyes Hernández, D. J. (2020). *Análisis de datos a través de machine learning para predecir el comportamiento de máquinas de aserrío de alta productividad* [Tesis de grado, Universidad del Bio-Bio]. Repositorio Institucional. <http://repobib.ubiobio.cl/jspui/handle/123456789/3723>
- García, B. (2021). *Industria 4.0. La cuarta revolución industrial*. *Universitat Politècnica de València*. <https://riunet.upv.es/handle/10251/165996>
- Gasca, M. C., Camargo, L. L., & Medina, B. (2020). Gestión del mantenimiento para la confiabilidad operacion. *Espacios*, 41(47), 250-261. <https://doi.org/10.48082/espacios-a20v41n47p18>
- Gómez Mercado, P. S. (2021). *Modelo de gestión para determinar plan de cambio de bastidores y orugas aplicando Machine Learning en la flota de tractores de orugas de Cerrejón* [Tesis de maestría, Universidad Industrial de Santander]. Repositorio Institucional. <https://noesis.uis.edu.co/handle/20.500.14071/9412>
- Gouveia, C. G. N. (2022). *Técnicas de aprendizaje de máquina aplicadas à predição de vazamentos em ramais de redes de distribuição de água* [Tesis de maestría, Universidade De Brasília]. Repositorio Institucional. <http://repositorio.unb.br/handle/10482/43766>
- Guartazaca Uyaguari, J. S. (2024). *Predicción de fallas mediante un modelo de aprendizaje automático en motores de combustión interna*. [Tesis de pregrado, Universidad Politécnica Salesiana]. Repositorio Institucional. <http://dspace.ups.edu.ec/handle/123456789/28661>
- Haro Velasco, O. A. (2023). *Implementación de un algoritmo para la detección temprana de fallas en equipos inalámbricos de una empresa proveedora de servicios de Internet utilizando técnicas de aprendizaje autónomo* [Tesis de maestría, Escuela superior politécnica del litoral]. Repositorio Institucional. <http://www.dspace.espol.edu.ec/handle/123456789/58578>
- Huang, G.-B., Zhu, Q.-Y., & Siew, C.-K. (2006). Extreme learning machine: Theory and applications. *Neurocomputing*, 70(1), 489-501. <https://doi.org/10.1016/j.neucom.2005.12.126>

- Jaramillo Alcazar, A., Govea, J., & Villegas Ch, W. (2023). Anomaly Detection in a Smart Industrial Machinery Plant Using IoT and Machine Learning. *Sensors*, 23(19), Article 19. <https://doi.org/10.3390/s23198286>
- Lee, W. J., Wu, H., Yun, H., Kim, H., Jun, M. B. G., & Sutherland, J. W. (2019). Predictive Maintenance of Machine Tool Systems Using Artificial Intelligence Techniques Applied to Machine Condition Data. *Procedia CIRP*, 80, 506-511. <https://doi.org/10.1016/j.procir.2018.12.019>.
- Leites, L. R. L. (2023). *Estudo da aplicação de técnicas de análise de dados e Machine Learning em uma indústria de arroz parboilizado: Manutenção preditiva e estudo de falhas em uma caldeira* [Tesis de grado, Universidade Federal do Pampa]. Repositorio Institucional. <https://repositorio.unipampa.edu.br/jspui/handle/rii/9300>
- Lemos, T. D., & Zelaquett de Souza, L. A. (2022). Abordagem Preditiva de Quebras Baseada em Logs de Eventos na Indústria Automotiva. *Revista de Ingeniería e Investigación Aplicada*, 7(3), 54-63. <https://doi.org/10.25286/repa.v7i3.2460>
- Lima, G. P. (2021). *MOMENT: Sistema de aprendizado de máquina para manutenção preditiva* [Tesis de grado, Universidade Federal Do Ceará]. Repositorio Institucional. <http://repositorio.ufc.br/handle/riufc/61228>
- Liu, F. T., Ting, K. M., & Zhou, Z.-H. (2008). Isolation Forest. *2008 Eighth IEEE International Conference on Data Mining*, 413-422. <https://doi.org/10.1109/ICDM.2008.17>
- López Restrepo, L. M., & Acevedo Vanegas, D. (2022). *Modelado predictivo aplicado al comportamiento de componentes de la infraestructura tecnológica en empresas de bienes y servicios* [Tesis de especialización, Universidad Católica Luis Amigó]. Repositorio Institucional. <http://repository.ucatolicaluissamigo.edu.co/handle/20.500.14.531/4259>
- Mafla Yépez, C. N., Morales Bayetero, C. F., Hernández Rueda, E. P., & Benavides Cevallos, I. B. (2023). Vehicle maintenance management based on machine learning in agricultural tractor engines. *DYNA*, 90(225), Article 225. <https://doi.org/10.15446/dyna.v90n225.103612>
- Majidzadeh Gorjani, O., Byrtus, R., Dohnal, J., Bilik, P., Koziorek, J., & Martinek, R. (2021). Human Activity Classification Using Multilayer Perceptron. *Sensors*, 21(18), Article 18. <https://doi.org/10.3390/s21186207>

