

**Análisis de modelos de mantenimiento predictivo de motores de inducción trifásicos
mediante IoT y algoritmos de machine learning**

Laura Graciano Olarte

Asesor

Cindy Vanessa Carmona Cadavid

Ingeniera de Control – MSc en Ingeniería

Universidad Nacional Abierta y a Distancia UNAD

Escuela de Ciencias Básicas, Tecnología e Ingeniería - ECBTI

Ingeniería Electrónica

2026

Agradecimientos

En este camino académico, ninguna meta hubiera sido posible sin el apoyo de quienes han sido parte fundamental de mi vida.

Agradezco, en primer lugar, a mis padres, quienes con amor, disciplina y sacrificios incontables han estado siempre a mi lado. Gracias por enseñarme que la perseverancia y la humildad son valores que abren puertas y que los sueños se alcanzan con esfuerzo diario. A ustedes debo la fortaleza que me permitió llegar hasta aquí.

A mi familia: abuelos, tíos y primos, quienes han sido una red de apoyo constante, compartiendo conmigo palabras de aliento, consejos, compañía y cariño en cada etapa de este proceso. Su presencia me ha recordado que ningún logro tiene verdadero valor si no se comparte con quienes más amamos.

Quiero expresar un agradecimiento especial a la señorita María Eugenia, mi docente de Física y Matemáticas en el colegio, quien creyó en mis capacidades y me mostró que sí era capaz de enfrentar el desafío de estudiar una ingeniería. Gracias a sus palabras de aliento y a la confianza que depositó en mí, aprendí a transformar el miedo en valentía y la inseguridad en determinación.

Extiendo también mi gratitud a mis profesores universitarios, quienes compartieron con paciencia y dedicación su conocimiento, motivándome a ir más allá de lo evidente y a entender que la ingeniería no solo resuelve problemas, sino que también construye futuro.

A mis compañeros, aunque el contacto fue limitado por la modalidad virtual, agradezco los momentos de apoyo y colaboración que compartimos. Sus aportes, incluso a la distancia, fueron valiosos y me recordaron que el aprendizaje también se construye en comunidad, aun cuando no siempre estemos físicamente juntos.

Finalmente, agradezco a todos aquellos que de una u otra manera contribuyeron a que hoy este proyecto sea una realidad. Cada palabra de ánimo, cada gesto de apoyo y cada enseñanza recibida están presentes en este logro.

Dedicatoria

A mis padres, Waned y Margoth, quienes han sido la guía y el faro en cada paso de mi vida. Gracias por enseñarme con el ejemplo que los sueños se construyen con esfuerzo, constancia y amor. Ustedes me han mostrado que las dificultades son solo oportunidades para crecer y que la educación es el legado más valioso que se puede dejar a un hijo. Todo lo que soy hoy se lo debo a su sacrificio, paciencia y fe inquebrantable en mí.

A mi hija, Valery, porque en ti encontré la razón más grande para no rendirme nunca. Eres mi motor, mi inspiración y el reflejo de mis anhelos. Cada logro que alcanzo lleva tu nombre, porque eres la fuerza que me impulsa a levantarme en los días difíciles y la alegría que llena mi corazón en los momentos de triunfo. Este trabajo es, sobre todo, para ti, porque me enseñaste que ser madre no es un límite, sino la mayor motivación para luchar con más determinación.

Este logro no es solo mío: es nuestro, porque cada paso en este camino estuvo acompañado de su amor, su apoyo y su presencia incondicional. Por eso, esta dedicatoria la entrego con todo mi corazón, a ustedes tres, que son mi mayor tesoro y mi razón de ser.

Resumen

En los últimos años, el mantenimiento predictivo de los motores de inducción trifásicos se ha convertido en un tema clave dentro de la industria, esto debido a que los motores representan una parte importante del consumo energético y del funcionamiento de muchas plantas productivas. Este trabajo presenta una revisión de distintas investigaciones que estudian la aplicación de tecnologías como el Internet de las cosas y el machine learning para anticipar fallas y mejorar el rendimiento de las máquinas eléctricas. En particular, se enfatiza en la relevancia de los motores de inducción trifásicos por su amplio uso industrial, su operación continua y su susceptibilidad a fallas eléctricas, mecánicas y térmicas que pueden afectar la eficiencia y la continuidad de los procesos productivos.

Durante el proceso se recopiló información reciente de estudios que abordan el diagnóstico predictivo desde diversos enfoques como modelos de redes neuronales y análisis de series temporales. Asimismo, se analizan arquitecturas de monitoreo basadas en IoT, considerando la adquisición de datos mediante sensores, protocolos de comunicación industrial y plataformas de procesamiento en la nube y en el borde (edge computing), lo que permite comprender el flujo de información desde el motor hasta sistemas de análisis. A partir de esta revisión se reconocen avances y desafíos que limitan la implementación de estos sistemas en entornos industriales, como la gestión de grandes volúmenes de datos, la interoperabilidad entre dispositivos, la ciberseguridad y restricciones presupuestales.

El propósito general es ofrecer una visión clara cómo la integración del IoT con el machine learning puede fortalecer las estrategias de mantenimiento en motores eléctricos, en el contexto latinoamericano, donde la adopción de tecnologías digitales sigue en crecimiento. Adicionalmente, el trabajo plantea un enfoque orientado a soluciones viables y de bajo costo,

destacando que la implementación del mantenimiento predictivo no depende exclusivamente de infraestructuras complejas, sino de un diseño de arquitecturas escalables y modelos analíticos eficientes. Este análisis busca servir como base teórica para futuras investigaciones sobre monitoreo predictivo de motores de inducción trifásicos, aportando un marco de referencia que facilite la transición hacia prácticas alineadas con los principios de la Industria 4.0.

Palabras clave: IoT, mantenimiento predictivo, motores de inducción, machine learning, Industria 4.0

Abstract

In recent years, predictive maintenance of three-phase induction motors has become a key topic in industry, as these motors represent a significant portion of energy consumption and are essential for the operation of many production plants. This work presents a review of different studies that analyze the application of technologies such as the Internet of Things (IoT) and machine learning to anticipate failures and improve the performance of electrical machines. In particular, the importance of three-phase induction motors is emphasized due to their widespread industrial use, continuous operation, and susceptibility to electrical, mechanical, and thermal faults that may affect efficiency and the continuity of production processes.

During the study, recent information from different research works addressing predictive diagnosis through various approaches was compiled, including neural network models and time series analysis. In addition, IoT-based monitoring architectures are examined, considering data acquisition through sensors, industrial communication protocols, and processing platforms in the cloud and at the edge (edge computing). This makes it possible to understand the information flow from the motor to the analysis systems. From this review, the main advances are identified, as well as some challenges that still limit the implementation of these systems in real industrial environments, such as the management of large volumes of data, interoperability between devices, cybersecurity, and budget constraints.

The main objective is to provide a clear overview of how the integration of IoT with machine learning can strengthen maintenance strategies for electric motors, particularly in the Latin American context, where the adoption of digital technologies continues to grow. Additionally, the work proposes an approach focused on feasible and low-cost solutions, highlighting that the implementation of predictive maintenance does not depend exclusively on

complex infrastructures, but also on the proper design of scalable architectures and efficient analytical models. This analysis aims to serve as a theoretical basis for future research on predictive monitoring of three-phase induction motors, providing a reference framework that supports the transition toward practices aligned with the principles of Industry 4.0.

Keywords: IoT, predictive maintenance, induction motors, machine learning, Industry 4.0

Contenido

Introducción	11
Planteamiento del problema	14
Justificación.....	16
Objetivos	17
Objetivo General	17
Objetivos Específicos	17
Marco metodológico	18
Marco de referencia.....	20
Estado del Arte	20
Marco conceptual	24
Análisis de las arquitecturas de monitoreo basadas en IoT y los modelos predictivos más empleados en el diagnóstico de fallas	38
Propuesta metodológica que integre IoT y machine learning para el monitoreo predictivo de motores de inducción trifásicos	48
Conclusiones	57
Recomendaciones	60
Referencias Bibliográficas.....	61

Lista de Tablas

Tabla 1 <i>Autores vs Metodología</i>	30
Tabla 2 <i>Clasificación de Modelos de Maching Learning</i>	32
Tabla 3 <i>Comparación de Técnicas</i>	37
Tabla 4 <i>Comparación de Modelos Predictivos en Mantenimiento de Motores</i>	42
Tabla 5 <i>Comparación de arquitecturas de IoT en Mantenimiento Predictivo</i>	44
Tabla 6 <i>Fases de la propuesta Metodológica</i>	53
Tabla 7 <i>Indicadores de Desempeño del Sistema</i>	56

Lista de Figuras

Figura 1 <i>Partes del Motor Trifásico</i>	25
Figura 2 <i>Fallas en los Motores de Inducción Trifásicos y Monofásicos</i>	26
Figura 3 <i>Red Neuronal Artificial (ANN)</i>	33
Figura 4 <i>Arbol de Decisión y Random Forest</i>	34
Figura 5 <i>k-NN (k- Nearest Neighbors)</i>	34
Figura 6 <i>Redes LSTM (Series Temporales)</i>	35
Figura 7 <i>Funciones de Pérdida en el Aprendizaje Automático</i>	36
Figura 8 <i>Arquitectura Básica de Tres Capas en un Sistema IoT</i>	39
Figura 9 <i>Arquitectura de Mantenimiento Predictivo Basada en IoT</i>	46
Figura 10 <i>Arquitectura Basada en Edge Computing para la Gestión de Datos IoT y Multimedia</i>	47
Figura 11 <i>Diagrama de la Propuesta Metodológica para el Monitoreo Predictivo de Motores de Inducción Trifásicos Basado en IoT y Machine Learning</i>	54

Introducción

La transformación digital ha cambiado profundamente la manera en que operan las industrias modernas. La automatización, el intercambio de datos y la inteligencia artificial han permitido que los procesos sean más rápidos, eficientes y precisos (Gouda et al., 2022). Sin embargo, esta evolución tecnológica también ha traído nuevos retos, especialmente en la gestión del mantenimiento de los equipos, donde una falla inesperada puede significar pérdidas económicas significativas y paradas prolongadas en la producción.

Entre todos los equipos que forman parte del entorno industrial, los motores eléctricos, en especial los de inducción trifásicos, desempeñan un papel esencial en la mayoría de los procesos productivos (Valbério Gonzaga De Araujo, 2024). Su uso es generalizado por su alta fiabilidad, bajo costo de operación y capacidad para funcionar de manera continua, pero cuando presentan una falla, las consecuencias se reflejan directamente en la productividad y el consumo energético (Adamou, 2024).

En el contexto colombiano, estos motores son fundamentales en sectores como la minería, la energía y la manufactura. Su desempeño impacta directamente la competitividad industrial, y por ello, mantener su operatividad es una prioridad estratégica. Las estrategias de mantenimiento tradicionales, como el mantenimiento correctivo o el preventivo, han demostrado ser insuficientes. El primero actúa solo después de que ocurre la falla, y el segundo se basa en cronogramas fijos que no reflejan el estado real del equipo.

