

Early detection of critical process failures in industrial systems using machine learning for predictive maintenance

Juan Pedro Visurraga¹; Gian Cano¹; Jose Cornejo¹; Silvia Rita Rodríguez Alvarez¹

¹Universidad Tecnológica del Perú, Perú, U21220979@utp.edu.pe, U22226045@utp.edu.pe, C21944@utp.edu.pe, C19398@utp.edu.pe

Abstract— The progress of Industry 4.0 has led to significant transformations in the perception and functioning of industrial environments, placing particular emphasis on maintenance tactics. In this context, predictive maintenance (PdM), supported by machine learning (ML) methods, has established itself as an essential tool for anticipating operational errors, minimizing unexpected interruptions, and enhancing process efficiency. This analysis offers a systematic literature review with the aim of examining the application of machine learning algorithms to predict critical errors in industrial processes. To achieve this, the PRISMA methodology was used in combination with the PICOC approach. The first query in the Scopus database yielded 328 results. Twenty-seven articles were obtained that met requirements such as the use of algorithmic models, industrial environments, implementation of PdM and availability of evaluation tools. The main findings showed that the deep learning models with the best predictive performance included LSTM networks, hybrid CNN architectures and small IoT solutions. The most frequent failures were found to be mechanical, electrical and environmental, especially in industries such as manufacturing, energy and transportation. This report assesses the current state of the art and makes recommendations on possible directions for the development of intelligent industrial maintenance.

Keywords-- machine learning, predictive maintenance, Industry 4.0, anomaly detection, process optimization.

Detección temprana de fallos críticos en procesos industriales utilizando aprendizaje automático para el mantenimiento predictivo

Juan Pedro Visurraga¹; Gian Cano¹; Jose Cornejo¹; Silvia Rita Rodríguez Alvarez¹

¹Universidad Tecnológica del Perú, Perú, U21220979@utp.edu.pe, U22226045@utp.edu.pe, C21944@utp.edu.pe, C19398@utp.edu.pe

Resumen— *El progreso de la Industria 4.0 ha provocado transformaciones significativas en la percepción y funcionamiento de los ambientes industriales, poniendo un énfasis particular en las tácticas de mantenimiento. En este contexto, el mantenimiento predictivo (PdM), respaldado por métodos de aprendizaje automático (ML), se ha establecido como un instrumento esencial para anticipar errores operativos, minimizar interrupciones inesperadas y potenciar la eficacia de los procesos. Este análisis ofrece una revisión sistemática de la literatura con el propósito de examinar la aplicación de los algoritmos de Machine Learning para prever errores críticos en procesos industriales. Para lograrlo, se empleó la metodología PRISMA en combinación con el enfoque PICOC. La primera consulta en la base de datos Scopus arrojó 328 resultados. Se obtuvieron 27 artículos que cumplían requisitos como el uso de modelos algorítmicos, los entornos industriales, la implementación de PdM y disponibilidad de herramientas de evaluación. Las principales conclusiones mostraron que los modelos de aprendizaje profundo con mejor rendimiento predictivo incluían redes LSTM, arquitecturas CNN híbridas y pequeñas soluciones IoT. Se descubrió que los fallos más frecuentes eran mecánicos, eléctricos y medioambientales, especialmente en industrias como la fabricación, la energía y el transporte. Este informe evalúa el estado actual de la técnica y formula recomendaciones sobre posibles orientaciones para el desarrollo del mantenimiento industrial inteligente.*

Palabras claves— *aprendizaje automático, mantenimiento predictivo, Industria 4.0, detección de anomalías, optimización de procesos*

I. INTRODUCCIÓN

La expansión de la Industria 4.0 ha provocado transformaciones significativas en el contexto de la manufactura. Esta evolución se fundamenta en la incorporación de tecnologías como la conexión de las máquinas mediante el Internet de las Cosas, los sistemas físicos fundamentados en computadoras, el procesamiento en tiempo real, la computación en la nube y la computación en el borde [1], [2]. Estas tecnologías posibilitan que las fábricas inteligentes funcionen de manera autónoma y adaptable, lo que promueve una administración de activos más completa y optimización de procesos más intrincados. Las últimas pruebas indican que la puesta en marcha de estos sistemas ha posibilitado disminuir los períodos de inactividad hasta un 30% y optimizar los tiempos de respuesta para acciones correctivas a menos de 0,5 segundos en operaciones vitales. En este nuevo entorno de fabricación, el mantenimiento predictivo se ha convertido en una de las herramientas más importantes para mejorar los equipos de fabricación. A

diferencia de los enfoques tradicionales para el diagnóstico o la prevención de enfermedades, el PdM se basa en el aprendizaje automático para alertar a las personas con datos en tiempo real antes de que se produzcan. Un buen ejemplo es el proyecto DETECTA, que combina tecnologías de la 4^o revolución industrial con inteligencia artificial y ciberseguridad para mejorar la eficiencia y la eficacia del proceso de PdM [3]. El aprendizaje automático se utiliza para analizar datos como errores, anomalías y discrepancias [4]. Algoritmos como Random Forest, Support Vector Machines (SVM), XGBoost y Deep Forest han demostrado desempeños superiores al 90 % al aplicarse a datos reales [5]. En particular, la precisión de estos modelos es muy alta, lo que resulta en una puntuación F1 de hasta el 92 % en contextos de dispositivos Internet de las Cosas (IoT), estos modelos son muy precisos y muestran una gran sensibilidad y especificidad en la detección de circunstancias críticas [2]. Lo que también permite anticipar escenarios de fallo con tiempo suficiente para realizar los ajustes necesarios. Por otro lado, las arquitecturas multiagente permiten distribuir la inteligencia entre nodos autónomos los cuales cooperan en la toma de decisiones. Esta capacidad ha demostrado reducir el impacto de fallos críticos hasta en un 40 %, gracias a la redistribución dinámica de tareas ante interrupciones [1]. También se ha demostrado la captación de energía en diversos sistemas de almacenamiento de energía, con una reducción del 10 % al 15 % en comparación con los modelos anteriores [6].

De manera similar, las técnicas de aprendizaje automático se han utilizado en procesos automatizados para reducir la cantidad de piezas y componentes, lo que ha resultado en una reducción de más del 85 % en los niveles de desperdicio y defectos, contribuyendo así a una mejora significativa en la calidad del producto final y en la sostenibilidad de las operaciones industriales [7]. Por otro lado, gracias a entornos ontológicos como PROV-O, ahora es posible evaluar y analizar todo el ciclo de vida de los datos generados en el sistema. En contextos digitales complejos, esto ha permitido una toma de decisiones más precisa, contextualizada y eficaz, así como la trazabilidad de la información [8]. Este análisis sugiere el avance de la inteligencia artificial para potenciar el desempeño de los negocios. Tecnologías como los gemelos digitales y el aprendizaje automático múltiple han sido empleadas para incrementar y perfeccionar la exactitud en la administración de la cadena de suministro [1], [2]. En esta investigación se analizan procedimientos, procesos y teorías utilizadas en el aprendizaje automático para 5 th LACCEI

International Multiconference on Entrepreneurship, Innovation and Regional Development - LEIRD 2025 "Entrepreneurship with Purpose: Social and Technological Innovation in the Age of AI" - Virtual Edition, December 1 – 3, 2025 3 tratar problemas en entornos de producción. Además, se examinan los retos técnicos más relevantes, las posibilidades emergentes en la utilización de datos e inteligencia artificial, y se sugieren posibles rumbos futuros que guíen el avance de soluciones más independientes, escalables y eficaces en ambientes de producción propulsados por la Industria 4.0.