- Marriaga Páez, A. C. (2024). Integración de la eficiencia operativa y la sostenibilidad en la administración empresarial. [Trabajo de grado, Universidad Nacional Abierta y a Distancia (UNAD)]. Repositorio Institucional. <http://repository.unad.edu.co/handle/10596/61735>
- MathWorks. (2023). *What Is a Recurrent Neural Network (RNN)?* <https://la.mathworks.com/discovery/rnn.html>
- MathWorks. (2024a). *Introducción a Deep Learning*. <https://la.mathworks.com/discovery/deep-learning.html>
- MathWorks. (2024b). *Introduction to Hidden Markov Models (HMM)*. <https://la.mathworks.com/help/stats/hidden-markov-models-hmm.html>
- MathWorks. (2024c). *MATLAB - El lenguaje del cálculo técnico*. <https://la.mathworks.com/products/matlab.html>
- McLaughlin, E., & Choi, J.-K. (2023). Utilizing machine learning models to estimate energy savings from an industrial energy system. *Resources, Environment and Sustainability*, 12, 100103. <https://doi.org/10.1016/j.resenv.2022.100103>
- Mian, S. M., Khan, M. S., Shawez, M., & Kaur, A. (2024). Artificial Intelligence (AI), Machine Learning (ML) & Deep Learning (DL): A Comprehensive Overview on Techniques, Applications and Research Directions. *2024 2nd International Conference on Sustainable Computing and Smart Systems (ICSCSS)*, 1404-1409. <https://doi.org/10.1109/ICSCSS60660.2024.10625198>
- Mine, F. H. (2024). *Detecção de falhas em ativos críticos utilizando redes neurais artificiais*. [Tesis de especialización, Universidade Federal de Ouro Preto]. Repositorio Institucional. <http://www.monografias.ufop.br/handle/35400000/6871>
- MIT. (2020). *La inteligencia artificial en las compañías latinoamericanas: Visión panorámica de la adopción y tendencias en la región*. Instituto Tecnológico de Massachusetts (MIT). https://www.anuarioseguros.lat/admin/storage/files/EVERIS_3.pdf
- Mnih, V., Kavukcuoglu, K., Silver, D., Graves, A., Antonoglou, I., Wierstra, D., & Riedmiller, M. (2013, diciembre 19). *Playing Atari with Deep Reinforcement Learning*. <https://doi.org/10.48550/arXiv.1312.5602>
- Mohri, M., Rostamizadeh, A., & Talwalkar, A. (2018). *Foundations of Machine Learning*. MIT Press.

- Naeem, S., Ali, A., Anam, S., & Ahmed, M. (2023). An Unsupervised Machine Learning Algorithms: Comprehensive Review. *IJCDS Journal*, 13, 911-921. <https://doi.org/10.12785/ijcnds/130172>
- Nascimento, M. V. R. (2023). *Análise e predição de falhas em aerogeradores utilizando deep learning* [Tesis de grado, Universidade Estadual Paulista]. Repositorio Institucional. <http://hdl.handle.net/11449/242775>
- Organización Internacional del Trabajo (OIT) (Ed.). (2013). *El desafío de la promoción de empresas sostenibles en América Latina y el Caribe: Un análisis regional comparativo*. OIT. https://www.ilo.org/sites/default/files/wcmsp5/groups/public/%40americas/%40ro-lima/documents/publication/wcms_205234.pdf
- Oliveira, J. B. de, Gino, J. V. S. R., Filho, J. I. da S., & Lima, C. J. de. (2023). Aplicação de inteligência artificial através de algoritmos de aprendizagem de máquina para redução do número de OS em campo, baseado em falhas encontradas na linha de montagem de refrigeradores em uma indústria multinacional de bens de consumo. *Revista de Gestão e Secretariado*, 14(10), 18396-18416. <https://doi.org/10.7769/gesec.v14i10.3055>
- Oreshkin, B. N., Carпов, D., Chapados, N., & Bengio, Y. (2020). *N-BEATS: Neural basis expansion analysis for interpretable time series forecasting* (No. arXiv:1905.10437). arXiv. <https://doi.org/10.48550/arXiv.1905.10437>
- Ortiz Reyes, J. C. (2023). *Diseño de un modelo para el control del consumo de filtros y lubricantes del equipo caminero y maquinaria pesada del GAD del Cantón La Maná mediante algoritmos de inteligencia artificial* [Tesis de maestría, Universidad Técnica de Ambato]. Repositorio Institucional. <https://repositorio.uta.edu.ec/handle/123456789/40173>
- Paez, A. (2017). Gray literature: An important resource in systematic reviews. *Journal of Evidence-Based Medicine*, 10(3), 233-240. <https://doi.org/10.1111/jebm.12266>
- Pérez Rondón, F. A. (2021). *Conceptos generales en la gestión del mantenimiento industrial*. Universidad Santo Tomás. <https://repository.usta.edu.co/handle/11634/33276>
- Pinto, M. C. (2021). *Sistema de manutenção preditiva de falhas em válvulas em um processo industrial utilizando inteligência artificial*. [Tesis de grado, Universidade Federal de Uberlândia]. Repositorio Institucional. <https://repositorio.ufu.br/handle/123456789/32268>

