

Estudio de técnicas de Inteligencia Artificial para el Mantenimiento Predictivo en Sistemas de Control Industrial

Carlos Felipe Becerra Bayona
Universidad Santo Tomás,
Bucarmanga, Colombia
carlos.becerra01@ustabuca.edu.co

Carlos Daniel Pimentel Díaz
Universidad Santo Tomás,
Bucarmanga, Colombia
carlos.pimentel@ustabuca.edu.co

Resumen - El mantenimiento predictivo ha adquirido gran relevancia en la industria debido a la necesidad de mejorar la confiabilidad operativa y reducir fallas en sistemas industriales. En este contexto, la presente monografía analiza la implementación de técnicas de Inteligencia Artificial (IA) aplicadas al mantenimiento predictivo en diferentes sectores industriales, mediante un estudio de mapeo sistemático y análisis bibliométrico de literatura científica publicada en los últimos años. La metodología empleada incluyó la revisión de artículos indexados en bases de datos académicas especializadas y el análisis de tendencias mediante la herramienta VOSviewer, permitiendo identificar áreas de investigación, técnicas implementadas y sectores con mayor desarrollo tecnológico. Los resultados evidencian una amplia aplicación de herramientas como aprendizaje automático, redes neuronales artificiales y aprendizaje profundo en sectores manufactureros, energéticos y automatizados, principalmente para detección temprana de fallas, monitoreo de condición y optimización del mantenimiento. Asimismo, se identificaron desafíos relacionados con calidad de datos, escalabilidad, costos de implementación y acceso tecnológico. Finalmente, el estudio destaca el papel de la IA como elemento estratégico en la transformación digital y evolución del mantenimiento industrial.

Palabras clave: Inteligencia Artificial, mantenimiento predictivo, Machine Learning, lógica difusa, Industria 4.0, monitoreo de condición, Internet de las Cosas (IoT), análisis de datos, automatización industrial.

Abstract - Predictive maintenance has gained significant relevance in industry due to the need to improve operational reliability and reduce failures in industrial systems. In this context, this monograph analyzes the implementation of Artificial Intelligence (AI) techniques applied to predictive maintenance across different industrial sectors through a systematic mapping study and bibliometric analysis of scientific literature published in recent years. The adopted methodology included the review of indexed articles from specialized academic databases and trend analysis using the VOSviewer tool, allowing the identification of research areas, implemented techniques, and sectors with the highest technological development. The results reveal a wide application of tools such as machine learning, artificial neural networks, and deep learning in manufacturing, energy, and automated sectors, mainly for early fault detection, condition monitoring, and maintenance optimization. Additionally, challenges related to data quality, scalability, implementation costs, and technological accessibility were identified. Finally, the study highlights the role of AI as a strategic element in the digital transformation and evolution of industrial maintenance.

Keywords - Artificial Intelligence, predictive maintenance, Machine Learning, Fuzzy Logic, Industry 4.0, condition monitoring, Internet of Things (IoT), data analysis, industrial automation.

I. INTRODUCCIÓN

En los últimos años, la transformación digital de la industria ha impulsado la adopción de tecnologías avanzadas orientadas a mejorar la eficiencia operativa, la confiabilidad y la sostenibilidad de los procesos productivos. En este contexto, el mantenimiento industrial ha evolucionado desde enfoques tradicionales de tipo correctivo y preventivo hacia estrategias basadas en el análisis de datos y la toma de decisiones inteligente, dando lugar al desarrollo del mantenimiento predictivo como uno de los pilares de la Industria 4.0.

El mantenimiento predictivo se fundamenta en la supervisión continua del estado de los equipos mediante sensores, sistemas SCADA y plataformas de adquisición de datos, permitiendo identificar patrones de degradación y anticipar posibles fallas antes de que ocurran. A diferencia de los enfoques convencionales, esta estrategia busca optimizar los recursos de mantenimiento, reducir tiempos de inactividad no programados y aumentar la disponibilidad operativa de los sistemas industriales [1]. La creciente disponibilidad de datos provenientes de entornos automatizados ha favorecido la incorporación de técnicas de inteligencia artificial (IA) y aprendizaje automático para el análisis avanzado de condiciones operativas y la predicción de fallas.

Actualmente, diversas industrias como manufactura, energía, petróleo y gas, minería, transporte y sector salud han comenzado a implementar soluciones basadas en IA para fortalecer sus estrategias de mantenimiento predictivo. Estas aplicaciones abarcan desde el análisis de vibraciones en maquinaria rotativa hasta sistemas de monitoreo inteligente apoyados en visión artificial, procesamiento de señales y modelos predictivos basados en datos históricos [2]. El interés científico e industrial en este campo ha crecido significativamente durante la última década, generando una amplia producción académica relacionada con técnicas, aplicaciones y desafíos asociados a la integración de la inteligencia artificial en entornos industriales.

Sin embargo, a pesar del incremento en el número de investigaciones publicadas, existe una alta diversidad de enfoques, sectores de aplicación y metodologías

implementadas, lo que dificulta identificar tendencias claras sobre el uso de la IA en mantenimiento predictivo. En consecuencia, se hace necesario desarrollar estudios de revisión y análisis bibliométrico que permitan organizar el conocimiento existente, identificar áreas de concentración investigativa y reconocer posibles vacíos o líneas futuras de investigación [3].

En este sentido, la presente monografía tiene como propósito analizar las aplicaciones de técnicas de inteligencia artificial en mantenimiento predictivo dentro de diferentes sectores industriales, mediante un estudio de mapeo sistemático apoyado en la herramienta VOSviewer. El trabajo busca identificar tendencias de investigación, sectores con mayor implementación tecnológica y principales desafíos asociados a la adopción de estas herramientas en sistemas industriales.

Para el desarrollo del documento, inicialmente se presenta la metodología utilizada para el estudio de mapeo sistemático y el análisis bibliométrico realizado con VOSviewer. Posteriormente, se analizan las aplicaciones de inteligencia artificial en diferentes sectores industriales relacionados con el mantenimiento predictivo. Finalmente, se exponen los principales desafíos, limitaciones y direcciones futuras identificadas en la literatura científica, así como las conclusiones derivadas del análisis realizado.

II. METODOLOGÍA: ESTUDIO DE MAPEO SISTEMÁTICO Y ANÁLISIS CON VOSVIEWER

La presente monografía se desarrolló mediante un enfoque de revisión documental basado en un estudio de mapeo sistemático de literatura, complementado con un análisis bibliométrico utilizando la herramienta VOSviewer. Esta metodología permitió identificar tendencias de investigación, áreas de aplicación y relaciones temáticas asociadas al uso de técnicas de inteligencia artificial en mantenimiento predictivo dentro de diferentes sectores industriales.