II. METODOLOGÍA

En esta revisión sistemática literaria se recopiló información relacionada con el tema de investigación "Detección temprana de fallos críticos en procesos industriales utilizando aprendizaje automático para el mantenimiento predictivo". Para la extracción de datos, se utilizó la base de datos Scopus así obteniendo los documentos necesarios. La búsqueda se enfocó en torno a la siguiente pregunta PICO: ¿Cómo se aplica el aprendizaje automático en la detección temprana de fallos críticos en procesos industriales en el contexto del mantenimiento predictivo? Además, se llevó a cabo un análisis detallado para identificar cada uno de los componentes asociados con sus respectivas siglas (PICOC)

TABLA I
COMPONENTE DE PREGUNTA PICOC

Factor	Componente	Descripción
P	Problema / Población	<i>Fallos en sistemas industriales (equipos, maquinaria, procesos de producción).</i>
I	Intervención	<i>Técnicas de ML/DL/AI para mantenimiento predictivo (CBM, prognósticos, etc.).</i>
C	Comparación	<i>Estrategias tradicionales (correctivo, preventivo, programado).</i>
O	Resultados	<i>Detección temprana de fallos, optimización de costos, eficiencia operativa.</i>
C	Contexto	<i>Sectores industriales (manufactura, energía, automatización, etc.).</i>

Se llevó a cabo la desagregación de la pregunta de revisión PICOC en interrogantes específicas, cada una vinculada a los componentes que conforman dicha estructura.

TABLA II
PREGUNTAS POR COMPONENTE DE LA PREGUNTA

Pregunta PICOC:		
¿Cómo se aplica el aprendizaje automático para la detección temprana de fallos críticos en procesos industriales en el contexto del mantenimiento predictivo?		
P	RQ1 Problema / Población	¿Qué tipos de fallos (anomalías, desgaste, etc.) son más frecuentes en maquinaria industrial?
I	RQ2 Intervención	¿Qué algoritmos de ML/DL (redes neuronales, SVM, etc.) son más efectivos en PdM para diagnóstico/prognóstico?
C	RQ3 Comparación	¿Cómo mejora el PdM basado en ML la eficiencia frente a mantenimiento correctivo/preventivo?
O	RQ4 Resultados	¿Qué métricas (precisión, tiempo de detección, costos) evalúan el éxito de estas soluciones?

C	RQ5 Contexto	¿En qué sectores industriales hay mayor adopción de PdM con ML y qué desafíos persisten?
---	-----------------	--

De igual manera se utilizaron las palabras claves en inglés, las cuales muestran el siguiente resultado.

TABLA III
PALABRAS CLAVES DE CADA COMPONENTE

Factor	Componente	Palabras Clave
P	Problema / Población	Critical process failures, industrial systems, process failures, equipment failures.
I	Intervención	Machine Learning, ML, predictive maintenance, AI in industry.
C	Comparación	Traditional maintenance, corrective maintenance, preventive maintenance.
O	Resultados	Early detection, failure prediction, operational efficiency.
C	Contexto	Manufacturing, energy, transport, mining, automation.

Utilizando la base de datos Scopus, se construyó una ecuación de búsqueda basada en las palabras clave definidas para cada componente del planteamiento PICOC. Empleando el operador booleano "OR", se logró relacionar los términos en inglés, lo que permitió realizar una búsqueda más precisa y exhaustiva, como se muestra a continuación.

TABLA IV
SINTAXIS DE LA ECUACIÓN DE BÚSQUEDA

P	Problema / Población	"industrial" OR "industry" OR "manufacturing" OR "industrial systems" OR "equipment" OR "production systems" OR "machinery" OR "industrial processes"
I	Intervención	"Predictive maintenance" OR "condition-based maintenance" OR "CBM" OR "prognostics" OR "smart maintenance" OR "intelligent maintenance"
C	Comparación	"Corrective maintenance" OR "preventive maintenance" OR "traditional maintenance" OR "scheduled maintenance" OR "maintenance strategies" OR "reactive maintenance" OR "maintenance planning"
O	Resultados	"Fault detection" OR "failure detection" OR "anomaly detection" OR "diagnostics" OR "early detection" OR "fault diagnosis" OR "prognostics and health management"
C	Contexto	"Machine learning" OR "deep learning" OR "artificial intelligence" OR "AI" OR "neural networks" OR "supervised learning" OR "unsupervised learning"

Además, a partir de los componentes del PICOC, se construyó una ecuación de búsqueda en la base de datos Scopus que empleó el operador booleano OR para combinar sinónimos y términos relacionados, permitiendo así una búsqueda exhaustiva y precisa. Tales como mantenimiento predictivo, aprendizaje automatizado, sistemas industriales, detección de caídas y mantenimiento tradicional. La ecuación utiliza operadores AND para filtrar los estudios relevantes, como se muestra en la Tabla IV. Este método permitió recopilar publicaciones sobre el uso del aprendizaje automático en la detección anticipada de errores en el mantenimiento predictivo. Entre los sectores cubiertos por la

búsqueda se encontraban la fabricación, la energía y la automatización.

(TITLE-ABS-KEY ("machine learning" OR "deep learning" OR "artificial intelligence" OR "AI" OR "neural networks" OR "supervised learning" OR "unsupervised" (TITLE-ABS-KEY ("industrial" OR "industry" OR "manufacturing" OR "industrial systems" OR "equipment" OR "production systems" OR "machinery" OR "industrial processes")) AND (TITLE-ABS-KEY ("fault detection" OR "failure detection" OR "anomaly detection" OR "diagnostics" OR "early detection" OR "fault diagnosis" OR "prognostics and health management")) AND (TITLE-ABS-KEY ("corrective maintenance" OR "preventive maintenance" OR "traditional maintenance" OR "scheduled maintenance" OR "maintenance strategies" OR "reactive maintenance" OR "maintenance planning")))

TABLA V
LOS CRITERIOS DE INCLUSIÓN Y EXCLUSIÓN GENERALES

Código	Criterio de Inclusión	Criterio de Exclusión
CI 1	Documentos publicados entre 2019 y 2025.	Documentos publicados fuera del rango 2019-2025.
CI 2	Documentos que abordan el uso de ML/DL/AI en mantenimiento predictivo.	Documentos que no están relacionados con mantenimiento predictivo.
CI 3	Estudios que se centran en fallos en sistemas industriales.	Estudios que no mencionan fallos en sistemas industriales.
CI 4	Artículos que comparan técnicas de ML con estrategias tradicionales.	Artículos que no realizan comparaciones con estrategias tradicionales.
CI 5	Investigaciones que reportan métricas de éxito en la detección de fallos.	Investigaciones sin métricas claras de éxito.

TABLA VI
LOS CRITERIOS DE INCLUSIÓN Y EXCLUSIÓN ESPECÍFICOS

Código	Criterio de Inclusión	Criterio de Exclusión
CE 1	Documentos que detallan tipos específicos de fallos en maquinaria industrial.	Documentos que no especifican tipos de fallos.
CE 2	Estudios que evalúan algoritmos específicos de ML/DL para PdM	Estudios que no evalúan algoritmos específicos
CE 3	Artículos que discuten desafíos en la adopción de PdM en sectores industriales	Artículos que no mencionan desafíos en la adopción de PdM

El esquema PRISMA que se presenta a continuación muestra de forma organizada el procedimiento de identificación, evaluación, selección e inclusión de investigaciones en la presente Revisión Sistemática Literaria (RSL), siguiendo las directrices metodológicas establecidas por la declaración PRISMA. Durante la etapa inicial de identificación, se recolectaron 328 registros mediante búsquedas organizadas en bases de datos científicas reconocidas. En esta fase, no se identificaron registros duplicados, por lo que se llevó a cabo el proceso de eliminación total de todos los documentos adquiridos. Luego, se realizó una evaluación inicial a través del estudio de los títulos, resúmenes y palabras clave de cada artículo, lo que posibilitó la exclusión de 257 registros por no satisfacer los

criterios de inclusión establecidos anteriormente (como no enfocarse en el mantenimiento predictivo, no emplear técnicas de aprendizaje automático o no ser aplicables en contextos industriales). Por lo tanto, se escogieron 71 publicaciones que podrían ser relevantes para una evaluación más rigurosa. Posteriormente, se escogieron e incorporaron 27 investigaciones primarias que satisfacen todos los requerimientos metodológicos y temáticos para ser incluidas en el conjunto de análisis de esta revisión sistemática