- Polamuri, S. R., Kumbhkar, M., & Daniel, A. P. (2022). *Introduction to Deep Learning* (1.^a ed.). AGPH Books.
- Quiñones Alvarez, L. I., Moncada Lozano, C. A., & Montenegro Bravo, D. A. (2022). Metodología para el mantenimiento predictivo de transformadores de distribución basada en aprendizaje automático. *Electrical and Electronic Engineering*, 27(3), Article 3. <https://doi.org/10.14483/23448393.17742>
- Quiroga Niño, J. A. (2023). *Aplicación de escritorio para mantenimiento predictivo de equipos industriales de refrigeración a través de machine learning*. [Tesis de maestría, Universidad Santo Tomás]. Repositorio Institucional. <https://repository.usta.edu.co/handle/11634/51260>
- Rastogi, A. K., Taterh, S., & Kumar, B. S. (2023). Dimensionality Reduction Algorithms in Machine Learning: A Theoretical and Experimental Comparison. *Engineering Proceedings*, 59(1), Article 1. <https://doi.org/10.3390/engproc2023059082>
- Reino Chérrez, E. F., & Cochancela Araujo, J. R. (2022). *Desarrollo de un sistema de predicción de falla de cojinete de turbina hidráulica basado en redes neuronales recurrentes con LSTM* [Tesis de maestría, Universidad Poletécnica Salesiana]. Repositorio Institucional. <http://dspace.ups.edu.ec/handle/123456789/21930>
- Resner, K., & Pinotti, M. (2023, noviembre 21). *Aplicação de Machine Learning para Previsão da Vida de Ferramentas de Usinagem*. XXV Coloquio de Mecanizado, Brusque. <https://doi.org/10.29327/xxv-coloquio-de-usinagem.691368>
- Reyes Núñez, C. (2021). *Dependencia tecnológica, corporaciones transnacionales e inteligencia artificial en América Latina* [Tesis de maestría, Universidad Nacional Autónoma de México]. Repositorio Institucional. <https://hdl.handle.net/20.500.14330/TES01000809955>
- Reyna, M. V. S., Toro, A. V. del, Vincent, N. A. M., Amado, F. R., Salazar, M. O. G., González, A. M. B., & Ávila, J. M. J. (2021). Revisión sistemática: El más alto nivel de evidencia. *Orthotips AMOT*, 17(4), 217-221. <https://doi.org/10.35366/102220>
- Riego Martinez, A. (2018). *Desarrollo y aplicación de un modelo predictivo para gestión de mantenimiento en subestaciones de distribución de energía eléctrica en redes de media tensión* [Tesis de maestría, Universidad Nacional Autónoma de México]. Repositorio Institucional. <https://hdl.handle.net/20.500.14330/TES01000780181>

- Righetto, S. B., Hattori, L. T., Nunes, G. G., Carvalho, E. G., Martins, M. A. I., & De Francisci, S. (2021). *Failure Prediction in Automatic Reclosers Using Machine Learning Approaches*. 320-324. <https://doi.org/10.1109/URUCON53396.2021.9647250>
- Rocha, A. P. da. (2022). *Manutenção preditiva de máquinas rotativas para detecção de falhas mecânicas com técnicas de aprendizado de máquina utilizando dados reais de sensores de vibração* [Tesis de grado, Universidade Federal de Santa Catarina.]. Repositorio Institucional. <https://repositorio.ufsc.br/handle/123456789/243320>
- Rodríguez Amaya, A., & Pérez Aponte, D. A. (2023). *Construcción de un modelo que permita identificar fallas en generadores de centrales hidroeléctricas* [Tesis de maestría, Pontificia Universidad Javeriana.]. Repositorio Institucional. <https://vitela.javerianacali.edu.co/handle/11522/791>
- Rojas Bances, D. P. (2021). Machine learning para mejorar la gestión de mantenimiento de máquinas industriales. [Trabajo de grado, Universidad Cesar Vallejo]. Repositorio Institucional. <https://repositorio.ucv.edu.pe/handle/20.500.12692/85837>
- Rojko, A. (2017). Industry 4.0 Concept: Background and Overview. *International Journal of Interactive Mobile Technologies (iJIM)*, 11(5), Article 5. <https://doi.org/10.3991/ijim.v11i5.7072>
- Rondon Chavez, R. E. (2022). Machine learning en la disponibilidad y confiabilidad de la flota vehicular de una calera. *Repositorio Institucional - UCV*. <https://repositorio.ucv.edu.pe/handle/20.500.12692/129812>
- Russell, S. J., & Norvig, P. (2007). *Artificial Intelligence: A Modern Approach 2Nd Ed*. Prentice-Hall Of India Pvt. Limited.
- Sanchez, G. C., Gómez, G. R., Pabón, E. G., Fontani, T., Tovar, I. D., Navarro, L. B., & Guerra, A. M. (2024). E-maintenance in hydropower energy generation: A case study of Enel Colombia. *RE&PQJ*, 105-110. <https://doi.org/10.52152/3998>
- Santos Dutra, A. (2023). *Análise de dados de inspeção em motores de indução para classificação utilizando técnicas de machine learning* [Tesis de grado, Universidade Federal de Ouro Preto.]. Repositorio Institucional. <http://www.monografias.ufop.br/handle/35400000/5999>

- Sanz Angulo, P., & Maisueche Cuadrado, A. (2019). *Utilización del Machine Learning en la industria 4.0* [Trabajo Fin de Máster, Universidad de Valladolid]. Repositorio Institucional. <https://uvadoc.uva.es/handle/10324/37908>
- Saraiva, G. E. (2023). *Manutenção de motores diesel marítimos: Qualidade do óleo lubrificante* [Tesis de grado, Centro de Instrução Almirante Alexandrino (CIAA)]. Repositorio Institucional. <https://www.repositorio.mar.mil.br/handle/ripcmb/847163>
- Schmidtke, T., Koch, H., & Camarero García, V. (with Friedrich-Ebert-Stiftung). (2020). *Los sectores económicos en América Latina y su participación en los perfiles exportadores: Tobias Schmidtke, Hernriette Koch y Verónica Camarero García*. Friedrich-Ebert-Stiftung Proyecto Regional Transformación Social-Ecológica. <https://library.fes.de/pdf-files/bueros/mexiko/14815.pdf>
- Schulman, J., Wolski, F., Dhariwal, P., Radford, A., & Klimov, O. (2017, agosto 28). *Proximal Policy Optimization Algorithms*. <https://doi.org/10.48550/arXiv.1707.06347>
- Segarra López, J. F., & Andrade Veloz, P. S. (2017). *Modelo predictivo de fallas en alimentadores primarios de concesión de la Empresa Eléctrica Regional Centro Sur usando aprendizaje profundo de máquina* [Tesis de grado, Universidad de Cuenca]. Repositorio Institucional. <https://dspace.ucuenca.edu.ec/handle/123456789/28579>
- Sepulvene, L. H. M. (2019). *Aplicação de técnicas de aprendizado de máquina para o diagnóstico de falhas em módulos rastreadores de frotas veiculares*. [Tesis de maestría, Universidad Federal de Itajubá]. Repositorio Institucional. <https://repositorio.unifei.edu.br/jspui/handle/123456789/1984>
- Shalev Shwartz, S., & Ben David, S. (2014). *Understanding Machine Learning: From Theory to Algorithms*. Cambridge University Press. <https://doi.org/10.1017/CBO9781107298019>
- Soares, S. G. (2015). *Ensemble Learning Methodologies for Soft Sensor Development in Industrial Processes* [Tesis de doctorado, Universidade de Coimbra]. Repositorio Institucional. <https://estudogeral.uc.pt/handle/10316/28313>
- Sutton, R. S., & Barto, A. G. (2018). *Reinforcement Learning, second edition: An Introduction*. MIT Press.
- Universidad Complutense de Madrid. (2021). *¿Qué es el Machine Learning?* <https://www.masterdatascienceucm.com/que-es-machine-learning/>