El estudio de mapeo sistemático se seleccionó debido a su capacidad para organizar y clasificar grandes volúmenes de literatura científica, facilitando la identificación de patrones investigativos y vacíos de conocimiento en un área específica [4]. Adicionalmente, el análisis bibliométrico mediante VOSviewer permitió representar gráficamente las relaciones de coocurrencia entre términos clave presentes en los artículos analizados, proporcionando una visión estructurada de las líneas de investigación predominantes.

La metodología se estructuró en tres etapas principales: planeación, ejecución y reporte de resultados. Durante estas etapas se definieron las preguntas de investigación, criterios de búsqueda, bases de datos científicas, criterios de inclusión y exclusión, así como los procedimientos de análisis de la información recopilada.

2.1 Proceso del Estudio de Mapeo Sistemático

El proceso metodológico inició con la definición de las preguntas de investigación orientadas a identificar cómo la inteligencia artificial ha sido aplicada en estrategias de mantenimiento predictivo dentro de distintos sectores industriales. Las principales preguntas formuladas fueron:

- ¿Cuáles son los sectores industriales con mayor implementación de inteligencia artificial en mantenimiento predictivo?
- ¿Qué técnicas de inteligencia artificial son más utilizadas en cada sector?
- ¿Cuáles son las principales tendencias y desafíos identificados en la literatura científica reciente?

Posteriormente, se realizó la búsqueda bibliográfica en bases de datos académicas reconocidas internacionalmente, seleccionadas por su relevancia en ingeniería, automatización industrial e inteligencia artificial. Las principales fuentes consultadas fueron:

- Scopus
- Web of Science
- IEEE Xplore
- ScienceDirect

La búsqueda se realizó considerando publicaciones comprendidas entre los años 2015 y 2025, con el propósito de analizar las investigaciones más recientes relacionadas con el desarrollo de la Industria 4.0 y las aplicaciones contemporáneas de inteligencia artificial en mantenimiento predictivo.

Para la recuperación de documentos se emplearon combinaciones de palabras clave en inglés, entre ellas:

- “Predictive Maintenance”
- “Artificial Intelligence”
- “Machine Learning”
- “Industrial Maintenance”
- “Industry 4.0”
- “Fault Diagnosis”
- “Condition Monitoring”

Los criterios de inclusión definidos para la selección documental fueron:

- Artículos científicos publicados en revistas indexadas o conferencias internacionales.
- Investigaciones relacionadas con aplicaciones de inteligencia artificial en mantenimiento predictivo.
- Estudios enfocados en sectores industriales reales.
- Publicaciones dentro del rango temporal establecido.

Por otro lado, se excluyeron:

- Documentos duplicados.
- Artículos sin relación directa con mantenimiento predictivo.
- Estudios centrados únicamente en mantenimiento preventivo o correctivo.
- Publicaciones sin acceso al contenido completo.

Una vez recopilados los documentos, se realizó un proceso de depuración y clasificación de la información, organizando los artículos según el sector industrial, tipo de aplicación y técnicas de inteligencia artificial implementadas.

2.2 Interpretación de los Resultados de VOSviewer

El análisis bibliométrico de la literatura científica relacionada con inteligencia artificial y mantenimiento predictivo se desarrolló mediante la herramienta VOSviewer, especializada en la construcción y visualización de redes de coocurrencia, colaboración científica y análisis temático [5]. Para el desarrollo del estudio, se realizó una búsqueda de literatura científica en las bases de datos Scopus, IEEE

Xplore y ScienceDirect, empleando combinaciones de palabras clave como “predictive maintenance”, “artificial intelligence”, “machine learning”, “deep learning” e “industrial systems”.

La búsqueda se delimitó a publicaciones realizadas entre 2014 y 2024, obteniéndose inicialmente un total de 186 documentos científicos entre artículos, conferencias y revisiones bibliográficas. Posteriormente, se aplicaron criterios de inclusión y exclusión relacionados con pertinencia temática, duplicidad y disponibilidad del documento completo, obteniéndose finalmente un conjunto de 124 documentos para el análisis bibliométrico.

Los registros bibliográficos fueron exportados en formato compatible con VOSviewer (.csv y .ris) e importados en la herramienta para desarrollar un análisis de coocurrencia de palabras clave (*co-occurrence analysis*). El análisis se configuró utilizando las palabras clave proporcionadas por los autores y términos indexados en las bases de datos. Asimismo, se estableció un umbral mínimo de cinco ocurrencias por término, con el fin de filtrar palabras de baja relevancia y mejorar la representación de las relaciones temáticas presentes en la literatura.

Como resultado del procesamiento bibliométrico, VOSviewer identificó 58 términos relevantes distribuidos en cinco clústeres temáticos principales, representados mediante colores diferenciados dentro de la red de coocurrencia. Cada clúster agrupó términos con alta relación temática y frecuencia de aparición conjunta dentro de las publicaciones analizadas.




Fig. 1. Ejemplo de red de coocurrencia de palabras clave relacionadas con mantenimiento predictivo e Industria 4.0 generada mediante VOSviewer. Adaptado de “Bibliometric Analysis and Systematic Literature Review of Predictive Maintenance in Industry 4.0” (2024).

El primer clúster estuvo asociado principalmente con aplicaciones de *Machine Learning* y monitoreo de condición, incluyendo términos como “condition monitoring”, “fault diagnosis”, “random forest” y “support vector machine”. Este grupo evidenció una fuerte concentración de investigaciones orientadas a la detección temprana de fallas en maquinaria industrial.

El segundo clúster se relacionó con técnicas de *Deep Learning* y procesamiento avanzado de señales, destacándose términos como “deep learning”, “neural networks”, “signal processing” y “vibration analysis”. Este clúster mostró un crecimiento importante en investigaciones enfocadas al análisis automatizado de datos provenientes de sensores industriales.

El tercer clúster agrupó investigaciones relacionadas con Internet of Things e Industria 4.0, integrando términos como “IoT”, “smart manufacturing”, “cyber-physical systems” y “industrial automation”. La presencia de este clúster evidenció la relación directa entre transformación digital y mantenimiento predictivo inteligente.

El cuarto clúster se enfocó en gestión del mantenimiento industrial y toma de decisiones, incluyendo conceptos asociados a optimización de mantenimiento, confiabilidad operacional y gestión de activos.

Finalmente, el quinto clúster estuvo relacionado con tendencias emergentes y análisis predictivo basado en grandes volúmenes de datos, incorporando términos como “big data”, “predictive analytics” y “data-driven maintenance”.

La interpretación de la red de coocurrencia permitió identificar las áreas temáticas con mayor desarrollo científico y evidenciar cómo las investigaciones recientes se orientan hacia la integración de inteligencia artificial, análisis de datos e infraestructura digital en estrategias de mantenimiento predictivo. Asimismo, el análisis de densidad de términos permitió reconocer áreas con menor nivel de investigación, representando posibles oportunidades para futuros estudios en sectores industriales con baja adopción tecnológica.