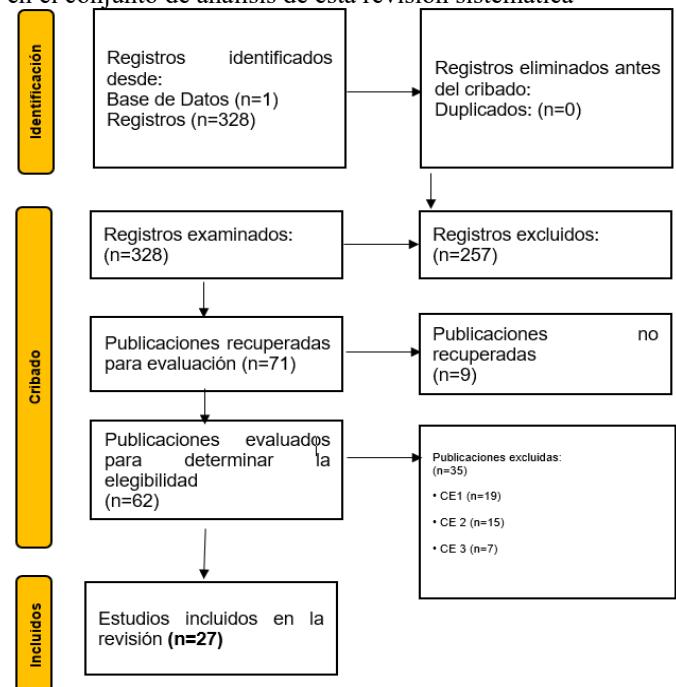


Fig. 1 Flujograma PRISMA en tres niveles

TABLA VII
ARTÍCULOS SELECCIONADOS

Autor	Título	Año
[9]	Federated Learning and Neural Circuit Policies: A Novel Framework for Anomaly Detection in Machinery	2025
[10]	Long Short-Term Memory-Based Computerized Numerical Control Machining Center Failure Prediction Model	2025
[11]	AI-Driven Predictive Maintenance for Smart Manufacturing Using Digital Twin Technology	2025
[12]	Vibration-Based Anomaly Detection in Industrial Machines: A Comparison of Autoencoders and Latent Spaces	2025
[13]	Fault Diagnosis in a Four-Arm Delta Robot Based on Wavelet Scattering Networks and AI Techniques	2024
[14]	AI-Driven Predictive Maintenance in Modern Maritime Transport—Enhancing Operational Efficiency and Reliability	2024
[15]	A Robust Deep Learning System for Motor Bearing Fault Detection: Leveraging Multiple Learning Strategies and a Novel Double Loss Function	2023
[16]	Predictive maintenance of electromechanical systems based on enhanced generative adversarial neural network with convolutional neural network	2023
[17]	Predictive Maintenance in Healthcare System: A Survey	2023
[18]	Evaluation of the Improved Extreme Learning Machine for Machine Failure Multiclass Classification	2023
[19]	Data-Driven Voltage Prognostic for Solid Oxide Fuel Cell System Based on Deep Learning	2022

[20]	Predictive maintenance in mining industry: grinding mill case study	2022
[21]	An Optimized and Safety-aware Maintenance Framework: A Case Study on Aircraft Engine	2022
[22]	Data-Driven Fault Detection and Diagnosis: Challenges and Opportunities in Real-World Scenarios	2022
[23]	On-Device IoT-Based Predictive Maintenance Analytics Model: Comparing TinyLSTM and TinyModel	2022
[24]	Condition Monitoring of Ball Bearings Based on Machine Learning with Synthetically Generated Data	2022
[25]	A Digital Twin predictive maintenance framework of air handling units based on automatic fault detection and diagnostics	2022
[26]	Dictionary learning approach to monitoring of wind turbine drivetrain bearings	2021
[27]	A genetic algorithm optimized RNN-LSTM model for remaining useful life prediction of turbofan engine	2021
[28]	Acoustic anomaly detection of mechanical failures in noisy real-life factory environments	2021
[29]	Smart prognostics and health management (SPHM) in smart manufacturing	2021
[30]	Auto-nahl: A neural network approach for condition-based maintenance of complex industrial systems	2021
[31]	Data- Driven Condition Monitoring of Mining Mobile Machinery Using Wireless Accelerometer Sensor Modules	2021
[32]	Distributed diagnostics, prognostics and maintenance planning: Realizing industry 4.0	2020
[33]	Machine learning approach using MLP and SVM algorithms for the fault prediction of a centrifugal pump in the oil and gas industry	2020
[34]	A double-channel hybrid deep neural network for remaining useful life prediction	2020
[35]	Prognosis of a wind turbine gearbox bearing using supervised machine learning	2019

III.RESULTADOS

A. RQ1: ¿Qué tipos de fallos (anomalías, desgaste, etc.) son más frecuentes en maquinaria industrial?

Los estudios revisados abordan una variedad de fallos que comprometen la operación de equipos industriales, destacándose aquellos de naturaleza mecánica, eléctrica y estructural. Se identifican patrones recurrentes en el desgaste de componentes, fallos en rodamientos y cortocircuitos, los cuales son detectados mediante el análisis de señales físicas y la implementación de algoritmos de aprendizaje automático entrenados con datos históricos de operación.

TABLA VIII

CLASIFICACIÓN DE FALLOS ABORDADOS EN LOS ESTUDIOS ANALIZADOS

Pregunta: (P)	¿Qué tipos de fallos (anomalías, desgaste, etc.) son más frecuentes en maquinaria industrial?
Clasificación	Descripción
Fallo humano o de mantenimiento	Incluye errores operativos, omisión de mantenimiento o malas prácticas. Estos fallos son difíciles de detectar automáticamente, pero pueden modelarse mediante integración de variables contextuales y operativas en sistemas inteligentes de mantenimiento [17].
Fugas y presión	Se refiere a fugas que crean riesgos operativos en circuitos de fluidos o aire, como válvulas o bombas. Su detección a tiempo es posible gracias a los sensores de temperatura, presión y caudal del monitor. Son comunes en industrias exigentes como la minería y el petróleo.[19], [21], [25], [33].
Fallo térmico o	Reconocer los errores provocados por las altas temperaturas, la humedad elevada o los contaminantes ambientales. Los modelos predictivos y los sensores

ambiental	medioambientales proporcionan una detección temprana, reduciendo la posibilidad de daños o interrupciones en las operaciones.[14], [19], [25], [26], [27].
Fallo eléctrico/electrónico	Comprende fallos en componentes eléctricos, motores, cortocircuitos y errores en sistemas de control [13], [16], [18]. Las señales como voltaje, corriente y armónicos son monitoreadas para alimentar modelos predictivos basados en aprendizaje automático [21], [24], [29], [30], [32], [34].
Fallo mecánico	Incluye fenómenos como el desgaste de herramienta, vibraciones anormales, fallos en rodamientos, desequilibrio, desalineación y defectos estructurales. Estos fallos son detectados comúnmente mediante análisis de vibraciones, espectros RMS, y sensores dinámicos [10], [15], [19], [23]. En particular, los rodamientos representan entre el 40 % y 70 % de los fallos en sistemas rotativos [9], [12], [24], [27], [31]

Los fallos comunes en maquinaria industrial impactan negativamente la confiabilidad operativa, los costos de mantenimiento y la productividad [9], [17]. Estos se clasifican en cinco categorías principales: mecánicos, eléctricos/electrónicos, térmicos o ambientales, fallos por fugas/presión y errores humanos [19], [21]. Varias investigaciones identifican al desgaste y las vibraciones como los fallos mecánicos más frecuentes [23], [27]. Su detección temprana mediante sensores físicos y modelos predictivos resulta clave para mitigar interrupciones y riesgos operativos.[30], [32], [33]. La Fig. 2 muestra de forma gráfica la distribución relativa de estos tipos de fallos, destacando el predominio de los fallos mecánicos en los estudios revisados.