- Urza González, C., & Ramos Maldonado, M. (2023). A machine learning approach for plywood quality prediction. *Ciencia y tecnología*, 25, 22. <https://doi.org/10.4067/s0718-221x2023000100436>
- Vallim Filho, A. R. de A., Farina Moraes, D., Bhering de Aguiar Vallim, M. V., Santos da Silva, L., & da Silva, L. A. (2022). A Machine Learning Modeling Framework for Predictive Maintenance Based on Equipment Load Cycle: An Application in a Real World Case. *Energies*, 15(10), Article 10. <https://doi.org/10.3390/en15103724>
- Vargas, M., Mosquera, R., Fuertes, G., Alfaro, M., & Perez Vergara, I. G. (2024). Process Optimization in a Condiment SME through Improved Lean Six Sigma with a Surface Tension Neural Network. *Processes*, 12(9), Article 9. <https://doi.org/10.3390/pr12092001>
- Vázquez, M. E. (2024). *Diseño e implementación de tablero de mantenimiento y predicción de fallas con Machine Learning en una empresa de saneamiento urbano* [Tesis de grado, Universidad Nacional del Centro de la Provincia de Buenos Aires.]. <https://www.ridaa.unicen.edu.ar/items/1bbf05e1-2d2c-450d-8338-b64e849e797d>
- Vega Álvarez, F. B. (2023). Predicción de fallas en un motor de combustión interna de la empresa OCP Ecuador. *Ciencia Latina Revista Científica Multidisciplinar*, 7(1), Article 1. https://doi.org/10.37811/cl_rcm.v7i1.4749
- Velasquez, V., & Flores, W. (2022). Machine Learning Approach for Predictive Maintenance in Hydroelectric Power Plants. *2022 IEEE Biennial Congress of Argentina (ARGENCON)*, 1-6. <https://doi.org/10.1109/ARGENCON55245.2022.9939782>
- Vera Otálvaro, L. M. (2023). Adopción de tecnologías de Inteligencia Artificial: Un estudio para las empresas en Colombia. [Trabajo de grado, Universidad EAFIT]. Repositorio Institucional. <http://hdl.handle.net/10784/32618>
- Villano, F., Mauro, G. M., & Pedace, A. (2024). A Review on Machine/Deep Learning Techniques Applied to Building Energy Simulation, Optimization and Management. *Thermo*, 4(1), Article 1. <https://doi.org/10.3390/thermo4010008>
- Villegas Ch, W., Gaibor Naranjo, W., & Sanchez Viteri, S. (2024). Application of Deep Learning Techniques for the Optimization of Industrial Processes Through the Fusion of Sensory Data. *International Journal of Computational Intelligence Systems*, 17(1). Scopus. <https://doi.org/10.1007/s44196-024-00596-4>

- Watkins, C. (1989). *Learning From Delayed Rewards* [Tesis de doctorado], University of Cambridge.
https://www.researchgate.net/publication/33784417_Learning_From_Delayed_Rewards
- Wen, Y., Fashiar Rahman, Md., Xu, H., & Tseng, T.-L. B. (2022). Recent advances and trends of predictive maintenance from data-driven machine prognostics perspective. *Measurement*, 187, 110276. <https://doi.org/10.1016/j.measurement.2021.110276>
- Xavier, L. M. S. (2024). *Aplicações de aprendizado de máquina na detecção de anomalias em sistemas eólicos* [Tesis de maestría, Universidad Federal de Pernambuco]. Repositorio Institucional. <https://repositorio.ufpe.br/handle/123456789/56306>
- Yates, D., & Islam, M. Z. (2021). FastForest: Increasing random forest processing speed while maintaining accuracy. *Information Sciences*, 557, 130-152. <https://doi.org/10.1016/j.ins.2020.12.067>
- Yato Flores, D. E., & Zamudio Navarro, J. D. (2024). Modelo de gestión de inventarios para el abastecimiento de repuestos de una flota de operaciones aplicando Machine Learning en una mina subterránea del sur del Perú. [Trabajo de grado, Universidad Peruana de Ciencias Aplicadas (UPC)]. Repositorio Institucional. <https://repositorioacademico.upc.edu.pe/handle/10757/674554>
- Zelle, J. M. (2004). *Python Programming: An Introduction to Computer Science*. Franklin, Beedle & Associates, Inc.
- Ziat, A., Delasalles, E., Denoyer, L., & Gallinari, P. (2017). Spatio-Temporal Neural Networks for Space-Time Series Forecasting and Relations Discovery. *2017 IEEE International Conference on Data Mining (ICDM)*, 705-714. <https://doi.org/10.1109/ICDM.2017.80>

Anexos

*Anexo 1 Matriz con los documentos encontrados***Tabla 7***Casos de implementación del ML en el MP en América Latina*