2.3 Relevancia de la Metodología

La combinación entre el estudio de mapeo sistemático y el análisis bibliométrico mediante VOSviewer proporcionó una metodología estructurada y objetiva para analizar el estado actual de la investigación sobre inteligencia artificial aplicada al mantenimiento predictivo.

El mapeo sistemático permitió clasificar y organizar la literatura científica disponible, mientras que el análisis bibliométrico facilitó visualizar relaciones entre conceptos, tendencias investigativas y áreas de concentración temática. Esta integración metodológica permitió obtener una visión global del desarrollo científico del área, identificando sectores industriales con mayor actividad investigativa y tecnologías con mayor nivel de implementación [2].

Adicionalmente, la metodología utilizada contribuyó a identificar vacíos de investigación y posibles líneas futuras de desarrollo, especialmente en aspectos relacionados con escalabilidad, calidad de datos, interpretabilidad de modelos y acceso tecnológico en entornos industriales.

III. APLICACIONES DE INTELIGENCIA ARTIFICIAL EN MANTENIMIENTO PREDICTIVO

La incorporación de técnicas de inteligencia artificial en estrategias de mantenimiento predictivo ha tenido un crecimiento significativo durante la última década, impulsada por el avance de la Industria 4.0 y el incremento en la disponibilidad de datos provenientes de sistemas de monitoreo industrial. Actualmente, diferentes sectores

productivos implementan soluciones basadas en inteligencia artificial para optimizar la detección de fallas, mejorar la disponibilidad operativa y reducir costos asociados a paradas no programadas [6].

TABLA I
TÉCNICAS DE INTELIGENCIA ARTIFICIAL APLICADAS AL
MANTENIMIENTO PREDICTIVO

Sector Industrial	Sector Industrial	Técnica IA	Aplicación	Ventajas
Manufactura	Zhang et al. [3]	<i>Machine Learning</i>	Detección de fallas en maquinaria industrial	Alta precisión en diagnóstico predictivo
Energía	Qin et al. [17]	<i>Redes Neuronales</i>	Monitoreo de turbinas eólicas	Mejora de confiabilidad operacional
Petróleo y gas	Alao et al. [19]	<i>Random Forest y ANN</i>	Predicción de desgaste en bombas	Reducción de fallas inesperadas
Hospitalario	Ahmed et al. [26]	<i>Redes Neuronales</i>	Supervisión de sistemas UPS	Incremento de confiabilidad energética
Transporte	Liu et al. [29]	<i>Machine Learning</i>	Monitoreo de baterías eléctricas	Optimización de vida útil de baterías

3.1 Aplicaciones en la Industria Manufacturera

La industria manufacturera es uno de los sectores con mayor adopción de técnicas de inteligencia artificial para mantenimiento predictivo, debido al alto nivel de automatización presente en líneas de producción y sistemas de control industrial. En este contexto, las investigaciones se enfocan principalmente en el monitoreo de maquinaria rotativa, motores eléctricos, sistemas hidráulicos y bandas transportadoras.

Diversos estudios reportan el uso de redes neuronales artificiales y algoritmos de aprendizaje automático para analizar señales de vibración y detectar anomalías en motores industriales. Carvalho et al. [2] destacan que las técnicas basadas en aprendizaje supervisado han demostrado alta precisión en la identificación temprana de fallas mecánicas en equipos de producción automatizada.

Asimismo, investigaciones recientes han incorporado modelos de *Deep Learning* y análisis de imágenes para inspección automática y control de calidad en procesos manufactureros. Estas aplicaciones permiten detectar defectos superficiales, desgaste de componentes y desviaciones operativas mediante sistemas de visión artificial integrados con plataformas de monitoreo industrial.

Otro aspecto relevante en este sector es la integración entre sistemas SCADA, sensores IoT y plataformas de análisis predictivo, permitiendo desarrollar arquitecturas inteligentes capaces de supervisar continuamente el estado de los equipos y generar alertas tempranas ante posibles fallas [7].

Zhang et al. [3] desarrollaron un estudio orientado al mantenimiento predictivo de motores industriales en líneas de manufactura automatizada utilizando algoritmos de *Machine Learning* basados en Random Forest y Support Vector Machine (SVM). Los autores emplearon datos de vibración, temperatura y corriente eléctrica obtenidos mediante sensores instalados en maquinaria rotativa,

logrando identificar patrones asociados a desgaste mecánico y desalineación de componentes. Los resultados evidenciaron una precisión superior al 94 % en la detección temprana de fallas, demostrando la efectividad de los modelos supervisados para aplicaciones industriales de alta criticidad.

Por otra parte, Lee et al. [6] implementaron una arquitectura basada en redes neuronales profundas (*Deep Learning*) para el monitoreo de rodamientos industriales en sistemas automatizados de manufactura. El modelo fue entrenado utilizando señales vibracionales adquiridas en tiempo real, permitiendo clasificar diferentes modos de falla asociados a fatiga y deterioro mecánico. Los autores concluyeron que el uso de redes neuronales convolucionales mejora significativamente la capacidad de diagnóstico frente a métodos tradicionales basados únicamente en análisis estadístico.

De manera complementaria, Wang et al. [16] desarrollaron una arquitectura de monitoreo inteligente integrando sensores IoT, plataformas SCADA y análisis predictivo para supervisar bandas transportadoras en plantas manufactureras inteligentes. La investigación permitió implementar un sistema de supervisión continua capaz de detectar comportamientos anómalos y generar alertas automáticas ante posibles condiciones de falla. Los resultados mostraron mejoras en la disponibilidad operativa y reducción de tiempos de inactividad no programados.

En términos generales, las investigaciones desarrolladas en la industria manufacturera evidencian un predominio de técnicas basadas en aprendizaje supervisado, redes neuronales y análisis de datos provenientes de sensores industriales. Asimismo, se observa una creciente integración entre plataformas IoT, sistemas SCADA y herramientas de inteligencia artificial dentro de entornos asociados a la Industria 4.0. Sin embargo, las principales limitaciones reportadas están relacionadas con la calidad de los datos, necesidad de infraestructura tecnológica especializada y altos volúmenes de información requeridos para el entrenamiento de modelos predictivos.




Fig. 2. Arquitectura de referencia para mantenimiento predictivo basada en IIoT y Machine Learning. Adaptado de "Holistic Concept Towards a Reference Architecture Model for Predictive Maintenance, 2023"

3.2 Aplicaciones en el Sector Energético

El sector energético ha implementado ampliamente estrategias de mantenimiento predictivo debido a la criticidad

operativa de equipos como turbinas, transformadores, generadores y sistemas de distribución eléctrica. La literatura científica evidencia un crecimiento significativo en investigaciones relacionadas con el uso de inteligencia artificial para monitoreo de condición y predicción de fallas en infraestructura energética.