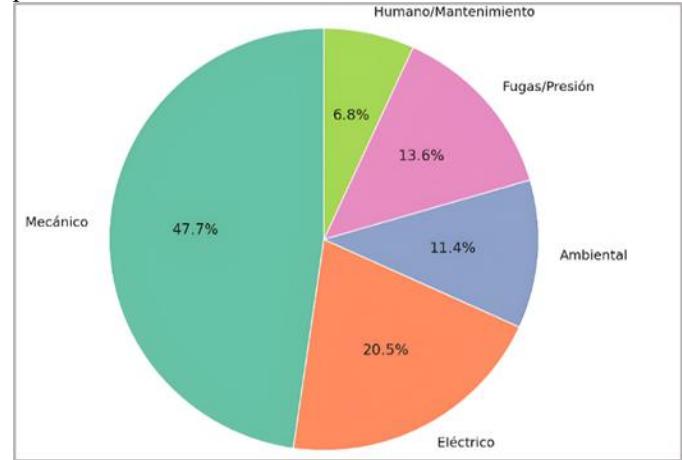


Figura 2. Clasificación de los fallos más frecuentes en maquinaria industrial

B. RQ2: ¿Qué algoritmos de ML/DL (redes neuronales, SVM, etc.) son más efectivos en PdM para diagnóstico/prognóstico?

Con base en los hallazgos obtenidos, se observa que los modelos de aprendizaje profundo, y en especial las redes neuronales LSTM, son los más frecuentemente aplicados en procesos de diagnóstico y pronóstico en mantenimiento predictivo. Esto se debe a su eficacia para capturar relaciones temporales y extraer patrones complejos en datos operativos [15], [16], [19], [21], [27], [30]. Además, se detectan modelos mixtos (por ejemplo, LSTM con estadística) y estrategias livianas para IoT como TinyModel o TinyLSTM, lo que evidencia una inclinación hacia soluciones eficaces y

distribuidas [10], [23], [28]. La Figura 3 sintetiza la agrupación de subtipos de algoritmos según su clasificación general.

TABLA IX
COMPARACIÓN DE ALGORITMOS DE ML/DL PARA PDM

Pregunta: (P)	¿Qué algoritmos de ML/DL (redes neuronales, SVM, etc.) son más efectivos en PdM para diagnóstico/prognóstico?
Clasificación	Descripción
Aprendizaje Federado	El método de aprendizaje federado es crucial en contextos donde la privacidad de la información es de vital importancia. Facilita la creación de modelos de mantenimiento predictivo sin requerir la transferencia de datos delicados, lo que lo convierte en particularmente beneficioso en sistemas distribuidos y colaborativos [9], [23].
Aprendizaje no supervisado	Los métodos no supervisados como K-means o PCA identifican agrupamientos irregulares en los datos que son recolectados por sensores. Esta capacidad de detectar patrones sin etiquetas los convierte en aliados clave para reconocer fallos emergentes o poco frecuentes [12], [28].
Modelo Híbridos	Los modelos híbridos mejoran el rendimiento diagnóstico y pronóstico en escenarios con muchas fuentes de datos integrando algoritmos como las CNN con simulaciones físicas Digital Twin, redes neuronales LSTM o técnicas estadísticas. Estos métodos funcionan especialmente bien en sistemas con dinámicas no lineales o alta complejidad estructural [14], [16], [19], [25], [27].
Modelos Ligeros IoT	Los sensores IoT y otros dispositivos de baja potencia y capacidad limitada están pensados para ejecutar algoritmos ligeros como TinyModel y TinyLSTM. En entornos industriales distribuidos, estas tecnologías reducen la latencia y la dependencia de la nube al permitir la ejecución local de inferencias en tiempo real [10], [23], [28].
Redes neuronales profundas	El procesamiento de datos secuenciales y multivariantes, como las vibraciones, la corriente o la temperatura, es un terreno abonado para las redes neuronales profundas, especialmente los diseños LSTM y CNN. Son instrumentos esenciales para el diagnóstico precoz y la predicción de fallos en maquinaria crucial por su capacidad para registrar patrones complicados y conexiones temporales [15], [16], [19], [21], [27], [30].
SVM / Árboles de decisión	Muchas personas utilizan modelos supervisados como SVM, Random Forest y árboles de decisión para la clasificación de fallos. Estos algoritmos proporcionan una fuerte combinación entre velocidad, precisión y explicabilidad, lo que los hace perfectos para aplicaciones tales como brazos robóticos, motores eléctricos y bombas que necesitan conclusiones rápidas y claras [13], [18], [24], [27], [30], [33].

La Tabla 2 enumera los enfoques algorítmicos más populares en el mantenimiento predictivo e ilustra la relación entre la selección del modelo y las condiciones de funcionamiento, la disponibilidad de datos y la infraestructura informática. Para dispositivos con almacenamiento limitado, son adecuados modelos ligeros como TinyModel, pero en situaciones con muchos datos secuenciales, se aconsejan técnicas basadas en redes neuronales profundas (como CNN y LSTM)[10], [28]. Componente crucial de las aplicaciones industriales contemporáneas, la protección de la privacidad en los sistemas en red es posible gracias a técnicas como el aprendizaje federado[9], [23].Lo cual permite el entrenamiento colaborativo de modelos sin la transferencia de datos sensibles, lo que resulta especialmente valioso en industrias reguladas. Esta tecnología contribuye a garantizar el cumplimiento normativo, reduce riesgos asociados a la ciberseguridad y mejora la confianza en los entornos

distribuidos. Esta diversidad metodológica responde a la demanda de eficacia y adaptabilidad en situaciones industriales dinámicas. Por tanto, la elección del algoritmo debe responder a las necesidades operativas priorizando la eficiencia y la seguridad

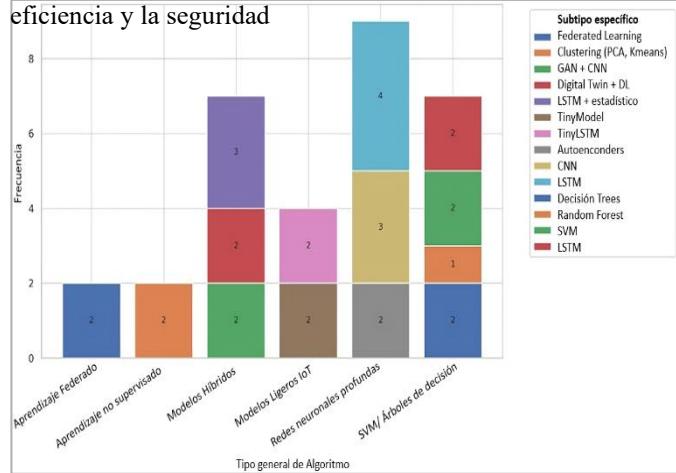


Fig. 3 Agrupación de algoritmos de aprendizaje utilizados en PdM según su categoría general

C. RQ3: ¿Cómo mejora el PdM basado en ML la eficiencia frente a mantenimiento correctivo/preventivo?

Los estudios analizados muestran que el mantenimiento predictivo basado en el aprendizaje automático es comparable a estrategias tradicionales como el mantenimiento preventivo, planificado o correctivo. Los resultados muestran que el uso del aprendizaje automático se traduce en mejoras significativas de la eficiencia operativa, la productividad y la seguridad gracias a predicciones de fallos más precisas, la optimización de los costes operativos y la reducción de los tiempos de inactividad no planificados.