Ítem	Título	País	Industria	Equipos/Sistemas	Tipo de dato	Busca predecir	Técnica de ML	Lenguaje de programación	Cita
1	Aplicación de escritorio para mantenimiento predictivo de equipos industriales (...)	Colombia	Industria Oil & Gas	Equipos de refrigeración y aire acondicionado	Presión, Temperatura, Amperaje y tipo de refrigerante.	Fugas de refrigerante, fallos en el compresor y motor	FFR	C# y F#	(Quiroga Niño, 2023)
2	Modelo de gestión para determinar plan de cambio de bastidores y orugas (...)	Colombia	Industria minera	Bastidores y orugas	Historial de desgaste, porcentaje de desgaste y horas de operación.	Fallos en zapatas, bujes, cadenas, rodillos y rueda guía.	SVM	Matlab	(Gómez Mercado, 2021)
3	Optimización de Procesos en una PyME de Condimentos (...)	Chile	Industria de alimentos	Proceso de producción de sal de ajo	Datos de temperatura y humedad en tiempo real	Variaciones en la temperatura y humedad que afectan la calidad del producto	STNN	No especificado.	(Vargas et al., 2024)
4	Implementación de Analítica de Datos para el Mantenimiento Predictivo (...)	Colombia	Industria manufacturera	Motores eléctricos	Corriente, voltaje y temperatura en tiempo real	Fallas en el funcionamiento de los motores eléctricos	LogR y DT	Python	(Correa Mira et al., 2023)

Tabla 7*Continuación*

5	Un enfoque basado en wavelets y aprendizaje automático para construir (...)	Brasil	Industria energética	Interruptores de alta tensión (HVCB) aislados con SF ₆	Historial de presión de llenado, temperaturas, densidad y corriente de línea	Pérdidas de presión de SF ₆ , problemas de aislamiento y fallas en el funcionamiento.	LSTM, MLP y XGBoost	Matlab y Python	(Bezerra et al., 2023)
6	Un marco de modelado de aprendizaje automático para mantenimiento predictivo (...)	Brasil	Industria energética	Turbinas de una planta hidroeléctrica	Historial del ciclo de carga, tiempo de operación y otras variables monitoreadas	Fallas en las turbinas debido al desgaste de componentes por uso continuo.	DT, ANN, LR, y RF.	R	(Vallim Filho et al., 2022)
7	Enfoque de Aprendizaje Automático para el Mantenimiento Predictivo (...)	Honduras	Industria energética	Turbinas y unidades de una planta hidroeléctrica	Series temporales de sensores y eventos de fallas registrados en SCADA.	Fallos en los componentes de la turbina y el generador.	DNN y LSTM	Python	(Velasquez & Flores, 2022)
8	Metodología para el mantenimiento predictivo de transformadores (...)	Colombia	Industria energética	Transformadores de distribución en la red eléctrica	Historial de fallas, condiciones climáticas, tasa de quema, ubicación y densidad de rayos.	Fallas en los transformadores de distribución que afectan la continuidad del servicio.	SVM	Matlab	(Quiñones Alvarez et al., 2022)

Tabla 7*Continuación*

9	Diseño e implementación de tablero de mantenimiento y predicción (...)	Argentina	Industria de servicios	Flota de vehículos de saneamiento urbano.	Datos de temperatura, presión y vibración en tiempo real.	Fallos en el motor, sistema hidráulico y transmisión.	RNN y MLP	JavaScript	(Vázquez, 2024)
10	Modelo de Pronóstico como soporte para el Mantenimiento Predictivo (...)	Argentina	Industria energética	Sistema de filtración de aire en una turbina de gas.	Datos de presión en los filtros de aire y tiempo de operación de la turbina	Cambio de filtros para evitar paradas no programadas.	N-Beats y LSTM.	Python	(Carrizo, 2022)
11	Predicción de fallas en un motor de combustión interna (...)	Ecuador	Industria de Transporte y Logística	Motor de combustión interna Wartsila 12V32LN.	Datos de sensores del motor, como presión, temperatura, viscosidad, entre otros.	Fallas en el motor de combustión interna para evitar interrupciones en el transporte de crudo	NB, DT, SVM, ANN, DR y K-Means	JavaScript	(Vega Álvarez, 2023)
12	Análisis de datos a través de Machine Learning para predecir el (...)	Chile	Industria manufacturera	Máquinas de aserrío de alta productividad.	Datos operativos de velocidad de alimentación, vibraciones, entre otros.	Desgaste y fallos en equipos de aserrado para mantener la productividad	MLP, SVM y RNN	Python	(Galdames Sepúlveda et al., 2020)

Tabla 7*Continuación*

13	Rediseño al proceso de laminado del acero para aumentar la producción (...)	Chile	Industria siderúrgica	Laminador de acero en la planta Colina de AZA.	Datos de sensores de temperatura, torque, corriente y vibración.	Fallas mecánicas en el laminador de acero	DT y XGBoost	Python	(Burgos Tapia, 2023)
14	Un enfoque de Machine Learning para la predicción de la (...)	Chile	Industria manufacturera	Rodillos y prensas	Datos de temperatura de la chapa, cantidad de adhesivo y condiciones ambientales	Rechazo de tableros debido a fallas en la adherencia y resistencia a la tracción perpendicular.	ANN y SVM	Python y R	(Urrea González & Ramos Maldonado, 2023)
15	Desarrollo de un sistema de predicción de falla de cojinete de turbina (...)	Ecuador	Industria energética	Cojinete de turbina hidráulica en la central hidroeléctrica Saymirín III-IV.	Historial de temperatura axial del cojinete, caudal, y potencia de la unidad.	Sobrecalentamiento y fallo en el cojinete de la turbina.	RNN, RL y LSTM	Python	(Reino Chérrez & Cochancela Araujo, 2022)
16	Implementación de un algoritmo para la detección temprana de fallas (...)	Ecuador	Industria de telecomunicaciones	Equipos CPE de MikroTik	Datos de potencia de recepción, transmisión promedio, entre otros.	Pérdida de conectividad o degradación de la señal inalámbrica	K-NN	Matlab	(Haro Velasco, 2023)