Frente a estas limitaciones, el mantenimiento predictivo surge como una alternativa más precisa y eficiente. Esta estrategia de mantenimiento permite monitorear el estado de los motores en tiempo real mediante el uso de sensores in-situ y algoritmos de análisis de datos, anticipando posibles fallas y evitando interrupciones imprevistas (Felipe Lima Aires, 2025). Gracias al

Internet de las Cosas (IoT) y al machine learning, las empresas pueden analizar el comportamiento de los equipos, detectar patrones anómalos y tomar decisiones basadas en datos.

Esta monografía se enfoca en una revisión de artículos y estudios recientes, donde se busca analizar como tecnologías como el Internet de las cosas (IoT) y el aprendizaje automático (Machine Learning) pueden complementarse al mantenimiento predictivo y así mejorar la confiabilidad de los motores y la eficiencia en los procesos industriales.

Planteamiento del Problema

Los motores de inducción trifásicos representan uno de los pilares fundamentales de la industria moderna, ya que impulsan una amplia variedad de sistemas en sectores como la manufactura, la minería, la energía y los servicios públicos. Se estima que más del 60 % de la energía eléctrica consumida a nivel industrial es utilizada por este tipo de motores, lo que evidencia su papel crucial en los procesos productivos (Boglietti, Cavagnino & Tenconi, 2020).

Su funcionamiento continuo y eficiente es esencial para mantener la estabilidad operativa y evitar interrupciones que puedan comprometer la productividad y generar pérdidas económicas.

En muchas industrias, los motores de inducción todavía son críticos y dependen de estrategias de mantenimiento que no permiten anticipar los fallos, ya que se basan en cronogramas fijos o en la reparación una vez que la falla ha ocurrido (Jha, Sai, Krishna Reddy & Singh, 2022). Este enfoque conlleva paradas no planificadas, reemplazos prematuros de componentes y un uso menos eficiente de los recursos disponibles.

El mantenimiento predictivo ha surgido como una alternativa más eficiente al permitir el monitoreo continuo de variables eléctricas y mecánicas, y gracias al Internet de las Cosas (IoT) y al aprendizaje automático (Machine Learning), es posible analizar datos de operación y detectar anomalías antes de que se conviertan en fallas (Kumar, Andriollo, Cirrincione & Tortella, 2022). Aun así, su implementación en contextos como los países en desarrollo enfrenta barreras como la falta de estandarización, la carencia de datos adecuados y la limitada adopción tecnológica (Sobhi, Reshadi, Zarft, Terheide & Dick, 2023).

Por ello, esta monografía propone una revisión sobre el uso combinado de IoT y machine learning en el mantenimiento predictivo de motores de inducción trifásicos, con el propósito de

identificar los avances más relevantes, las limitaciones actuales y las oportunidades de aplicación en el contexto industrial latinoamericano.

Pregunta de investigación:

¿Cómo la integración de tecnologías de Internet de las Cosas (IoT) y machine learning en Colombia puede mejorar la detección temprana de fallas en motores de inducción trifásicos?

Justificación

El funcionamiento confiable de los motores de inducción trifásicos es esencial para mantener la continuidad de los procesos industriales, ya que estos equipos impulsan gran parte de la maquinaria utilizada en sectores como la manufactura, la minería y la energía. Su papel es tan relevante que una sola falla puede ocasionar interrupciones en la producción y pérdidas económicas considerables. De acuerdo con Sheikh et al. (2022), cerca del 37 % de las fallas en motores de inducción están relacionadas con el estator y un 41 % con los rodamientos, lo que evidencia la necesidad de contar con estrategias de mantenimiento más precisas y predictivas.

Esta investigación se justifica porque, aunque en los últimos años se han logrado avances importantes en el uso de tecnologías como el Internet de las Cosas (IoT) y el aprendizaje automático (Machine Learning) para el diagnóstico de fallas (Sheikh et al., 2022), su aplicación en países latinoamericanos sigue siendo limitada. En contextos como el colombiano, donde gran parte de la industria depende del funcionamiento continuo de estos motores, la implementación de sistemas predictivos podría representar una mejora significativa en la eficiencia, confiabilidad y sostenibilidad operativa. Sin embargo, para lograrlo es necesario comprender las metodologías y modelos que han demostrado ser efectivos tanto en otros entornos industriales como en otros países.

Por tanto, este trabajo reúne y analiza estudios recientes sobre el mantenimiento predictivo en motores de inducción trifásicos a nivel mundial, con el propósito de identificar los avances, limitaciones y oportunidades que ofrecen las tecnologías emergentes. De esta forma, se busca aportar una base que oriente futuras investigaciones y fomente la adopción de soluciones tecnológicas que contribuyan a mejorar la gestión del mantenimiento en la industria colombiana.

Objetivos

Objetivo General

Analizar los modelos de mantenimiento predictivo en motores de inducción trifásicos a través de una revisión de investigaciones recientes que integran tecnologías de Internet de las Cosas (IoT) y algoritmos de machine learning.

Objetivos Específicos

Identificar los principales enfoques y metodologías utilizados en la literatura sobre la aplicación de IoT y machine learning en el mantenimiento predictivo de motores de inducción trifásicos.

Analizar las arquitecturas de monitoreo basadas en IoT y los modelos predictivos más empleados en el diagnóstico de fallas, evaluando sus ventajas, limitaciones y posibles aplicaciones en entornos industriales.

Establecer una propuesta metodológica que integre IoT y machine learning para el monitoreo predictivo de motores de inducción trifásicos.

Marco Metodológico

La metodología utilizada en este trabajo tiene un enfoque cualitativo, puesto que se basa en el análisis de información documental. No se busca realizar una validación práctica o experimental, sino comprender a profundidad cómo diferentes autores han abordado el mantenimiento predictivo de motores de inducción trifásicos mediante el uso de tecnologías como el Internet de las Cosas (IoT) y el machine learning.

El tipo de investigación es descriptivo y documental, ya que se parte de la revisión de estudios, artículos científicos, informes técnicos y tesis publicadas entre los años 2019 y 2026. A través de esta revisión, se busca identificar los métodos, algoritmos y modelos que se han utilizado para anticipar fallas y mejorar el funcionamiento de los motores de inducción trifásicos.

Para el desarrollo del estudio se siguieron tres fases principales. En la primera, se realizó la búsqueda y recolección de información en bases de datos académicas como IEEE Xplore, ScienceDirect, SpringerLink y repositorios universitarios. En la segunda fase, se llevará a cabo la organización y análisis de los documentos seleccionados, clasificándolos de acuerdo con su relevancia y aportes al tema. Finalmente, en la tercera fase, se elaborará una síntesis que permitirá reconocer las tendencias actuales, los avances más importantes y los desafíos que aún existen en la aplicación del mantenimiento predictivo en motores de inducción trifásicos. A partir de este análisis, se planteará una propuesta metodológica de carácter conceptual, orientada a integrar los elementos más relevantes identificados en la revisión documental. Esta propuesta no contempla una validación experimental ni una implementación práctica, sino que busca estructurar de manera teórica un modelo de referencia basado en arquitecturas IoT y técnicas de machine learning aplicadas al diagnóstico predictivo. Con lo descrito anteriormente se busca dar respuesta a cada uno de los objetivos propuestos de éste trabajo.

Así mismo, se busca construir una base sólida de conocimiento y generar una visión clara de cómo las tecnologías digitales pueden transformar las estrategias de mantenimiento industrial, especialmente en el contexto latinoamericano, donde la adopción de soluciones inteligentes aún se encuentra en proceso de crecimiento.

Marco de Referencia

En este capítulo se presentan los fundamentos y los antecedentes más relevantes que sustentan el estudio sobre el mantenimiento predictivo aplicado a motores de inducción trifásicos, a partir del uso de tecnologías como el Internet de las Cosas (IoT) y el machine learning. Este marco busca ofrecer una comprensión clara del contexto tecnológico e industrial en el que se desarrolla el tema, así como de los principales conceptos y aportes de investigaciones previas.

Estado del Arte

En los últimos años, el mantenimiento predictivo ha tomado un papel fundamental en el sector industrial, especialmente en el diagnóstico de motores de inducción trifásicos. Diversos estudios han mostrado que cerca del 60 % del consumo energético industrial proviene de este tipo de motores, lo que resalta su importancia en la operación continua de plantas de producción (Sheikh et al., 2022). Debido a esto, la detección temprana de fallas resulta esencial para evitar paradas no planificadas y pérdidas económicas significativas.

Los avances recientes en el mantenimiento predictivo se relacionan principalmente con la incorporación de tecnologías como el Internet de las Cosas (IoT) y el machine learning, que permiten recopilar y analizar grandes volúmenes de datos para predecir el comportamiento de los equipos con mayor precisión. Según Drakaki et al. (2022), los algoritmos de aprendizaje automático, como redes neuronales (ANN), máquinas de soporte vectorial (SVM), Random Forest, k-Nearest Neighbors (k-NN) y modelos de aprendizaje profundo como: Long Short-Term Memory (LSTM) y Convolutional Neural Network (CNN), han demostrado alta efectividad para identificar patrones de deterioro en motores eléctricos. Estos modelos permiten analizar tanto señales eléctricas como mecánicas, facilitando la detección temprana de fallas complejas que no

son evidentes mediante métodos tradicionales. Sin embargo, la mayoría de estos estudios se han desarrollado en entornos controlados o de laboratorio, lo que incentiva nuevas investigaciones para su validación en escenarios industriales reales.

Desde la perspectiva del internet de las cosas (IoT), diversos autores señalan el uso de plataformas y tecnologías específicas que permiten el monitoreo continuo de los motores. Kumar et al. (2022) destacan que la integración de gateways industriales y microcontroladores como: Raspberry Pi, ESP32, Arduino Industrial Shields y PLCs con capacidad IoT, ha permitido conectar sensores con protocolos como MQTT (Message Queuing Telemetry Transport), OPC-UA (Open Platform Communications Unified Architecture), Modbus TCP, Wi-Fi industrial, LoRaWAN (Long Range Wide Area Network) y Ethernet/IP, logrando comunicaciones estables y de baja latencia. La selección del protocolo depende del entorno industrial, la criticidad del proceso y los requerimientos de confiabilidad y tiempo real del sistema de monitoreo. Estas tecnologías facilitan la transmisión en tiempo real de variables críticas como vibración, temperatura, corriente y voltaje.