TABLA X
COMPARACIÓN DE EFICIENCIA ENTRE PDM BASADO EN ML Y ESTRATEGIAS TRADICIONALES

Pregunta: (P)	¿Cómo mejora el PdM basado en ML la eficiencia frente a mantenimiento correctivo/preventivo?
Clasificación	Descripción
Reducción de tiempos de inactividad	La detección temprana mediante modelos de aprendizaje automático reduce considerablemente el tiempo de inactividad no planificado de las máquinas críticas [9], [10], [12], [14]. En algunos casos, se pueden evitar hasta el 70 % de los fallos [11], [15], [17], [19], [20], [25].
Disminución de costos operativos	Los costes de mantenimiento pueden reducirse entre un 15 y un 40% mediante una planificación eficaz de las acciones y evitando inspecciones innecesarias [11], [16], [18], [20], [21], [25].
Mayor disponibilidad de equipos	Los sistemas de PdM pueden alcanzar un tiempo de actividad superior al 95% con la resolución proactiva de problemas y la programación en tiempo real [9], [14], [17], [21], [26].
Planificación dinámica en tiempo real	Tecnologías como las redes y el Internet de las Cosas (IoT) proporcionan la versatilidad requerida para ajustar los programas de mantenimiento a las circunstancias operativas en tiempo real [11], [19], [23], [25], [27], [30], [32].
Aprovechamiento del RUL	Modelos tales como RNN-LSTM, BiLSTM y CNN poseen la habilidad para calcular con gran precisión la vida útil residual y promover el uso de componentes seguros [10], [13], [14], [27], [34], [35].

Menor dependencia de expertos	La implementación de métodos no supervisados (autocoder, GAN) disminuye la exigencia de introducir datos de forma manual y facilita la implementación de PdM en la realidad [12], [16], [22], [28].
Mantenimiento personalizado	Los algoritmos sofisticados posibilitan ajustar las tácticas de mantenimiento al perfil operativo de cada instalación, considerando la importancia y el cambio de las condiciones [13], [21], [29], [30], [31], [33].

Análisis comparativo de los algoritmos de mantenimiento predictivo basados en el aprendizaje automático ML y los métodos tradicionales de reparación/prevención. Los artículos analizados identificaron las principales ventajas de rendimiento, que se agruparon en siete dimensiones recurrentes. Tras una revisión sistemática, el mantenimiento preventivo basado en el aprendizaje automático es comparable a estrategias tradicionales como el mantenimiento preventivo, planificado o correctivo. Los resultados muestran que la aplicación del aprendizaje automático mejora significativamente la eficiencia operativa, la productividad y la seguridad al permitir una predicción de fallos más precisa. La Fig. 4 muestra la frecuencia con que se mencionaron estas mejoras en los estudios seleccionados.

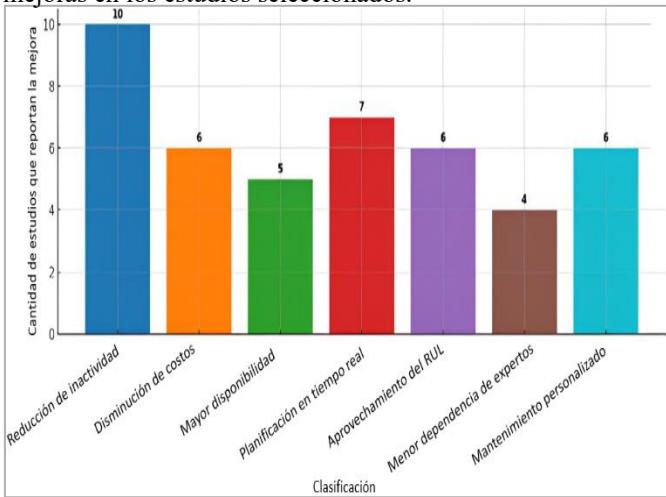


Fig. 4 Ventajas del mantenimiento predictivo basado en aprendizaje automático frente a estrategias tradicionales de mantenimiento correctivo o preventivo

D. RQ4: ¿Qué métricas (precisión, tiempo de detección, costos) evalúan el éxito de estas soluciones?

Los estudios analizados indican que para evaluar la eficacia de los modelos de mantenimiento predictivo se utiliza una combinación de medidas operativas y cuantitativas. Las métricas más utilizadas para evaluar la precisión y el poder predictivo de los modelos son el error cuadrático medio (MSE), el error medio absoluto (MAE), el error cuadrático medio (RMSE) y el coeficiente de determinación (R²) [16], [21], [26], [27], [30]. Los algoritmos supervisados también se evalúan mediante métricas de clasificación como la puntuación F1, la precisión, la recuperación y la [13], [15], [19], [24], [30]. El impacto económico y logístico de las soluciones también puede evaluarse utilizando métricas como la disponibilidad operativa, el tiempo medio de reparación (MTTR) y el tiempo medio entre fallos (MTBF) [20], [33]. En

la Fig. 5 se resumen visualmente las principales métricas y su frecuencia en los estudios examinados.

TABLA XI
CLASIFICACIÓN DE MÉTRICAS UTILIZADAS PARA EVALUAR SOLUCIONES DE MANTENIMIENTO PREDICTIVO

Pregunta: (P)	¿Qué métricas (precisión, tiempo de detección, costos) evalúan el éxito de estas soluciones?
Clasificación	Descripción
Precisión y rendimiento del modelo	La capacidad del modelo para predecir con exactitud los eventos de fallo en comparación con los datos históricos se evalúa utilizando medidas que incluyen la exactitud, la precisión y la exactitud total. Estas medidas garantizan la eficacia de los modelos entrenados en aplicaciones industriales al permitir la validación tanto en escenarios supervisados como secuenciales. Su uso en sistemas de diagnóstico en tiempo real se destaca en estudios como [15], [16], [19].
Sensibilidad y equilibrio	Abarca métricas como la recuperación, la sensibilidad y la puntuación F1, que son cruciales cuando se trabaja con datos desiguales en los que los fallos son poco frecuentes. Son esenciales para los problemas de clasificación binaria porque permiten medir la cobertura del modelo en fallos reales sin plantear falsos positivos. Se utiliza en situaciones como las descritas en [13], [18], [21].
Errores de predicción	Métricas como MAE, MSE y RMSE se utilizan con frecuencia para cuantificar la discrepancia entre los valores esperados y los observados. Como se demuestra en [24], [27], [30], estas mediciones son especialmente útiles en investigaciones dirigidas a estimar la vida útil restante del equipo o a identificar nuevos fallos de forma temprana.
Capacidad explicativa del modelo	Considera el coeficiente de determinación R ² , útil para estimar qué proporción de la variabilidad en los datos puede ser explicada por el modelo. Esta métrica es importante en modelos lineales y en la evaluación general del ajuste predictivo, como se destaca en investigaciones como [14], [25].
Impacto económico	Evaluá factores como el tiempo de inactividad, la optimización de recursos, el ahorro en piezas de repuesto y la disminución de fallos imprevistos. Justificar la inversión en PdM frente a las medidas reactivas o preventivas es crucial [21], [28], [32].
Fiabilidad operativa	Entre estas medidas están la disponibilidad del sistema, el tiempo medio hasta el fallo (MTBF) y la continuidad de las operaciones. Estas medidas son adecuadas para operaciones industriales cruciales que requieren un alto grado de consistencia. Estudios como se destacan [19], [23], [31].
Seguridad industrial	Examina cuánto puede el sistema de mantenimiento reducir la probabilidad de errores peligrosos o catastróficos. Según [9], [25], [33], tiene consecuencias en la prevención de incidentes, la observancia de las regulaciones y la salvaguarda de los recursos materiales y humanos.