Tabla 7*Continuación*

17	Desarrollo y aplicación de un modelo predictivo para la gestión (...)	México	Industria energética	Transformadores de distribución en subestaciones eléctricas	Datos de temperatura del aceite en transformadores obtenidos a través del sistema SCADA	Sobrecalentamiento en transformadores, que puede conducir a fallos inesperados y costosos apagones.	ANN	R	(Riego Martinez, 2018)
18	Aplicaciones de aprendizaje de máquina en la detección de anomalías (...)	Brasil	Industria energética	Caja de engranajes y rodamiento de un aerogenerador	Temperatura y datos operativos en la caja de engranajes y el rodamiento	Sobrecalentamiento en componentes críticos	MLR, LSTM y XGBoost	Python	(Xavier, 2024)
19	Enfoque integrado de Entropía-MAUT con soporte de Fuzzy K-means: una herramienta (..)	Brasil	Industria energética	Unidad hidroeléctrica Kaplan.	Historial de operación y mantenimiento y órdenes de servicio	Componentes críticos para priorizar mantenimiento predictivo y preventivo.	FK-Means	No especificado.	(Bellinello et al., 2022)
20	Predicción de fallos inminentes en una centrífuga industrial (...)	Brasil	Industria alimentaria	Centrífuga industrial eléctrica	Datos de vibración, temperatura de rodamientos, corriente del motor y niveles de lubricación	Fallos inminentes en la centrífuga industrial eléctrica.	RF	Python	(Filho et al., 2023)

Tabla 7*Continuación*

21	Minería de datos y aprendizaje de máquina aplicados al pronóstico de fallas (...)	Brasil	Industria aeronáutica	Válvulas reguladoras de presión y componentes del sistema de aire acondicionado y presurización	Datos del sistema neumático, mensajes de alerta, registros de mantenimiento.	Vida útil remanente de los componentes del sistema neumático	GB	Python	(Coelho, 2020)
22	Gemelo digital y aprendizaje automático para el apoyo a la toma de decisiones (...)	Brasil	Industria energética	Motores de combustión	Parámetros mecánicos, térmicos y eléctricos de operación.	La degradación de componentes y fallas futuras.	LR, GBR y MLP	Python	(Deon et al., 2022)
23	Optimización del mantenimiento predictivo en sistemas de bombeo (...)	Brasil	Industria petrolera	Bombas eléctricas sumergibles (ESPs).	Datos de presión, temperatura, frecuencia de la bomba, y corriente.	Fallos inminentes en las ESPs para optimizar la operación y reducir el tiempo de inactividad.	XGBoost	No especificado.	(Abdalla et al., 2022)
24	Un marco para el proceso analítico de Big Data y mapeo (...)	Brasil	Industria energética	Turbinas y generadores	Datos históricos de operación y mantenimiento, variables eléctricas, mecánicas y de temperatura	Fallos en generadores y turbinas que podrían interrumpir la generación de energía.	DT y ANN	R	(de Carvalho Chrysostomo et al., 2020)

Tabla 7*Continuación*

25	Mantenimiento predictivo de sistemas de generación (..)	Colombia	Industria energética	Cojinetes de una turbina	Datos de temperatura del aceite, del metal del rodamiento y la potencia activa.	Desgaste en los cojinetes y en la potencia activa	ANN y HMM	No especificado.	(Sánchez et al., 2024)
26	Aplicación de técnicas de aprendizaje profundo para la (...)	Ecuador	Industria manufacturera	Hornos, prensas, rodamientos, engranajes, sistemas neumáticos e hidráulicos	Datos de temperatura, vibración, sonido e imágenes de visión computacional	Sobrecalentamientos en hornos y prensas, desgaste en rodamientos y engranajes, fallos en sistemas neumáticos e hidráulicos.	CNN, RNN, LSTM, GRU y DNN	No especificado.	(Villegas Ch et al., 2024)
27	Detección de anomalías en una planta de maquinaria industrial (...)	Ecuador	Industria manufacturera	Máquinas y equipos industriales	Datos de temperatura, presión, aceleración, flujo y datos visuales de cámaras IoT	Anomalías y fallos en el funcionamiento de maquinaria para evitar interrupciones.	CNN, SVM y RF	No especificado.	(Jaramillo Alcazar et al., 2023)
28	Gestión del mantenimiento de vehículos basada en el aprendizaje autónomo (...)	Ecuador	Industria agrícola	Motor de tractor agrícola	Datos de vibración obtenidos de un sensor piezoeléctrico en el motor del tractor	Fallas en el sistema de alimentación de combustible y anomalías en el proceso de combustión.	DT	Matlab	(Mafla Yépez et al., 2023)

Tabla 7*Continuación*

29	Algoritmo de aprendizaje automático para la localización (...)	Perú	Industria minera	Excavadoras hidráulicas Caterpillar de 75TN	Historial de frecuencia de fallos, tiempo medio entre fallos, tiempo medio de reparación, y criticidad	Ubicación de fallos en el sistema de excavadoras hidráulicas	BT	Matlab	(Castro Puma et al., 2023)
30	Mantenimiento 4.0: Diseño de Modelo Predictivo para la Definición (...)	Colombia	Industria Oil & Gas	Equipos críticos en la empresa.	Historial de mantenimiento, tiempos de parada, frecuencia de fallas, y métricas de rendimiento.	Fallas en los equipos para reducir tiempos de inactividad no planificados.	LR y RF	Python	(Alvarado Beltrán & Longo Meneses, 2024)
31	Construcción de un modelo que permita identificar fallas en generadores (...)	Colombia	Industria energética	Rodamientos y aceites de las turbinas Pelton	Historial de temperaturas, aceites y vibraciones del sistema SCADA,	Fallos en los equipos y evitar sanciones por incumplimiento en la generación de energía	RF, SVM XGBoost	Python	(Rodríguez Amaya & Pérez Aponte, 2023)
32	Herramientas de Machine Learning para Implementar Mantenimiento Predictivo (...)	Chile	Industria naval	Turbina a gas GE LM2500 y motores diésel Siemens	Historial de temperatura, presión y velocidad de operaciones.	Fallas en la turbina a gas y otros componentes del sistema de propulsión.	K-NN	Matlab	(Carrasco Vidal, 2020)