En cuanto a los sensores, la literatura reporta el uso de acelerómetros MEMS (Micro-Electro-Mechanical Systems) para vibración, sensores PT100 para temperatura, transformadores de corriente (CT), sensores Hall, sensores piezoeléctricos y módulos de adquisición capaces de operar en ambientes industriales (Zhao et al., 2022). La selección del sensor está directamente relacionada con el tipo de falla que se desea detectar, tal como lo señalan estudios recientes sobre diagnóstico basado en análisis multimodal de señales (Alvarado-Hernández et al., 2022): las fallas mecánicas como desbalance, desalineación y desgaste de rodamientos se identifican principalmente mediante sensores de vibración y acústicos; las fallas térmicas mediante sensores de temperatura; mientras que las fallas eléctricas, como cortocircuitos inter-espigas, barras rotas

del rotor o desequilibrio de fases, se detectan a través del análisis de corriente, voltaje y flujo magnético.

Los casos reales reportados en la literatura muestran distintos niveles de implementación. En entornos controlados, estudios como el de Sobhi et al. (2023) demuestran que las redes neuronales y los modelos LSTM (Long Short-Term Memory) alcanzan precisiones superiores al 95 % en la predicción de fallas utilizando señales de vibración y corriente en bancos de pruebas. En escenarios industriales reales, investigaciones como las de Gouda et al. (2023) evidencian implementaciones exitosas en plantas de manufactura y procesamiento, donde se integran sensores IoT con plataformas en la nube para monitoreo remoto. Otros trabajos en fábricas de alimentos y refinerías han empleado sistemas híbridos basados en OPC-UA (Open Platform Communications – Unified Architecture) y MQTT (Message Queuing Telemetry Transport) para monitoreo continuo, logrando reducir tiempos de inactividad entre un 15 % y un 35 %, lo que evidencia el impacto positivo de estas tecnologías en la eficiencia operativa y la gestión del mantenimiento industrial.

A pesar de los avances, la literatura evidencia la falta de estudios aplicados al contexto latinoamericano, donde las limitaciones tecnológicas y económicas dificultan la adopción de sistemas de monitoreo avanzados. Ante esta situación, diversos estudios como los de Bedi et al. (2022) y Dina et al. (2023) proponen el uso de soluciones de bajo costo, basadas en microcontroladores como ESP32 y Raspberry Pi, sensores MEMS (Micro-Electro-Mechanical Systems) económicos como el ADXL345 y MPU6050 y plataformas de análisis orientadas al procesamiento y visualización de datos, tales como Grafana, Node-RED y entornos de programación en Python. Asimismo, se plantea el uso de módulos de comunicación LoRaWAN y Wi-Fi industrial de bajo consumo. De acuerdo con Bedi et al. (2022), este tipo de arquitecturas

IoT de bajo costo logra desempeños comparables a soluciones industriales tradicionales en tareas de monitoreo y diagnóstico, siempre que se realice una adecuada selección de sensores y modelos de análisis. De forma similar, Dina et al. (2023) reportan que la aplicación de modelos de machine learning sobre datos adquiridos con sensores económicos mantiene niveles aceptables de precisión en la detección temprana de fallas, lo que respalda la viabilidad técnica y económica de estas soluciones. Estos trabajos reportan que dichas arquitecturas permiten reducir los costos de implementación sin afectar significativamente la precisión del diagnóstico, facilitando su adopción en pequeñas y medianas empresas (PMI). En síntesis, las investigaciones recientes demuestran el potencial de la integración entre IoT y machine learning para optimizar el mantenimiento predictivo de motores de inducción trifásicos. Sin embargo, persisten desafíos relacionados con la adaptación de estas tecnologías a contextos reales, la estandarización de metodologías y la validación de resultados en condiciones industriales diversas. Este trabajo busca aportar una revisión teórica que contribuya a cerrar esas brechas y a fortalecer el conocimiento sobre el tema en el ámbito regional.


En investigaciones más recientes, Aires et al. (2025) proponen un enfoque basado en la construcción de un índice de salud (Health Index) combinado con técnicas de inteligencia artificial para mejorar la confiabilidad de motores de inducción trifásicos, integrando variables eléctricas y mecánicas dentro de un esquema de mantenimiento predictivo estructurado. Por su parte, Garcia Tucci (2025) desarrolla un modelo de análisis de señales orientado a la detección de rotura de barras en el rotor mediante técnicas de clasificación supervisada, evidenciando la aplicabilidad de algoritmos de aprendizaje automático en el diagnóstico de fallas eléctricas. En la misma línea, Moraes (2025) plantea la utilización de arquitecturas computacionales optimizadas

para el procesamiento de señales industriales, enfocadas en mejorar la precisión del reconocimiento de patrones asociados a fallas incipientes en motores de inducción.

Asimismo, Zapata Álvarez et al. (2025) proponen un enfoque no intrusivo basado en el análisis de señales de corriente utilizando técnicas de inteligencia artificial, lo que reduce la necesidad de instrumentación adicional sobre el motor y facilita su aplicación en entornos industriales reales. De igual manera, Silva et al. (2025) enfatizan la importancia de la correcta selección de características, el análisis de vibraciones y la estructuración adecuada de los conjuntos de datos como factores determinantes para garantizar la confiabilidad y reproducibilidad de los modelos predictivos aplicados al mantenimiento basado en condición.

Marco Conceptual

Los motores de inducción trifásicos son ampliamente utilizados en la industria por su robustez, bajo costo y facilidad de mantenimiento. Estos motores convierten la energía eléctrica en energía mecánica mediante la interacción entre el campo magnético giratorio del estator y la corriente inducida en el rotor, lo que los hace indispensables en aplicaciones como ventilación, bombeo, transporte y sistemas de producción. Como se presenta en la Figura 1, un motor de inducción trifásico está compuesto por el estator (parte fija que genera el campo magnético), el rotor (parte móvil donde se inducen corrientes), la carcasa, los rodamientos y el sistema de ventilación. Estos componentes trabajan en conjunto para garantizar un funcionamiento estable y eficiente. Sin embargo, debido a su funcionamiento continuo, están expuestos a diversas fallas que pueden afectar su rendimiento, como desequilibrios eléctricos, fallos en el aislamiento, vibraciones excesivas, sobrecalentamiento y desgaste de rodamientos (Sheikh et al., 2022). Estas fallas no solo reducen la eficiencia, sino que también pueden causar interrupciones costosas en los procesos industriales.

Figura 1*Partes del Motor Trifásico*

Nota. Se presentan los principales componentes de un motor de inducción trifásico y su función básica dentro del sistema electromecánico. Tomado de. Motor Trifásico.


<https://www.areatecnologia.com/electricidad/motor-trifasico.html>

Las fallas en los motores de inducción trifásicos pueden clasificarse de manera general en fallas eléctricas, mecánicas, térmicas y magnéticas. Las fallas eléctricas incluyen cortocircuitos entre espiras, cortocircuitos a masa, cortocircuitos entre fases y daño en las barras del rotor, como barras rotas o fisuradas, las cuales generan incrementos anómalos de corriente, pérdidas de eficiencia y deterioro progresivo del aislamiento (Alvarado-Hernández et al., 2022; Silva et al., 2025) (ver Figura 2). Dentro de las fallas mecánicas se encuentran el desgaste y daño en los rodamientos, el desalineamiento del eje, el desequilibrio dinámico y deformaciones estructurales, siendo los rodamientos una de las principales causas de falla en aplicaciones industriales (Silva et al., 2025). Por su parte, las fallas térmicas están asociadas al sobrecalentamiento provocado por sobrecargas, ventilación deficiente o degradación del aislamiento, lo que puede derivar en

quemaduras parciales o totales del bobinado. Finalmente, las fallas magnéticas comprenden fenómenos como la excentricidad del entrehierro y alteraciones en la distribución del flujo magnético, afectando directamente el comportamiento electromagnético y el rendimiento operativo del motor (Alvarado-Hernández et al., 2022).

Figura 2

Fallas en los Motores de Inducción Trifásicos y Monofásicos



Nota. Se ilustran algunas de las fallas eléctricas y mecánicas más comunes presentes en motores industriales. Tomado de. <https://es.scribd.com/doc/117394807/catalogo-fallas>

Desde el punto de vista energético, muchas de estas fallas también se manifiestan a través de variaciones en indicadores eléctricos como la potencia activa, potencia reactiva, factor de potencia y distorsión armónica (Clerc, 2022; Kumar et al., 2022). Por ejemplo, un aumento anormal en la potencia reactiva o una disminución del factor de potencia puede indicar problemas de carga mecánica excesiva o deterioro en el aislamiento (Bahgat et al., 2023). De

igual forma, la presencia de armónicos elevados suele estar asociada a defectos en el sistema de alimentación, variadores de velocidad o saturación magnética, lo que puede acelerar el envejecimiento del motor (Clerc, 2022). Asimismo, incrementos inesperados en la potencia activa pueden reflejar pérdidas por fricción, desalineación o desgaste de rodamientos (Kumar et al., 2022). El análisis conjunto de estas variables permite correlacionar el comportamiento energético con fallas físicas, fortaleciendo el diagnóstico integral en esquemas de mantenimiento predictivo (González & Pérez, 2022; Ioannides et al., 2023).

Para minimizar estos riesgos, las estrategias de mantenimiento se han convertido en un componente clave de la gestión industrial. Tradicionalmente, se ha recurrido al mantenimiento correctivo, que actúa una vez ocurre la falla, y al mantenimiento preventivo, que se basa en revisiones periódicas programadas. Sin embargo, ambos enfoques presentan limitaciones, ya que no consideran el estado real de la máquina, lo que puede generar reemplazos innecesarios o tiempos muertos prolongados (Kumar et al., 2022). En contraste, el mantenimiento predictivo se centra en anticipar las fallas antes de que ocurran, mediante la observación constante de las condiciones del equipo y el análisis de los datos que se generan durante su operación. Esta metodología permite planificar intervenciones solo cuando son necesarias, optimizando recursos y prolongando la vida útil de los equipos.

Además, el mantenimiento predictivo contribuye a mejorar la confiabilidad operativa de los sistemas industriales, reducir los costos asociados a paradas no programadas y aumentar la seguridad del personal, al permitir la detección temprana de condiciones anómalas que podrían derivar en fallas catastróficas.

El mantenimiento predictivo se apoya en la adquisición de datos mediante sensores que miden variables como temperatura, corriente, vibración, flujo magnético y nivel de ruido. Estos

sensores pueden incluir acelerómetros MEMS (Micro-Electro-Mechanical Systems) para vibración, sensores de temperatura (RTD o termopares), sensores de corriente basados en efecto Hall, micrófonos industriales para análisis acústico y sensores de flujo magnético. El avance de tecnologías como el Internet de las Cosas (IoT) ha permitido recopilar esta información en tiempo real, utilizando redes inalámbricas y plataformas en la nube para el almacenamiento y análisis de datos. Gracias al IoT, los sistemas industriales pueden tener una visión continua y actualizada del estado de cada motor, lo que mejora la toma de decisiones y la capacidad de respuesta ante posibles anomalías (Bedi et al., 2022). Esta infraestructura facilita la detección temprana de desviaciones en el comportamiento normal del motor, permitiendo correlacionar variables eléctricas, mecánicas y térmicas para un diagnóstico más integral del estado de salud del equipo.