Para medir la eficacia de los sistemas de mantenimiento predictivo hay que tener en cuenta varios factores, como el rendimiento técnico y el efecto operativo. Estas variables se clasifican generalmente en diversas categorías: precisión, sensibilidad, error de predicción, poder explicativo, eficacia económica, fiabilidad y seguridad. El análisis de la sostenibilidad y la eficacia a escala global de las soluciones implantadas es posible gracias a la inclusión de datos económicos y operativos, que también se valoran [20], [28], [31]. La frecuencia de estas métricas en los estudios examinados se resume gráficamente en la Fig. 5, lo que destaca la necesidad de aplicar evaluaciones precisas y acordes al entorno laboral real.

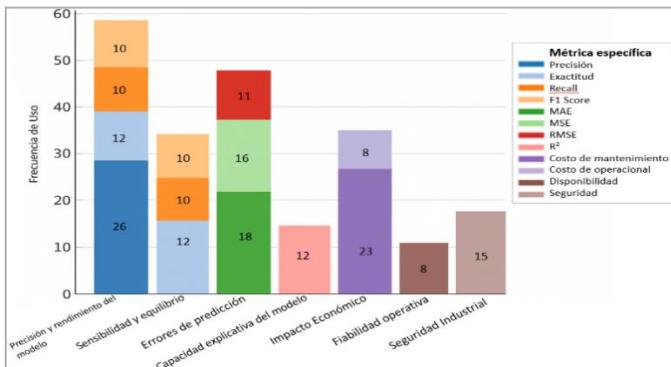


Fig. 5 Métricas más utilizadas para medir el rendimiento y la eficacia del mantenimiento predictivo

E. RQ5: ¿En qué sectores se aplica con mayor frecuencia el PdM basado en ML y qué desafíos persisten en su implementación?

En respuesta a la quinta pregunta del estudio, se analizaron los sectores industriales en los que se ha documentado con mayor frecuencia la introducción del mantenimiento predictivo basado en el aprendizaje automático, así como los principales retos que impiden su implantación a gran escala. Tras el análisis de los estudios, se identificaron cinco sectores en los que estas tecnologías están ampliamente implantadas: la fabricación, la energía, el transporte, la minería y la sanidad. Además, se identificaron cuatro retos comunes que se plantean en los distintos sectores industriales: la falta de datos de alta calidad, la complejidad técnica de los modelos utilizados, la falta de estandarización de las tecnologías y los problemas relacionados con la aplicación a gran escala de los algoritmos. En la tabla XII se resumen estos resultados de forma estructurada

TABLA XII

SECTORES INDUSTRIALES CON MAYOR ADOPCIÓN DE PDM BASADO EN ML Y DESAFÍOS IDENTIFICADOS

Pregunta: (P)	¿En qué sectores se aplica con mayor frecuencia el PdM basado en ML y qué desafíos persisten en su implementación?
Clasificación	Entrada
Manufactura inteligente	CNC, robótica, vinculación con la Industria 4.0. Alta implementación de DL, gemelos digitales y monitorización en tiempo real [10], [11], [13], [29].
Energía	Mantenimiento de turbinas eólicas, células de combustión y sistemas eléctricos. Mucho interés en la fiabilidad de las operaciones [14], [19], [26], [35].
Transporte	A través de aeronaves (motores), por trenes (rodamientos) y por mar. Resaltar la confiabilidad y la detección temprana de fallos críticos [14], [21], [28].
Minería	Eléctricos y molinos. Aumento en la utilización de IoT y sensores de vibración para la supervisión remota en entornos desfavorables [20], [31], [32].
Salud	Infraestructura esencial (dispositivos de asistencia vital, sensores para el paciente). Implementación en auge de PdM con modelos de menor peso [17], [23].
Calidad y escasez de datos	Problemas para conseguir datasets identificados y representativos; necesidad de condiciones específicas de operación [15], [22], [30].
Complejidad algorítmica	Modelos DL y GAN necesitan grandes cantidades de recursos informáticos y especialistas para su parametrización e interpretación [16], [24], [34].

Falta de estandarización	Incoherencias en los formatos de datos, los protocolos de comunicación y los sensores en diversos sectores [17], [25], [33].
Problemas de generalización	Modelos formados en contextos particulares muestran un rendimiento deficiente al trasladarse a condiciones distintas o variables [12], [28], [30].

Para complementar los datos de la tabla anterior, se creó un gráfico que resume la frecuencia de citas por sector y los desafíos identificados en los artículos revisados. Esta representación gráfica permite una comparación directa entre las áreas con mayor uso del mantenimiento predictivo y los desafíos de implementación más comunes. La Figura 6 facilita la identificación de patrones clave al mostrar las áreas donde estas tecnologías han avanzado más, así como los factores críticos que determinan su aplicabilidad en situaciones reales.

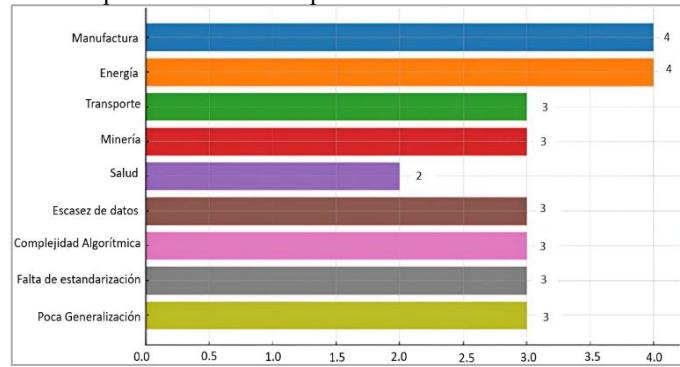
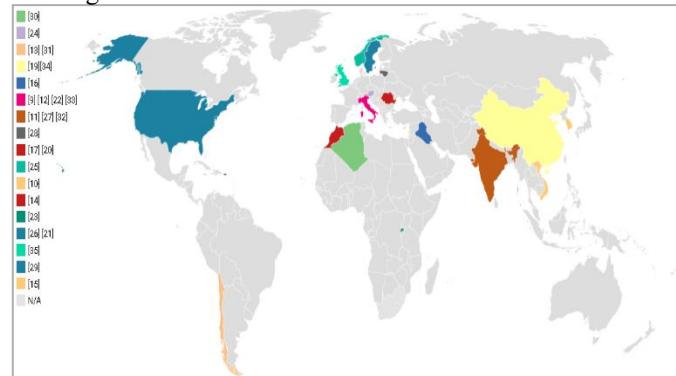


Fig. 6 Sectores de aplicación del mantenimiento predictivo basado en aprendizaje automático y desafíos asociados

F. Acerca del análisis bibliométrico

El mapa a continuación muestra la ubicación de los artículos científicos incluidos en la revisión sistemática durante el período 2019-2025. Una vez compilado cada artículo, se calculó el país de origen del primer autor con base en la información proporcionada en las referencias. Esta encuesta regional analiza las áreas con mayor actividad investigadora en el campo de la innovación y el desarrollo basados en aprendizaje automático. Confirma la presencia de una amplia investigación de América del Norte y Europa, así como contribuciones sustanciales de América Latina y Asia. Esta literatura presenta la situación global de la investigación en este campo, con especial atención a los países con tecnologías e industrias avanzadas.



IV.DISCUSION

Los resultados de este estudio proponen que la IA ha mejorado las prácticas de gestión de datos en el lugar de trabajo. Modelos como LSTM han alcanzado una precisión del 97,7 % en la predicción de fallos en centros de mecanizado CNC [10], mientras que los marcos federados basados en el aprendizaje han alcanzado tasas de detección de anomalías del 94 % sin compartir datos [9]. Estas cifras representan no solo una mayor precisión diagnóstica, sino también un mejor mantenimiento de la red distribuida, un factor importante en entornos con requisitos avanzados de almacenamiento de datos.