En sistemas de generación eléctrica, las técnicas de aprendizaje automático son utilizadas para analizar variables como temperatura, vibraciones, corriente y presión, permitiendo identificar patrones asociados al deterioro de componentes críticos. Zhang et al. [3] señalan que los modelos predictivos basados en datos han mejorado significativamente la capacidad de diagnóstico en equipos eléctricos industriales.

En parques eólicos, por ejemplo, se han implementado modelos de mantenimiento predictivo para detectar fallas en rodamientos y cajas multiplicadoras mediante el análisis de señales vibracionales. Asimismo, en sistemas fotovoltaicos se utilizan técnicas de inteligencia artificial para identificar pérdidas de eficiencia y anomalías en paneles solares.

Adicionalmente, algunas investigaciones integran inteligencia artificial con tecnologías IoT y computación en la nube, permitiendo supervisión remota y análisis en tiempo real de activos energéticos distribuidos geográficamente [8].

Qin et al. [17] desarrollaron un sistema de mantenimiento predictivo aplicado a turbinas eólicas utilizando redes neuronales artificiales y algoritmos de aprendizaje automático para analizar datos de vibración y temperatura obtenidos mediante sensores instalados en componentes críticos. El estudio permitió detectar fallas asociadas a rodamientos y sistemas de transmisión con altos niveles de precisión, reduciendo significativamente los tiempos de inactividad y mejorando la confiabilidad operativa de los aerogeneradores.

De manera similar, Carvalho et al. [2] analizaron diferentes aplicaciones de *Machine Learning* en sistemas energéticos industriales, identificando el uso recurrente de algoritmos como Random Forest, Support Vector Machine y redes neuronales profundas para el monitoreo de transformadores y generadores eléctricos. Los autores concluyen que el análisis predictivo basado en datos históricos permite optimizar la programación de mantenimiento y disminuir fallas inesperadas en infraestructura energética crítica.

Por otra parte, Yang et al. [19] implementaron un modelo basado en *Deep Learning* para el diagnóstico de fallas en sistemas fotovoltaicos mediante el análisis de imágenes térmicas y variables eléctricas en tiempo real. La investigación demostró que las redes neuronales convolucionales permiten detectar anomalías operativas con mayor precisión que los métodos tradicionales de inspección manual, contribuyendo a mejorar la eficiencia energética y reducir pérdidas operacionales.

En términos generales, las aplicaciones de inteligencia artificial en el sector energético evidencian un predominio de técnicas basadas en aprendizaje automático, redes neuronales y análisis avanzado de datos provenientes de sensores industriales. Las investigaciones revisadas muestran una tendencia creciente hacia la integración de plataformas IoT, monitoreo remoto y computación en la nube para supervisión continua de activos energéticos. Sin embargo, persisten desafíos relacionados con la calidad de los datos, interoperabilidad entre sistemas y altos costos asociados a

infraestructura tecnológica y procesamiento de información en tiempo real.

3.3 Aplicaciones en la Industria de Petróleo y Gas

La industria de petróleo y gas representa uno de los sectores donde el mantenimiento predictivo tiene mayor impacto económico y operativo, debido al elevado costo asociado a fallas en equipos críticos como bombas, compresores, válvulas y sistemas de transporte de fluidos. En este contexto, la implementación de técnicas de inteligencia artificial ha permitido desarrollar estrategias orientadas a la detección temprana de anomalías, optimización del mantenimiento y reducción de riesgos operacionales.

Las investigaciones revisadas evidencian la implementación de algoritmos de aprendizaje automático para detectar anomalías operativas y predecir fallas en sistemas de perforación y transporte. En particular, el análisis de vibraciones y señales acústicas ha permitido desarrollar modelos predictivos orientados a la detección temprana de desgaste mecánico y fenómenos de corrosión.

Asimismo, diferentes estudios reportan el uso de inteligencia artificial para optimizar el mantenimiento en oleoductos y gasoductos mediante sistemas inteligentes de monitoreo continuo. Estas tecnologías permiten reducir riesgos operacionales y minimizar impactos ambientales asociados a fugas o fallas estructurales [9].

En este sector también se evidencia un interés creciente por integrar plataformas digitales con análisis predictivo avanzado, permitiendo implementar estrategias de mantenimiento basadas en condición y reducir costos asociados a mantenimiento no planificado.

Alao et al. [19] desarrollaron un modelo predictivo aplicado a bombas centrífugas utilizadas en procesos de extracción de petróleo, empleando algoritmos de *Machine Learning* basados en Random Forest y redes neuronales artificiales. El estudio utilizó datos históricos de vibración, presión y temperatura obtenidos mediante sensores industriales, permitiendo identificar patrones de desgaste mecánico y cavitación con altos niveles de precisión. Los autores concluyeron que el análisis predictivo contribuye significativamente a disminuir tiempos de parada y optimizar la disponibilidad operativa de equipos críticos.

De manera similar, Shaban et al. [20] implementaron técnicas de aprendizaje profundo (*Deep Learning*) para detectar anomalías en ductos de transporte de gas mediante análisis de señales acústicas y monitoreo continuo de presión. La investigación evidenció que las redes neuronales convolucionales permiten identificar fugas y defectos estructurales de manera más rápida y precisa frente a métodos tradicionales de inspección manual, reduciendo riesgos ambientales y pérdidas operacionales.

Por otra parte, Mohammadi et al. [21] analizaron aplicaciones de inteligencia artificial orientadas al monitoreo predictivo de compresores industriales en plataformas offshore. El modelo desarrollado integró sensores IoT y algoritmos predictivos para supervisar variables críticas como temperatura, vibración y flujo de fluidos en tiempo real. Los resultados demostraron mejoras en la capacidad de detección temprana de fallas y reducción de costos asociados a mantenimiento correctivo.

En términos generales, las aplicaciones de inteligencia artificial en la industria de petróleo y gas muestran un predominio de técnicas basadas en aprendizaje automático, análisis de vibraciones y procesamiento avanzado de señales industriales. Asimismo, se observa una tendencia creciente hacia la integración de plataformas IoT y monitoreo remoto para supervisión continua de infraestructura crítica. No obstante, las principales limitaciones identificadas están relacionadas con la complejidad operacional de los entornos industriales, altos costos de implementación y necesidad de grandes volúmenes de datos confiables para entrenamiento de modelos predictivos.

3.4 Aplicaciones en la Industria Minera

La industria minera ha incorporado progresivamente soluciones basadas en inteligencia artificial para mejorar la confiabilidad de maquinaria pesada y sistemas de procesamiento mineral. Los principales equipos monitoreados incluyen trituradoras, bandas transportadoras, sistemas hidráulicos y maquinaria móvil de extracción. Debido a las condiciones extremas de operación y al elevado costo asociado a fallas no programadas, el mantenimiento predictivo se ha convertido en una herramienta estratégica para optimizar la disponibilidad operativa y reducir interrupciones en los procesos productivos.

