

MANTENIMIENTO PREDICTIVO BASADO EN MACHINE LEARNING: UNA REVISIÓN SISTEMÁTICA DE LA LITERATURA Y PERSPECTIVAS EN LA INDUSTRIA 4.0

PREDICTIVE MAINTENANCE BASED ON MACHINE LEARNING: A SYSTEMATIC LITERATURE REVIEW AND PERSPECTIVES IN INDUSTRY 4.0

Sofía Tapia¹, Gustavo Aguilera¹, Luis Rojas¹, José García²

(1) Universidad de La Serena, Facultad de Ingeniería, Departamento de Ingeniería Civil Mecánica. La Serena 1720169, Chile;

(2) Doctorado en Industria Inteligente, Facultad de Ingeniería, Pontificia Universidad Católica de Valparaíso,
Valparaíso 2362804, Chile
(e-mail: sofia.tapiaa@userena.cl)

Recibido: 15/07/2024 - Evaluado: 15/08/2024 - Aceptado: 21/09/2024

<https://doi.org/10.65093/aci.v15.n4.2024.3>

RESUMEN

En el marco de la Industria 4.0, el mantenimiento predictivo (PdM) emerge como componente esencial para maximizar la disponibilidad de activos y garantizar la excelencia operacional. La explosión de datos de sensores y la complejidad creciente de los sistemas productivos exigen enfoques analíticos avanzados. Esta revisión sistemática examina literatura donde se aplican técnicas de aprendizaje automático (ML) al PdM en sectores como energía eólica, ferrocarriles, manufactura e infraestructuras. Se analizan algoritmos utilizados, escenarios de despliegue, métricas de rendimiento y resultados reportados. Redes neuronales, máquinas de vectores de soporte y métodos de conjuntos dominan la detección de fallas, estimación de vida útil remanente y planificación de intervenciones. Los estudios muestran mejoras en precisión pronóstica, reducción de tiempos de paro y disminución de costos. Se concluye que el ML actúa como habilitador del PdM orientado a datos, reforzando confiabilidad y sostenibilidad, y se identifican líneas de investigación para estrategias de mantenimiento inteligente futuro.

ABSTRACT

Within the framework of Industry 4.0, predictive maintenance (PdM) emerges as an essential component to maximize asset availability and ensure operational excellence. The explosion of sensor data and the increasing complexity of production systems require advanced analytical approaches. This systematic review examines literature where machine learning (ML) techniques are applied to PdM in sectors such as wind energy, railroads, manufacturing and infrastructure. Algorithms used, deployment scenarios, performance metrics and reported results are analyzed. Neural networks, support vector machines and ensemble methods dominate fault detection, remaining life estimation and intervention planning. Studies show improvements in prognostic accuracy, downtime reduction and cost reduction. It is concluded that ML acts as an enabler of data-driven PdM, enhancing reliability and sustainability, and lines of research for future intelligent maintenance strategies are identified.

Palabras clave: mantenimiento predictivo, Industria 4.0, aprendizaje automático, mantenimiento basado en datos

Keywords: predictive maintenance, Industry 4.0, machine learning, data-driven maintenance

INTRODUCCIÓN

La gestión eficiente de activos industriales se ha consolidado como un factor determinante para la competitividad y sostenibilidad de las empresas manufactureras en la era de la Industria 4.0. En este contexto, el *Mantenimiento Predictivo (PdM)* emerge como una estrategia superadora del mantenimiento reactivo y preventivo, prometiendo la anticipación de fallos, la optimización de intervenciones y, consecuentemente, una significativa reducción de costos operativos, un aumento en la disponibilidad de equipos y una mejora en la seguridad de las operaciones. Este paradigma avanzado se fundamenta en la convergencia de la sensorización ubicua, la interconexión de sistemas y el procesamiento masivo de datos, lo que posibilita la monitorización en tiempo real del estado de los activos y la detección temprana de anomalías.

El advenimiento del *Aprendizaje Automático (Machine Learning - ML)* ha revolucionado el PdM, dando lugar al *Mantenimiento Predictivo Inteligente (PdMI)*. Esta disciplina aprovecha la capacidad de los algoritmos de ML para extraer conocimiento valioso a partir de datos industriales. El ML ofrece un amplio espectro de técnicas, desde el aprendizaje supervisado hasta el no supervisado y el aprendizaje por refuerzo, permitiendo abordar los desafíos del PdMI en diversas dimensiones, como la detección y clasificación de fallos, la estimación de la vida útil remanente (RUL, *Remaining Useful Life*) y la optimización de estrategias de mantenimiento. Algoritmos como las Redes Neuronales Artificiales (RNA), las Máquinas de Vectores de Soporte (SVM), los árboles de decisión y los métodos ensemble se han aplicado con éxito en diversos contextos industriales, mejorando la precisión de las predicciones y la eficiencia en la gestión del mantenimiento (Çinar *et al.*, 2020; Hoffmann & Lasch, 2024; Antosz *et al.*, 2024). Estudios recientes demuestran la aplicación efectiva de técnicas de ML en áreas como la predicción del consumo de combustible en motores marinos (Gkerekos *et al.*, 2019), la detección de anomalías en motores eléctricos (Nikfar *et al.*, 2022), la gestión del mantenimiento de turbinas eólicas (Rodríguez *et al.*, 2023), y la optimización en infraestructuras complejas (Rodríguez *et al.*, 2023). La integración de técnicas de procesamiento de imágenes, como la termografía infrarroja, con algoritmos de ML ha abierto nuevas vías para la inspección automatizada y la detección temprana de fallos (Venegas *et al.*, 2022).

A pesar del creciente cuerpo de investigación y validación empírica del PdMI, la literatura científica se encuentra dispersa, careciendo de una síntesis que identifique patrones, tendencias y desafíos comunes. La proliferación de estudios, con diversas metodologías, algoritmos y aplicaciones sectoriales, dificulta la extracción de conclusiones generales y la identificación de mejores prácticas. Por ello, se justifica una *Revisión Sistemática de la Literatura (RSL)* que, mediante una metodología transparente y reproducible, sintetice y analice críticamente la evidencia científica existente, ofreciendo una visión panorámica y estructurada del estado del arte del PdMI basado en ML. Esta RSL se configura como una herramienta para investigadores y profesionales que buscan comprender el panorama actual, identificar áreas de oportunidad y orientar futuras investigaciones e implementaciones.

Esta RSL se propone: (1) mapear y categorizar las técnicas de ML aplicadas al PdM industrial, (2) identificar los sectores industriales y aplicaciones específicas del PdMI, (3) analizar las métricas de rendimiento y resultados reportados, y (4) identificar tendencias emergentes y desafíos que limitan la adopción del PdMI.

Para alcanzar estos objetivos, se diseñó una *estrategia de búsqueda sistemática y exhaustiva* en bases de datos como Web of Science (WoS) y Scopus. Se definieron *criterios de inclusión y exclusión* rigurosos, garantizando la relevancia y calidad de la evidencia. La búsqueda empleó *términos clave y combinaciones booleanas* abarcando Mantenimiento Predictivo, Machine Learning y aplicaciones industriales. Los estudios seleccionados fueron sometidos a un *proceso estandarizado de extracción y análisis de datos*, permitiendo la síntesis cuantitativa y cualitativa. Finalmente, se realizó un *análisis temático*, agrupando los hallazgos en clusters que representan las áreas de investigación y aplicación del PdMI, facilitando la identificación de patrones, tendencias y vacíos de conocimiento.

METODOLOGÍA DE LA SISTEMÁTICA

En esta sección se detalla la metodología seguida para la ejecución de la Revisión Sistemática de la Literatura (RSL), incorporando tanto la perspectiva de Procesamiento de Lenguaje Natural (PLN) como la validación crítica

por parte de expertos en mantenimiento industrial. El objetivo es garantizar rigor científico, trazabilidad y consistencia en cada fase del proceso, desde la selección y depuración de artículos hasta el análisis cuantitativo y cualitativo final. La Tabla 1 detalla el método del flujo de trabajo propuesto, con énfasis en las herramientas semiautomáticas de análisis y la revisión exhaustiva del equipo investigador.

Tabla 1: Resumen de Metodología Sistemática

Fase	Descripción
1. Búsqueda inicial	Identificación de artículos relevantes en las bases de datos Scopus y Web of Science (WoS) utilizando criterios de búsqueda predefinidos.
2. Selección Preliminar	Aplicación de criterios de inclusión y exclusión para filtrar los resultados de la búsqueda inicial, generando una lista preliminar de documentos.
3. Integración y Limpieza	Combinación de los resultados de ambas bases de datos, eliminación de duplicados y preparación de los datos de análisis
4. Revisión Completa	Revisión exhaustiva del texto completo de cada artículo preseleccionado para con- firmar su relevancia y adecuación a los objetivos de la revisión.
5. Análisis Temático	Uso de técnicas de Procesamiento del Lenguaje Natural (NLP) combinado con la validación y refinamiento por parte de expertos en el área para identificar los temas principales y agrupar los artículos en <u>clústeres temáticos</u> .
6. Análisis Cuantitativo	Generación de visualizaciones (gráficos, diagramas) e indicadores clave (por ejemplo, número de publicaciones por año, distribución por país) para analizar la distribución y evolución de la investigación en cada clúster.
7. Análisis Cualitativo.	Síntesis descriptiva de los hallazgos clave dentro de cada clúster, identificando tendencias, brechas y oportunidades de investigación futura.

Fuentes de Información

Dada la amplia cobertura en ciencia y tecnología industrial, se seleccionaron las bases de datos *Scopus* y *Web of Science (WoS)* por su relevancia y trayectoria en indexación de artículos revisados por pares y contribuciones de alto impacto. Para minimizar el sesgo de cobertura temática, se emplearon estrategias de búsqueda similares en ambos repositorios, incluyendo operadores booleanos y términos en inglés tales como "*machine learning*", "*predictive maintenance*" y "*fault detection*"; siguiendo el enfoque descrito en (Garcia *et al.*, 2022).

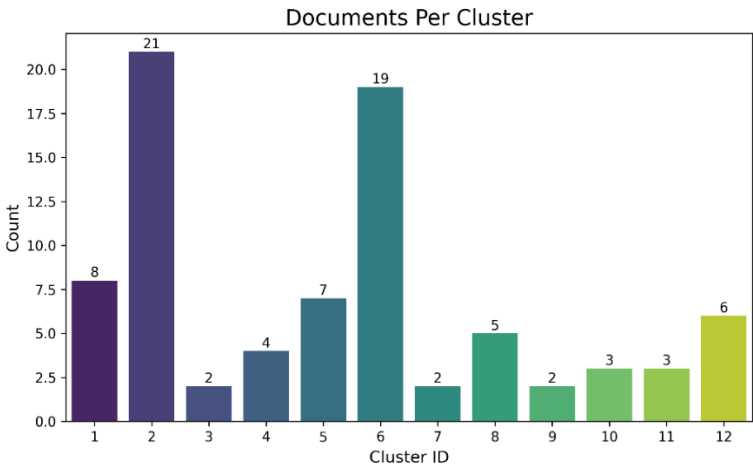


Fig. 1: Documentos por Cluster

La Figura 1 muestra la distribución de los artículos entre los grupos o *clusters* temáticos con mayor afinidad semántica. Cada clúster agrupa artículos con enfoques y campos de aplicación similares, facilitando la detección de áreas consolidadas y de posibles vacíos de investigación.

En la Figura 2 se observa la calificación compuesta de las 12 revistas más sobresalientes, establecida por la combinación de criterios como número de citas, aporte teórico y replicabilidad industrial. Este ranking facilita la identificación de aquellas Revistas que han contribuido de forma significativa a la evolución del mantenimiento inteligente y a la aplicación de algoritmos de optimización y análisis predictivo (Garcia *et al.*, 2022; Sánchez-Garrido *et al.*, 2023; García *et al.*, 2023).



Fig. 2: calificación de las revistas

Búsqueda, Integración y Limpieza de Documentos

Al concluir la búsqueda y la descarga de metadatos bibliográficos, se ejecutaron filtros rigurosos de inclusión y exclusión:

- *Criterios de Inclusión:*
 - Artículos científicos (revistas Q1/Q2 según *Scopus* o *WoS*), o congresos con revisión rigurosa.
 - Publicados entre 2015 y 2025.
 - Idioma inglés.
 - Al menos 1 cita comprobable en bases indexadas.
 - Vínculo directo a equipos industriales, preferentemente orientados a minería o industrias intensivas en mantenimiento.
- *Criterios de Exclusión:*
 - Publicaciones con acceso restringido que impida la validación de datos.
 - Idiomas distintos al inglés.
 - Duplicados en más de una base de datos.
 - Falta de enfoque en mantenimiento predictivo o machine learning para activos industriales.

La unificación de referencias y la eliminación de duplicados se realizaron con gestores bibliográficos especializados, asignando identificadores únicos para el control de documentos. Luego de la *limpieza*, se obtuvo un listado preliminar de documentos seleccionables.

Esta última visualización (Figura 3) refuerza los hallazgos previos, señalando la relevancia de la convergencia entre *fault diagnosis*, *optimal decision-making* y metodologías de *predictive maintenance* para mejorar la vida útil de los equipos en entornos industriales críticos.

Revisión Completa y Validación de Inclusión

Cada documento preseleccionado fue sometido a una revisión crítica, confirmando su pertinencia temática y la solidez de su metodología. El *juicio experto* jugó un rol fundamental para descartar estudios con deficiencias en rigor estadístico, falta de reproducibilidad o alejados del objeto de estudio (García *et al.*, 2023; García *et al.*, 2022). Este proceso aseguró que la muestra final incluyera únicamente contribuciones de *alta calidad* y aplicabilidad real en mantenimiento predictivo.

Respecto a las revistas y conferencias con mayor número de publicaciones indexadas (Figura 4), *Journal of Quality in Maintenance Engineering* y *Applied Sciences* destacan como canales preferentes de difusión en el área de mantenimiento inteligente, optimización y minería digital. Estas fuentes se han posicionado como referentes para la comunidad académica e industrial, brindando espacios de discusión y divulgación de estrategias de vanguardia en gestión de activos y monitoreo de fallas.

La Figura 5 ofrece una perspectiva visual de la frecuencia de aparición de términos relacionados con el mantenimiento predictivo, la optimización y el uso de IA. Este tipo de representación es particularmente útil para identificar rápidamente los conceptos más recurrentes y su relación con tópicos emergentes.




Fig. 3: Comparativa adicional de palabras clave de autor, resaltando la coocurrencia de términos como "intelligent maintenance system" y "reliability", entre otras

Análisis Temático: Integración de NLP y Conocimiento Experto

Para clasificar las líneas de investigación principales, se empleó un *análisis semiautomático* que combina algoritmos de Procesamiento de Lenguaje Natural (PLN) con la validación crítica de ingenieros especializados (García *et al.*, 2022; García *et al.*, 2023). Los pasos principales incluyen:

Preprocesamiento

- (NLP Pre-processing): Limpieza textual (tokenización, remoción de *stop-words*, normalización léxica).
- Extracción de Características (Embeddings): Modelos de representación (p.e. *word2vec*, *sentence-BERT*) para capturar la semántica de términos recurrentes.
- Modelado de Tópicos No Supervisado (Clustering): Se aplicaron algoritmos (p.e. *k-means*, *LDA*) para agrupar artículos según afinidad semántica, analizando métricas de coherencia y *silhouette score*.
- Revisión Experta Iterativa: Especialistas en mantenimiento minero y optimización validaron el contenido de cada *cluster*, ajustando etiquetas temáticas y descartando solapamientos.