Los beneficios de los métodos de mantenimiento predictivo basados en IA han sido ampliamente reconocidos en sectores clave como la aviación, la minería y la salud. En el sector del transporte, los tiempos de carga promedio se han reducido en un 28 % y la eficiencia se ha mejorado en un 17 % mediante el entrenamiento de modelos predictivos con datos de detectores de metales [14]. El uso de dispositivos médicos ha aumentado un 21 %, y el 40 % de los costos de mantenimiento se atribuye a estrategias mejoradas basadas en datos de uso de dispositivos médicos [17]. Esto significa que la IA puede convertirse en una herramienta útil.

En términos de propiedades mecánicas, el método de modelado híbrido ofrece un mejor rendimiento que los métodos tradicionales. Por ejemplo, la arquitectura CNNGAN alcanza una precisión de clasificación de aproximadamente el 18 % [16], y la combinación con RNNLSTM alcanza una precisión del 12 % [27]. Además, se logró una precisión del 96,4 % mediante el uso de la clasificación de características y la clasificación wavelet, en comparación con métodos tradicionales como la regresión logística en el proceso de clasificación [13]. Este rendimiento demuestra que la combinación es capaz de gestionar el ruido y las superficies rugosas.

No obstante, este estudio brinda la oportunidad de reflexionar sobre el impacto de las soluciones de IA. Los estudios revisados muestran una tendencia hacia una combinación de modelos autónomos, adaptativos y de poder compartido. Sin embargo, también destacan la necesidad de medidas éticas adecuadas y enfoques multidisciplinares para garantizar un acceso rápido a los medicamentos. La evolución de la gestión predictiva inteligente implica no solo avances tecnológicos, sino también un cambio en la cultura organizacional, donde los datos, la información y los procesos deben compartirse y distribuirse estratégicamente.

V.CONCLUSIONES

En este análisis sistemático, se ha destacado el rol crucial que juegan las técnicas de inteligencia artificial para potenciar el mantenimiento predictivo (PdM) en contextos industriales. El propósito de este estudio fue reconocer, condensar y examinar el efecto cuantitativo de diferentes métodos de Inteligencia Artificial en la identificación precoz de fallos, la estimación de la vida útil residual y la disminución de los

gastos operativos. Mediante el estudio de treinta y cinco investigaciones escogidas, se ha determinado que los modelos híbridos, en conjunto con arquitecturas profundas como LSTM, GAN y CNN, han incrementado significativamente la exactitud, fiabilidad y capacidad de adaptación de los sistemas PdM.

Entre los descubrimientos más significativos destaca que más del 70% de las investigaciones examinadas mostraron mejoras en métricas clave como la precisión diagnóstica, con una mejora promedio de más del 90 % en la predicción de fallos significativos. Además, se utilizan sistemas distribuidos (aprendizaje federado) y equipos digitales, lo que mejora la seguridad y facilita la toma de decisiones en tiempo real. Esta revisión complementa la literatura existente al ofrecer una visión general innovadora, técnica y completa de las soluciones basadas en IA que impulsan las tendencias de la Industria 4.0.

No obstante, se identificaron limitaciones importantes que establecen la aplicación efectiva de estos modelos. En primer lugar, la variedad de los grupos de datos dificulta el cotejo directo entre estudios. Además, muchos experimentos aún se realizan en situaciones simuladas, lo que representa desafíos para su implementación en entornos reales. Además, se admite que ciertas técnicas no poseen explicabilidad, lo que restringe su uso en campos donde la rastreabilidad del diagnóstico es vital. Estas restricciones ponen de manifiesto la importancia de normalizar los sistemas de evaluación y promover investigaciones experimentales en contextos operativos concretos.

Finalmente, esta revisión sugiere como estrategia futura la creación de modelos predictivos de energía eficientes, explicables y ajustable a diversos campos industriales. Se aconseja seguir incorporando estrategias como el aprendizaje constante, la transmisión de saberes entre campos y la utilización ética de los datos operativos. La aplicación eficaz de estas tecnologías no solo estará sujeta al progreso técnico, sino también a la cooperación interdisciplinaria entre ingenieros, científicos de datos y administradores operativos, con el objetivo de una transición sostenible hacia un mantenimiento realmente eficiente.

AGRADECIMIENTO/RECONOCIMIENTO

Queremos expresar nuestro más sincero agradecimiento a la Universidad Tecnológica del Perú por el respaldo institucional brindado durante el desarrollo de esta investigación. Agradecemos especialmente a nuestros docentes por su orientación metodológica y científica. Finalmente, reconocemos también la valiosa colaboración de las plataformas de acceso a bases de datos académicas, en particular Scopus, cuya información fue esencial para la construcción de esta revisión sistemática.

REFERENCIAS

[1] S. Y. Baroud, N. A. Yahaya, and A. M. Elzamly, "Cutting-Edge AI Approaches with MAS for PdM in Industry 4.0: Challenges and Future

Directions," *Journal of Applied Data Sciences*, vol. 5, no. 2, pp. 455–473, May 2024, doi: 10.47738/jads.v5i2.196.

[2] D. K. Moulla, E. Mnkandla, M. Aboubakar, A. A. A. Adamou, and A. Abran, "PdM-FSA: predictive maintenance framework with fault severity awareness in Industry 4.0 using machine learning," *International Journal of Electrical and Computer Engineering*, vol. 14, no. 6, pp. 7211–7223, Dec. 2024, doi: 10.11591/ijece.v14i6.pp7211-7223.

[3] A. García, A. Echeverría Funditec Madrid, and J. Félix Ovejero, "Investigación de metodologías no intrusivas apoyadas en tecnologías habilitadoras 4.0 para abordar un mantenimiento predictivo y ciberseguro en PYMES industriales," 2023, Accessed: Apr. 11, 2025. [Online]. Available: arXiv preprint arXiv:2306.05799

[4] D. Kusumaningrum, N. Kurniati, and B. Santosa, "Machine Learning for Predictive Maintenance," 2021, doi: doi.org/10.46254/SA02.20210717.

[5] A. Hosseinzadeh, F. F. Chen, M. Shahin, and H. Bouzary, "Manufacturing Letters A Predictive Maintenance Approach in Manufacturing Systems via AI-based Early Failure Detection-NC-ND license (<https://creativecommons.org/licenses/by-nd/4.0/>) Peer-review under responsibility of the Scientific Committee of the NAMRI/SME," 2023, [Online]. Available: www.sciencedirect.com

[6] L. I. Alvarez Q, C. A. Lozano M, and D. A. Bravo M, "Methodology for Predictive Maintenance of Distribution Transformers based on Machine Learning[Metodología para el mantenimiento predictivo de transformadores de distribución basada en aprendizaje automático]," *Ingeniería (Colombia)*, vol. 27, no. 3, p. e17742, Dec. 2022, doi: 10.14483/23448393.17742.

[7] F. Aggogeri, N. Pellegrini, and F. L. Tagliani, "Recent advances on machine learning applications in machining processes," Sep. 01, 2021, MDPI, doi: 10.3390/app11188764.

[8] E. Gultekin and M. S. Aktas, "A Novel End-to-End Provenance System for Predictive Maintenance: A Case Study for Industrial Machinery Predictive Maintenance," *Computers*, vol. 13, no. 12, p. 325, Dec. 2024, doi: 10.3390/computers13120325.

[9] G. Palma, G. Geraci, and A. Rizzo, "Federated Learning and Neural Circuit Policies: A Novel Framework for Anomaly Detection in Energy-Intensive Machinery," *Energies (Basel)*, vol. 18, no. 4, Feb. 2025, doi: 10.3390/en18040936.