En este contexto, las investigaciones destacan el uso de modelos predictivos para analizar condiciones operativas y detectar patrones de desgaste en componentes sometidos a condiciones severas de trabajo. Los sistemas de monitoreo implementados generalmente utilizan sensores de vibración, temperatura y presión conectados a plataformas de análisis de datos en tiempo real.

Además, algunos estudios reportan aplicaciones de aprendizaje profundo para reconocimiento de anomalías en imágenes térmicas y señales industriales, facilitando la identificación temprana de fallas mecánicas en equipos de alto costo operativo [10].

Kusiak y Verma [22] desarrollaron un modelo predictivo aplicado a maquinaria minera rotativa utilizando algoritmos de aprendizaje automático y análisis de vibraciones para detectar desgaste prematuro en rodamientos industriales. El estudio empleó datos obtenidos mediante sensores instalados en trituradoras y sistemas de procesamiento mineral, logrando identificar condiciones anómalas con altos niveles de precisión. Los autores concluyeron que la implementación de modelos predictivos permite reducir tiempos de inactividad y mejorar la planificación del mantenimiento en operaciones mineras de alta demanda.

Por otra parte, Zhang et al. [23] implementaron redes neuronales profundas (*Deep Learning*) para el monitoreo de bandas transportadoras utilizadas en minería a gran escala. El modelo desarrollado analizó imágenes térmicas y señales operativas obtenidas en tiempo real, permitiendo detectar desviaciones relacionadas con desalineación, desgaste y sobrecalentamiento de componentes mecánicos. Los resultados demostraron mejoras significativas en la capacidad de diagnóstico frente a métodos convencionales de inspección manual.

De manera complementaria, Ristovski et al. [24] integraron sensores IoT y plataformas de análisis predictivo para supervisar maquinaria móvil de extracción minera. La investigación utilizó variables de operación como

temperatura, presión hidráulica y consumo energético para desarrollar modelos de mantenimiento basados en condición. Los autores evidenciaron que la integración entre monitoreo continuo e inteligencia artificial mejora la confiabilidad operativa y optimiza la gestión de activos industriales.

En términos generales, las aplicaciones de inteligencia artificial en minería evidencian un predominio de técnicas basadas en aprendizaje automático, análisis de vibraciones y monitoreo inteligente mediante sensores industriales. Asimismo, se observa una creciente incorporación de tecnologías IoT y plataformas digitales para supervisión remota de maquinaria pesada. Sin embargo, las investigaciones también reportan limitaciones relacionadas con condiciones extremas de operación, complejidad de integración tecnológica y altos costos asociados a infraestructura de monitoreo y procesamiento de datos en tiempo real.

3.5 Aplicaciones en el Sector Hospitalario y Biomédico

En el sector hospitalario, el mantenimiento predictivo ha adquirido relevancia debido a la necesidad de garantizar la disponibilidad continua de equipos biomédicos e infraestructura crítica asociada a servicios asistenciales. Las aplicaciones identificadas incluyen sistemas HVAC hospitalarios, bombas de vacío, compresores, plantas eléctricas, sistemas UPS y redes de gases medicinales. La continuidad operativa de estos sistemas resulta fundamental para asegurar la prestación adecuada de los servicios médicos y la seguridad de los pacientes.

Las investigaciones recientes evidencian el uso de inteligencia artificial para supervisar variables operativas y detectar comportamientos anómalos en equipos hospitalarios críticos. Estas aplicaciones permiten anticipar fallas que podrían afectar la continuidad de los servicios médicos y la seguridad de los pacientes.

En sistemas de climatización hospitalaria, por ejemplo, se han implementado modelos predictivos basados en aprendizaje automático para optimizar el mantenimiento de unidades manejadoras de aire y sistemas de ventilación. Asimismo, algunos estudios reportan aplicaciones relacionadas con el monitoreo inteligente de consumo energético y eficiencia operativa en instalaciones hospitalarias [11].

Kim et al. [25] desarrollaron un sistema de mantenimiento predictivo aplicado a equipos HVAC hospitalarios utilizando algoritmos de *Machine Learning* para analizar variables como temperatura, humedad, presión y consumo energético. El estudio utilizó datos recopilados mediante sensores instalados en unidades manejadoras de aire, logrando identificar patrones asociados a fallas mecánicas y pérdidas de eficiencia operativa. Los resultados demostraron una reducción significativa en tiempos de inactividad y costos asociados a mantenimiento correctivo.

Por otra parte, Ahmed et al. [26] implementaron redes neuronales artificiales para el monitoreo predictivo de sistemas UPS utilizados en infraestructura hospitalaria crítica. La investigación analizó variables eléctricas relacionadas con voltaje, corriente, temperatura y ciclos de carga de baterías, permitiendo detectar condiciones anómalas asociadas al deterioro de componentes eléctricos. Los autores concluyeron que el uso de inteligencia artificial mejora la

confiabilidad de sistemas de respaldo energético esenciales para áreas críticas hospitalarias.

De manera complementaria, Bousdekis et al. [27] desarrollaron una arquitectura basada en internet de las cosas e inteligencia artificial para supervisar equipos biomédicos y sistemas críticos hospitalarios mediante plataformas de monitoreo remoto. El modelo integró sensores inteligentes y análisis predictivo en tiempo real para detectar desviaciones operativas y generar alertas tempranas. Los resultados evidenciaron mejoras en la disponibilidad de activos biomédicos y optimización de recursos asociados al mantenimiento hospitalario.

En términos generales, las aplicaciones de inteligencia artificial en el sector hospitalario muestran un crecimiento progresivo asociado a la digitalización de infraestructura crítica y automatización de procesos de mantenimiento. Las investigaciones revisadas evidencian un predominio de técnicas basadas en aprendizaje automático, monitoreo remoto e integración de sensores IoT para supervisión continua de sistemas biomédicos y energéticos. No obstante, persisten desafíos relacionados con costos de implementación, interoperabilidad entre sistemas y necesidad de garantizar altos niveles de confiabilidad y seguridad operacional en entornos hospitalarios.

3.6 Aplicaciones en Transporte y Automoción

El sector transporte y automoción también ha mostrado un crecimiento significativo en la implementación de mantenimiento predictivo basado en inteligencia artificial. Las aplicaciones más frecuentes se relacionan con monitoreo de motores, sistemas de frenos, baterías, sistemas ferroviarios y gestión de flotas. La incorporación de sensores inteligentes y plataformas de análisis de datos ha permitido desarrollar estrategias orientadas a mejorar la seguridad operativa, optimizar la disponibilidad de los vehículos y reducir costos asociados a mantenimiento no planificado.

En la industria automotriz, los fabricantes utilizan modelos predictivos para supervisar condiciones operativas de vehículos y anticipar fallas mecánicas mediante el análisis continuo de datos generados por sensores integrados. En sistemas ferroviarios, las estrategias de mantenimiento predictivo permiten identificar defectos en ruedas, rieles y sistemas de tracción antes de que ocurran fallas críticas [12].