Análisis Cuantitativo: Visualizaciones e Indicadores Clave

Sobre el conjunto de artículos seleccionados tras la depuración, se realizó un análisis cuantitativo en profundidad:

- Distribución de Artículos por Año: Se observó un crecimiento constante desde 2018, con proyecciones hacia 2024 (Figura 7).
- Fuentes de Publicación: Diversas revistas y congresos, destacando *Journal of Quality in Maintenance Engineering* y *Applied Sciences* como los más frecuentes (Figura 4).
- Análisis de Palabras Clave: Terminología recurrente como "*machine learning*", "*predictive maintenance*", "*fault detection*", confirmando la orientación principal de la literatura (Figura 3).
- Colaboración y Autoría: Se identificaron equipos internacionales con alta coautoría, enfatizando la naturaleza multidisciplinaria y global de la investigación.

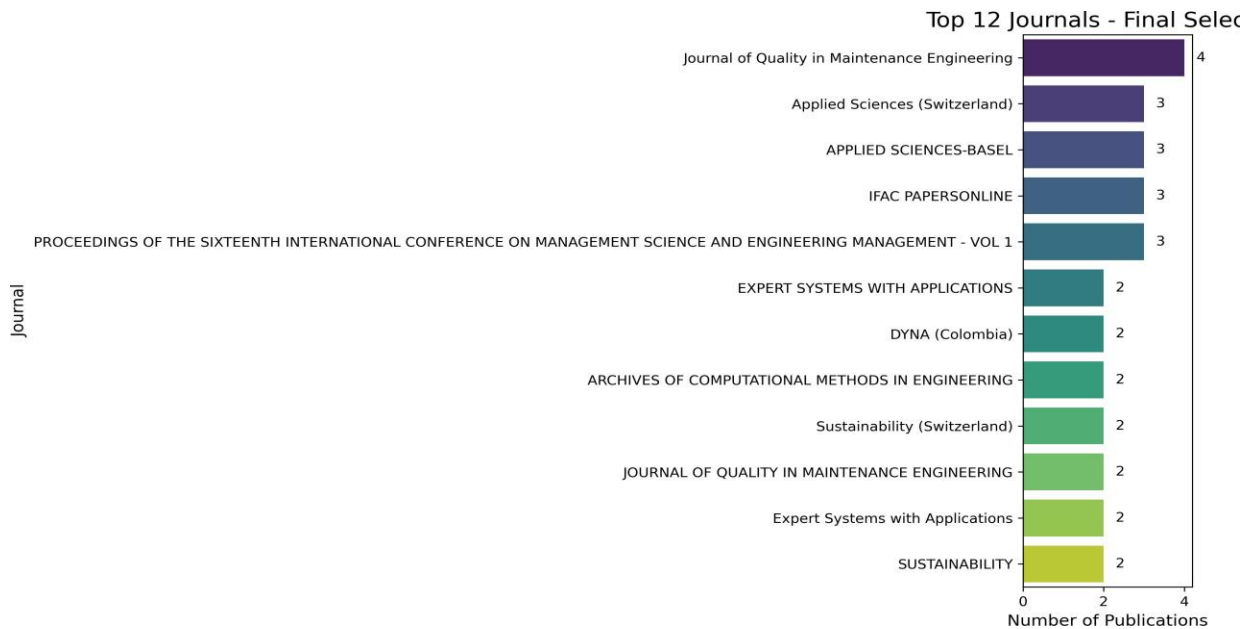


Fig. 4: Fuentes de publicación más relevantes dentro del conjunto de artículos seleccionados.

Para reforzar la robustez de los hallazgos, se aplicó una *evaluación de calidad* (ranking) basada en criterios como rigor metodológico, relevancia industrial y métricas de impacto (Sección 6).

Análisis Cualitativo: Síntesis Descriptiva de Hallazgos Clave

En una segunda fase, se llevó a cabo un análisis cualitativo exhaustivo, focalizado en:

- Contribuciones Significativas: Estudios pioneros en algoritmos avanzados de IA o integraciones novedosas de Big Data para mantenimiento [Çinar *et al.*, 2020, Hoffmann & Lasch, 2024].
- Temas Emergentes: Principales vacíos y oportunidades de investigación, tales como *deep reinforcement learning*, optimización multiobjetivo, o aplicaciones en minería extrema (subterránea).
- Validación en Campo: Estudios con implementaciones reales en plantas de procesamiento o equipos mina, evaluando su eficacia e impacto económico.

La *meta-síntesis* final permitió la formulación de recomendaciones prácticas, cubriendo líneas futuras de investigación, la adopción de tecnologías en entornos mineros y la convergencia con otros sectores industriales (García *et al.*, 2022; García *et al.*, 2023).

En la Figura 6 se evidencia cuáles términos han sido más empleados por los investigadores, mostrando la frecuencia de palabras clave como *machine learning*, *predictive maintenance* y *fault detection*. Su interpretación permite identificar la orientación temática predominante en la literatura reciente, así como la importancia creciente de enfoques de IA en las estrategias de mantenimiento. A un nivel avanzado, el análisis de la concentración de ciertos términos refleja tendencias emergentes y el grado de madurez de técnicas específicas (p. ej., uso de modelos híbridos o algoritmos de optimización) en el sector industrial.

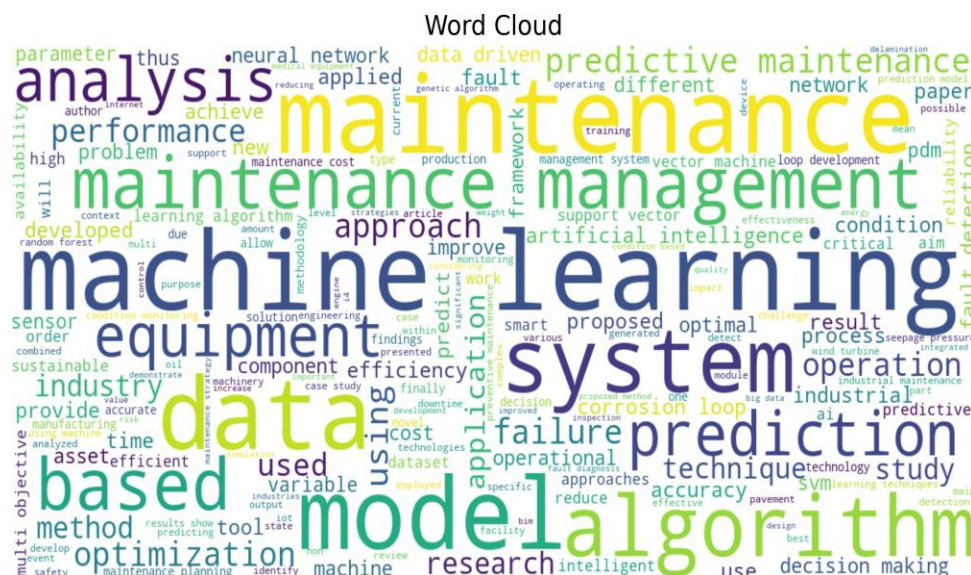


Fig. 5: Nube de palabras construida a partir de términos clave presentes en los resúmenes y títulos de los artículos seleccionados.




Fig. 6: Distribución de las principales palabras clave de los autores.

Análisis Finales de la Metodología

La estrategia descrita mantiene y expande los fundamentos de la RSL original, agregando:

1. Búsquedas Extensas (2015–2025) con Filtros Adicionales de Calidad: Doble filtro en *Scopus* y *WoS*, incluyendo sólo publicaciones con mínimo de 1 cita y relevancia verificada.
2. Integración Profunda de PLN: Aplicación de técnicas de *embeddings*, *k-means*, análisis semántico e iteraciones con juicio experto.
3. Evaluación Dual (Cuantitativo y Cualitativo): Visualizaciones bibliométricas y un análisis crítico de aportes novedosos, vacíos temáticos y replicabilidad industrial.
4. Enfoque en Sectores Industriales Exigentes (Minería, Energía, Manufactura): Garantizando la relevancia práctica y la posible transferencia de tecnología.

La Figura 7 presenta la evolución cronológica del número de publicaciones desde 2018 hasta 2024, mostrando una clara tendencia al alza. Este incremento puede asociarse a la adopción de nuevas tecnologías digitales (*big data*, *IoT*, *edge computing*), que facilitan la implantación de modelos de mantenimiento cada vez más complejos y precisos.

Así, se obtiene una revisión sistemática rigurosa y multidimensional, alineada con las tendencias más recientes en inteligencia artificial, mantenimiento predictivo y optimización de procesos industriales.

Finalmente, se obtuvieron varios *clusters* de investigación coherentes, tales como "*Energy Efficiency and Sustainability*", "*Sectoral Applications & Monitoring of Critical Failures*", "*Digital Twins & Asset Management*" y "*Foundational Technologies & Advanced Methodologies*".

En síntesis, la extensión de la búsqueda bibliográfica, la integración de técnicas de análisis semántico y la evaluación mixta (cuantitativa y cualitativa) han permitido identificar de forma más robusta las tendencias, fortalezas y vacíos en la literatura reciente, sentando las bases para la próxima generación de aplicaciones industriales en mantenimiento inteligente y optimización de activos.

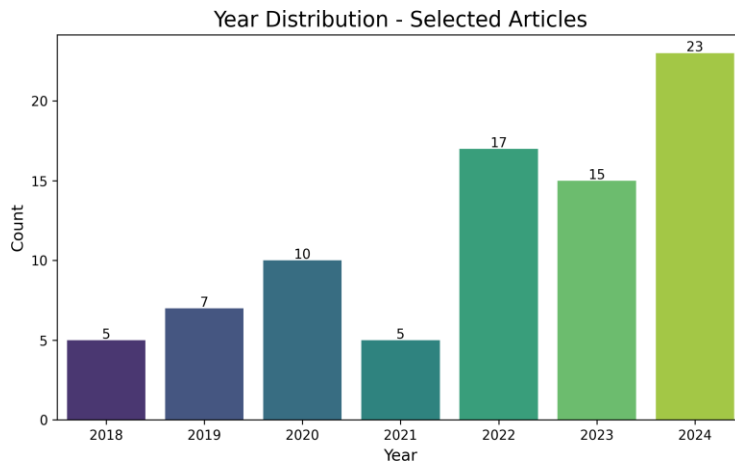


Fig. 7: Distribución temporal de las publicaciones consideradas en la RSL.

HALLAZGOS Y SÍNTESIS DE CLUSTERS

Cluster 1: Aplicaciones de Inteligencia Artificial en el Sector de Energías Renovables

El primer cluster identificado en nuestro análisis bibliométrico se centra en la creciente y significativa aplicación de la Inteligencia Artificial (IA) y, en particular, las técnicas de Machine Learning (ML) en el sector de las energías renovables. Este cluster, compuesto por ocho artículos, revela una tendencia consolidada hacia la optimización, el

análisis y la mejora de la eficiencia en diversas tecnologías de energía sostenible, abarcando desde sistemas fotovoltaicos y eólicos hasta la gestión de subestaciones eléctricas y transformadores de distribución. La motivación subyacente de estas investigaciones radica en la necesidad de maximizar la eficiencia, reducir costos operativos y mejorar la sostenibilidad de las fuentes de energía renovable, elementos cruciales para la transición energética global (Dubey *et al.*, 2022; Marquez & Gonzalo, 2022; Tiwari, 2023).

Un hilo conductor prominente en este cluster es la aplicación de IA para la optimización y el control de sistemas fotovoltaicos (PV). Kumar *et al.* (2024) y Kumar *et al.* (2022), destacan la creciente complejidad y el volumen de datos generados en los sistemas PV modernos, lo que demanda soluciones automatizadas e inteligentes para su gestión. Kumar *et al.* (2024), en su revisión sistemática, exploran exhaustivamente el rol de los algoritmos de IA en el diseño, la previsión y el mantenimiento de sistemas fotovoltaicos, subrayando el potencial de estas técnicas para abordar los desafíos computacionales y la gestión de grandes volúmenes de datos. Esta perspectiva se complementa con el análisis de Kumar *et al.* (2022), quienes se centran específicamente en la predicción de la generación de energía fotovoltaica mediante ML, resaltando las oportunidades y dimensiones de un marco computacional robusto para este fin. La capacidad de predecir con precisión la generación de energía solar es vital para la integración efectiva de la energía fotovoltaica en las redes eléctricas y para la planificación operativa y de mantenimiento.

En la misma línea de las energías renovables, la energía eólica emerge como otro foco importante dentro de este cluster. Dubey *et al.* (2022), presentan una revisión exhaustiva de los sistemas inteligentes para la predicción de energía eólica utilizando ML, considerando factores cruciales como el costo de mantenimiento, la producción de energía eólica y la gestión de periodos sin viento. Este estudio enfatiza la necesidad de enfoques innovadores para maximizar el aprovechamiento de la energía eólica, dada su naturaleza variable, y destaca la utilidad de diversas técnicas de ML como *Support Vector Machines* (SVM), *K-Nearest Neighbors* (KNN) y *Redes Neuronales Convolucionales* (CNN) para lograr predicciones precisas. Complementariamente, Marquez y Gonzalo (2022), ofrecen una revisión comprehensiva de la IA en la energía eólica, reforzando la importancia de la IA como herramienta clave en la gestión y optimización de este recurso renovable.

Más allá de la generación, el cluster también aborda la aplicación de la IA en la gestión de la infraestructura eléctrica asociada a las energías renovables. Zheng *et al.* (2022) (artículo retractado, pero inicialmente incluido en la búsqueda), exploran la aplicación de la IA en la operación y el mantenimiento de subestaciones eléctricas en China, un contexto donde la expansión de la red eléctrica y la demanda de eficiencia son prioritarias. Si bien uno de este artículo fue retractado, refleja el interés en la inteligencia artificial para mejorar la gestión de subestaciones, resaltando la búsqueda de soluciones inteligentes para desafíos operativos complejos. En un contexto similar, de Freitas *et al.* (2018), investigan el uso de Redes Neuronales Artificiales (RNA) en transformadores de distribución inmersos en aceite vegetal, con el objetivo de estimar la temperatura del aceite y, consecuentemente, la vida útil del transformador. Este trabajo demuestra cómo la IA puede contribuir a la gestión del mantenimiento de estos componentes críticos, comparando incluso el rendimiento con transformadores que utilizan aceite mineral, y destacando el potencial de la IA para la optimización económica y la gestión del mantenimiento.

Finalmente, Tiwari (2023), proporciona una visión panorámica del rol de la IA en el sector de la energía sostenible en su conjunto. El estudio evalúa la capacidad de los algoritmos de IA para superar los métodos convencionales en aspectos fundamentales como la estabilidad, la gestión de grandes volúmenes de datos, la operación de redes inteligentes, la optimización del ahorro energético y la gestión planificada del mantenimiento para energías renovables. La conclusión principal de Tiwari (2023) es que la IA se erige como un componente esencial para el futuro del sector energético, instando a las industrias, empresas y administradores de redes eléctricas a priorizar la adopción de tecnologías de IA para alcanzar mejores resultados en la sostenibilidad y eficiencia del sector.

En síntesis, el Cluster 1 pone de manifiesto la profunda y multifacética influencia de la Inteligencia Artificial en el sector de las energías renovables. Los estudios incluidos abarcan un amplio espectro de aplicaciones, desde la optimización de la generación y predicción de energía solar y eólica, hasta la mejora de la gestión y el mantenimiento de infraestructuras críticas como subestaciones y transformadores. La síntesis de estos hallazgos

converge en la idea de que la IA no solo es una herramienta prometedora, sino un componente fundamental para el desarrollo y la sostenibilidad del sector energético en el siglo XXI.