El Internet de las Cosas (IoT) se define como una red de dispositivos capaces de recopilar, transmitir y procesar información mediante internet, sin intervención humana directa. En el contexto industrial, el IoT permite que máquinas, sensores y sistemas se comuniquen entre sí utilizando tecnologías como Wi-Fi industrial, LoRaWAN (Long Range Wide Area Network), Modbus TCP (Transmission Control Protocol), OPC-UA (Open Platform Communications – Unified Architecture) y MQTT (Message Queuing Telemetry Transport), lo que facilita la supervisión continua y remota de los motores (Ioannides et al., 2023; Ahmed & Lee, 2023; Gutiérrez-Trejo et al., 2023). Asimismo, el uso de arquitecturas IoT permite implementar sistemas distribuidos, donde parte del procesamiento puede realizarse en dispositivos locales (edge computing), reduciendo la latencia, el consumo de ancho de banda y la dependencia de infraestructuras centralizadas (Debauche et al., 2022; Yu et al., 2023; Correa Esquivia et al., 2022).

En este contexto, han surgido nuevas arquitecturas de procesamiento y comunicación que se consideran tendencias actuales en los sistemas IoT industriales. Entre ellas se destacan el cloud computing, el edge computing, el fog computing y el 5G-MEC (Multi-access Edge Computing), las cuales permiten distribuir el procesamiento de la información según los requerimientos de latencia, volumen de datos y capacidad computacional del sistema de monitoreo (Debauche et al., 2022; Yu et al., 2023; Gutiérrez-Trejo et al., 2023; Ahmed & Lee, 2023).

El cloud computing se emplea principalmente para el almacenamiento de grandes volúmenes de datos históricos y el entrenamiento de modelos de machine learning, mientras que el edge computing permite realizar análisis preliminares y detección de anomalías cerca del motor, reduciendo los tiempos de respuesta. De manera complementaria, el fog computing actúa como una capa intermedia entre el borde y la nube, facilitando la gestión de múltiples dispositivos IoT y mejorando la escalabilidad del sistema. Por su parte, el 5G-MEC combina las redes móviles 5G con capacidades de procesamiento en el borde de la red, permitiendo comunicaciones de alta velocidad, baja latencia y mayor confiabilidad, lo cual resulta especialmente relevante para aplicaciones industriales de mantenimiento predictivo en tiempo casi real (Debauche et al., 2022; Yu et al., 2023; Gutiérrez-Trejo et al., 2023).

Por su parte, el machine learning se ha convertido en una herramienta esencial para analizar los grandes volúmenes de datos generados por los sensores. A través de algoritmos de aprendizaje supervisado y no supervisado, es posible reconocer patrones anómalos y predecir el comportamiento futuro de los motores. Modelos como las redes neuronales, los árboles de decisión, el algoritmo Random Forest o las redes LSTM (Long Short-Term Memory) han demostrado ser eficaces para la detección temprana de fallas y la estimación del estado de salud

del motor (Dina et al., 2023). En este sentido, en la Tabla 1 se presenta una síntesis de diversos autores y las metodologías empleadas en el diagnóstico de fallas, permitiendo identificar tendencias actuales en la integración de IoT y machine learning.

Tabla 1

Autores vs Metodología

Autor(es)	Metodología utilizada	Aplicación
Sheikh et al. (2022)	Análisis de fallas en motores	Clasificación de fallas eléctricas y mecánicas
Bedi et al. (2022)	IoT + sensores MEMS	Monitoreo en tiempo real
Ahmed & Lee (2023)	Machine Learning + IoT	Diagnóstico predictivo
Dina et al. (2023)	Modelos ML (ANN, LSTM)	Predicción de fallas
Zhao et al. (2022)	CNN + análisis de vibraciones	Detección de fallas mecánicas
Gutiérrez-Trejo et al. (2023)	Arquitecturas IoT	Procesamiento de datos industriales

Nota. Resumen de investigaciones recientes relacionadas con IoT y machine learning aplicados al mantenimiento predictivo.

Como se observa en la tabla, existe una clara tendencia hacia la integración de tecnologías IoT con modelos de aprendizaje automático para el diagnóstico de fallas.

De lo anterior, es posible identificar un concepto usado para conocer la “salud de un motor”, este concepto se conoce como índice de salud o “health index”, el cual corresponde a un indicador compuesto que resume el estado general del motor a partir de múltiples variables monitorizadas (Dina et al., 2023; Ahmed & Lee, 2023). Este índice se construye mediante la fusión de datos provenientes de sensores eléctricos, mecánicos y térmicos, procesados mediante algoritmos de análisis estadístico o modelos de machine learning, permitiendo representar el nivel de degradación del activo en una métrica cuantificable (Gutiérrez-Trejo et al., 2023). De

manera formal, el health index puede expresarse como una suma ponderada de variables normalizadas:

$$HI = \sum_{i=1}^n w_i \cdot x_i$$

donde x_i corresponde al valor normalizado de cada parámetro monitorizado (vibración, temperatura, corriente, armónicos, entre otros), y w_i representa el peso asignado según su influencia relativa en la degradación del motor (Aires et al., 2025). El health index permite transformar grandes volúmenes de datos en un valor único o escala normalizada (por ejemplo, de 0 a 1 o de 0 a 100), facilitando la interpretación por parte del personal de mantenimiento.

El estado óptimo se define generalmente como la condición de operación nominal del motor bajo parámetros eléctricos y mecánicos dentro de los límites establecidos por el fabricante y normas técnicas (por ejemplo, niveles de vibración, temperatura, corriente y factor de potencia dentro de rangos permitidos). En un modelo normalizado basado en suma ponderada, el estado óptimo ocurre cuando los valores x_i se mantienen cercanos a sus condiciones nominales, lo que produce un índice bajo o cercano al valor de referencia saludable. En escalas de 0 a 1, valores cercanos a 1 (cuando el modelo está invertido hacia condición saludable) o cercanos a 0 (cuando el modelo mide degradación acumulada) pueden asociarse con operación normal; en escalas porcentuales, rangos entre 80–100% suelen indicar condición normal, valores entre 50–80% estado de alerta o degradación incipiente, y valores inferiores al 50% condición crítica o alto riesgo de falla. Estos umbrales se determinan a partir de análisis histórico de fallas, entrenamiento supervisado del modelo y límites normativos aplicables al sistema específico (Ahmed & Lee, 2023; Dina et al., 2023; Aires et al., 2025).

En general, estos modelos permiten procesar los datos históricos y generar pronósticos más precisos que los métodos estadísticos tradicionales. Las redes neuronales artificiales (ANN) (ver Figura 3) se inspiran en el funcionamiento del cerebro humano y pueden identificar relaciones complejas entre múltiples variables. Los árboles de decisión y el modelo Random Forest (ver Figura 4) organizan la información mediante reglas tipo “si-entonces”; en el caso de Random Forest, se emplean múltiples árboles para mejorar la precisión del diagnóstico. El algoritmo k-NN (k-Nearest Neighbors) (ver Figura 5) clasifica eventos según su similitud con casos previos, y las redes LSTM (Long Short-Term Memory) (ver Figura 6) pueden analizar datos secuenciales para predecir fallas futuras. Asimismo, las CNN (Convolutional Neural Network) permiten analizar señales convertidas en espectrogramas, logrando altos niveles de precisión en la detección de fallas. En relación con la diversidad de enfoques, en la Tabla 2 se presenta una clasificación de los modelos de machine learning utilizados en mantenimiento predictivo.

Tabla 2

Clasificación de Modelos de Maching Learnig

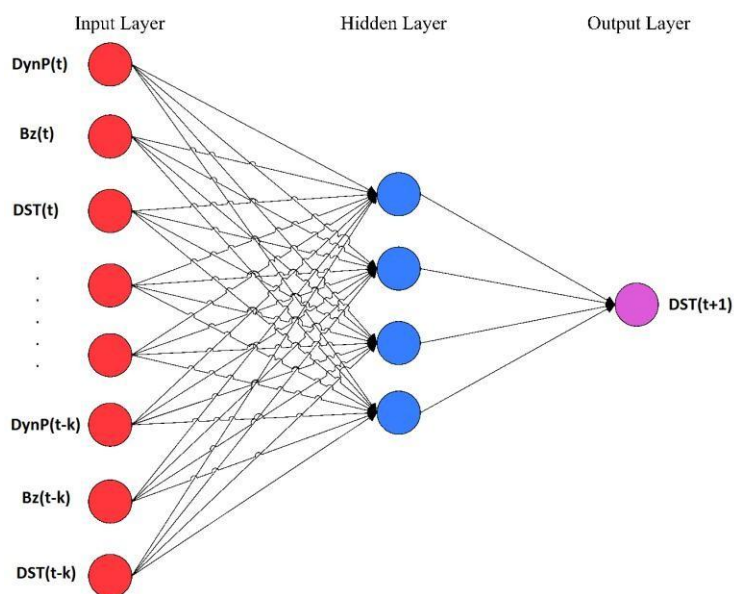
Tipo de modelo	Algoritmos	Características	Aplicación
Supervisado	Random Forest, k-NN, SVM	Usa datos etiquetados	Clasificación de fallas
No supervisado	Clustering	Detecta patrones ocultos	Detección de anomalías
Deep Learning	ANN, CNN, LSTM	Alta precisión, requiere muchos datos	Series temporales, vibraciones
Estadísticos	ARIMA, Prophet	Modelos simples y explicables	Predicción de tendencias

Nota. Clasificación de algoritmos de machine learning según su aplicación y capacidad de análisis en mantenimiento predictivo.

De acuerdo con esta clasificación, los modelos supervisados son los más utilizados en el diagnóstico de fallas, debido a su capacidad para aprender a partir de datos etiquetados y generar predicciones precisas. Sin embargo, los modelos no supervisados también presentan un gran potencial en la detección de anomalías cuando no se dispone de información previa sobre fallas. Por su parte, los modelos basados en series temporales resultan fundamentales en el análisis de datos secuenciales, permitiendo anticipar comportamientos futuros del sistema.