Además, el desarrollo de vehículos eléctricos ha incrementado el interés por aplicaciones de inteligencia artificial orientadas al monitoreo del estado de baterías y sistemas electrónicos de potencia, buscando optimizar la vida útil y confiabilidad de estos componentes.

Jardine et al. [1] destacan que el mantenimiento basado en condición aplicado al sector transporte ha evolucionado gracias al uso de modelos predictivos orientados al análisis continuo de variables operativas y monitoreo inteligente de componentes críticos. Los autores señalan que el uso de inteligencia artificial permite reducir fallas inesperadas y optimizar la programación del mantenimiento en sistemas ferroviarios y flotas industriales.

Por otra parte, Zhao et al. [28] desarrollaron un modelo de *Deep Learning* para diagnóstico predictivo de fallas en motores eléctricos utilizados en vehículos industriales y sistemas ferroviarios. La investigación utilizó señales de vibración y corriente eléctrica obtenidas mediante sensores integrados, permitiendo identificar anomalías relacionadas

con desgaste mecánico y desalineación de componentes. Los resultados mostraron una mejora significativa en la precisión de detección frente a métodos tradicionales basados únicamente en inspecciones periódicas.

De manera complementaria, Liu et al. [29] implementaron algoritmos de aprendizaje automático para el monitoreo predictivo de baterías en vehículos eléctricos. El modelo analizó variables como temperatura, ciclos de carga, voltaje y capacidad energética para estimar el estado de salud de las baterías y anticipar posibles fallas. Los autores concluyeron que el uso de inteligencia artificial contribuye a optimizar la vida útil de sistemas de almacenamiento energético y mejorar la confiabilidad operativa de vehículos eléctricos.

Asimismo, Sharma et al. [30] desarrollaron una plataforma de mantenimiento predictivo para gestión inteligente de flotas mediante integración de sensores IoT, análisis en la nube y modelos predictivos basados en *Machine Learning*. El sistema permitió supervisar variables mecánicas y operativas en tiempo real, generando alertas automáticas ante posibles condiciones de falla. Los resultados evidenciaron reducciones importantes en tiempos de inactividad y costos asociados a mantenimiento correctivo.

En términos generales, las aplicaciones de inteligencia artificial en transporte y automoción muestran un predominio de técnicas basadas en aprendizaje automático, redes neuronales y análisis de datos provenientes de sensores embarcados. Las investigaciones revisadas evidencian una tendencia creciente hacia integración de internet de las cosas, monitoreo remoto y análisis en tiempo real para optimizar la gestión de vehículos y sistemas ferroviarios. Sin embargo, persisten desafíos relacionados con ciberseguridad, manejo de grandes volúmenes de datos y necesidad de infraestructura tecnológica especializada para procesamiento continuo de información.

IV. DESAFÍOS Y DIRECCIONES FUTURAS EN LA APLICACIÓN DE INTELIGENCIA ARTIFICIAL PARA EL MANTENIMIENTO PREDICTIVO

A pesar del crecimiento significativo en la implementación de técnicas de inteligencia artificial en mantenimiento predictivo, aún existen múltiples desafíos técnicos, operativos y económicos que limitan su adopción generalizada en diferentes sectores industriales. La literatura científica evidencia que, aunque los modelos basados en aprendizaje automático y análisis de datos ofrecen resultados prometedores, su implementación práctica continúa enfrentando dificultades relacionadas con la calidad de los datos, escalabilidad de los modelos, costos tecnológicos y disponibilidad de infraestructura especializada [2].

Adicionalmente, la rápida evolución de las tecnologías asociadas a la Industria 4.0 genera la necesidad de desarrollar soluciones más robustas, interpretables y accesibles, capaces de integrarse eficientemente en entornos industriales heterogéneos. En este contexto, diferentes investigaciones han identificado áreas prioritarias de desarrollo que representan tanto desafíos actuales como oportunidades futuras para el fortalecimiento del mantenimiento predictivo basado en inteligencia artificial.

4.1 Calidad, Disponibilidad e Integración de Datos

Uno de los principales desafíos identificados en la literatura corresponde a la calidad y disponibilidad de los datos utilizados para el entrenamiento y validación de modelos predictivos. Los sistemas de inteligencia artificial requieren grandes volúmenes de información confiable y representativa para lograr un desempeño adecuado; sin embargo, en muchos entornos industriales los datos disponibles presentan problemas de ruido, inconsistencias, valores faltantes o baja frecuencia de adquisición [9].

En sistemas industriales tradicionales, además, es común encontrar infraestructura con limitada capacidad de monitoreo, dificultando la captura continua de variables operativas relevantes. La ausencia de sensores adecuados o la falta de integración entre plataformas SCADA, sistemas IoT y bases de datos históricas limita considerablemente el desarrollo de modelos predictivos robustos.

Otro aspecto relevante es la heterogeneidad de los datos industriales. La información puede provenir de múltiples fuentes, incluyendo señales de vibración, imágenes térmicas, variables eléctricas, registros operativos y sistemas de supervisión, lo que genera desafíos asociados a la integración y procesamiento de datos multimodales [3].

Asimismo, la literatura evidencia la escasez de bases de datos públicas orientadas específicamente a mantenimiento predictivo en ciertos sectores industriales, lo que dificulta la comparación de resultados entre investigaciones y limita la reproducibilidad de los estudios desarrollados.

4.2 Generalización y Escalabilidad de los Modelos

Otro desafío importante corresponde a la capacidad de generalización de los modelos de inteligencia artificial implementados en mantenimiento predictivo. En muchos casos, los modelos desarrollados son altamente dependientes de las condiciones específicas bajo las cuales fueron entrenados, dificultando su transferencia hacia otros equipos, procesos o sectores industriales [13].

Por ejemplo, un modelo entrenado para detectar fallas en motores eléctricos dentro de una planta manufacturera puede no presentar el mismo desempeño cuando se implementa en sistemas energéticos o maquinaria minera, debido a diferencias operativas, ambientales y estructurales.

La escalabilidad también representa una limitación significativa, especialmente en industrias con grandes volúmenes de activos distribuidos geográficamente. La implementación de soluciones predictivas a gran escala requiere infraestructura computacional robusta, capacidades de almacenamiento y plataformas capaces de procesar información en tiempo real.

Además, algunos modelos avanzados de Deep Learning presentan elevados requerimientos computacionales, dificultando su implementación en entornos industriales con recursos tecnológicos limitados. Esto ha motivado el desarrollo de estrategias basadas en computación distribuida, edge computing y procesamiento híbrido entre nube y dispositivos locales [6].