Cluster 2: Mantenimiento Predictivo en la Industria 4.0: Optimización y Aplicaciones de Machine Learning

El segundo *cluster* temático se consolida como un núcleo robusto en la investigación actual, al agrupar estudios que abordan el **Mantenimiento Predictivo (PdM)** en el marco de la **Industria 4.0**, con énfasis especial en la *aplicación y optimización de algoritmos de Machine Learning (ML)*. Este enfoque adquiere relevancia por la confluencia de varios factores determinantes: la creciente complejidad de los procesos industriales, la digitalización y la interconexión masiva de equipos, y la gran cantidad de datos operativos generados de manera continua (Çinar *et al.*, 2020; Hoffmann & Lasch, 2024). En suma, la Industria 4.0 ofrece el escenario idóneo para la implementación de PdM avanzado, potenciando la capacidad de los modelos de ML para detectar fallos incipientes, optimizar recursos de mantenimiento y minimizar el riesgo de paradas no planificadas (*Unplanned Downtime*, UPDT).

Optimización de Sistemas de Mantenimiento Inteligente

Varios artículos subrayan la optimización de *Intelligent Maintenance Systems (IMS)* orientados a la Industria 4.0. En particular, Thongtam *et al.* (2024), describen el uso de algoritmos de búsqueda en espacio de estados (*State Space Search*, SSS) para determinar la secuencia de mantenimiento más apropiada, atendiendo simultáneamente a la reducción de costos y a la ampliación de la vida útil de los activos. Esta línea de investigación cobra importancia a medida que las plantas inteligentes (*smart factories*) requieren estrategias de mantenimiento *ad hoc* para hacer frente a flujos productivos variables y exigentes, tal como se observa en trabajos previos sobre integración de Big Data y PdM inteligente (Del Buono *et al.*, 2022).

Predicción del Estado de Salud de Maquinaria Crítica

Dentro de este *cluster*, se destaca el interés por los métodos de *Machine Learning* para la predicción del estado de salud de maquinaria y componentes esenciales en entornos de alto impacto, como aeromotores o motores diésel de gran capacidad. Por ejemplo, Szrama (2024), aborda el análisis de aceite en turbinas aeronáuticas utilizando algoritmos de ML robustos para la extracción de características químicas, estableciendo correlaciones con el estado de salud de los motores turbofan. Este enfoque ilustra la capacidad transformadora de la IA para automatizar el diagnóstico de fallos y optimizar la gestión del mantenimiento, reduciendo los tiempos de revisión manual y minimizando riesgos operativos (Pourramezan & Rohani, 2024; Devi *et al.*, 2024). Igualmente, estos hallazgos son coherentes con la evidencia en sistemas rotativos y CNC, donde la interpretabilidad de los modelos de ML se ha convertido en un factor clave para la adopción en entornos críticos (Nikfar *et al.*, 2022; Mbilong *et al.*, 2023).

Planificación Predictiva del Mantenimiento en la Industria 4.0

La *planificación predictiva* (PdM planning) constituye otro eje temático central. Estudios como Abidi *et al.* (2022) proponen marcos de planificación que integran modelado data-driven, IoT (Internet of Things) y BIM (*Building Information Modeling*) para mejorar la vida útil de componentes mecánicos, eléctricos y de fontanería (MEP). Al emplear redes neuronales avanzadas (Abidi *et al.*, 2022; Cheng *et al.*, 2020), combinadas con técnicas híbridas de optimización, es posible estimar con mayor precisión la condición futura de los activos y definir calendarios de mantenimiento más rentables y sostenibles. Esta línea de investigación converge con otras iniciativas orientadas a la automatización de la clasificación de fallos, la asignación proactiva de recursos y la toma de decisiones estratégica (Thongtam *et al.*, 2024; Mbilong *et al.*, 2023).

Clasificación Automatizada y Calidad de Datos de Mantenimiento

Un aspecto notable del *cluster* es la *clasificación automatizada de datos de mantenimiento*, la cual aborda la calidad, consistencia y completitud de la información recolectada. Hong *et al.* (2022), diseñan un enfoque sistemático para manejar datos faltantes e inconsistentes en bases de mantenimiento de edificaciones (p.ej., HVAC en entornos universitarios). Empleando algoritmos como SVM, Random Forest y perceptrones multicapa, alcanzan precisiones superiores al 85%. Por su parte, André *et al.* (2023), examina la aplicación de modelos de ML para priorizar recomendaciones de inspección técnica (TIRs), mostrando la utilidad del procesamiento de

lenguaje natural (*NLP*) para categorizar la criticidad de las actividades de mantenimiento. Estas iniciativas refuerzan la tendencia general a aprovechar datos textuales y semiestructurados, integrando ML con técnicas de limpieza y normalización de datos para la toma de decisiones (Abidi *et al.*, 2022; Lima *et al.*, 2019).

Perspectiva Global y Revisiones Exhaustivas de la IA en Mantenimiento

Por último, el *cluster* cita revisiones integradoras como las de Hoffmann & Lasch (2024) y Çinar *et al.* (2020), que agrupan y evalúan algoritmos punteros de mantenimiento *data-driven*. Hoffmann & Lasch (2024), presentan una taxonomía exhaustiva para la selección de enfoques de IA en diversos escenarios de mantenimiento, mientras que Çinar *et al.* (2020), se centra en una visión más panorámica de la manufactura inteligente y la categorización de técnicas ML. Estas revisiones no solo proporcionan un sustento teórico, sino que también guían las prácticas de implementación, resaltando la progresiva madurez de la IA como herramienta vertebral para el Mantenimiento Predictivo en la Industria 4.0.

En definitiva, el Cluster 2 evidencia la evolución consistente de la Industria 4.0 hacia la *digitalización extendida del mantenimiento*, articulada con *algoritmos avanzados de ML* para la optimización y predicción de fallos. Las contribuciones abarcan desde la planificación del mantenimiento basada en datos, hasta la gestión inteligente de *health states* en motores críticos y la optimización de rutinas de IMS. La convergencia de técnicas (p.ej., redes neuronales profundas, algoritmos genéticos, procesamiento de texto) impulsa la *ubicuidad del PdM*, con resultados concretos en eficiencia operacional y competitividad industrial (Szrama, 2024; Pourramezan & Rohani, 2024; Hong *et al.*, 2022; André *et al.*, 2023).

Al incorporar volúmenes masivos de datos en entornos *cyber-physical*, se refuerza la idea de un mantenimiento más *proactivo* y *autónomo*, capaz de reducir drásticamente los costos y las interrupciones en la producción. En coherencia con otros *clusters* (como el 5 y el 6, centrados en IoT y Big Data), las líneas aquí mostradas confirman la importancia crítica del ML en la Industria 4.0, tanto para la manufactura como para industrias de gran escala, incluido el sector minero y energético. De esta forma, el Cluster 2 concluye subrayando el carácter estratégico del *mantenimiento predictivo inteligente* en el futuro de la producción industrial.

Cluster 3: Mantenimiento Predictivo y Gestión de Calidad en Producción (versión ampliada y mejorada)

El tercer *cluster* examinado se enfoca en la *integración del Mantenimiento Predictivo (PdM) con la Gestión de Calidad (Quality Management)* en entornos de producción, subrayando cómo estas dos perspectivas pueden converger para mejorar la eficiencia y la competitividad en distintas industrias (Tiwari, 2023). En contraste con las soluciones más centradas en la digitalización pura o en la adopción tecnológica (Cluster 2), aquí se explora la *dimensión holística* del mantenimiento, en la que la calidad del producto, la optimización de recursos y la sostenibilidad del sistema productivo resultan estrechamente vinculadas al PdM.

Convergencia entre Mantenimiento Predictivo y Mejora Continua

Varios estudios proponen que la inclusión de estrategias de PdM en los ciclos de mejora continua (*continuous improvement*) aporta resultados significativos en la *reducción de defectos*, la *minimización de reprocesos* y la *garantía de calidad final* en líneas de producción (Tiwari, 2023; Lima *et al.*, 2019).

Control Estadístico de Procesos (CEP) y Machine Learning

Este *cluster* también revela la *sinergia* entre técnicas de Control Estadístico de Procesos (CEP) y algoritmos de Machine Learning para la supervisión en tiempo real y la detección temprana de condiciones anómalas (Alam *et al.*, 2022; Ahmed *et al.*, 2021). Se han identificado casos en los que redes neuronales convolucionales (CNN) o métodos *ensemble* complementan el análisis de cartas de control, permitiendo predecir desviaciones en parámetros críticos de producción antes de que se vean comprometidos los indicadores de calidad (Hoffmann & Lasch, 2024; Gkerekos *et al.*, 2019). Así, la adopción simultánea de CEP y ML ofrece una cobertura más exhaustiva de los posibles modos de fallo o deterioro en la línea de producción, contribuyendo a incrementar la robustez y fiabilidad del sistema.

Mantenimiento Preventivo vs. Predictivo: un Escenario de Transición

Otro aspecto clave que emerge en este *cluster* es la discusión en torno a la transición desde mantenimientos reactivos o preventivos basados en intervalos fijos hacia *mantenimientos predictivos* basados en modelos de IA (Cheng *et al.*, 2020). En muchas organizaciones, el mantenimiento preventivo ha sido históricamente la práctica estándar por su simplicidad, aunque adolece de ineficiencias y costos excesivos cuando los intervalos no reflejan la condición real del activo. Al integrar algoritmos de ML para analizar datos procedentes de sensores, históricos de paradas y resultados de inspección, se logra elaborar planes de mantenimiento *dinámicos* que ajustan la periodicidad y el alcance de las intervenciones, maximizando la disponibilidad de la maquinaria y asegurando la calidad final del producto.

Rol de la Cultura de Calidad en la Implantación del PdM

La literatura también resalta que la adopción de PdM, si bien depende de herramientas analíticas, requiere una *cultura organizacional* orientada a la calidad y a la mejora continua (Tiwari, 2023; André *et al.*, 2023). En este sentido, la coordinación entre los departamentos de producción, mantenimiento e ingeniería de calidad resulta determinante para el éxito de los proyectos de transformación digital (Lima *et al.*, 2019; Ahmed *et al.*, 2021). Estudios de caso muestran que la falta de capacitación o la resistencia al cambio pueden limitar la eficacia de las soluciones de ML, aun cuando los resultados técnicos sean prometedores. Por el contrario, cuando hay un compromiso transversal con la *excelencia operativa*, el PdM se convierte en un pilar estratégico para mantener la competitividad en mercados globales de alta exigencia (Thongtam *et al.*, 2024).

En síntesis, el Cluster 3 proporciona una visión holística de cómo el Mantenimiento Predictivo puede integrarse con la Gestión de Calidad, potenciando la mejora continua y la productividad en las líneas de producción. La adopción de algoritmos de ML para la detección de fallas, la monitorización de la condición del activo y el aseguramiento de la calidad del producto evidencia un camino claro hacia la manufactura inteligente y sostenible. Esta visión es coherente con otros clústers (por ejemplo, el 2 y el 8), donde la *optimización de estrategias* y la *gestión de recursos* soportadas por IA impulsan la competitividad industrial. Además, el énfasis en la cultura de calidad como factor crítico de éxito sugiere que las organizaciones que combinen la capacitación de sus equipos humanos con la inversión en tecnologías de IA lograrán mayor sostenibilidad y satisfacción del cliente en el largo plazo.

Cluster 4: Mantenimiento Predictivo y Reconocimiento de Patrones en Infraestructuras Ferroviarias (versión ampliada y mejorada)

El Cluster 4 se caracteriza por su enfoque especializado en la aplicación de técnicas de *Machine Learning (ML)* al *mantenimiento predictivo y el reconocimiento de patrones en infraestructuras ferroviarias*, con un énfasis particular en el desempeño de los *interruptores de vía (railway switches)*. Tales infraestructuras representan puntos críticos para la seguridad y eficiencia del transporte, dada la complejidad de su operación y el riesgo de fallas que pueden interrumpir el servicio (Muñoz del Río *et al.*, 2024; Kasraei & Garmabaki, 2024; Martinez, 2025).

Reconocimiento de Patrones mediante ML en Interruptores de Vía

Este núcleo temático subraya la relevancia de algoritmos de ML para identificar y clasificar patrones de comportamiento en los *interruptores de vía*, elementos que posibilitan el cambio de ruta en el sistema ferroviario (del Río *et al.*, 2022; Muñoz del Río *et al.*, 2024). Por ejemplo, Muñoz del Río *et al.* (2024), presenta un enfoque que combina análisis estadístico segmentado de curvas de potencia con técnicas de clasificación supervisada (p.ej., K-Nearest Neighbors, Support Vector Machines) para detectar anomalías en el movimiento de los interruptores.

De manera complementaria, del Río *et al.* (2022), describen la aplicación de algoritmos avanzados de aprendizaje automático para capturar tempranamente desviaciones en la traza de potencia, permitiendo la *anticipación de fallos* y reduciendo así los costos de mantenimiento.

La precisión conseguida (superior al 90% con KNN y SVM) evidencia la capacidad de ML para extraer información crítica de las señales de operación, validando su aplicación en escenarios con alta variabilidad y condiciones

ambientales exigentes (del Río *et al.*, 2022). Estos estudios confirman la pertinencia de una *monitorización proactiva* que anticipe fallas en infraestructuras ferroviarias, un sector donde los paros inesperados representan fuertes pérdidas económicas y, en especial, riesgos para la seguridad de pasajeros.

Robustez de Activos Ferroviarios ante Alteraciones Climáticas

Otra dimensión de este *cluster* aborda la *resiliencia de los activos ferroviarios frente a condiciones climáticas* adversas (Kasraei & Garmabaki, 2024). Estudios como los de Kasraei & Garmabaki (2024), proponen modelos predictivos basados en ML para clasificar y mitigar fallas en redes ferroviarias, incorporando variables geográficas y climáticas (e.g., temperatura extrema, precipitaciones nevadas, inundaciones). Este enfoque adquiere relevancia en regiones donde el cambio climático incrementa la frecuencia de eventos extremos y amplifica la vulnerabilidad de las vías y de los interruptores de vía.

La capacidad de categorizar activos de acuerdo con zonas climáticas o condiciones meteorológicas prevalentes facilita una *gestión más documentada y eficiente* del mantenimiento, priorizando intervenciones en los segmentos de la red con mayor propensión a fallos. Además, el uso de algoritmos de agrupamiento y clasificación supervisada contribuye a generar *alertas tempranas*, reforzando las políticas de seguridad y reduciendo drásticamente el *downtime* (Tiware, 2023; Martinez, 2025). Así, la aplicación de IA en infraestructuras ferroviarias no solo optimiza el mantenimiento, sino que también fortalece la resiliencia ante los efectos de un entorno cambiante.

Convergencia con Otras Áreas Industriales

Si bien este *cluster* se centra en el sector ferroviario, sus hallazgos se conectan con otros sectores analizados en la RSL, como la energía renovable (Cluster 1) y la manufactura (Cluster 2). La *versatilidad de ML* demostrada en la detección y predicción de fallos bajo condiciones operativas altamente variables (Lemache-Caiza *et al.*, 2023) confirma la adopción transversal de la IA para la transformación digital en industrias críticas. Tanto en turbinas eólicas como en equipos ferroviarios, la *monitorización continua*, la robustez ante entornos cambiantes y la capacidad de predecir fallas marcan la pauta hacia un mantenimiento inteligente.