Tabla 7*Continuación*

33	Aplicación de técnicas de aprendizaje automático para el diagnóstico de fallas en (...)	Brasil	Industria de Transporte y Logística	Módulos rastreadores de flotas vehiculares	Señales de entrada y salida y atributos relacionados con fallas.	Detección y clasificación de fallas en módulos rastreadores	RF, NB, SVM, MLP y CNN	Python	(Sepulvene, 2019)
34	Predicción de fallas mediante un modelo de aprendizaje automático en motores (...)	Ecuador	Industria automotriz	Motores de combustión interna	Historial de temperatura en el refrigerante, flujo de aire, presión del colector, entre otros.	Desgaste de piezas, fallas de sensores y fugas.	DT y K-NN	Matlab	(Guartazaca Uyaguari, 2024)
35	Modelo predictivo de fallas en alimentadores primarios de concesión de la Empresa (...)	Ecuador	Industria energética	Alimentadores primarios	Historial de paradas no programadas desde 2011 hasta 2015.	Fallas en alimentadores con ubicación y fecha aproximada.	LSTM	Python	(Segarra López & Andrade Veloz, 2017)
36	Desarrollo de modelo predictivo de desgaste basado en datos de ensayos (...)	Perú	Industria manufacturera	Probetas para pruebas de desgaste	Datos de desgaste y composición química	Desgaste de materiales bajo condiciones específicas	K-NN, ANN y ELM	Python	(Cabanillas Flores, 2022)

Tabla 7*Continuación*

37	MOMENT - Sistema de Aprendizaje de Máquina para Mantenimiento (...)	Brasil	Industria automotriz	Filtro de aire del motor de un Suzuki Grand Vitara 2014 AWD	Datos de presión, flujo de aire, temperatura de admisión, carga del motor, entre otros.	Necesidad de mantenimiento del filtro de aire	SVM, RF y K-NN	Python	(Lima, 2021)
38	Desarrollo de un modelo de aprendizaje automático para predecir el estado de (...)	Brasil	Industria de construcción	Transmisiones Powershift de maquinaria de construcción.	Datos operacionales almacenados en la memoria EEPROM del vehículo	Fallas en el sistema de transmisión, desgastes y sobrecargas en componentes clave.	SVM, RF y K-NN	Python	(C. A. Almeida, 2024)
39	Propuesta de aplicación de métodos de Machine Learning en mantenimiento predictivo.	Brasil	Industria energética	Sistemas de ventilación, circuito de agua del motor y circuito intercooler.	Registros de alarmas, datos de potencia, temperatura y presión de los equipos.	Sobrecalentamiento, variaciones de presión y otros problemas operativos.	ANN	Python	(Alonso, 2023)
40	Mantenimiento predictivo de máquinas rotativas para detección de fallas mecánicas (...)	Brasil	Industria manufacturera	Maquinaria rotativa	Datos de sensores de vibración.	Fallas mecánicas, desalineamiento, desbalanceo y folga rotativa	RF	Python	(Rocha, 2022)

Tabla 7*Continuación*

41	Enfoque predictivo de fallas basado en registros de eventos en la industria automotriz	Brasil	Industria automotriz	Brazo robótico con pinzas de soldadura.	Logs de eventos y registros de órdenes de trabajo de emergencia.	Falla en las pinzas de soldadura de los brazos robóticos	ANN y MLP	No especificado.	(Lemos & Zelaquett de Souza, 2022)
42	Análisis de datos de inspección en motores de inducción para clasificación (...)	Brasil	Industria siderurgia	Motores de inducción	Datos de resistencia, impedancia, inductancia, ángulo de fase, relación corriente/frecuencia y contaminación.	Fallas en las barras del rotor, desalineaciones, cortocircuitos y desequilibrios eléctricos en las fases del motor.	K-Means y DT	Matlab	(Santos Dutra, 2023)
43	Mantenimiento Predictivo de Motores Diesel Marítimos (...)	Brasil	Industria naval	Motores diésel	Calidad del aceite lubricante, viscosidad, niveles de partículas de carbón y presencia de agua en PPM	Fallas en pistones, bielas, anillos sobrecalentamientos, bloqueo completo del motor y deterioro de los rodamientos.	RF y SVM	No especificado.	(Saraiva, 2023)
44	Investigando una Solución para la Predicción de Fallas en Turbinas Hidráulicas (...)	Brasil	Industria energética	Turbinas hidráulicas	Datos de sensores de operación y alarmas generados por el sistema de la planta	Fallas en turbinas hidráulicas para evitar interrupciones no planificadas en la generación de energía.	AE	Python	(de Farias & Coelho, 2022)