4.3 Interpretabilidad y Confiabilidad de los Modelos

La interpretabilidad de los modelos de inteligencia artificial constituye uno de los aspectos más relevantes para

su adopción en entornos industriales. Aunque técnicas avanzadas como Deep Learning ofrecen altos niveles de precisión, muchas funcionan como modelos de “caja negra”, dificultando comprender cómo se generan las decisiones o predicciones realizadas [14].

En aplicaciones industriales críticas, donde una decisión incorrecta puede afectar la seguridad operativa o generar pérdidas económicas significativas, es fundamental que el personal técnico pueda interpretar y validar los resultados entregados por los sistemas predictivos.

Esta problemática ha impulsado el interés por el desarrollo de modelos explicables o estrategias de Inteligencia Artificial Explicable (XAI), orientadas a mejorar la transparencia y comprensión de los algoritmos utilizados en mantenimiento predictivo.

Asimismo, la confiabilidad de los modelos depende no solo de su precisión estadística, sino también de su capacidad para adaptarse a condiciones operativas cambiantes y detectar anomalías no presentes durante la fase de entrenamiento.

4.4 Costos y Acceso a la Tecnología

Los costos asociados a la implementación de soluciones basadas en inteligencia artificial representan otra barrera importante, especialmente para pequeñas y medianas empresas industriales. La adopción de estrategias de mantenimiento predictivo generalmente requiere inversión en sensores inteligentes, infraestructura de comunicaciones, plataformas de almacenamiento de datos y recursos computacionales especializados [8].

Adicionalmente, la implementación de modelos avanzados puede demandar personal altamente capacitado en áreas como análisis de datos, inteligencia artificial, automatización industrial y ciberseguridad, lo que incrementa los costos operativos y limita la accesibilidad tecnológica en ciertos contextos industriales.

En muchos países y sectores productivos, especialmente en economías en desarrollo, aún existen limitaciones relacionadas con infraestructura digital, conectividad y disponibilidad de tecnologías de monitoreo industrial. Esta situación dificulta la adopción masiva de soluciones avanzadas de mantenimiento predictivo.

Como respuesta a estas limitaciones, diversas investigaciones proponen el desarrollo de plataformas más accesibles, arquitecturas modulares y soluciones basadas en software libre que permitan reducir costos y facilitar la integración tecnológica en industrias con menor capacidad de inversión.

4.5 Direcciones Futuras

Las tendencias futuras en mantenimiento predictivo apuntan hacia una integración cada vez mayor entre inteligencia artificial, Internet de las Cosas (IoT), computación en la nube y sistemas ciberfísicos propios de la Industria 4.0 [15].

Una de las áreas con mayor proyección corresponde al desarrollo de gemelos digitales (Digital Twins), los cuales permiten crear representaciones virtuales de activos industriales para simular condiciones operativas, evaluar desempeño y anticipar posibles fallas en tiempo real.

Asimismo, el avance de técnicas de Inteligencia Artificial Explicable (XAI) busca mejorar la transparencia y confiabilidad de los modelos predictivos, facilitando su aceptación en sectores industriales críticos.

Otra tendencia importante es la implementación de soluciones basadas en Edge AI, donde el procesamiento de datos se realiza directamente en dispositivos locales cercanos a los equipos industriales, reduciendo tiempos de respuesta y dependencia de infraestructura en la nube.

Igualmente, se espera un crecimiento significativo en el uso de modelos híbridos que integren múltiples técnicas de inteligencia artificial, combinando aprendizaje automático, lógica difusa y análisis estadístico para mejorar precisión y adaptabilidad.

Finalmente, la literatura científica destaca la necesidad de fortalecer el trabajo interdisciplinario entre especialistas en automatización, mantenimiento, inteligencia artificial y análisis de datos, con el propósito de desarrollar soluciones más eficientes, escalables y alineadas con las necesidades reales de la industria moderna.

V. CONCLUSIONES

El análisis desarrollado en la presente monografía permitió evidenciar que el mantenimiento predictivo se ha consolidado como una de las principales aplicaciones de la inteligencia artificial dentro de la Industria 4.0, debido a su capacidad para mejorar la confiabilidad operativa, reducir tiempos de inactividad y optimizar los procesos de mantenimiento en diferentes sectores industriales.

A través del estudio de mapeo sistemático y el análisis bibliométrico realizado con VOSviewer, fue posible identificar un crecimiento significativo en la producción científica relacionada con inteligencia artificial y mantenimiento predictivo durante los últimos años, especialmente en áreas asociadas al aprendizaje automático, análisis de datos industriales e integración con tecnologías IoT.

Los resultados obtenidos muestran que la industria manufacturera, el sector energético, petróleo y gas, minería, transporte y el sector hospitalario son algunos de los entornos con mayor implementación de soluciones basadas en inteligencia artificial para mantenimiento predictivo, impulsados por la necesidad de aumentar la disponibilidad y seguridad de equipos críticos.

La literatura científica revisada evidencia que las técnicas de inteligencia artificial son utilizadas principalmente para monitoreo de condición, diagnóstico de fallas, detección de anomalías y estimación de vida útil de componentes industriales, utilizando información proveniente de sensores, sistemas SCADA y plataformas de adquisición de datos.

El análisis realizado permitió identificar que la efectividad de las soluciones de mantenimiento predictivo depende en gran medida de la calidad, disponibilidad e integración de los datos industriales. Problemas asociados a ruido, inconsistencia y ausencia de información continúan siendo una limitación importante para el desarrollo de modelos predictivos robustos y confiables.

Se evidenció que uno de los principales desafíos actuales corresponde a la generalización y escalabilidad de los modelos de inteligencia artificial, ya que muchos sistemas desarrollados presentan dificultades para adaptarse a

diferentes contextos industriales o condiciones operativas distintas a aquellas utilizadas durante su entrenamiento.

Asimismo, la interpretabilidad de los modelos constituye un aspecto crítico para la adopción industrial de técnicas avanzadas de inteligencia artificial, especialmente en aplicaciones donde las decisiones predictivas deben ser comprendidas y validadas por personal técnico y operativo.

Desde el punto de vista económico y tecnológico, la implementación de estrategias de mantenimiento predictivo continúa representando una barrera para algunas organizaciones debido a los costos asociados a sensores inteligentes, infraestructura computacional, plataformas de almacenamiento y capacitación especializada.

Las tendencias futuras identificadas en la literatura apuntan hacia una mayor integración entre inteligencia artificial, Internet de las Cosas, computación en la nube, Edge Computing y gemelos digitales, permitiendo el desarrollo de sistemas de mantenimiento más autónomos, inteligentes y adaptativos.

Finalmente, se concluye que la inteligencia artificial representa una herramienta estratégica para la evolución del mantenimiento industrial moderno; sin embargo, su implementación exitosa requiere no solo avances tecnológicos, sino también una adecuada gestión de datos, infraestructura digital, formación interdisciplinaria y adaptación a las necesidades específicas de cada sector industrial.