En conjunto, el Cluster 4 enfatiza la *aplicación efectiva de Machine Learning para solventar problemas críticos de mantenimiento* en infraestructuras ferroviarias, particularmente en los interruptores de vía. A través de métodos estadísticos y algoritmos de ML para el *reconocimiento avanzado de patrones*, se consigue una detección precoz de anomalías, así como una anticipación de potenciales fallos. Asimismo, la incorporación del factor climático extiende el alcance del PdM, permitiendo diseñar estrategias adaptativas para la preservación y operatividad de la red ferroviaria frente a fenómenos extremos.

Las implicaciones son significativas en términos de *reducción de costos* y *mejora de la seguridad*, consolidando a la IA y el ML como *herramientas indispensables* para la evolución del mantenimiento de infraestructuras críticas (Muñoz del Río *et al.*, 2024, Kasraei & Garmabaki, 2024). Este panorama se alinea con la tendencia general a migrar de técnicas reactivas hacia un *mantenimiento predictivo integral*, potenciando la optimización de activos en sectores tan diversos como la minería, la energía y la manufactura avanzada.

Cluster 5: Aplicaciones Diversas del Mantenimiento Predictivo con Machine Learning e IoT (versión ampliada y mejorada)

El Cluster 5 se caracteriza por la *amplitud de sus áreas de aplicación* en materia de Mantenimiento Predictivo (PdM), resaltando el valor transversal de *Machine Learning (ML)* y *IoT* como habilitadores principales. Las contribuciones en este núcleo abarcan desde la manufactura inteligente y el procesamiento a alta presión, hasta la gestión de *equipos médicos* y el mantenimiento de motores rotativos y turbojets (Calabrese *et al.*, 2020; Lemache-Caiza *et al.*, 2023; Roque *et al.*, 2022; Srisuwan & Innet, 2024). Esta diversidad ilustra la versatilidad del PdM para abordar problemáticas en diferentes sectores, dando continuidad a la tendencia observada en otros *clusters*, donde las técnicas de ML e IoT se adaptan de manera flexible a diversos contextos industriales (Vijayalakshmi *et al.*, 2024).

PdM en Manufactura y Procesamiento de Alta Presión

Uno de los focos principales de este *cluster* se ubica en la *manufactura inteligente*, incluyendo la industria de la madera, la metalmecánica y los procesos de producción. Calabrese *et al.* (2020) y Del Buono *et al.* (2022), por ejemplo, describen el sistema *SOPHIA*, una solución basada en eventos y big data para predecir la vida útil de máquinas carpinteras, demostrando cómo un *framework* IoT-ML puede escalar a cientos de máquinas y analizar terabytes de datos de registro. Las prácticas de monitorización continua permiten anticipar fallos en motores, rodamientos y mecanismos, reduciendo la inactividad y mejorando la eficiencia de la línea de producción.

Complementariamente, Srisuwan & Innet (2024), se concentran en *procesos de alta presión*, donde la integridad del equipo y la gestión del mantenimiento constituyen elementos críticos para sostener la productividad y la seguridad operativa. El empleo de algoritmos de ML, en particular métodos de clasificación y redes neuronales, ha probado su eficacia en la detección de anomalías y la programación proactiva de intervenciones, aliviando los costos de paradas no planificadas y la necesidad de mantenimientos preventivos excesivamente conservadores. Estos ejemplos, en conjunto, confirman la sólida posición de ML en la manufactura 4.0, tal como se ve en otros *clusters* (2 y 6).

PdM en el Sector Médico

Otra dimensión notable en este *cluster* concierne al *mantenimiento de equipos médicos*, un ámbito con requerimientos de confiabilidad extremadamente elevados, dada la importancia de asegurar la disponibilidad y exactitud de dispositivos de diagnóstico y tratamiento (AL-Tahat & Al-Rifa'e, 2023; Zamzam *et al.* 2023). Por ejemplo, AL-Tahat y Al-Rifa'e (2023), aborda la mejora del *Mean Time Between Failure (MTBF)* y la disponibilidad de equipos de resonancia magnética (MRI) mediante el análisis de datos de fallas históricas y el desarrollo de modelos predictivos de ML. Asimismo, Zamzam *et al.* (2023), propone un *framework* de análisis de fallos que integra ML para la gestión inteligente del mantenimiento de equipos clínicos, enfatizando la necesidad de guiar a los ingenieros hospitalarios en la asignación y priorización de recursos.

La relevancia de la IA en el campo médico coincide con la tendencia a automatizar y optimizar la toma de decisiones en sistemas críticos —similar a lo que se observa en la minería y en la energía eólica (Rodríguez *et al.*, 2023; Devi *et al.*, 2024). Al igual que en otros sectores, la capacidad de predecir fallos de manera temprana conlleva una reducción de costos y, en este caso, un impacto directo en la seguridad y atención de los pacientes.

Mantenimiento de Motores Rotativos y Turbojets

El *mantenimiento de maquinaria rotativa y motores aeronáuticos* completa el panorama de este *cluster*. Roque *et al.* (2022), plantea algoritmos de ML para reducir costos de mantenimiento en máquinas rotativas de entornos industriales, enfatizando la *predicción de fallos* y la recomendación de intervenciones antes de la avería. Este planteo coincide con la adopción de métodos de monitoreo de vibraciones y análisis de temperaturas, demostrado exitosamente en industrias de procesos químicos o refinerías (Nikfar *et al.*, 2022; Velmurugan *et al.*, 2023).

Por otro lado, Lemache-Caiza *et al.* (2023), examina el uso de ML para la detección temprana de fallos en *turbojets de doble flujo*, apoyándose en datos del Centro de Predicción de la NASA. Los hallazgos subrayan la alta precisión de algoritmos como *Random Forest* para discriminar patrones de falla incipiente, validando la utilidad de estas soluciones en la industria aeroespacial. Dada la similitud en la monitorización de variables críticas (presiones, temperaturas, vibraciones), se aprecia una posible *transferencia de conocimientos* hacia otros equipos rotativos de gran escala (p.ej., molinos y chancadoras en minería).

El Cluster 5 evidencia la *versatilidad y ubicuidad* del mantenimiento predictivo potenciado por ML e IoT, abarcando un abanico de sectores que trasciende la manufactura convencional para involucrar procesos de alta presión, equipamiento médico y motores de aplicación aeronáutica. Estas experiencias refuerzan los *hallazgos de Clusters 1 y 2*, subrayando la adopción transversal del PdM como estrategia central para aumentar la eficiencia operativa, reducir costos y mejorar la fiabilidad en ambientes industriales dispares (Calabrese *et al.*, 2020; Roque *et al.*, 2022; Srisuwan & Innet, 2024; Zamzam *et al.*, 2023).

En su conjunto, este *cluster* también deja en claro que la *conectividad IoT* juega un papel sustantivo: la recolección masiva de datos y la posibilidad de analizarlos en la nube o en el borde (*edge computing*) permiten la detección de señales de fallo más sutiles y la implantación de *protocolos de mantenimiento proactivos*. La potencialidad de ML en el diagnóstico y la predicción se integra de manera natural con la infraestructura IoT, constituyendo un *círculo virtuoso* en la gestión de activos. De esta forma, el Mantenimiento Predictivo mantiene su papel protagónico como *catalizador de competitividad* en los diferentes sectores industriales que requieran alta disponibilidad y seguridad en la operación de sus equipos.

Cluster 6: Mantenimiento Predictivo Inteligente en Sistemas Industriales: IIoT, Big Data y Diagnóstico Avanzado (versión ampliada y mejorada)

El Cluster 6 agrupa un conjunto de investigaciones enfocadas en la **implementación de enfoques de Mantenimiento Predictivo (PdM) de vanguardia** en sistemas industriales complejos. Dicho enfoque se sustenta principalmente en la adopción del *Industrial Internet of Things* (IIoT), la analítica de *Big Data* y el *diagnóstico avanzado* mediante *Machine Learning* (ML). La confluencia de estas tres tecnologías potencia la obtención y el análisis de datos en tiempo real, habilitando estrategias de mantenimiento cada vez más precisas, proactivas y escalables (Del Buono *et al.*, 2022; Mbilong *et al.*, 2023; Vijayalakshmi *et al.*, 2024).

Monitorización Continua e IIoT en Sistemas Industriales

Uno de los pilares de este *cluster* es la **monitorización continua y la detección de anomalías** a través de redes IIoT. Velmurugan *et al.* (2023), proponen un sistema de detección de anomalías y gestión del mantenimiento para *máquinas rotativas* industriales, cimentado en el monitoreo en tiempo real de variables como vibración y temperatura. La infraestructura IIoT posibilita la transmisión ininterrumpida de datos relevantes, superando los desafíos de la distancia geográfica y las condiciones adversas a menudo presentes en plantas de manufactura o zonas mineras (Roque *et al.*, 2022; Nikfar *et al.*, 2022).

En el campo de la **transmisión de datos** en sistemas críticos, Zhao & Wang (2024) y Orellana *et al.* (2024), profundizan en la aplicación de Big Data para optimizar la operación y el mantenimiento de equipos de transmisión radioeléctrica. Así, la capacidad de manejar grandes volúmenes de datos (incluso no estructurados) permite el descubrimiento de patrones y la extracción de *insights* predictivos que los métodos convencionales de monitoreo difícilmente podrían detectar (Devi *et al.*, 2024; Vijayalakshmi *et al.*, 2024).

Diagnóstico Inteligente de Fallas con ML y Big Data

La *detección inteligente de fallos* mediante IA se enfatiza en estudios, tales como; Devi *et al.* (2024), Mbilong *et al.* (2023) y Garcia *et al.* (2025), los cuales demuestran cómo las arquitecturas de *Deep Learning* —tales como LSTM y autoencoders— pueden incrementar la capacidad de predecir fallos en tiempo real. La detección anticipada de anomalías es especialmente crítica en *maquinaria CNC* y motores de gran potencia, donde una *parada no planeada* puede suponer costos cuantiosos e interrumpir gravemente la cadena productiva (Mbilong *et al.*, 2023; Nikfar *et al.*, 2022).

Por ejemplo, Devi *et al.* (2024), describen el uso de un mecanismo de bloqueo con un autoencoder LSTM para la prevención de fallos en maquinaria industrial, apuntando a la preservación de la operación continua y la seguridad del sistema. Mientras tanto, Nikfar *et al.* (2022), proponen un modelo de ML en dos fases para el mantenimiento predictivo de *motores de baja tensión*, clasificando posibles modos de fallo y anticipando acciones correctivas. Estos aportes validan la adopción de frameworks de ML integrados con Big Data, capaces de identificar secuencias de deterioro en entornos con alta variabilidad y ruido (Roque *et al.*, 2022; Calabrese *et al.*, 2020).

Aplicaciones Específicas: Sector Eólico y Equipos Médicos

El sector eólico también gana protagonismo en este *cluster*. Rodriguez *et al.* (2023), realizan un análisis exploratorio de datos SCADA (*Supervisory Control and Data Acquisition*) en turbinas eólicas mediante algoritmos de *clustering* (p. ej., K-Means), revelando patrones anómalos que permiten optimizar la estrategia de mantenimiento y disminuir los costos de inactividad (Jiménez *et al.*, 2018). Estas prácticas enlazan de forma

natural con los hallazgos del Cluster 1 en energías renovables y ratifican la necesidad de una vigilancia permanente, reforzada por metodologías de ML.

Por otro lado, la aplicación del PdM en **equipos médicos** demuestra la amplitud de los escenarios cubiertos. Haowei *et al.* (2023), describen un sistema de predicción del ciclo de vida para dispositivos de diagnóstico ECG e incubadoras, mientras Venegas *et al.* (2022), desarrollan herramientas basadas en termografía infrarroja y ML para mantenimiento electrónico en la industria petrolera y de hidrocarburos. Si bien se trata de sectores aparentemente disímiles, comparten el requisito de una elevada confiabilidad en la operación y la imposibilidad de tolerar fallos catastróficos (Zamzam *et al.*, 2023; AL-Tahat & Al-Rifa'e, 2023).

Monitorización Acústica y otras Técnicas Avanzadas de Detección

Paralelamente, se destacan **métodos de monitorización no invasiva** como la *monitorización acústica* o la *termografía infrarroja*, demostrando su eficacia como enfoques de diagnóstico complementarios en el PdM (Aradi & Varga, 2024; Venegas *et al.*, 2022). Por ejemplo, Aradi y Varga (2024), proponen el uso de *Machine Learning* en señales acústicas para detectar cambios sutiles en la operación de servomotores, un aspecto de particular valor en líneas de producción automatizadas. La *combinación* de estos métodos con modelos de ML contribuye a un cuadro más completo del estado de salud del activo, habilitando diagnósticos y pronósticos significativamente más precisos (Roque *et al.*, 2022; Hong *et al.*, 2022).

El Cluster 6 enfatiza la posición central del *Mantenimiento Predictivo Inteligente* como un paradigma clave para la gestión de activos en la Industria 4.0. A través de la adopción masiva de **IIoT**, el análisis intensivo de **Big Data** y las herramientas de **ML avanzado**, los estudios reunidos demuestran cómo la detección temprana de anomalías y la predicción de fallos se vuelven más robustas y escalables (Devi *et al.*, 2024; Mbilong *et al.*, 2023; Vijayalakshmi *et al.*, 2024; Velmurugan *et al.*, 2023). La incorporación de enfoques innovadores, desde el aprendizaje federado hasta la monitorización acústica, ilustra la riqueza metodológica que puede aplicarse en distintos sectores, desde la manufactura y la energía eólica hasta la salud y las telecomunicaciones. En conjunto, los hallazgos de este *cluster* reflejan la *madurez y sofisticación* crecientes del PdM en la era de la transformación digital, reforzando la relevancia de un enfoque basado en datos y analítica avanzada para la optimización de costos, la mejora de la fiabilidad y la apuesta por la competitividad en mercados globales.

Cluster 7: Optimización del Proceso de Desarrollo de Bucles de Corrosión en Tuberías de Petróleo y Gas (versión ampliada y mejorada)

El Cluster 7, compuesto por un conjunto reducido de artículos (Rachman & Ratnayake, 2020) se aboca a la *optimización del proceso de desarrollo de bucles de corrosión en sistemas de tuberías de petróleo y gas*. Pese a su alcance más restringido, este cluster aborda un problema crítico y altamente especializado, dada la importancia de la corrosión como factor determinante en la *integridad y seguridad* de las infraestructuras de transporte y procesamiento de hidrocarburos. La corrosión no solo plantea riesgos de fugas o roturas, sino que también involucra costos operativos y ambientales significativos (Hoffmann & Lasch, 2024; Lima *et al.*, 2019).

Complejidad del Desarrollo de Bucles de Corrosión

El término *bucles de corrosión* (*corrosion loops*) alude a la agrupación de tramos de tubería con características y condiciones operativas similares (e.g., material, presión de trabajo, composición química del fluido), con el fin de optimizar las actividades de inspección y mantenimiento. Tradicionalmente, la definición de dichos bucles conlleva *procesos de análisis manual* e intensivo de ingeniería, demandando un volumen considerable de horas-hombre [Rachman and Ratnayake, 2020]. Además, la variabilidad en las metodologías y el juicio de los expertos puede producir resultados inconsistentes y poca trazabilidad en la toma de decisiones.

Sinergia entre Machine Learning y Group Technology (GT)

Una de las contribuciones clave de Rachman & Ratnayake (2020), radica en la *combinación de Machine Learning (ML) y la metodología de Group Technology (GT)* para automatizar y estandarizar el desarrollo de bucles de

corrosión. La *Group Technology* se fundamenta en identificar y agrupar componentes o procesos con características afines para maximizar la eficiencia de la manufactura y la gestión de procesos (García *et al.*, 2022). En este contexto, la GT facilita la *clasificación y estandarización* de tuberías, reduciendo la redundancia de evaluaciones e incrementando la coherencia de los resultados. Paralelamente, los algoritmos de ML se enfocan en ***analizar grandes volúmenes de datos*** relacionados con la corrosión—por ejemplo, datos de inspección, composición de fluidos y condiciones operativas—*identificando patrones predictivos* y optimizando los parámetros del proceso de desarrollo de bucles (Borroto-Pentón *et al.*, 2021; Tiwari, 2023).