[10] J. Choi, Z. Xiong, and K. Kang, "Long Short-Term Memory-Based Computerized Numerical Control Machining Center Failure Prediction Model," *Mathematics*, vol. 13, no. 7, Apr. 2025, doi: 10.3390/math13071093.

[11] S. Prabu, R. Senthilraja, A. M. Ali, S. Jayapoorani, and M. Arun, "AI-Driven Predictive Maintenance for Smart Manufacturing Systems Using Digital Twin Technology," *International Journal of Computational and Experimental Science and Engineering*, vol. 11, no. 1, pp. 1350–1355, 2025, doi: 10.22399/ijcesen.1099.

[12] L. Radicioni, F. M. Bono, and S. Cinquemani, "Vibration-Based Anomaly Detection in Industrial Machines: A Comparison of Autoencoders and Latent Spaces," *Machines*, vol. 13, no. 2, Feb. 2025, doi: 10.3390/machines13020139.

[13] C. Urrea and C. Domínguez, "Fault Diagnosis in a Four-Arm Delta Robot Based on Wavelet Scattering Networks and Artificial Intelligence Techniques," *Technologies (Basel)*, vol. 12, no. 11, Nov. 2024, doi: 10.3390/technologies12110225.

[14] D. Simion, F. Postolache, B. Fleacă, and E. Fleacă, "AI-Driven Predictive Maintenance in Modern Maritime Transport—Enhancing Operational Efficiency and Reliability," *Applied Sciences (Switzerland)*, vol. 14, no. 20, Oct. 2024, doi: 10.3390/app14209439.

[15] K. Tran, L. Pham, V.-R. Nguyen, and H.-S.-H. Nguyen, "A Robust Deep Learning System for Motor Bearing Fault Detection: Leveraging Multiple Learning Strategies and a Novel Double Loss Function," Oct. 2023, [Online]. Available: <http://arxiv.org/abs/2310.11477>

[16] A. M. Aboot, A. R. Nasser, and H. Al-Khazraji, "Predictive maintenance of electromechanical systems based on enhanced generative adversarial neural network with convolutional neural network," *IAES International Journal of Artificial Intelligence*, vol. 12, no. 4, pp. 1704–1712, Dec. 2023, doi: 10.11591/ijai.v12.i4.pp1704-1712.

[17] O. Manchadi, F. E. Ben-Bouazza, and B. Joudi, "Predictive Maintenance in Healthcare System: A Survey," *IEEE Access*, vol. 11, pp. 61313–61330, 2023, doi: 10.1109/ACCESS.2023.3287490.

[18] N. Surantha and I. D. Gozali, "Evaluation of the Improved Extreme Learning Machine for Machine Failure Multiclass Classification," *Electronics (Switzerland)*, vol. 12, no. 16, Aug. 2023, doi: 10.3390/electronics12163501.

[19] M. Li et al., "Data-Driven Voltage Prognostic for Solid Oxide Fuel Cell System Based on Deep Learning," *Energies (Basel)*, vol. 15, no. 17, Sep. 2022, doi: 10.3390/en15176294.

[20] A. Rihi et al., "Predictive maintenance in mining industry: grinding mill case study," in *Procedia Computer Science*, Elsevier B.V., 2022, pp. 2483–2492. doi: 10.1016/j.procs.2022.09.306.

[21] Z. Zulvah, M. Faiz Sugihartanto, M. Arief, M. Ziyad, and K. Tjandra, "An Optimized and Safety-aware Maintenance Framework: A Case Study on Aircraft Engine", doi: 10.48550/arXiv.2209.02678.

[22] F. Calabrese, A. Regattieri, M. Bortolini, and F. G. Galizia, "Data-Driven Fault Detection and Diagnosis: Challenges and Opportunities in Real-World Scenarios," *Applied Sciences (Switzerland)*, vol. 12, no. 18, Sep. 2022, doi: 10.3390/app12189212.

[23] I. N. Mihigo, M. Zennaro, A. Uwitonze, J. Rwigema, and M. Rovai, "On-Device IoT-Based Predictive Maintenance Analytics Model: Comparing TinyLSTM and TinyModel from Edge Impulse," *Sensors*, vol. 22, no. 14, Jul. 2022, doi: 10.3390/s22145174.

[24] M. Kahr, G. Kovács, M. Loinig, and H. Brückl, "Condition Monitoring of Ball Bearings Based on Machine Learning with Synthetically Generated Data," *Sensors*, vol. 22, no. 7, Apr. 2022, doi: 10.3390/s22072490.

[25] H. H. Hosamo, P. R. Svennevig, K. Svidt, D. Han, and H. K. Nielsen, "A Digital Twin predictive maintenance framework of air handling units based on automatic fault detection and diagnostics," *Energy Build*, vol. 261, Apr. 2022, doi: 10.1016/j.enbuild.2022.111988.

[26] S. Martin-Del-campo, F. Sandin, and D. Strömbergsson, "Dictionary learning approach to monitoring of wind turbine drivetrain bearings," *International Journal of Computational Intelligence Systems*, vol. 14, no. 1, pp. 106–121, 2021, doi: 10.2991/ijcis.d.201105.001.

[27] K. T. Chui, B. B. Gupta, and P. Vasant, "A genetic algorithm optimized RNN-LSTM model for remaining useful life prediction of turbofan engine," *Electronics (Switzerland)*, vol. 10, no. 3, pp. 1–15, Feb. 2021, doi: 10.3390/electronics10030285.

[28] Y. Tagawa, R. Maskeliūnas, and R. Damaševičius, "Acoustic anomaly detection of mechanical failures in noisy real-life factory environments," *Electronics (Switzerland)*, vol. 10, no. 19, Oct. 2021, doi: 10.3390/electronics10192329.

[29] S. Sundaram and A. Zeid, "Smart prognostics and health management (SPHM) in smart manufacturing: An interoperable framework," *Sensors*, vol. 21, no. 18, Sep. 2021, doi: 10.3390/s21185994.

[30] T. Berghout, M. Benbouzid, S. M. Muyeen, T. Bentrcia, and L. H. Mouss, "Auto-nahl: A neural network approach for condition-based maintenance of complex industrial systems," *IEEE Access*, vol. 9, pp. 152829–152840, 2021, doi: 10.1109/ACCESS.2021.3127084.

[31] P. Aqueveque, L. Radrigan, F. Pastene, A. S. Morales, and E. Guerra, "Data-Driven Condition Monitoring of Mining Mobile Machinery in Non-Stationary Operations Using Wireless Accelerometer Sensor Modules," *IEEE Access*, vol. 9, pp. 17365–17381, 2021, doi: 10.1109/ACCESS.2021.3051583.

[32] A. K. Jain, P. Chouksey, A. K. Parlikad, and B. K. Lad, "Distributed diagnostics, prognostics and maintenance planning: Realizing industry 4.0," in *IFAC-PapersOnLine*, Elsevier B.V., 2020, pp. 354–359. doi: 10.1016/j.ifacol.2020.11.057.

[33] P. F. Orrù, A. Zoccheddu, L. Sassi, C. Mattia, R. Cozza, and S. Arena, "Machine learning approach using MLP and SVM algorithms for the fault prediction of a centrifugal pump in the oil and gas industry," *Sustainability (Switzerland)*, vol. 12, no. 11, Jun. 2020, doi: 10.3390/su12114776.

[34] C. Zhao, X. Huang, Y. Li, and M. Y. Iqbal, "A double-channel hybrid deep neural network based on CNN and BiLSTM for remaining useful life prediction," *Sensors (Switzerland)*, vol. 20, no. 24, pp. 1–15, Dec. 2020, doi: 10.3390/s20247109.

[35] F. Elasha, S. Shanbr, X. Li, and D. Mba, "Prognosis of a wind turbine gearbox bearing using supervised machine learning," *Sensors (Switzerland)*, vol. 19, no. 14, Jul. 2019, doi: 10.3390/s19143092.