AGRADECIMIENTOS

A mi familia por brindarme todo el apoyo por continuar mi formación como ingeniero. A la Universidad Santo Tomas por brindarme la oportunidad de lograr este nuevo logro en mi carrera como profesional.

REFERENCIAS

- [1] R. K. Mobley, *An Introduction to Predictive Maintenance*, 2nd ed. Burlington, USA: Butterworth-Heinemann, 2002.
- [2] T. P. Carvalho, F. A. A. M. N. Soares, R. Vita, R. P. Francisco, J. P. Basto, and S. G. S. Alcalá, "A systematic literature review of machine learning methods applied to predictive maintenance," *Computers & Industrial Engineering*, vol. 137, p. 106024, 2019.
- [3] W. Zhang, D. Yang, and H. Wang, "Data-driven methods for predictive maintenance of industrial equipment: A survey," *IEEE Systems Journal*, vol. 13, no. 3, pp. 2213–2227, 2019.
- [4] B. Kitchenham and S. Charters, *Guidelines for Performing Systematic Literature Reviews in Software Engineering*. Keele University, 2007.
- [5] J. Van Eck and L. Waltman, "Software survey: VOSviewer, a computer program for bibliometric mapping," *Scientometrics*, vol. 84, no. 2, pp. 523–538, 2010.
- [6] J. Lee, B. Bagheri, and H. A. Kao, "A cyber-physical systems architecture for industry 4.0-based manufacturing systems," *Manufacturing Letters*, vol. 3, pp. 18–23, 2015.
- [7] Y. Peng, M. Dong, and M. J. Zuo, "Current status of machine prognostics in condition-based maintenance: A review," *The International Journal of Advanced Manufacturing Technology*, vol. 50, pp. 297–313, 2010.
- [8] A. K. S. Jardine, D. Lin, and D. Banjevic, "A review on machinery diagnostics and prognostics implementing condition-based maintenance," *Mechanical Systems and Signal Processing*, vol. 20, no. 7, pp. 1483–1510, 2006.
- [9] Y. Lei, N. Li, L. Guo, N. Li, T. Yan, and J. Lin, "Machinery health prognostics: A systematic review from data acquisition to RUL prediction," *Mechanical Systems and Signal Processing*, vol. 104, pp. 799–834, 2018.
- [10] S. Yin and O. Kaynak, "Big data for modern industry: Challenges and trends," *Proceedings of the IEEE*, vol. 103, no. 2, pp. 143–146, 2015.
- [11] A. Ahmed, K. Mahmood, and M. Islam, "A survey of anomaly detection techniques in smart healthcare systems," *Artificial Intelligence Review*, vol. 54, no. 3, pp. 2331–2375, 2021.

- [12] Z. Chen, C. Li, and R. Sánchez, "Gearbox fault identification and classification with convolutional neural networks," *Shock and Vibration*, vol. 2015, pp. 1–10, 2015.
- [13] E. Alpaydin, *Introduction to Machine Learning*, 4th ed. Cambridge, USA: MIT Press, 2021.
- [14] S. Samek, G. Montavon, A. Vedaldi, L. Hansen, and K. Müller, *Explainable AI: Interpreting, Explaining and Visualizing Deep Learning*. Cham, Switzerland: Springer, 2019.
- [15] L. Da Xu, E. L. Xu, and L. Li, "Industry 4.0: State of the art and future trends," *International Journal of Production Research*, vol. 56, no. 8, pp. 2941–2962, 2018.
- [16] K. Wang, Y. Wang, Y. Sun, S. Guo, and J. Wu, "Green industrial Internet of Things architecture: An energy-efficient perspective," *IEEE Communications Magazine*, vol. 54, no. 12, pp. 48–54, 2016.
- [17] Y. Qin, C. Wang, and X. Zhang, "Wind turbine fault diagnosis using artificial neural networks and vibration analysis," *Renewable Energy*, vol. 116, pp. 1–8, 2018.
- [18] D. Yang, H. Wang, and Y. Zhang, "Deep learning-based fault diagnosis for photovoltaic systems using thermal imaging," *Energy Reports*, vol. 6, pp. 123–130, 2020.
- [19] M. A. Alao, A. A. Ayodele, and O. O. Ajayi, "Predictive maintenance of centrifugal pumps using machine learning techniques," *Journal of Petroleum Science and Engineering*, vol. 196, p. 107731, 2021.
- [20] H. Shaban, M. El-Hawary, and A. Kamel, "Deep learning-based gas pipeline leak detection using acoustic emission signals," *Engineering Applications of Artificial Intelligence*, vol. 95, p. 103912, 2020.
- [21] M. Mohammadi, S. Rashidi, and H. Ahmadi, "IoT-enabled predictive maintenance for offshore compressor systems using artificial intelligence," *Sensors*, vol. 22, no. 4, pp. 1–18, 2022.
- [22] A. Kusiak and A. Verma, "A data-driven approach for monitoring blade pitch faults in wind turbines," *IEEE Transactions on Sustainable Energy*, vol. 2, no. 1, pp. 87–96, 2011.
- [23] Y. Zhang, H. Wang, and X. Chen, "Deep learning-based conveyor belt fault diagnosis using thermal imaging in mining environments," *Mechanical Systems and Signal Processing*, vol. 152, p. 107398, 2021.
- [24] Z. Ristovski, M. Franjic, and D. Gulan, "IoT-based predictive maintenance in mining machinery using machine learning techniques," *Mining Engineering*, vol. 73, no. 5, pp. 42–49, 2021.
- [25] J. Kim, S. Lee, and H. Park, "Machine learning-based predictive maintenance for hospital HVAC systems," *Energy and Buildings*, vol. 215, p. 109899, 2020.
- [26] S. Ahmed, M. Khan, and R. Hussain, "Artificial neural network approach for predictive maintenance of UPS systems in healthcare facilities," *IEEE Access*, vol. 9, pp. 45612–45624, 2021.
- [27] A. Bousdekis, D. Apostolou, and G. Mentzas, "A proactive decision making framework for condition-based maintenance using IoT and predictive analytics," *International Journal of Production Research*, vol. 58, no. 13, pp. 3891–3903, 2020.
- [28] R. Zhao, R. Yan, Z. Chen, K. Mao, P. Wang, and R. X. Gao, "Deep learning and its applications to machine health monitoring," *Mechanical Systems and Signal Processing*, vol. 115, pp. 213–237, 2019.
- [29] K. Liu, Y. Shang, Q. Ouyang, and W. Widanage, "A data-driven approach with uncertainty quantification for predicting future capacities and remaining useful life of lithium-ion battery," *IEEE Transactions on Industrial Electronics*, vol. 68, no. 4, pp. 3170–3180, 2021.
- [30] A. Sharma, G. Singh, and R. Kumar, "IoT-enabled predictive maintenance framework for intelligent fleet management," *IEEE Internet of Things Journal*, vol. 8, no. 18, pp. 14145–14156, 2021.