El interés de esta aproximación radica en su capacidad de *disminuir el tiempo* y la *variabilidad en los resultados*, correlacionando datos históricos de corrosión con modelos de predicción, y proponiendo esquemas de mitigación más eficientes. La naturaleza crítica de los sistemas de petróleo y gas resalta la relevancia de contar con herramientas fiables, pues una falla en la tubería puede desencadenar costos muy elevados en reparaciones, pérdidas de producción y daños ambientales (Rachman & Ratnayake, 2020).

Implicaciones Económicas y Operativas

Aunque el trabajo de Rachman & Ratnayake (2020), no detalla exhaustivamente los algoritmos de ML o la cuantificación precisa de los resultados, la propuesta subraya un incremento notable en la eficiencia y la predictibilidad del desarrollo de bucles de corrosión. Al reducir el tiempo requerido para clasificar y agrupar los segmentos de tubería, las empresas pueden:

- Optimizar sus planes de inspección y mantenimiento, centrándose en las áreas con mayor potencial de falla.
- Ajustar la asignación de recursos (e.g., personal, costos de inspección) con base en criterios de riesgo y estado real de la infraestructura.
- Evitar la excesiva variabilidad en la toma de decisiones, generando mayor consistencia y confiabilidad en las estrategias de mitigación de la corrosión.

En sectores con fuertes restricciones de seguridad y alta regulación, como el petróleo y el gas, la adopción de metodologías basadas en IA y GT puede suponer una *ventaja competitiva* en términos de reducción de costos operativos, planificación más precisa y sostenibilidad de largo plazo (Alqaili *et al.*, 2021).

Conexiones con la Industria 4.0 y la Transformación Digital

Si bien la corrosión se ha estudiado tradicionalmente desde un prisma más químico y mecánico, la aparición de la Industria 4.0 impulsa la recolección sistemática de datos, la implementación de sensores en línea y el uso de sistemas de gestión del mantenimiento asistidos por IA (Thongtam *et al.*, 2024; Goti *et al.*, 2019). Este *cluster* enlaza con esa línea, confirmando que la integración de ML y GT no sólo mejora la eficiencia en la definición de bucles de corrosión, sino que allana el camino para la creación de *modelos predictores* y *digital twins* que supervisen la salud de la infraestructura de manera continua (Devi *et al.*, 2024).

En conclusión, Cluster 7 pone en evidencia *la adaptabilidad de las técnicas de Machine Learning* para solucionar problemas altamente específicos y críticos en el sector de petróleo y gas, como la corrosión en tuberías de transporte. La combinación de *Group Technology* y ML propuesta en Rachman & Ratnayake (2020), ilustra un mecanismo para *reducir el tiempo* y la *variabilidad* en la creación de bucles de corrosión, brindando al mismo tiempo una *base de datos más rigurosa* para la planificación de actividades de inspección y mitigación de riesgos. A pesar de su carácter especializado, esta metodología resulta representativa de la tendencia global hacia la *adopción del mantenimiento inteligente* impulsado por la analítica de datos, confirmando la *versatilidad y el poder de la IA* para abordar nichos sectoriales de gran relevancia económica y social.

Cluster 8: Optimización y Priorización en la Gestión de Mantenimiento con Machine Learning

El Cluster 8 pone el foco en la ***optimización y priorización de decisiones en la gestión de mantenimiento***, empleando *Machine Learning* (ML) como herramienta de soporte analítico y estratégico. Este grupo de estudios muestra cómo distintas técnicas de aprendizaje automático pueden mejorar la eficacia de la toma de decisiones en diferentes fases

del proceso de mantenimiento, ya sea optimizando parámetros críticos, definiendo políticas de intervención o priorizando recursos en situaciones con presupuesto limitado (Ahmed *et al.*, 2021; Lima *et al.*, 2019; Liu *et al.*, 2024).

Optimización Multi-Objetivo de Procesos Industriales Complejos

Varios trabajos resaltan la *optimización multiobjetivo* de procesos industriales mediante ML. Por ejemplo, Liu *et al.* (2024), propone un marco de optimización multicriterio para plantas de tratamiento de aguas residuales, integrando algoritmos de ML interpretable y métodos de búsqueda global (p. ej., NSGA-II). El objetivo es equilibrar factores como la eficiencia del proceso, los costos operativos y la huella ambiental. Con la interpretabilidad de los modelos de ML, los decisores pueden comprender las relaciones entre las variables y justificar las acciones más adecuadas. Esto cobra importancia en sectores críticos o fuertemente regulados, donde la aceptación de un modelo predictivo depende de su transparencia y robustez (Tiwari, 2023; Rojas *et al.*, 2025).

Priorización de Activos en Mantenimiento 4.0

Otro aspecto destacado de este *cluster* es la *priorización de activos* bajo la óptica del Mantenimiento 4.0, donde confluyen la digitalización, el IoT y la analítica avanzada (Lima *et al.*, 2019; Tiwari, 2023). Por ejemplo, (Lima *et al.*, 2019; Orellana *et al.*, 2024) aplica técnicas de ML al método de toma de decisiones AHP (Analytic Hierarchy Process), contribuyendo a automatizar la asignación de recursos de mantenimiento según criterios de costo, criticidad y riesgos. Dado que los activos industriales pueden presentar demandas o frecuencias de fallos muy distintas, contar con un *modelo computacional* que procese grandes volúmenes de datos históricos y características de diseño se convierte en una ventaja competitiva (Ahmed *et al.*, 2021; Goti *et al.*, 2019).

Mantenimiento en Instalaciones Sanitarias y Modelos Neutrosóficos

Un caso singular se presenta en la *priorización del mantenimiento en instalaciones sanitarias* (por ej., hospitales y clínicas), un entorno con requerimientos críticos de seguridad y disponibilidad (Ahmed *et al.*, 2021). Aquí se introduce el uso de *Machine Learning Neutrosófico*, una variante de ML que facilita la modelación de incertidumbres y niveles de subjetividad. Esta propuesta se orienta a optimizar el proceso de renovación y mantenimiento de activos (e.g., sistemas HVAC, equipos de esterilización), un escenario altamente complejo por la cantidad y variedad de equipos, y la necesidad de un servicio continuo para la atención de pacientes. Este ejemplo confirma la adaptabilidad del ML para escenarios donde la fiabilidad de los activos es un factor crítico que impacta directamente en la seguridad y el bienestar (Alqailli *et al.*, 2021; Hong *et al.*, 2022).

Conexión con Otros Clusters y Perspectiva General

Los trabajos de optimización y priorización aquí descritos guardan coherencia con la necesidad transversal de mejorar la gestión del mantenimiento en ambientes productivos complejos (Clusters 2 y 3) y en infraestructuras críticas (Cluster 4). Además, la consideración de *múltiples objetivos*—costo, riesgo, impacto ecológico— se alinea con tendencias contemporáneas de *sostenibilidad industrial* y *responsabilidad social* (Tiwari, 2023).

El Cluster 8 pone de relieve la importancia del *Machine Learning* no sólo para detectar y predecir fallos, sino también para **optimizar y priorizar** la gestión de mantenimiento de forma integral y estratégica. Al contemplar criterios múltiples y la modelización de incertidumbre, se potencia la decisión basada en datos (*data-driven maintenance planning*), logrando una asignación de recursos más eficiente y reduciendo la dependencia de metodologías puramente reactivas o de mantenimiento preventivo tradicional (Ahmed *et al.*, 2021; Lima *et al.*, 2019; Liu *et al.*, 2024; Garcia *et al.*, 2025). Así, el desarrollo de *Sistemas de Soporte a la Decisión* (DSS) y de algoritmos híbridos de optimización se presenta como una vía prometedora para la evolución del mantenimiento inteligente hacia entornos 4.0 y más allá, beneficiando industrias que van desde las plantas de tratamiento de aguas hasta el cuidado de la salud.

Cluster 9: Optimización Multi-Objetivo para la Gestión del Mantenimiento de Pavimentos con Recursos Limitados

El Cluster 9, a pesar de contar con apenas dos artículos (Alqailli *et al.*, 2021), aborda un tema de **gran interés práctico**: la *optimización multiobjetivo en la gestión del mantenimiento de pavimentos*, especialmente en *países en desarrollo* con presupuestos anuales restringidos. Este enfoque resalta la aplicación de algoritmos de *Machine Learning*

(ML) en un campo que, tradicionalmente, se ha apoyado en métodos más convencionales de planificación y asignación de recursos para la conservación de infraestructuras viales (Abbondati *et al.*, 2023; Marcelino *et al.*, 2020).

Contexto de Pavimentos con Recursos Limitados

La gestión de pavimentos resulta crítica en muchos países donde la infraestructura vial está sujeta a alto desgaste, presupuestos acotados y, frecuentemente, planificación ineficiente (Alqaili *et al.*, 2021; Jin *et al.*, 2023). Bajo estas condiciones, resulta imprescindible adoptar metodologías que equilibren objetivos potencialmente en conflicto, como la *maximización de la calidad del pavimento* y la *minimización de los costos de mantenimiento*. Dada la variabilidad de los factores climáticos, el uso intensivo de las vías y la escasez de datos de calidad, la aplicación de ML abre nuevas vías para la toma de decisiones más precisas y fundamentadas (Ahmed *et al.*, 2021; Lima *et al.*, 2019).

Integer Search Algorithm (ISA) y Comparación con Algoritmo Genético

El centro de la propuesta en Alqaili *et al.* (2021), es el desarrollo de un *nuevo algoritmo multi-objetivo*, llamado *Integer Search Algorithm (ISA)*, diseñado para optimizar la gestión del mantenimiento de pavimentos. El ISA se orienta a la selección simultánea de soluciones que maximicen el *Performance Condition Rating (PCR)* de la vía, al tiempo que minimizan los costos totales. La comparación con un algoritmo genético (GA) permite validar la eficacia del ISA en contextos donde las variables de decisión son discretas —algo usual en planes de mantenimiento vial— y en escenarios realistas con alta variabilidad de parámetros (Abbondati *et al.*, 2023; Lima *et al.*, 2019). Además de la maximización del PCR, se contempla la disponibilidad de recursos en un horizonte trianual (tres años), otorgando a las agencias de transporte una *estrategia de planificación de mediano plazo* y permitiendo una mejor adaptación a ciclos presupuestarios y requerimientos de servicio (Jin *et al.*, 2023).

Aportaciones al Campo de la Infraestructura Civil

La novedad principal de este *cluster* radica en la capacidad de aplicar *técnicas metaheurísticas avanzadas* para afrontar los desafíos de la optimización multiobjetivo en la administración de pavimentos. El ISA —combinado con GA— demuestra el potencial de los algoritmos de ML y optimización para tratar problemas intrínsecamente complejos, donde la decisión de *cuándo y cómo intervenir* en cada segmento de la vía impacta en la durabilidad global y en la asignación eficiente de recursos limitados (Alqaili *et al.*, 2021). Esta línea de investigación se hace eco de tendencias observadas en sectores como la *minería* (donde también se aplican algoritmos multiobjetivo para planificar el mantenimiento de equipos mina (Lima *et al.*, 2019; Alqaili *et al.*, 2021) y en la *industria manufacturera* (que optimiza la producción y el mantenimiento en sistemas complejos (Çinar *et al.*, 2020; Goti *et al.*, 2019). En tal sentido, la *modularidad* de estos algoritmos facilita su adopción en otras infraestructuras como puentes, aeropuertos o redes ferroviarias.

En definitiva, el Cluster 9 pone de relieve el papel fundamental de las *técnicas de optimización multi-objetivo* (ISA y GA) en la ***gestión de pavimentos con recursos escasos***. Al introducir metodologías basadas en ML y metaheurísticas, no solo se refinan las decisiones de mantenimiento, sino que también se ajustan a la realidad económica y operativa de países en desarrollo, donde priorizar intervenciones se torna esencial para sostener la calidad de las infraestructuras y promover el desarrollo social y económico (Alqaili *et al.*, 2021). Así, la convergencia de estos algoritmos con métodos de evaluación del estado de la vía como el PCR refuerza la necesidad de una *ingeniería de pavimentos* orientada a datos, permitiendo a las agencias viales maximizar el impacto de inversiones limitadas y salvaguardar la seguridad vial.

Cluster 10: Predicción del Deterioro y Rendimiento de Pavimentos mediante Machine Learning (versión ampliada y mejorada)

El Cluster 10 concentra su atención en la ***predicción del deterioro y del rendimiento de pavimentos***, re-
alzando el uso de *Machine Learning (ML)* como catalizador para la gestión eficiente de infraestructuras viales y aeroportuarias. Se destacan aspectos críticos de la planeación de mantenimiento, así como la optimización de los recursos necesarios para garantizar la seguridad y la continuidad operativa de los tramos de pavimento (Abbondati *et al.*, 2023; Marcelino *et al.*, 2020).

Predicción del Deterioro de la Fricción en Pistas Aeroportuarias

Uno de los tópicos relevantes en este *cluster* es la ****predicción del deterioro de la fricción**** en pistas de aeropuertos. Abbondati *et al.* (2023), proponen la aplicación de un *Sistema Adaptativo Neuro-Fuzzy de Inferencia (ANFIS)* para cuantificar la pérdida de fricción a lo largo del tiempo. La fricción del pavimento influye directamente en la maniobrabilidad de las aeronaves y, por ende, en la seguridad operacional; una disminución imprevista puede incrementar los riesgos de deslizamiento y complicar las rutinas de aterrizaje y despegue (Abbondati *et al.*, 2023; Borroto-Pentón *et al.*, 2021). Al modelar de forma robusta las relaciones no lineales entre variables (p. ej., tipo de asfalto, carga de tráfico, factores climáticos), ANFIS contribuye a una gestión de mantenimiento más planificada, asignando los recursos donde más se requieren y evitando interrupciones dispendiosas en la operatividad aeroportuaria.

Rendimiento de Pavimentos en Contextos de Datos Limitados y Aprendizaje por Transferencia

Otro punto clave gira en torno a la ****predicción del rendimiento de pavimentos cuando se dispone de datos limitados****, una problemática frecuente para agencias de carreteras con infraestructuras extensas y escasa monitorización histórica (Marcelino *et al.*, 2020). Para enfrentar esta situación, Marcelino *et al.* (2020), proponen un esquema de *aprendizaje por transferencia (Transfer Learning)* que reutiliza el conocimiento adquirido en proyectos con datos abundantes para mejorar la eficiencia de los modelos predictivos en dominios con datos reducidos. Esta metodología resulta valiosa al capacitar a las agencias viales para desarrollar modelos de gestión más precisos y confiables, a pesar de las brechas de información. La aplicación de Transfer Learning en pavimentos además demuestra la flexibilidad de ML para adentrarse en escenarios con restricción de datos y alta heterogeneidad de condiciones geotécnicas (Ahmed *et al.*, 2021; Alqailli *et al.*, 2021).