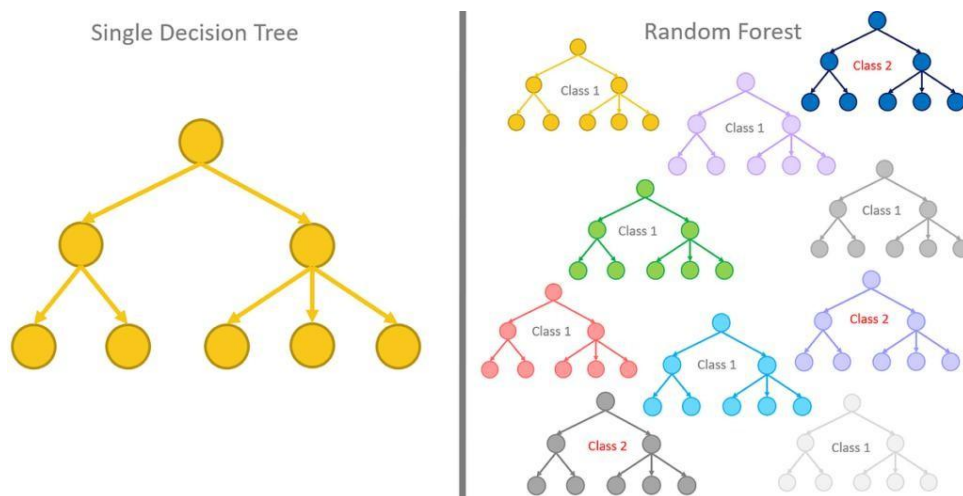
Figura 3

Red Neuronal Artificial (ANN)




Nota. Representación básica de una red neuronal artificial utilizada en tareas de clasificación y predicción de fallas. Tomado de. Las Redes Neurales Artificiales se posicionan como el mejor modelo para cuantificar los impactos ambientales sobre el recurso hídrico, Montoya, S, (2013)

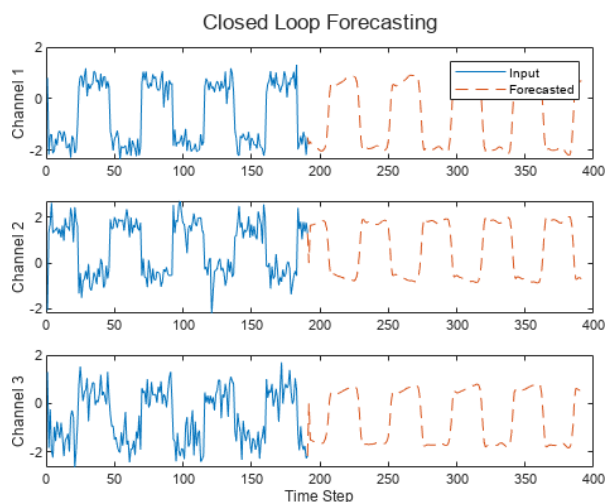
<https://gidahatari.com/ih-es/las-redes-neurales-artificiales-se-posesionan-como-el-mejor-modelo-para-cuantificar-los-impactos-ambientales-sobre-el-recurso-hdrico>

Figura 4*Arbol de Decisión y Random Forest*

Nota. Comparación visual entre un árbol de decisión individual y el modelo Random Forest basado en múltiples árboles. Tomado de. <https://machinelearningparatodos.com/arboles-de-decision-en-python/>

Figura 5*k-NN (k-Nearest Neighbors)*

Nota. Ejemplo del funcionamiento del algoritmo k-NN mediante clasificación basada en proximidad entre datos. Tomado de. K-nearest neighbour (K-nn) Algorithm, Bhardwaj, N, (2024) <https://blog.gopenai.com/k-nearest-neighbour-k-nn-algorithm-25085df55654>

Figura 6*Redes LSTM (Series Temporales)*

Nota. Arquitectura LSTM utilizada para el análisis de series temporales y predicción de comportamientos futuros. Tomado de. Introducción a la memoria a corto-largo plazo (LSTM),

<https://la.mathworks.com/discovery/lstm.html>

En el desarrollo de modelos de machine learning, los datos suelen dividirse en conjuntos de entrenamiento y prueba, comúnmente utilizando una proporción del 70 % para entrenamiento y 30 % para validación, con el fin de evaluar la capacidad de generalización del modelo. Esta separación permite entrenar el algoritmo con una parte de los datos y verificar su desempeño con información no vista previamente, reduciendo el riesgo de sobreajuste. La adecuación del modelo se determina a partir de su capacidad para identificar correctamente patrones de fallas y mantener un desempeño consistente frente a nuevos datos.

Para evaluar el desempeño de los modelos predictivos, se emplean métricas cuantitativas que permiten medir la precisión y confiabilidad de las predicciones. Entre las métricas más utilizadas se encuentran el Error Absoluto Medio (MAE), que mide la diferencia promedio entre los valores reales y los predichos; el Error Cuadrático Medio (MSE) y su raíz (RMSE), que

penalizan errores grandes y permiten evaluar la estabilidad del modelo (ver Figura 7); y la exactitud (Accuracy), utilizada principalmente en problemas de clasificación para medir el porcentaje de predicciones correctas (Chollet, 2021; Géron, 2022). Estas métricas proporcionan criterios objetivos para comparar distintos modelos y seleccionar aquel que ofrezca el mejor equilibrio entre precisión y complejidad (Zhang et al., 2021).

Figura 7

Funciones de Pérdida en el Aprendizaje Automático

Mean squared error	$\text{MSE} = \frac{1}{n} \sum_{t=1}^n e_t^2$
Root mean squared error	$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{t=1}^n e_t^2}$
Mean absolute error	$\text{MAE} = \frac{1}{n} \sum_{t=1}^n e_t $

Nota. Comparación de métricas de error utilizadas para evaluar el desempeño de modelos predictivos. Tomado de. Loss Functions in Machine Learning (MAE, MSE, RMSE), Kumar, N, (2019) <https://theprofessionalspoint.blogspot.com/2019/02/loss-functions-in-machine-learning-mae.html>

Dado que existen múltiples técnicas de machine learning aplicables al mantenimiento predictivo, resulta necesario comparar sus características, ventajas y limitaciones para una adecuada selección según el contexto de aplicación. En la Tabla 3 se presenta una comparación de los modelos más utilizados en el diagnóstico de fallas en motores de inducción trifásicos.

Tabla 3*Comparación de Técnicas*

Modelo	Ventajas	Limitaciones	Uso recomendado
ANN	Alta precisión	Requiere muchos datos	Fallas complejas
Random Forest	Fácil interpretación	Menor rendimiento en series temporales	Datos estructurados
LSTM	Ideal para datos en el tiempo	Alto costo computacional	Series temporales
k-NN	Simple	Sensible a ruido	Clasificación básica
ARIMA	Fácil implementación	Limitado a datos lineales	Tendencias estables

Nota. Comparación de ventajas, limitaciones y aplicaciones de distintos modelos predictivos empleados en motores eléctricos.

Como se evidencia en la comparación, no existe un modelo único que sea óptimo para todos los escenarios. La selección del algoritmo depende de factores como el tipo de datos disponibles, el volumen de información, la complejidad del sistema y los requerimientos de interpretabilidad. En este sentido, modelos como Random Forest ofrecen un buen equilibrio entre precisión e interpretabilidad, mientras que las redes neuronales y LSTM destacan en el análisis de patrones complejos y datos temporales. Esta diversidad de enfoques respalda la necesidad de diseñar arquitecturas flexibles que integren diferentes técnicas según las necesidades del sistema.

La integración del IoT con el machine learning ha revolucionado el mantenimiento industrial, al combinar la capacidad de monitoreo continuo con la inteligencia analítica de los algoritmos. Este enfoque ha demostrado mejorar la confiabilidad de los equipos, reducir los costos de operación y aumentar la seguridad en las plantas industriales (Ahmed & Lee, 2023; Gutiérrez-Trejo et al., 2023; Dina et al., 2023). En el contexto latinoamericano, donde muchas industrias aún operan con sistemas convencionales, la adopción de estas tecnologías representa

una oportunidad significativa para modernizar los procesos productivos y fortalecer la competitividad. Comprender cómo estas herramientas se aplican al mantenimiento predictivo de motores de inducción trifásicos es esencial para avanzar hacia una gestión más eficiente, sostenible y alineada con los principios de la Industria 4.0 (Debauche et al., 2022; Yu et al., 2023).

En cuanto al tipo de fallas detectables mediante estas tecnologías, los sistemas de mantenimiento predictivo permiten identificar fallas mecánicas (desalineación, desequilibrio, desgaste de rodamientos, holguras), fallas eléctricas (barras rotas del rotor, fallas en el aislamiento, desequilibrio de fases), fallas térmicas (sobrecalentamiento, mala ventilación) y fallas magnéticas (excentricidad del entrehierro, saturación). La combinación de sensores IoT y modelos de machine learning permite una detección más precisa y temprana de estas anomalías. Esta capacidad de diagnóstico integral facilita la transición desde esquemas reactivos hacia sistemas de mantenimiento inteligentes, basados en datos, que contribuyen a una gestión más eficiente y proactiva de los activos industriales.

Análisis de las Arquitecturas de Monitoreo Basadas en Iot Y Los Modelos Predictivos más Empleados en el Diagnóstico de Fallas


En el mantenimiento predictivo de motores de inducción trifásicos, las arquitecturas de monitoreo basadas en el Internet de las Cosas se han convertido en el pilar fundamental para la recopilación y gestión de datos. Estas arquitecturas permiten la conexión de sensores, dispositivos de comunicación, plataformas de almacenamiento y sistemas analíticos, conformando un ecosistema inteligente que facilita la supervisión continua de las condiciones operativas de los motores (Bedi et al., 2022). Su principal ventaja es la capacidad de detectar

cambios sutiles en el comportamiento del equipo antes de que se produzcan fallas críticas, permitiendo programar mantenimientos más eficientes y seguros.

Un sistema típico de monitoreo predictivo basado en IoT está compuesto por tres niveles (ver Figura 8):

Figura 8

Arquitectura Básica de Tres Capas en un Sistema IoT



Nota. Arquitectura IoT compuesta por las capas de percepción, comunicación y procesamiento de datos. Tomado de. https://www.researchgate.net/figure/Basic-three-layered-IoT-architecture_fig1_346555860

A diferencia de otros enfoques tradicionales, el mantenimiento predictivo se basa en monitorear el estado real del equipo para anticipar las fallas antes de que ocurran. Mientras que el mantenimiento correctivo actúa únicamente después de que la falla se presenta, generando paradas inesperadas y altos costos, el mantenimiento preventivo se realiza en intervalos fijos sin considerar el comportamiento real del motor, lo que puede llevar a intervenciones innecesarias. En cambio, el mantenimiento predictivo utiliza sensores, análisis de datos y modelos avanzados

para identificar anomalías tempranas y estimar el momento óptimo para intervenir, logrando una gestión más eficiente, precisa y alineada con las necesidades operativas del sistema.

Cuando se tiene un enfoque en IoT, es indispensable pensar en capas operativas, las cuales son la capa de adquisición de datos, la capa de comunicación y la capa de análisis. En la primera se utilizan sensores encargados de medir variables como la temperatura, la vibración, la corriente y el voltaje, parámetros que son clave para detectar anomalías en el funcionamiento del motor (Li et al., 2021).

En particular, diversos estudios recientes sobre monitoreo predictivo de motores eléctricos reportan que la combinación de acelerómetros MEMS para vibración, sensores de corriente basados en efecto Hall y sensores de temperatura tipo RTD o termopares resulta especialmente efectiva para la detección temprana de fallas mecánicas, eléctricas y térmicas, respectivamente (Zhao et al., 2022; Bedi et al., 2022; Ahmed & Lee, 2023). Por ejemplo, las fallas en rodamientos se asocian principalmente a incrementos en la vibración, mientras que los cortocircuitos en devanados o el desequilibrio de fases se reflejan en variaciones anómalas de corriente y temperatura.