Tabla 7*Continuación*

45	Análisis y predicción de fallas en aerogeneradores utilizando Deep Learning	Brasil	Industria energética	Aerogeneradores en parques eólicos	Datos de vibración y potencia de sensores en los aerogeneradores.	Fallas en la caja de engranajes y los rodamientos	AE, SVM y IF	Python	(Nascimento, 2023)
46	Detección de anomalías mediante Machine Learning: Estudio de caso (...)	Brasil	Industria de transporte y logística	Sistema neumático en camiones Scania	Datos de sensores del sistema neumático, presión y funcionamiento.	Fallas en el sistema neumático de camiones y en el sistema de frenado.	RF, NB y LogR	Python	(Cabreira, 2022)
47	Aplicación de Machine Learning para la previsión de la vida de (...)	Brasil	Industria manufacturera	Herramientas de mecanizado en fresadoras verticales.	Historial de desgaste, velocidad de corte, profundidad de corte, avance, entre otros.	Vida útil restante de las herramientas de mecanizado para optimizar el cambio y reducir el desgaste.	LogR	Python	(Resner & Pinotti, 2023)
48	Mantenimiento predictivo del acoplamiento flexible (...)	Brasil	Industria energética	Acoplamiento flexible de turbinas eólicas	Datos de vibración de los acoplamientos flexibles, obtenidos mediante sensores.	Fallas en el acoplamiento flexible de las turbinas eólicas.	SVM	Matlab	(Fantin et al., 2020)

Tabla 7*Continuación*

49	Modelo de mantenimiento predictivo y proactivo para el funcionamiento (...)	Ecuador	Industria siderúrgica	Hornos, grúas y otros equipos críticos de la planta	Historial de fallas, tiempos de inactividad, y variables de rendimiento recolectadas.	Fallas en maquinarias para reducir costos y optimizar el mantenimiento	DNN, DT, NB, RF y K-NN	JavaScript	(Cifuentes Simbaña, 2023)
50	Estudio de la aplicación de técnicas de análisis de datos y Machine Learning en una industria de arroz (...)	Brasil	Industria de alimentos	Caldera mixta de biomasa	Datos de presión de vapor, el tiraje, flujo de vapor y temperatura.	Predicción de fallas y tiempo de vida útil remanente (VUR) de la caldera	XGBoost, RF y LR	Python	(Leites, 2023)
51	Predicción de Fallos en Reconnectores Automáticos Usando (...)	Brasil	Industria energética	Reconnectores Automáticos	Historial de temperatura, alarmas específicas extraídas de un datalake, SCADA, GIS y SAP.	Fallos en los reconnectores automáticos, asociados a alarmas de funcionamiento	NB, DNN, DT, GBT y RF	No especificado.	(Righetto et al., 2021)
52	Modelado Predictivo Aplicado al Comportamiento de Componentes (...)	Colombia	Industria de servicios	Servidores, especialmente las unidades de disco	Servidores, especialmente las unidades de disco	Datos históricos de rendimiento de CPU, uso de memoria y uso de disco de servidores	IF, LR y LogR	Python	(López Restrepo & Acevedo Vanegas, 2022)

Tabla 7*Continuación*

53	Diseño de un modelo para el control del consumo de filtros y lubricantes del equipo (...)	Ecuador	Industria de construcción	Equipo caminero y maquinaria pesada	Datos de kilometraje y horómetro de los vehículos	Consumo excesivo y el desgaste prematuro de filtros y lubricantes	NAR	Python, R y Matlab	(Ortiz Reyes, 2023)
54	Sistema de Mantenimiento Predictivo de Fallas en Válvulas en un Proceso (...)	Brasil	Industria manufacturera	Válvulas de control tipo borboleta con actuador neumático	Datos de fallas, número de activaciones y tiempos de apertura.	Fallas en válvulas para evitar interrupciones en la línea de producción	K-Means y LR	Python	(Pinto, 2021)
55	Técnicas de Aprendizaje de Máquina Aplicadas a la Predicción de Fugas (...)	Brasil	Industria de servicios	Ramales de redes de distribución de agua	Historial de fugas, condiciones operativas, y variables ambientales y físicas.	Fugas en la red de distribución de agua para mejorar la eficiencia y reducir pérdidas.	LogR, SVM, K-NN, DT, NB, RF, GB y XGBoost.	Python	(Gouveia, 2022)
56	Utilización de Aprendizaje de Máquina en Sistemas de Digestores (...)	Brasil	Industria de reciclaje y gestión de residuos	Digestores comerciales de residuos orgánicos	Datos de peso de material orgánico procesado en series temporales.	Fallos y obstrucciones en los digestores	K-Means	Python	(F. M. J. de Almeida, 2023)

Tabla 7*Continuación*

57	Un modelo fundamentado en algoritmos de aprendizaje de máquina dedicado (...)	Brasil	Industria de bienes y consumo	Línea de montaje de refrigeradores.	Datos de fallas en la línea de montaje y órdenes de servicio postventa.	Cantidad de órdenes de servicio (OS) y fallas identificadas en la línea de montaje.	RF y LR	Python	(Oliveira et al., 2023)
58	Detección de Fallas en Activos Críticos Utilizando Redes (...)	Brasil	Industria de papel y celulosa	Bomba de cavacos del proceso de cocción	Datos de vibración, temperatura, presión y relación licor/cavaco de la bomba.	Fallos en la bomba y desgaste de componentes.	LSTM y RNN	Python	(Mine, 2024)
59	Desarrollo de un algoritmo mediante análisis de aprendizaje automático para la detección de fallos (...)	Ecuador	Industria automotriz	Vehículos M1 con motores de encendido provocado	Datos de presión, RPM, temperatura del motor, del aire, velocidad, entre otros.	Fallas que afecten la eficiencia del motor, consumo de combustible y emisiones.	SVM y K-Means	Matlab	(Cabrera Palacios & Chiluita Luna, 2018)
60	Detección de anomalías en series de tiempo del funcionamiento de bombas (...)	Colombia	Industria Oil & Gas	Bombas electro sumergibles (BES) de producción	datos de sensores, como presión, temperatura, y voltaje	Fallas eléctricas y anomalías de funcionamiento.	CNN y LSTM	No especificado.	(Calderón Gasca & Franco Niño, 2023)