Aportaciones a la Planeación de Mantenimiento y Seguridad Vial

Los ejemplos de predicción de fricción y rendimiento refuerzan la idea de que las herramientas de ML pueden integrarse en *Sistemas de Soporte a la Decisión (DSS)* para optimizar la planeación de mantenimientos a corto, mediano y largo plazo (Jin *et al.*, 2023). La detección temprana de signos de deterioro y la estimación confiable de la vida útil remanente de los tramos de pavimento permiten programar intervenciones preventivas o correctivas en franjas temporales de menor tráfico, o en intervalos en los que el impacto económico sea mínimo (Abbondati *et al.*, 2023; Lima *et al.*, 2019). Se garantiza así la seguridad del tráfico y se contribuye a evitar el deterioro abrupto de la infraestructura.

Convergencia con Otros Clusters y Proyecciones

Este *cluster* guarda nexos con el *Cluster 9* (mantenimiento de pavimentos con recursos restringidos), pues ambos subrayan la necesidad de una aproximación sofisticada —incluyendo ML y técnicas de optimización— para la definición de políticas de mantenimiento. Además, se alinea con iniciativas vistas en sectores como ferroviario (*Cluster 4*) o manufactura (*Cluster 2*) en las que la predicción de deterioro y la asignación de mantenimiento juegan un papel crucial en la continuidad operativa y la optimización de costos (Muñoz del Río *et al.*, 2024).

En resumen, *Cluster 10* evidencia la capacidad de ****Machine Learning**** para abordar *desafíos críticos en la gestión de pavimentos*, desde la pérdida de fricción en pistas de aeropuertos hasta la predicción del rendimiento de carreteras con datos limitados. El uso de modelos ANFIS o Transfer Learning ilustra la variedad de aproximaciones que se pueden adoptar, todas con la meta común de *maximizar la seguridad vial, optimizar el uso de los recursos y prolongar la vida útil de la infraestructura*. Estas soluciones, combinadas con la digitalización creciente y la posibilidad de sensorización masiva, preparan el terreno para un mantenimiento proactivo y eficiente, alineado con la búsqueda de mayor sostenibilidad y competitividad en el sector transporte.

Cluster 11: Predicción Inteligente para la Operación Segura y Eficiente de Sistemas Complejos (versión ampliada y mejorada)

El *Cluster 11* reúne estudios dedicados a la ****predicción inteligente de fallos**** y la ****operación segura**** de sistemas intrínsecamente complejos y de alto impacto, desde infraestructuras hidráulicas como presas de tierra y roca hasta motores de barcos en la industria marítima (Gkerekos *et al.*, 2019; Liu *et al.*, 2024). Aun cuando los

sectores a los que pertenecen estos trabajos parezcan dispares, la constante que los une es la aplicación de *Machine Learning* (ML) para pronosticar el comportamiento de sistemas cuyo fallo podría ocasionar consecuencias catastróficas o muy costosas.

Seguridad de Presas de Tierra y Roca

Uno de los ejes centrales de este *cluster* se vincula con la ****seguridad de presas****, infraestructuras críticas para la gestión de recursos hídricos y la prevención de desastres naturales (Liu *et al.*, 2024). La filtración (*seepage pressure*) es un indicador clave de la estabilidad de una presa; si la presión se incrementa en exceso, la integridad estructural puede verse comprometida. Liu *et al.* (2024), presentan un *modelo combinado de optimización y predicción*, fusionando múltiples técnicas de ML y descomposición de datos para manejar las señales no estacionarias propias de los registros de filtración. Este enfoque data-driven reconoce la importancia de procesar datos reales de la operación y mantenimiento de las presas, brindando un nivel superior de exactitud en la anticipación de potenciales riesgos. La seguridad de las presas no solo depende de la supervisión local de ingenieros y operadores; la integración de ML permite *extraer patrones* de grandes bases de datos históricos y correlacionar factores externos (p.ej., precipitaciones, cambios de temperatura) con la filtración y tensiones internas (Liu *et al.*, 2024; Borroto-Pentón *et al.*, 2021). Así, la adopción de soluciones de IA potencia la capacidad de respuesta y la agilidad ante riesgos de falla, reduciendo la dependencia de metodologías exclusivamente empíricas.

Industria Marítima: Predicción de Consumo de Combustible en Motores Principales

En un viraje temático, pero bajo la misma lógica de *predicción inteligente*, el *cluster* también incluye estudios sobre la ****industria marítima****, un sector esencial en la logística global y en la explotación de petróleo y gas en alta mar (Gkerekos *et al.*, 2019). Gkerekos *et al.* (2019), abordan el reto de *predecir el consumo de combustible de los motores principales de barcos*, un factor de alto impacto económico y medioambiental. Mediante la comparativa de diversos modelos de ML—Support Vector Machines, Random Forest Regressors, Extra Trees Regressors, e incluso redes neuronales—, se concluye que la predicción precisa del consumo de combustible habilita la optimización de rutas y la reducción de costos operativos, además de minimizar emisiones contaminantes. El *consumo de combustible* se relaciona profundamente con la *eficiencia y sostenibilidad* de las operaciones marítimas. Un pronóstico preciso permite a las navieras y compañías de servicios *programar escalas, estimar costos de transporte* y, en el caso de la exploración petrolera en alta mar, *asegurar el abastecimiento crítico* de combustible para la tripulación y las labores de perforación (Gkerekos *et al.*, 2019). El papel de ML se concentra en distinguir patrones a partir de variables como la velocidad de navegación, las condiciones meteoceánicas y la carga del buque, factores que influyen notoriamente en el rendimiento del motor.

Uniones Temáticas: Complejidad, Seguridad y Eficiencia

La diversidad de aplicaciones en este *cluster* no reduce su coherencia interna, ya que en ambos casos (presas y motores marítimos) confluyen la *seguridad y la operación eficiente* como ejes transversales. Las presas requieren un control riguroso de la estabilidad estructural para evitar catástrofes naturales, mientras que la industria marítima enfatiza la gestión del combustible para mantener la competitividad y la sostenibilidad. La IA se erige, por tanto, como un *instrumento de anticipación*, capaz de detectar anomalías y predecir evoluciones futuras de señales complejas.

Conexiones con Otros Clusters y Conclusiones

Este *cluster* complementa la panorámica de la RSL, mostrando cómo ML impacta en sistemas con alta complejidad física y riesgos inherentes. La monitorización de presas se vincula con la implementación de Big Data y diagnóstico avanzado (Cluster 6) y con la adopción de metodologías proactivas de mantenimiento (Cluster 2). Por otro lado, la optimización del combustible en el sector marítimo entronca con técnicas de optimización multiobjetivo (Cluster 8 y 9) y la toma de decisiones basada en datos.

En síntesis, Cluster 11 ejemplifica el poder de la *predicción inteligente* para la ****operación segura y eficiente**** de sistemas complejos. Los estudios sobre seguridad de presas y consumo de combustible de barcos confirman que la capacidad de anticipar comportamientos —gracias a algoritmos de ML— es decisiva para reducir riesgos, optimizar recursos y avanzar en la *sostenibilidad de las actividades industriales y de infraestructura*.

Cluster 12: Optimización de Umbrales y Decisiones en Mantenimiento Basado en Condición (versión ampliada y mejorada)

El Cluster 12 representa un avance hacia la ****sofisticación del Mantenimiento Basado en Condición (CBM)****, enfatizando la *optimización de umbrales de intervención* y la *toma de decisiones* orientada por datos. Este grupo de estudios, compuesto por seis investigaciones interrelacionadas, profundiza en la necesidad de refinar las estrategias de CBM más allá de la simple detección de fallos, incorporando modelos de *optimización analítica* que eleven la eficiencia y rentabilidad del mantenimiento (Boroto-Pentón et al., 2021; Goti et al., 2019; Jin et al., 2023; Durga Prasad & Radhakrishna, 2019).

Determinación de Umbrales de Mantenimiento Óptimos

Varios trabajos (Jin et al., 2023; Devi et al., 2024) abordan directamente la ****definición de umbrales de intervención**** en un esquema CBM. Mediante *modelos costo-beneficio*, se busca identificar el punto óptimo para realizar actividades preventivas que minimicen el gasto total —incluyendo costos correctivos y riesgos de falla— sin sacrificar la fiabilidad del sistema. A menudo se emplean *algoritmos evolutivos multiobjetivo* para equilibrar factores económicos y de riesgo, navegando en un espacio de soluciones con múltiples criterios en conflicto (Goti et al., 2019). Por ejemplo, establecer umbrales de intervención demasiado conservadores puede disparar los costos preventivos, mientras que umbrales muy altos podrían incrementar la probabilidad de fallos costosos.

Simulación del Estado de Equipo y Múltiples Eventos

En esta línea, Jin et al. (2023), introducen una *metodología innovadora* para simular la evolución del estado del equipo y optimizar los umbrales de mantenimiento considerando la influencia de *múltiples eventos* (p. ej., choques inesperados, fallas parciales, detenciones de producción). Al incorporar la naturaleza dinámica y multifactorial de los entornos operativos, esta aproximación habilita una adaptación más realista de los umbrales de CBM, ajustada a situaciones donde el deterioro no es lineal ni uniforme (Abidi et al., 2022; Devi et al., 2024). La simulación iterativa, apoyada en datos de condición y técnicas de aprendizaje automático, permite diseñar políticas de mantenimiento *proactivas y adaptativas*, ideales en industrias con elevada variabilidad de carga o condiciones ambientales exigentes.

Aplicaciones Multi-Objetivo en Cadenas Industriales Complejas

Además de la optimización de umbrales, se encuentran trabajos que extienden el *uso de algoritmos evolutivos multiobjetivo* a la *gestión integral de CBM en cadenas industriales complejas* (Goti et al., 2019). Esta perspectiva sistémica considera que cada activo puede influir en el estado de otros activos dentro de la misma línea de producción o infraestructura, por lo que la decisión de mantenimiento para un equipo no puede tomarse de forma aislada. La optimización a nivel de sistema o cadena industrial maximiza la eficiencia global del mantenimiento, equilibrando costos y riesgos a lo largo de múltiples equipos y procesos (Thongtam et al., 2024; Lima et al., 2019).

Sistemas de Soporte a la Decisión (DSS) y Aplicaciones en Infraestructuras Críticas

Una vertiente aplicada de este *cluster* engloba el desarrollo de *Sistemas de Soporte a la Decisión* (DSS) para la optimización de activos físicos. Durga Prasad y Radhakrishna (2019), describen un DSS con enfoque de *optimización de activos* (IAO) específicamente para *subestaciones eléctricas*, infraestructuras críticas en el suministro de energía. La relevancia radica en integrar datos de condición, modelos predictivos y métodos de optimización multi-objetivo para *generar recomendaciones de mantenimiento fundamentadas y estratégicas*. Este enfoque emula la adopción de DSS en otros clústeres (p. ej., 2 y 8), donde el *machine learning* y la analítica de datos conforman la base para decisiones más informadas (Radhakrishna, 2019; Tiwari, 2023).

Contribución General y Perspectiva de Futuro

Boroto-Pentón et al. (2021), ofrecen una revisión panorámica del estado del arte en la *optimización aplicada al mantenimiento de activos físicos*, contextualizando las investigaciones de este *cluster* en un marco más amplio. Se resalta el creciente papel de la *analítica avanzada*, el *machine learning* y las *técnicas de optimización* como herramientas esenciales para enfrentar los desafíos contemporáneos del mantenimiento industrial (Çinar et al., 2020; Hoffmann & Lasch, 2024; Rojas et al., 2025).

El Cluster 12 consolida la imagen de un *Mantenimiento Basado en Condición (CBM)* en plena evolución, donde la *optimización analítica* y la *toma de decisiones* basadas en datos adquieren un rol central. Desde la definición de *umbrales óptimos* de intervención (evitando el “sobre-mantenimiento” y el “bajo-mantenimiento”) hasta la *implementación de DSS* y la *optimización multiobjetivo* en cadenas industriales, los trabajos aquí reunidos demuestran el *potencial transformador* de la IA y las técnicas de ML para llevar el CBM a un nivel superior de madurez y eficiencia (Jin *et al.*, 2023; Goti *et al.*, 2019; Durga Prasad & Radhakrishna, 2019). En consonancia con otros clústeres, la sinergia entre machine learning, optimización y enfoques híbridos constituye el camino para la *industria inteligente del siglo XXI* y la gestión avanzada de activos en sectores clave como la energía, la manufactura y la infraestructura crítica.

DISCUSIÓN

La síntesis exhaustiva de los clusters temáticos revela un panorama multifacético y dinámico del Mantenimiento Predictivo (PdM) impulsado por *Machine Learning (ML)*. A través del análisis meticuloso de la literatura científica, se ha configurado una estructura comprensiva que no solo delimita las áreas de aplicación predominantes, sino que también ilumina las tendencias emergentes y los desafíos persistentes en este campo en constante evolución. Esta discusión profundizará en la interpretación de estos hallazgos, explorando sus implicaciones teóricas y prácticas, reconociendo las limitaciones inherentes al cuerpo de conocimiento actual y proyectando futuras líneas de investigación que prometen expandir las fronteras del PdM inteligente.

El análisis clusterial consolida la posición central del Mantenimiento Predictivo como un paradigma esencial en la gestión de activos industriales contemporánea, trascendiendo su rol tradicionalmente reactivo para erigirse como un componente estratégico en la optimización de la eficiencia, la seguridad y la sostenibilidad en diversos sectores (Tiwari, 2023; Vijayalakshmi *et al.*, 2024). La Industria 4.0 emerge como un catalizador fundamental en esta transformación, impulsando la adopción masiva del PdM gracias a la convergencia de tecnologías habilitadoras como el Internet de las Cosas (IoT), el Big Data y, fundamentalmente, el Machine Learning (Devi *et al.*, 2024). La capacidad de estas tecnologías para monitorizar continuamente el estado de los activos, analizar ingentes volúmenes de datos y generar predicciones precisas sobre el deterioro y los fallos, representa un salto cualitativo en la gestión del mantenimiento, permitiendo a las organizaciones transitar hacia modelos proactivos y anticipatorios que optimizan la toma de decisiones y la asignación de recursos.

La diversidad sectorial identificada en los clusters, abarcando desde las energías renovables y la manufactura avanzada hasta las infraestructuras ferroviarias, la industria marítima y el sector salud, subraya la universalidad y adaptabilidad del PdM inteligente (Lemache-Caiza *et al.*, 2023; Roque *et al.*, 2022; Srisuwan & Innet, 2024; Abbondati *et al.*, 2023; Gkerekos *et al.*, 2019; Ahmed *et al.*, 2021). Esta ubicuidad refleja la creciente madurez y confianza en las técnicas de ML como herramientas robustas y versátiles para abordar desafíos de mantenimiento en contextos operativos heterogéneos y complejos. No obstante, la especialización temática de clusters como el 7 y el 9, enfocados en problemas nicho como la corrosión en tuberías de petróleo y gas y la gestión de pavimentos en economías en desarrollo respectivamente (Rachman & Ratnayake, 2020; Alqaili *et al.*, 2021), pone de manifiesto la capacidad de la investigación en PdM para generar soluciones altamente especializadas y adaptadas a problemáticas sectoriales concretas, trascendiendo las aplicaciones generalistas y abordando desafíos específicos con un alto grado de granularidad y precisión.

Un hallazgo recurrente y transversal a lo largo de los clusters es la importancia creciente de la optimización en la gestión del mantenimiento. Clusters como el 8 y el 12 se centran explícitamente en la optimización multi-objetivo, la priorización de decisiones y la definición de umbrales óptimos de intervención en esquemas CBM (Lima *et al.*, 2019; Liu *et al.*, 2024; Jin *et al.*, 2023; Goti *et al.*, 2019; Durga Prasad & Radhakrishna, 2019). Esta tendencia hacia la optimización analítica refleja la evolución del PdM desde la mera predicción de fallos hacia la maximización del valor generado por las estrategias de mantenimiento, buscando no solo prevenir averías sino también optimizar costos, recursos y rendimiento global de los activos. La utilización de algoritmos evolutivos multiobjetivo, sistemas de soporte a la decisión (DSS) y técnicas de interpretabilidad del ML (Goti *et al.*, 2019; Durga Prasad & Radhakrishna, 2019;) subraya la creciente sofisticación de las herramientas y metodologías empleadas para la toma de decisiones estratégicas y operativas en el ámbito del mantenimiento inteligente.