Estos sensores pueden ser cableados o inalámbricos y se conectan a microcontroladores o gateways que actúan como intermediarios, procesando y enviando los datos hacia la nube o servidores locales mediante protocolos como MQTT (Message Queuing Telemetry Transport) o OPC-UA (Open Platform Communications Unified Architecture), ampliamente usados en entornos industriales (Gutiérrez-Trejo et al., 2023; Ioannides et al., 2023).

La capa de comunicación se encarga de garantizar la transmisión confiable de los datos hacia las plataformas de monitoreo. Con el avance de las redes industriales y las tecnologías de conectividad como Wi-Fi, Ethernet, LoRaWAN (Long Range Wide Area Network) o 5G, los

sistemas de mantenimiento predictivo pueden operar en tiempo real y con baja latencia (Gouda et al., 2023). Finalmente, en la capa de análisis se emplean algoritmos de machine learning y deep learning que procesan la información recibida, identifican patrones de comportamiento y determinan el estado de salud del motor (Dina et al., 2023; Ahmed & Lee, 2023). Estos modelos son capaces de reconocer comportamientos anómalos incluso en condiciones de ruido o con variaciones en la carga del sistema.

Entre los modelos predictivos más utilizados en el diagnóstico de fallas se destacan los basados en redes neuronales artificiales (ANN, Artificial Neural Networks), que permiten reconocer relaciones no lineales entre las variables medidas, logrando una alta precisión en la detección de fallas eléctricas y mecánicas (Soualhi et al., 2020). Otro modelo ampliamente implementado es el Random Forest, que clasifica el estado del motor a partir de múltiples árboles de decisión, reduciendo el riesgo de sobreajuste y aumentando la confiabilidad del diagnóstico. Asimismo, las redes neuronales convolucionales (CNN, Convolutional Neural Network) han mostrado gran efectividad en el análisis de señales de vibración y corriente, al poder identificar patrones característicos asociados a diferentes tipos de fallas (Zhao et al., 2022).

Las redes LSTM (Long Short-Term Memory), por su parte, se aplican en el análisis de series temporales para predecir comportamientos futuros de las variables eléctricas y mecánicas. Este tipo de modelo es especialmente útil cuando se dispone de grandes volúmenes de datos históricos, ya que tiene la capacidad de “recordar” tendencias pasadas y anticipar posibles anomalías (Dina et al., 2023). Por otro lado, los modelos estadísticos como ARIMA (AutoRegressive Integrated Moving Average) o Prophet siguen siendo herramientas relevantes en entornos donde los datos son más limitados o las condiciones de operación son estables. En este contexto, en la Tabla 4 se presenta una comparación de los principales modelos predictivos

utilizados en el diagnóstico de fallas en motores de inducción trifásicos, considerando sus características, ventajas, limitaciones y aplicaciones dentro del mantenimiento predictivo.

Tabla 4

Comparación de Modelos Predictivos en Mantenimiento de Motores

Modelo	Tipo	Características	Ventajas	Limitaciones	Aplicación
ANN (Redes neuronales)	Deep Learning	Modela relaciones no lineales complejas	Alta precisión	Requiere gran cantidad de datos	Fallas complejas
CNN	Deep Learning	Procesa señales como imágenes/espectrogramas	Alta precisión en vibraciones	Alto costo computacional	Análisis de vibración
LSTM	Deep Learning	Especializado en series temporales	Captura dependencias temporales	Entrenamiento complejo	Predicción de fallas
Random Forest	Supervisado	Conjunto de árboles de decisión	Robusto y preciso	Menor desempeño en series temporales	Clasificación de fallas
k-NN	Supervisado	Clasificación por similitud	Fácil implementación	Sensible al ruido	Diagnóstico básico
SVM	Supervisado	Separación de clases con hiperplanos	Alta precisión en datos pequeños	Difícil ajuste de parámetros	Clasificación
ARIMA	Estadístico	Modela tendencias lineales	Simple y explicable	No capta no linealidades	Predicción de tendencias
Prophet	Estadístico	Modelo aditivo con estacionalidad	Fácil implementación	Menor precisión en datos complejos	Series temporales

Nota. Comparación de algoritmos predictivos utilizados para identificar anomalías y predecir fallas en motores industriales.

Como se observa en la Tabla 4, los modelos de deep learning, como ANN, CNN y LSTM, destacan por su alta capacidad para modelar comportamientos complejos y no lineales, siendo especialmente útiles en el análisis de señales y series temporales. Por otro lado, los

modelos supervisados como Random Forest, SVM y k-NN ofrecen una buena precisión con menor complejidad computacional, lo que los hace adecuados para aplicaciones industriales con recursos limitados. Finalmente, los modelos estadísticos como ARIMA y Prophet continúan siendo relevantes en escenarios donde se requiere interpretabilidad y simplicidad, evidenciando que la selección del modelo depende directamente del tipo de datos y de los requerimientos del sistema de monitoreo.

La combinación de IoT (Internet de las cosas) y machine learning ha permitido desarrollar arquitecturas flexibles y escalables, adaptables tanto a grandes plantas industriales como a pequeñas empresas (ver Figura 9). No obstante, su implementación enfrenta desafíos importantes, entre ellos la necesidad de una correcta gestión de datos, la ciberseguridad, la integración con sistemas heredados y la capacitación del personal técnico. En este contexto, en la Tabla 5 se presenta una comparación de las principales arquitecturas IoT utilizadas en el mantenimiento predictivo, destacando sus características, ventajas y limitaciones. En regiones como América Latina, la adopción de estas tecnologías todavía es incipiente, pero su potencial para mejorar la confiabilidad y eficiencia de los procesos industriales es innegable (Sheikh et al., 2022). Por ello, el análisis de estas arquitecturas resulta fundamental para comprender las oportunidades y limitaciones que presenta su aplicación en contextos locales.

Tabla 5*Comparación de Arquitecturas de IoT en Mantenimiento Predictivo*

Arquitectura	Características	Ventajas	Limitaciones	Aplicación
Cloud Computing	Procesamiento centralizado en la nube	Alta capacidad de almacenamiento, escalabilidad	Alta latencia, dependencia de conexión	Análisis histórico y entrenamiento de modelos
Edge Computing	Procesamiento en el dispositivo o cerca del sensor	Baja latencia, respuesta en tiempo real	Limitación de recursos computacionales	Detección inmediata de fallas
Fog Computing	Procesamiento intermedio entre edge y cloud	Balance entre latencia y capacidad	Mayor complejidad de implementación	Sistemas distribuidos industriales
5G-MEC	Procesamiento en el borde de la red móvil	Alta velocidad, baja latencia	Infraestructura limitada	Aplicaciones en tiempo real industrial

Nota. Comparación de arquitecturas IoT según capacidad de procesamiento, latencia y aplicación industrial.

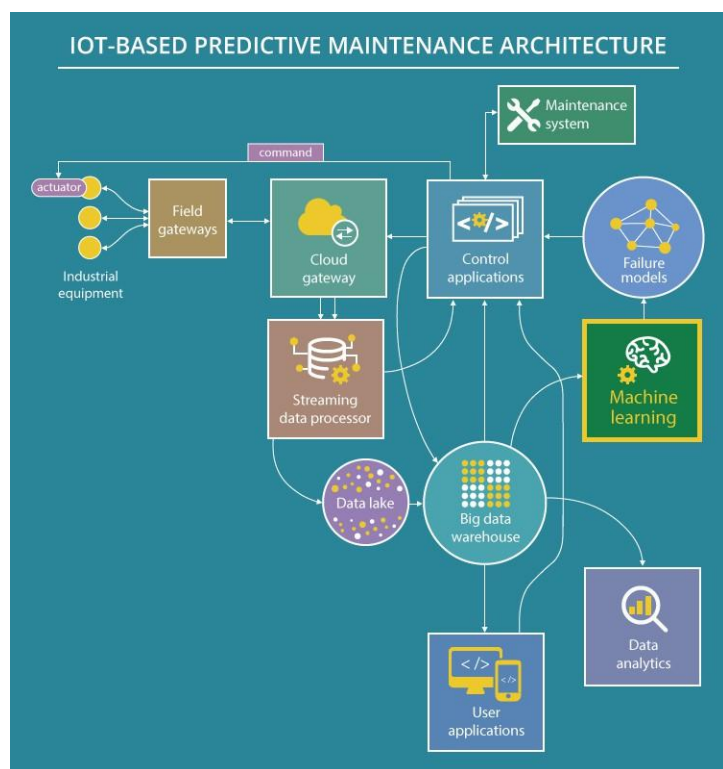
Como se observa en la tabla, cada arquitectura presenta ventajas específicas según los requerimientos del sistema. Mientras que el cloud computing resulta adecuado para almacenamiento y análisis de grandes volúmenes de datos, el edge computing destaca por su capacidad de respuesta en tiempo real. Por su parte, el fog computing permite una distribución eficiente del procesamiento, y tecnologías como 5G-MEC potencian aplicaciones industriales avanzadas. Esta diversidad evidencia la necesidad de seleccionar arquitecturas híbridas que optimicen el rendimiento del sistema de monitoreo predictivo.

La Figura 9 presenta una arquitectura típica de mantenimiento predictivo basada en IoT, donde se observa el flujo completo de datos desde los equipos industriales hasta los sistemas de

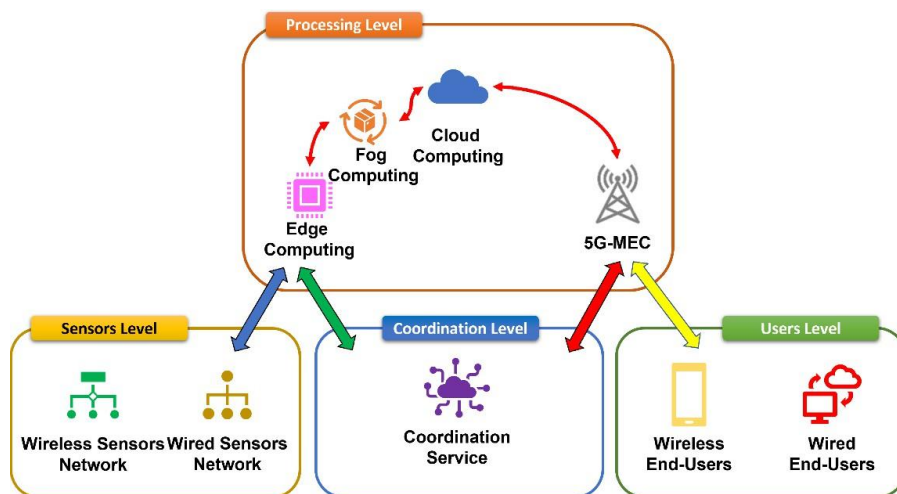
análisis avanzado. En esta estructura, los sensores instalados en la máquina capturan variables operativas y envían la información a través de field gateways, los cuales actúan como dispositivos intermediarios que consolidan los datos antes de transmitirlos hacia la nube mediante un cloud gateway. Una vez en la nube, los datos pueden procesarse en tiempo real mediante un motor de análisis de flujo (streaming data processor) o almacenarse en repositorios como data lakes y data warehouses, desde donde son utilizados por aplicaciones de control, modelos de fallas y algoritmos de machine learning. Este enfoque permite identificar patrones anómalos, estimar el estado de salud del motor y generar acciones correctivas o recomendaciones hacia el sistema de mantenimiento. Finalmente, los resultados pueden visualizarse en aplicaciones de usuario o integrarse con herramientas de analítica, facilitando decisiones informadas y una gestión más eficiente del mantenimiento. Esta arquitectura evidencia cómo el IoT posibilita un ciclo completo de monitoreo, diagnóstico y respuesta automatizada dentro del mantenimiento predictivo industrial

Figura 9

Arquitectura de Mantenimiento Predictivo Basada en IoT.