Las implicaciones de estos hallazgos son significativas tanto para la investigación futura como para la práctica industrial en el ámbito del mantenimiento. Desde una perspectiva investigadora, se abre un abanico de oportunidades para profundizar en la exploración de nuevas técnicas de ML y optimización aplicadas a problemas de mantenimiento cada vez más complejos y específicos. La investigación futura podría enfocarse en el desarrollo de modelos predictivos más robustos y adaptativos, capaces de integrar información multivariada, considerar la incertidumbre inherente a los datos operativos y generalizar su aplicabilidad a diferentes tipos de activos y entornos industriales. La interpretabilidad y explicabilidad de los modelos de ML emerge como un área de investigación crucial, buscando no solo mejorar la precisión predictiva sino también la comprensión de los mecanismos de fallo y deterioro, facilitando la toma de decisiones informadas y justificadas por parte de los gestores del mantenimiento. Asimismo, la investigación en algoritmos de optimización multiobjetivo y DSS promete generar herramientas más sofisticadas y eficientes para la planificación estratégica del mantenimiento, la asignación óptima de recursos y la gestión integral de activos en entornos industriales complejos y dinámicos.

Desde una perspectiva práctica, los hallazgos de esta síntesis robustecen el caso de negocio para la adopción e implementación del Mantenimiento Predictivo Inteligente en una amplia gama de industrias. La evidencia científica acumulada en los clusters demuestra el potencial tangible del PdM para reducir costos de mantenimiento, minimizar tiempos de inactividad, mejorar la eficiencia operativa, incrementar la seguridad y extender la vida útil de los activos (Roque *et al.*, 2022; Abbondati *et al.*, 2023; Jin *et al.*, 2023). Para las empresas, la inversión en sistemas de PdM impulsados por ML e IoT se presenta no solo como una estrategia para optimizar el mantenimiento sino también como una ventaja competitiva sostenible, permitiendo mejorar la eficiencia productiva, la calidad del producto, la satisfacción del cliente y, en última instancia, la rentabilidad global del negocio. En sectores específicos como la minería, la aplicación de técnicas de PdM inteligente, inspiradas en los hallazgos de clusters como el 4, 5 y 6, ofrece un camino concreto para optimizar el mantenimiento de equipos mina críticos, desde molinos y chancadoras hasta sistemas de transporte y equipos móviles, contribuyendo a mejorar la productividad, la seguridad y la sostenibilidad de las operaciones mineras.

Es fundamental reconocer las limitaciones inherentes a esta síntesis y al campo de investigación del PdM con ML en general. La heterogeneidad de las metodologías, los conjuntos de datos y las métricas de evaluación empleadas en los estudios analizados dificulta la comparación directa y la generalización de los resultados. La escasez de estudios longitudinales y validaciones en entornos industriales reales a gran escala limita la evidencia empírica sobre el impacto a largo plazo y la rentabilidad de las implementaciones de PdM inteligente. Además, la complejidad inherente a los sistemas industriales implica que los modelos de ML, por sofisticados que sean, son inherentemente aproximaciones de la realidad, y su precisión y robustez pueden verse afectadas por factores no modelados o eventos imprevistos.

En este contexto, las futuras líneas de investigación deberían enfocarse en abordar estas limitaciones y expandir las fronteras del conocimiento en PdM inteligente. Se requiere mayor rigor metodológico y estandarización en la investigación, promoviendo la utilización de conjuntos de datos de referencia, métricas de evaluación comunes y protocolos de validación robustos que faciliten la comparación y replicabilidad de los estudios. Es crucial fomentar la investigación aplicada y la colaboración entre la academia y la industria, llevando las innovaciones del PdM inteligente a entornos operativos reales y evaluando su impacto en condiciones industriales diversas y a gran escala. La investigación en técnicas de ML robustas y explicables, capaces de lidiar con la incertidumbre, la variabilidad y la complejidad de los sistemas industriales, representa un área de alto potencial para mejorar la fiabilidad, la interpretabilidad y la confianza en las soluciones de PdM inteligente. Finalmente, la exploración de nuevas áreas de aplicación del PdM inteligente, en sectores menos investigados o en problemáticas emergentes como la sostenibilidad y la resiliencia de las infraestructuras, promete expandir el alcance y el impacto del mantenimiento predictivo en el futuro.

En la Tabla 2 articula una discusión comparativa de los hallazgos clave en Mantenimiento Predictivo (PdM) con Machine Learning (ML), delineando tres perspectivas complementarias que convergen en la transformación profunda del mantenimiento industrial en la era digital. La *Perspectiva 1* destaca el cambio de paradigma del PdM,

impulsado por la Industria 4.0, desde una función reactiva a un rol estratégico en la gestión de activos, donde la digitalización redefine las prácticas tradicionales (See-To *et al.*, 2023; Zhao & Wang, 2024; Vijayalakshmi *et al.*, 2024). La *Perspectiva 2* enfatiza la ubicuidad y adaptabilidad del PdM inteligente, validado en una diversidad de sectores industriales y con soluciones especializadas para nichos específicos, subrayando la madurez y versatilidad de estas técnicas (Roque *et al.*, 2022; Lemache-Caiza *et al.*, 2023; Abbondati *et al.*, 2023; Ahmed *et al.*, 2021; Rachman & Ratnayake, 2020; Alqaili *et al.*, 2021). Finalmente, la *Perspectiva 3* reconoce los desafíos inherentes y proyecta las líneas futuras de investigación, instando a la comunidad científica a superar limitaciones metodológicas, validar empíricamente las soluciones de PdM inteligente a gran escala y desarrollar modelos más robustos, explicables y adaptativos.

El Machine Learning emerge como el hilo conductor que une estas perspectivas, catalizando la evolución del PdM hacia un paradigma inteligente, capaz de generar predicciones precisas, optimizar la toma de decisiones y transformar radicalmente la gestión de activos industriales (Devi *et al.*, 2024; Durga Prasad & Radhakrishna, 2019; Mbilong *et al.*, 2023; Vijayalakshmi *et al.*, 2024; Rachman & Ratnayake, 2020; Alqaili *et al.*, 2021; Liu *et al.*, 2024; Goti *et al.*, 2019). La optimización, en sus múltiples facetas (multiobjetivo, asignación de recursos, definición de umbrales), se revela como un objetivo central del PdM inteligente, buscando maximizar el valor generado por las estrategias de mantenimiento y transitar hacia una gestión proactiva y anticipatoria (Jin *et al.*, 2023; Goti *et al.*, 2019; Durga Prasad & Radhakrishna, 2019; Lima *et al.*, 2019; Ahmed *et al.*, 2021; Alqaili *et al.*, 2021).

Tabla 2: Discusión Comparativa de Hallazgos Clave y su Aplicación al Mantenimiento Minero en Chile

Tema Central	Perspectiva 1: Paradigma PdM y Industria 4.0	Perspectiva 2: Optimización y Diversidad Sectorial	Perspectiva 3: Desafíos y Futuro del PdM Inteligente
Rol del PdM	PdM trasciende el mantenimiento reactivo, integrándose como estrategia central en la Industria 4.0, impulsando eficiencia, seguridad y sostenibilidad (Vijayalakshmi <i>et al.</i> , 2024). La digitalización redefine el mantenimiento industrial (See-To <i>et al.</i> , 2023).	PdM se consolida como paradigma ubicuo y adaptable a diversos sectores (energía, manufactura, infraestructuras) (Roque <i>et al.</i> , 2022; Lemache-Caiza <i>et al.</i> , 2023; Abbondati <i>et al.</i> , 2023; Ahmed <i>et al.</i> , 2021). Soluciones especializadas emergen para nichos industriales (Rachman & Ratnayake, 2020; Alqaili <i>et al.</i> , 2021).	El futuro del PdM demanda superar limitaciones metodológicas y empíricas. Se requiere rigor, validación a gran escala y modelos más robustos y explicables.
Machine Learning (ML)	ML como catalizador de la transformación del PdM, permitiendo predicciones precisas y toma de decisiones optimizada (Devi <i>et al.</i> , 2024, Durga Prasad & Radhakrishna, 2019). IIoT y Big Data potencian el PdM inteligente (Mbilong <i>et al.</i> , 2023, Vijayalakshmi <i>et al.</i> , 2024).	ML se adapta a problemáticas específicas, desde corrosión en petróleo y gas hasta pavimentos (Rachman & Ratnayake, 2020; Alqaili <i>et al.</i> , 2021). Optimización multi-objetivo con ML para gestión integral del mantenimiento (Liu <i>et al.</i> , 2024; Goti <i>et al.</i> , 2019).	Desarrollar ML interpretable y explicable es crucial para la confianza y adopción del PdM. Investigación futura debe enfocarse en robustez y generalización de modelos ML.
Optimización y Decisión	PdM evoluciona hacia la optimización del valor del mantenimiento, maximizando eficiencia y rentabilidad (Jin <i>et al.</i> , 2023; Goti <i>et al.</i> , 2019). DSS y algoritmos evolutivos para decisiones estratégicas y operativas (Durga Prasad & Radhakrishna, 2019).	Optimización de recursos limitados en contextos específicos (ej., pavimentos en países en desarrollo) (Alqaili <i>et al.</i> , 2021). Priorización de activos y optimización de la asignación de recursos de mantenimiento (Lima <i>et al.</i> , 2019; Ahmed <i>et al.</i> , 2021).	Necesidad de herramientas de optimización más sofisticadas y adaptativas a sistemas industriales complejos. Investigación futura en DSS integrados y optimización dinámica del mantenimiento.
Aplicación en Minería Chilena	PdM inteligente esencial para plantas de procesos de minerales y equipos mina en Chile. Reduce costos, minimiza paradas, mejora seguridad y extiende vida útil.	Diversidad de equipos mineros (molinos, chancadoras, correas) se benefician del PdM. Adaptabilidad del PdM a condiciones operativas extremas en minería chilena (altura, clima árido, etc.).	Validación empírica del PdM inteligente en minería chilena es crucial. Desarrollar modelos predictivos robustos y adaptados a la minería local. Formación de capital humano especializado en PdM para la minería.

En el contexto específico del mantenimiento minero en plantas de procesos de minerales en Chile, los hallazgos sintetizados en esta tabla adquieren una relevancia estratégica innegable. La industria minera chilena, pilar fundamental de la economía nacional, enfrenta desafíos constantes en términos de eficiencia operativa, seguridad y sostenibilidad, donde el mantenimiento de equipos críticos (molinos, chancadoras, correas transportadoras, equipos de extracción) juega un rol protagónico. La implementación del PdM inteligente en este sector ofrece un camino concreto para reducir costos operativos, minimizar paradas no planificadas, mejorar la seguridad de los trabajadores, extender la vida útil de los equipos y optimizar el consumo de recursos, aspectos críticos para la competitividad y sostenibilidad de la minería chilena. La adaptabilidad del PdM a condiciones operativas extremas, tales como la altitud, la aridez y las fluctuaciones de temperatura típicas de los entornos mineros chilenos, representa una ventaja adicional, permitiendo implementar sistemas de monitorización y predicción robustos y fiables.

No obstante, la adopción exitosa del PdM inteligente en la minería chilena demanda superar desafíos específicos, tales como la necesidad de validación empírica en entornos mineros reales, el desarrollo de modelos predictivos robustos y adaptados a la idiosincrasia de los equipos y procesos mineros, y la formación de capital humano especializado en la intersección del mantenimiento, la minería y el Machine Learning. La colaboración entre la academia, la industria minera y los proveedores de tecnología se erige como un factor clave para impulsar la investigación aplicada, la transferencia tecnológica y la implementación efectiva del PdM inteligente en la minería chilena, permitiendo a este sector estratégico aprovechar al máximo el potencial transformador del mantenimiento predictivo en la era digital. En última instancia, la adopción del PdM inteligente no solo representa una mejora en las prácticas de mantenimiento, sino una inversión estratégica en la eficiencia, la seguridad y la sostenibilidad de la minería chilena, consolidando su liderazgo global en un contexto cada vez más competitivo y exigente.

CONCLUSIONES

La presente Revisión Sistemática de la Literatura (RSL) ha proporcionado una síntesis exhaustiva del panorama actual del Mantenimiento Predictivo (PdM) impulsado por Machine Learning (ML), revelando su posición estratégica en la Industria 4.0 y su creciente adopción en diversos sectores industriales. El análisis temático, basado en la evidencia científica disponible, consolida la transformación del PdM desde un enfoque reactivo a un paradigma proactivo y optimizado, donde el ML emerge como un catalizador fundamental para la gestión inteligente de activos.

Los hallazgos clave de esta RSL convergen en la centralidad del PdM como un componente esencial para la competitividad y sostenibilidad industrial. La ubicuidad del PdM inteligente, validada en sectores tan diversos como la energía, la manufactura, el transporte y la salud, subraya su adaptabilidad y potencial transformador en múltiples contextos operativos. La optimización de las estrategias de mantenimiento, impulsada por algoritmos evolutivos y sistemas de soporte a la decisión, se erige como una tendencia dominante, reflejando la evolución del PdM hacia la maximización del valor y la eficiencia en la gestión de activos.

No obstante, la investigación en PdM inteligente aún enfrenta desafíos metodológicos y empíricos. La heterogeneidad de los estudios, la escasez de validaciones a gran escala y la complejidad inherente a los sistemas industriales, limitan la generalización de los resultados y demandan futuras líneas de investigación. Se requiere un mayor rigor metodológico, la estandarización de métricas y la validación empírica robusta en entornos industriales reales. La interpretabilidad y explicabilidad de los modelos de ML emergen como áreas prioritarias, buscando no solo mejorar la precisión predictiva sino también la confianza y la comprensión de los mecanismos subyacentes. Asimismo, la exploración de nuevas técnicas de ML y algoritmos de optimización promete expandir las fronteras del PdM inteligente hacia aplicaciones más complejas y especializadas.

En el contexto específico de la industria minera chilena, la presente RSL destaca el potencial estratégico del PdM inteligente para optimizar la gestión de activos críticos. La adaptación del PdM a las condiciones operativas extremas de la minería chilena y el desarrollo de modelos predictivos robustos y explicables, representan líneas de acción prioritarias para impulsar la eficiencia, la seguridad y la sostenibilidad de este sector clave. La formación de capital humano especializado y la colaboración entre la academia, la industria y los proveedores de

tecnología se configuran como elementos fundamentales para la adopción exitosa del PdM inteligente en la minería chilena, permitiendo aprovechar al máximo su potencial transformador en la era de la Industria 4.0.

En conclusión, esta RSL provee una visión panorámica y crítica del estado del arte del PdM inteligente, identificando sus logros, desafíos y futuras direcciones. Se espera que este trabajo sirva como base sólida y hoja de ruta para investigadores, profesionales y tomadores de decisiones interesados en profundizar y expandir la aplicación del Machine Learning para la optimización del mantenimiento en la industria, contribuyendo a la construcción de sistemas productivos más eficientes, seguros y sostenibles en el futuro.

ABREVIACIONES

PdM	Mantenimiento Predictivo (Predictive Maintenance)
ML	Aprendizaje Automático (Machine Learning)
RUL	Vida Útil Remanente (Remaining Useful Life)
RNA	Redes Neuronales Artificiales (Artificial Neural Networks)
SVM	Máquinas de Vectores de Soporte (Support Vector Machines)
IoT	Internet de las Cosas (Internet of Things)
IIoT	Internet de las Cosas Industrial (Industrial Internet of Things)
WoS	Web of Science
RSL	Revisión Sistemática de la Literatura (Systematic Literature Review)
PLN	Procesamiento del Lenguaje Natural (Natural Language Processing)
CBM	Mantenimiento Basado en Condición (Condition-Based Maintenance)
DSS	Sistema de Soporte a la Decisión (Decision Support System)

AGRADECIMIENTOS

Los autores expresan su reconocimiento a la Pontificia Universidad Católica de Valparaíso (PUCV), en especial a la *Escuela de Construcción y Transporte*. Asimismo, se agradece el apoyo técnico-económico y la provisión de parámetros de campo suministrados por la compañía GMT Group.

REFERENCIAS

- Abbondati, F., Biancardo, S.A., Veropalumbo, R., Chen, X. & Dell'Acqua, G. (2023). An adaptive neuro-fuzzy inference system for assessing runway friction decay. *Measurement: Journal of the International Measurement Confederation*, 213, 112737.
- Abidi, M.H., Mohammed, M.K. & Alkhalefah, H. (2022). Predictive maintenance planning for industry 4.0 using machine learning for sustainable manufacturing. *Sustainability (Switzerland)*, 14 (6), 3387.
- Ahmed, R., Nasiri, F. & Zayed, T. (2021). A novel neutrosophic-based machine learning approach for maintenance prioritization in healthcare facilities. *Journal of Building Engineering*, 42, 102480.
- AL-Tahat, M.D. & Al-Rifa'e, F. (2023). Applying a data analytics approach to medical equipment maintenance management to improve the mean time between failure and availability. *Jordan Journal of Mechanical and Industrial Engineering*, 17(1), 33–40.
- Alam, M., Haque, A., Khan, M.A., Sobahi, N.M., Mehedi, I.M. & Khan, A. I. (2022). Condition monitoring and maintenance management with grid-connected renewable energy systems. *Computers, Materials and Continua*, 72(2), 3999–4017.
- Alqailli, A., Qais, M. & Al-Mansour, A. (2021). Integer search algorithm: A new discrete multi-objective algorithm for pavement maintenance management optimization. *Applied Sciences (Switzerland)*, 11 (15), 7170.

- André, L.A.A., André, L.R.D., Tomazela, B., Escovedo, T. & Kalinowski, M. (2023). *Machine learning applied to the classification of technical inspection recommendations regarding the trend to increase criticality*. PROCEEDINGS OF THE 19TH BRAZILIAN SYMPOSIUM ON INFORMATION SYSTEMS, SBSI'23. pages 17–27. <https://dl.acm.org/doi/10.1145/3592813.3592884>
- Antosz, K., Kulisz, M. & Husar, J. (2024). Evaluation and comparison of selected machine learning methods for improving maintenance processes. *IFAC PAPERSONLINE*, 58(8), 85–90.
- Aradi, A. & Varga, A.K. (2024). Enhancing predictive maintenance in industrial systems through acoustic monitoring of servo motors using machine learning (ai). *Intelligent and Fuzzy Systems*, 2, 1089, 690–697.
- Borroto-Pentón, Y., Caraza-Morales, M.A., Alfonso-Llanes, A. & Marrero- Delgado, F. (2021). Optimization tools applied to physical asset maintenance management: state of the art. *DYNA (Colombia)*, 88(219), 162–170.
- Calabrese, M., Cimmino, M., Fiume, F., Manfrin, M., Romeo, L., Ceccacci, S., et al. (2020). Sophia: An event-based iot and machine learning architecture for predictive maintenance in industry 4.0. *Information (Switzerland)*, 11(4), 202.
- Cheng, J.C.P., Chen, W., Chen, K. & Wang, Q. (2020). Data-driven predictive maintenance planning framework for mep components based on bim and iot using machine learning algorithms. *Automation in Construction*, 112, 103087.
- Çinar, Z.M., Nuhu, A.A., Zeeshan, Q., Korhan, O., Asmael, M. & Safaei, B. (2020). Machine learning in predictive maintenance towards sustainable smart manufacturing in industry 4.0. *Sustainability (Switzerland)*, 12(19), 8211.
- de Freitas, A.A.C., Santos, W.R.N., Veras, G.V.O. & Fernandes, E.D. (2018). *Artificial neural network applied in thermal process of distribution transformers immersed in vegetable oil*. 13th IEEE International Conference on Industry Applications (INDUSCON), Sao Paulo, Brazil, 2018, pp. 99-104, doi: 10.1109/INDUSCON.2018.8627280.
- Del Buono, F., Calabrese, F., Baraldi, A., Paganelli, M. & Regattieri, A. (2022). *Data-driven predictive maintenance in evolving environments: A comparison between machine learning and deep learning for novelty detection*. Sustainable Design and Manufacturing, KES-SDM 2021, 262, 109– 119.
- del Rio, A.M., Ramirez, I.S. & Marquez, F.P.G. (2022). *Machine learning techniques for pattern recognition in railway switches: A real case study*. Proceedings of the Sixteenth International Conference on Management Science and Engineering Management, 1, 144, 320–335.
- Devi, R.B., Suseela, G., Painam, R.K., Swetha, T., Suryanarayana, G. & Madhavi, R.K. (2024). Intelligent fault diagnosis in industrial machinery: Leveraging ai with ISTM autoencoder for enhanced fault detection. *Journal of Machine and Computing*, 4(4), 931–942.
- Dubey, A.K., Kumar, A., Ramirez, I.S. & Marquez, F.P.G. (2022). *A review of intelligent systems for the prediction of wind energy using machine learning*. Proceedings of the Sixteenth International Conference on Management Science and Engineering Management, 1, 144, 476–491.
- Durga Prasad, N.V.P.R. & Radhakrishna, C. (2019). Decision support system and integrated asset optimization (DSS & IAO). *International Journal of Engineering and Advanced Technology*, 9(1), 1070–1077.
- Garcia, J., Rios-Colque, L., Peña, A. & Rojas, L. (2025). Condition monitoring and predictive maintenance in industrial equipment: An NPL-assisted review of signal processing, hybrid models, and implementation challenges. *Applied Sciences*, 15(10), 5465.
- García, J., Leiva-Araos, A., Diaz-Saavedra, E., Moraga, P., Pinto, H. & Yepes, V. (2023). Relevance of machine learning techniques in water infrastructure integrity and quality: A review powered by natural language processing. *Applied Sciences*, 13(22), 12497.

- Garcia, J., Villavicencio, G., Altimiras, F., Crawford, B., Soto, R., Minatogawa, V., et al. (2022). Machine learning techniques applied to construction: A hybrid bibliometric analysis of advances and future directions. *Automation in Construction*, 142, 104532.
- Gkerekos, C., Lazakis, I. & Theotokatos, G. (2019). Machine learning models for predicting ship main engine fuel oil consumption: A comparative study. *OCEAN ENGINEERING*, 188, 106282.
- Goti, A., Oyarbide-Zubillaga, A., Sanchez, A., Akyazi, T. & Alberdi, E. (2019). Multi equipment condition based maintenance optimization using multi-objective evolutionary algorithms. *Applied Sciences (Switzerland)*, 9 (22), 4849.
- Haowei, M., Xu, C. & Yang, J. (2023). Design of fine life cycle prediction system for failure of medical equipment. *Journal of Artificial Intelligence and Technology*, 3 (2), 39–45.
- Hoffmann, M.A. & Lasch, R. (2024). Tackling industrial downtimes with artificial intelligence in data-driven maintenance. *ACM Computing Surveys*, 56 (4), 82.
- Hong, S., Kim, J. & Yang, E. (2022). Automated text classification of maintenance data of higher education buildings using text mining and machine learning techniques. *Journal of Architectural Engineering*, 28 (1), 04021045.
- Jiménez, A.A., Muñoz, C.Q.G. & Márquez, F.P.G. (2018). *Machine learning and neural network for maintenance management*. Proceedings of the Eleventh International Conference on management science and engineering management, pages 1377–1388.
- Jin, Y.X., Geng, J., Lv, C., Chi, Y. & Zhao, T. D. (2023). A methodology for equipment condition simulation and maintenance threshold optimization oriented to the influence of multiple events. *Reliability Engineering & System Safety*, 229, 108879.
- Kasraei, A. & Garmabaki, A.H.S. (2024). Reliability analysis of railway assets considering the impact of geographical and climatic properties. *Int. J. Syst. Assur. Eng. Manag.* <https://doi.org/10.1007/s13198-024-02397-6>.
- Kumar, A., Dubey, A.K., Ramírez, I.S., del Río, A.M. & Márquez, F.P.G. (2024). Artificial intelligence techniques for the photovoltaic system: A systematic review and analysis for evaluation and benchmarking. *ARCHIVES OF COMPUTATIONAL METHODS IN ENGINEERING*, 31, (8), 4429–4453.
- Kumar, A., Kumar, A., Ramírez, I.S., del Rio, A.M. & Márquez, F.P.G. (2022). A review and analysis of forecasting of photovoltaic power generation using machine learning. *PROCEEDINGS OF THE SIXTEENTH INTERNATIONAL CONFERENCE ON MANAGEMENT SCIENCE AND ENGINEERING MANAGEMENT*, 1, 144, 492–505.
- Lemache-Caiza, K., García-Mora, F., Valverde-González, V. & López, E.V. (2023). The machine learning approach to Industrial Maintenance Management. *Revista Universidad y Sociedad*, 15 (3), 628–637.
- Lima, E., Gorski, E., Loures, E.F.R., Santos, E.A.P. & Deschamps, F. (2019). Applying machine learning to AHP multicriteria decision making method to assets prioritization in the context of industrial maintenance 4.0. *IFAC PAPERSONLINE*, 52 (13), 2152–2157.
- Liu, B., Cen, W., Zheng, C., Li, D. & Wang, L. (2024). A combined optimization prediction model for earth-rock dam seepage pressure using multi-machine learning fusion with decomposition data-driven. *Expert Systems with Applications*, 242, 122798.
- Marcelino, P., de Lurdes Antunes, M., Fortunato, E. & Gomes, M.C. (2020). Transfer learning for pavement performance prediction. *International Journal of Pavement Research and Technology*, 13 (2), 154–167.
- Marquez, F.P.G. & Gonzalo, A.P. (2022). A comprehensive review of artificial intelligence and wind energy. *Archives of Computational Methods in Engineering*, 29, (5), 2935– 2958.

- Martínez, Y., Rojas, L., Peña, A., Valenzuela, M. & García, J. (2025). Physics-informed neural networks for the structural analysis and monitoring of railway bridges: A systematic review. *Mathematics*, 13(10):1571.
- Mbilong, P.M., Aarab, Z., Belouadha, F.-Z. & Kabbaj, M.I. (2023). Enhancing fault detection in CNC machinery: A deep learning and genetic algorithm approach. *Ingenierie des Systemes d'Information*, 28 (5), 1361–1375.
- Muñoz del Río, A., Segovia Ramirez, I., Papaalias, M. & García Márquez, F.P. (2024). Pattern recognition based on statistical methods combined with machine learning in railway switches. *Expert Systems with Applications*, 238, 122214.
- Nikfar, M., Bitencourt, J. & Mykoniatis, K. (2022). A two-phase machine learning approach for predictive maintenance of low voltage industrial motors. *3RD INTERNATIONAL CONFERENCE ON INDUSTRY 4.0 AND SMART MANUFACTURING*, 200, 111–120.
- Orellana, F., Durán, O., Vergara, J.L. & Arata, A. (2024). Maintainability analysis of remotely operated lng marine loading arms based on une 151001 standard. *Machines*, 12(6):407.
- Pourramezan, M.-R. & Rohani, A. (2024). Improved monitoring and classification of engine oil condition through two machine learning techniques. *SAE Int. J. Fuels Lubr.*, 18(1), 107-123, 2025, <https://doi.org/10.4271/04-18-01-0005>.
- Rachman, A. & Ratnayake, R. M. C. (2020). Corrosion loop development of oil and gas piping system based on machine learning and group technology method. *Journal of Quality in Maintenance Engineering*, 26 (3), 349–368.
- Rodríguez, P.C., Martí-Puig, P., Caiafa, C.F., Serra-Serra, M., Cusidó, J. & Solé- Casals, J. (2023). Exploratory analysis of scada data from wind turbines using the k-means clustering algorithm for predictive maintenance purposes. *Machines*, 11 (2), 270.
- Rojas, L., Peña, A. & García, J. (2025). Complex dynamics and intelligent control: Advances, challenges, and applications in mining and industrial processes. *Mathematics*, 13(6), 961.
- Roque, A.S., Krebs, V.W., Figueiro, I.C. & Jazdi, N. (2022). An analysis of machine learning algorithms in rotating machines maintenance. *IFAC PapersOnLine*, 55, (2), 252–257.
- Sánchez-Garrido, A.J., Navarro, I.J., García, J. & Yepes, V. (2023). A systematic literature review on modern methods of construction in building: An integrated approach using machine learning. *Journal of Building Engineering*, 73, 106725.
- See-To, E.W.K., Wang, X., Lee, K.-Y., Wong, M.-L. & Dai, H.-N. (2023). Deep-learning- driven proactive maintenance management of IOT-empowered smart toilet. *IEEE Internet of Things Journal*, 10(3), 2417–2429.
- Srisuwan, S. & Innet, S. (2024). *An investigation of machine learning algorithms for predictive maintenance in high pressure processing systems. 21st International Joint Conference on Computer Science and Software Engineering, JCSSE 2024*, pages 94–98.
- Szrama, S. (2024). Engine health status prediction based on oil analysis with augmented machine learning algorithms. *Tribology in Industry*, 46(4), 624–638.
- Thongtam, N., Sinthupinyo, S. & Chandrachai, A. (2024). Optimization of intelligent maintenance systems in smart factory using state space search algorithm. *Applied Sciences (Switzerland)*, 14(24), 11973.
- Tiwari, S. (2023). Artificial intelligence (ai) in the sustainable energy sector †. *Engineering Proceedings*, 37(1), 11.
- Velmurugan, K., Saravanasankar, S., Venkumar, P. & Sudhakarapandian, R. (2023). IIot based anomaly detection and maintenance management of an industrial rotary system. *Current Applied Science and Technology*, 23 (3). <https://doi.org/10.55003/cast.2022.03.23.002>

Venegas, P., Ivorra, E., Ortega, M. & de Ocariz, I. S. (2022). Towards the automation of infrared thermography inspections for industrial maintenance applications. *Sensors*, 22 (2), 613.

Vijayalakshmi, K., Rajakannu, A., Ramachandran, K.P. & Sri Rajkavin, A.V. (2024). Federated learning-based futuristic fault diagnosis and standardization in rotating machinery. *SSRG International Journal of Electronics and Communication Engineering*, 11 (9), 223–236.

Zamzam, A.H., Hasikin, K. & Wahab, A.K.A. (2023). Integrated failure analysis using machine learning predictive system for smart management of medical equipment maintenance. *Engineering Applications of Artificial Intelligence*, 125, 106715.

Zhao, Z. & Wang, L. (2024). Operation and maintenance strategy of radio transmission equipment based on big data. *Internet Technology Letters*, 7(2), e486.

Zheng, X., Zhang, H. & Shi, J. (2022). Application based on artificial intelligence in substation operation and maintenance management. *Computational Intelligence and Neuroscience*, 2022, 7509532. <https://doi.org/10.1155/2022/7509532>