Nota. Flujo general de adquisición, transmisión, almacenamiento y análisis de datos en un sistema de mantenimiento predictivo. Tomado de. A comprehensive guide to IoT-based predictive maintenance, Grizhnevich, A, (2018) <https://www.scnsoft.com/blog/iot-predictive-maintenance-guide>

Figura 10*Arquitectura Basada en Edge Computing para la Gestión de Datos IoT y Multimedia*

Nota. Ejemplo de arquitectura distribuida con procesamiento local y servicios en la nube para sistemas IoT industriales. Tomado de. A New Edge Computing Architecture for IoT and Multimedia Data Management, Debauche, O, Mahmoudi, S, Guttadauria, A, (2022) <https://www.mdpi.com/2078-2489/13/2/89>

La Figura 10 presenta una arquitectura moderna para la gestión de datos IoT basada en computación en el borde (edge computing), donde se organiza el flujo de información en tres niveles interconectados. En el nivel de sensores, los dispositivos cableados e inalámbricos capturan datos del entorno y los transmiten hacia el nivel de coordinación, donde un servicio central gestiona la comunicación y distribuye la información hacia los distintos recursos de procesamiento. En el nivel de procesamiento se integran tecnologías como edge computing, fog computing, cloud computing y 5G-MEC, que permiten realizar análisis distribuidos según la criticidad y el volumen de datos. Este diseño reduce la latencia y optimiza el uso del ancho de banda al procesar información cerca de su origen. Finalmente, en el nivel de usuarios, tanto terminales cableadas como inalámbricas acceden a los resultados del análisis para visualización, toma de decisiones o control operativo. Esta arquitectura destaca por su capacidad de escalar,

mejorar la eficiencia de los sistemas IoT y soportar aplicaciones complejas como el mantenimiento predictivo de equipos industriales.

Propuesta Metodológica que Integre Iot y Machine Learning para el Monitoreo Predictivo de Motores de Inducción Trifásicos

La presente propuesta metodológica integra el Internet de las Cosas (IoT) y el aprendizaje automático (machine learning) como base para el desarrollo de un sistema de monitoreo predictivo orientado a motores de inducción trifásicos. El propósito central es mejorar la gestión del mantenimiento industrial, mediante la detección temprana de anomalías y la predicción de fallas a partir del análisis continuo de variables eléctricas y mecánicas.

La propuesta inicia con la adquisición de datos, etapa en la cual se emplean sensores inteligentes capaces de registrar parámetros críticos como corriente, voltaje, temperatura, vibración y velocidad angular. Estos sensores, conectados a través de redes inalámbricas de comunicación industrial, envían la información en tiempo real hacia una plataforma central de monitoreo. En este nivel, los datos son almacenados en bases de datos locales o en la nube, dependiendo de la infraestructura tecnológica disponible en la industria. Este proceso de adquisición se fundamenta en arquitecturas IoT basadas en protocolos de comunicación como MQTT (Message Queuing Telemetry Transport) o OPC-UA (Open Platform Communications – Unified Architecture), que garantizan la interoperabilidad entre dispositivos de diferentes fabricantes y la transmisión segura de los datos. En términos de aplicación, MQTT se recomienda en escenarios con dispositivos de bajo consumo y redes inalámbricas con ancho de banda limitado, como soluciones IoT distribuidas o monitoreo remoto, debido a su arquitectura ligera basada en publicación/suscripción. Por su parte, OPC-UA es más adecuado en entornos industriales altamente automatizados donde se requiere integración con sistemas SCADA o PLC,

ya que ofrece mayor robustez, seguridad integrada y estandarización en la interoperabilidad entre equipos industriales.

Posteriormente, se desarrolla la etapa de procesamiento y pretratamiento de la información recolectada. Dado que los datos industriales suelen presentar ruido, valores faltantes o lecturas atípicas, se aplican técnicas de limpieza, normalización y filtrado para mejorar la calidad de la información. El objetivo de esta fase es preparar un conjunto de datos confiable que permita el entrenamiento y validación de los modelos predictivos. Asimismo, se contempla la implementación de estrategias de almacenamiento jerárquico, que permitan gestionar eficientemente la información histórica y facilitar el acceso para análisis posteriores. En esta etapa también se propone la incorporación de mecanismos automáticos de detección de anomalías tempranas, que permitan identificar comportamientos atípicos incluso antes del entrenamiento formal de los modelos de machine learning, fortaleciendo la capacidad preventiva del sistema.

Una vez garantizada la calidad de los datos, se procede a la aplicación de modelos de machine learning para el diagnóstico y pronóstico de fallas. En esta fase se utilizan algoritmos capaces de identificar patrones complejos en las señales eléctricas y mecánicas de los motores. Modelos como las redes neuronales artificiales (ANN), los árboles de decisión, Random Forest y las redes LSTM (Long Short-Term Memory) han demostrado una alta precisión en la detección de anomalías en máquinas rotativas (Sobhi et al., 2023; Dina et al., 2023; Ahmed & Lee, 2023), al poder analizar relaciones no lineales entre las variables monitorizadas.

En casos donde se disponga de series temporales extensas, se pueden emplear modelos estadísticos como ARIMA o Prophet, que permiten capturar tendencias de largo plazo y comportamientos estacionales en los indicadores de salud del motor. En términos de selección,

los modelos basados en árboles como Random Forest son apropiados cuando se dispone de conjuntos de datos tabulares estructurados y se busca interpretabilidad en la identificación de variables relevantes. Las redes neuronales profundas y LSTM son más adecuadas cuando existen grandes volúmenes de datos temporales y se requiere modelar dependencias dinámicas complejas en el tiempo. Por otro lado, ARIMA resulta útil en escenarios con patrones relativamente lineales y estables, mientras que Prophet es recomendable cuando se desean modelar tendencias con componentes estacionales y cambios abruptos, incluso con datos incompletos o ruidosos (Dina et al., 2023; Drakaki et al., 2022).

Asimismo, se plantea complementar estos modelos con técnicas avanzadas de análisis de señales, como la Transformada de Hilbert o la Transformada Wavelet, especialmente útiles para la detección de fallas incipientes relacionadas con vibraciones, rodamientos o desbalance mecánico (Llacua Toscano, 2020; Zhao et al., 2022). Estas estrategias avanzadas se emplean principalmente cuando las fallas se manifiestan en el dominio frecuencial antes que en el dominio temporal, como en defectos en rodamientos o excentricidades, donde pequeñas variaciones espectrales pueden pasar desapercibidas en análisis convencionales. La transformada de Hilbert permite analizar envolventes de señal para identificar modulaciones asociadas a fallas tempranas, mientras que las wavelets facilitan el análisis multirresolución, siendo especialmente útiles en señales no estacionarias propias de sistemas electromecánicos. Estas técnicas permiten extraer características más representativas y mejorar el rendimiento de los algoritmos de clasificación y predicción (Zhao et al., 2022).

Adicionalmente, se propone integrar un módulo de análisis energético orientado a evaluar la eficiencia del motor. El registro continuo de variables como potencia activa, potencia reactiva, distorsión armónica y factor de potencia permite identificar patrones de consumo que pueden

estar asociados a fallas mecánicas, pérdidas por fricción o problemas en el sistema de alimentación. Este componente amplía la visión del mantenimiento predictivo y contribuye a reducir costos operativos mediante el uso racional de la energía.

Además, es indispensable contar con un componente de visualización y toma de decisiones. Los resultados obtenidos de los modelos predictivos son integrados en una interfaz gráfica que permite al personal de mantenimiento supervisar en tiempo real el estado de los motores. A través de un índice de salud o “health index”, el sistema clasifica las condiciones del equipo en niveles de riesgo, permitiendo priorizar intervenciones y programar mantenimientos antes de que ocurra una falla crítica (Seitz, 2023). Esta información también puede integrarse con sistemas de gestión industrial (SCADA (Supervisory Control and Data Acquisition), MES (Manufacturing Execution System) o ERP (Enterprise Resource Planning)), para automatizar alertas y generar reportes operativos que respalden la toma de decisiones. Además, se propone incorporar un sistema de notificaciones inteligentes basado en umbrales adaptativos, que actualizan los límites de alerta de acuerdo con el comportamiento histórico del motor, evitando falsas alarmas y mejorando la precisión de las acciones correctivas.

Desde el punto de vista arquitectónico, la metodología propuesta plantea el uso de edge computing para procesar información crítica directamente en el punto de medición. Esto permite reducir la latencia, disminuir el tráfico de datos hacia la nube y garantizar la continuidad del servicio incluso en entornos con conectividad limitada. El procesamiento local facilita la detección inmediata de fallas y asegura que las alertas esenciales se generen aun en presencia de interrupciones de red.

En el contexto colombiano y latinoamericano, donde los recursos tecnológicos pueden ser limitados, se propone priorizar el uso de hardware de bajo costo y plataformas abiertas que

faciliten la implementación progresiva del sistema. Asimismo, se recomienda fortalecer la capacitación técnica del personal encargado de interpretar los resultados y mantener la infraestructura tecnológica, garantizando así la sostenibilidad del sistema a largo plazo. En este sentido, la creación de soluciones centradas en microcontroladores de bajo costo (como ESP32), sensores industriales modulares y gateways ligeros capaces de ejecutar tareas de edge computing pueden ser llamativas para el contexto local. Entre la instrumentación se puede contemplar sensores de corriente tipo SCT-013 o transformadores de corriente industriales, sensores de vibración MEMS como el ADXL345 o módulos piezoeléctricos industriales, sensores de temperatura tipo PT100 o termistores industriales, así como módulos de medición de voltaje aislados. En cuanto a los gateways, pueden emplearse dispositivos como Raspberry Pi, NVIDIA Jetson Nano o gateways industriales basados en Linux embebido, los cuales permiten ejecutar algoritmos de preprocesamiento, almacenamiento local y comunicación con la nube. El uso de estos sistemas resulta especialmente adecuada para la realidad colombiana, donde la mayoría de las industrias medianas y pequeñas requieren soluciones accesibles, resistentes y fáciles de mantener, sin depender de plataformas propietarias o infraestructuras complejas. Este enfoque permite utilizar una misma arquitectura para la recolección y el procesamiento de datos, lo que facilita la implementación del sistema y contribuye a reducir los costos de despliegue.

En conjunto, esta propuesta busca servir como una guía para la integración de tecnologías emergentes en el mantenimiento industrial, promoviendo un enfoque más proactivo que permita mejorar la gestión de los motores de inducción trifásicos. Lo que permitiría reducir los tiempos de inactividad, los costos operativos y aumentar la confiabilidad de los procesos productivos, contribuyendo al avance hacia una industria más inteligente y alineada con los principios de la Industria 4.0 y al contexto local.

Para estructurar de manera clara el funcionamiento del sistema propuesto, la metodología puede organizarse en un conjunto de fases secuenciales que integran la adquisición, procesamiento, análisis y toma de decisiones. En la Tabla 6 se presentan estas fases, junto con sus principales actividades y tecnologías asociadas, permitiendo una visión sistemática del modelo propuesto.

Tabla 6

Fases de la Propuesta Metodológica

Fase	Descripción	Actividades principales	Tecnologías
Adquisición de datos	Captura de variables del motor	Sensado de corriente, vibración, temperatura	Sensores IoT, MEMS, RTD, ESP32
Comunicación	Transmisión de datos	Envío hacia gateway o nube	MQTT, OPC-UA, WiFi, LoRa
Procesamiento	Limpieza y preparación	Filtrado, normalización, dataset	Python, Edge Computing
Modelado	Aplicación de algoritmos	Entrenamiento y predicción	ANN, LSTM, ARIMA
Evaluación	Validación del modelo	Métricas (MAE, RMSE, Accuracy)	Librerías ML
Decisión	Generación de acciones	Health Index, alertas	SCADA, dashboards

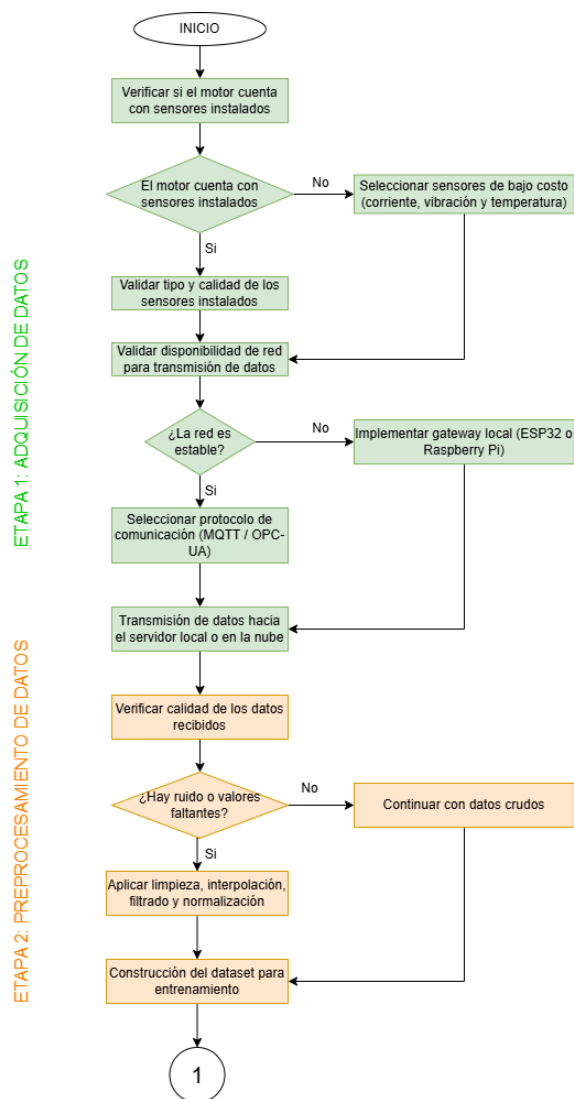
Nota. Se describen las principales etapas propuestas para la integración de IoT y machine learning en el monitoreo predictivo de motores de inducción trifásicos.

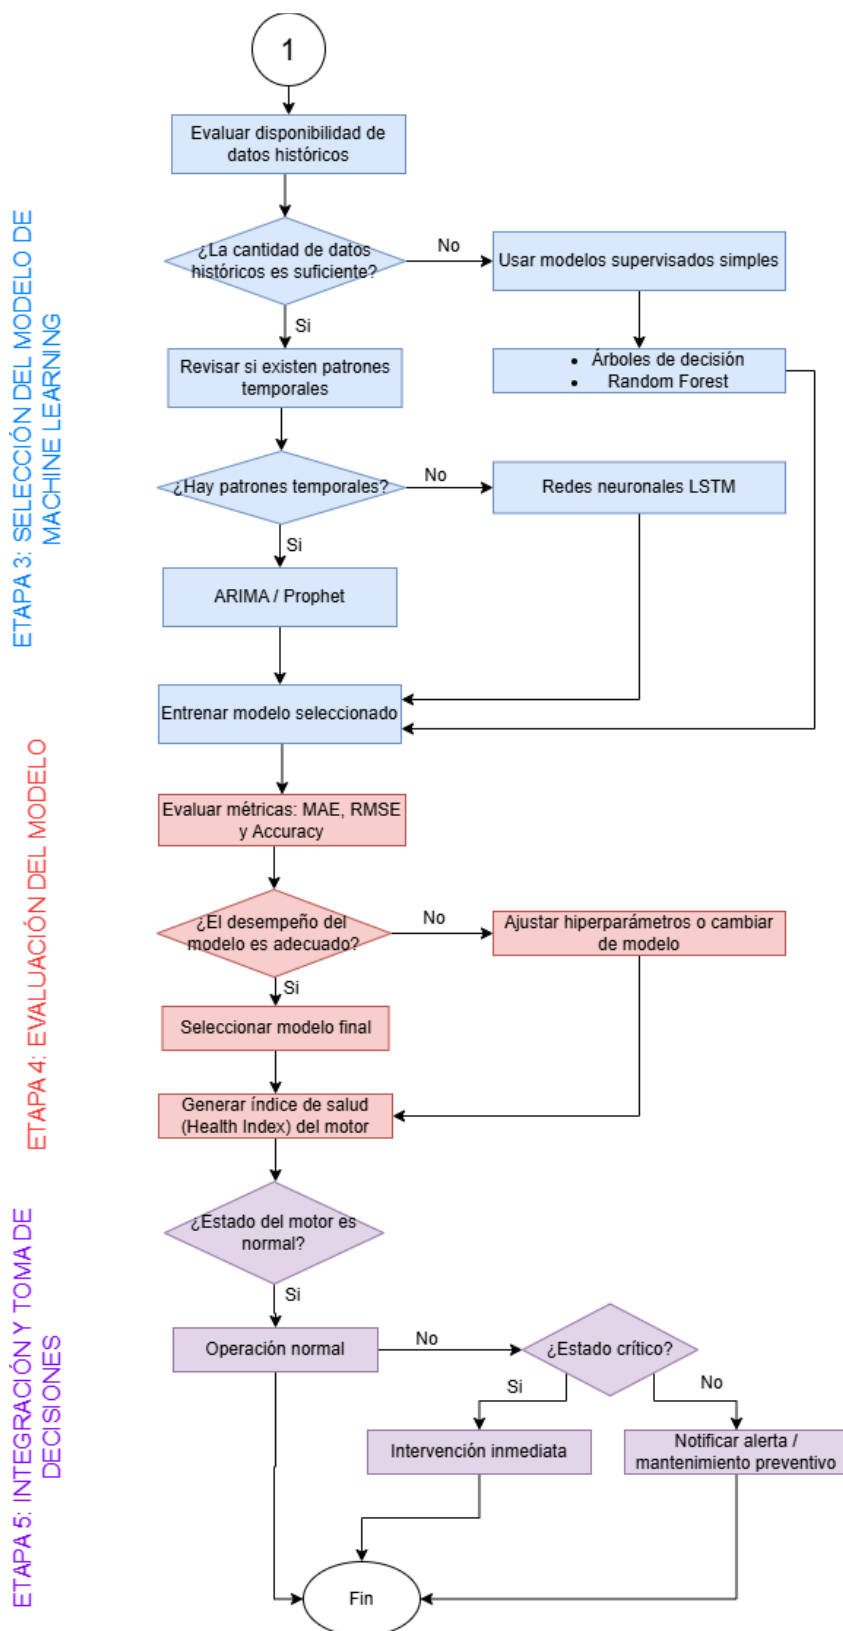
Como se observa en la Tabla 6, la propuesta metodológica se estructura en fases interrelacionadas que permiten transformar los datos adquiridos en información útil para la toma de decisiones.

La metodología propuesta se sintetiza en un esquema conceptual que integra las etapas de adquisición de datos, procesamiento de información, aplicación de modelos de machine learning y generación de indicadores para la toma de decisiones. Este diagrama permite visualizar de manera general la interacción entre los componentes del sistema de monitoreo predictivo basado en IoT y los diferentes niveles de procesamiento de datos (ver Figura 11).

Figura 11

Diagrama de la Propuesta Metodológica para el Monitoreo Predictivo de Motores de Inducción Trifásicos Basado en IoT y Machine Learning.





Nota. Autoría propia

Para complementar la propuesta metodológica, es fundamental definir indicadores que permitan evaluar el desempeño del sistema en términos de precisión, eficiencia y capacidad de respuesta. En la Tabla 7 se presentan los principales indicadores utilizados para la evaluación del sistema de monitoreo predictivo.

Tabla 7

Indicadores de Desempeño del Sistema

Indicador	Descripción	Objetivo
Accuracy	Predicciones correctas	Medir precisión del modelo
MAE	Error absoluto medio	Evaluar desviación
RMSE	Error cuadrático medio	Penalizar errores grandes
Tiempo de respuesta	Tiempo de detección	Evaluar rapidez
Latencia	Retardo en comunicación	Evaluar red IoT
Disponibilidad	Tiempo activo	Garantizar continuidad
Tasa de detección	Fallas detectadas	Medir efectividad

Nota. Se describen algunos indicadores utilizados para evaluar el desempeño, precisión y confiabilidad del sistema de monitoreo predictivo.

Como se muestra en la Tabla 7, la evaluación del sistema no se limita únicamente a la precisión de los modelos predictivos, sino que también considera aspectos operativos como la latencia, la disponibilidad y el tiempo de respuesta. Esto permite realizar un análisis integral del desempeño del sistema, integrando tanto el componente analítico como la infraestructura tecnológica que lo soporta.

Conclusiones

La revisión de la literatura permitió evidenciar que el monitoreo predictivo de motores de inducción trifásicos mediante la integración de tecnologías IoT y algoritmos de machine learning representa una estrategia sólida y altamente eficiente para mejorar la confiabilidad operativa en entornos industriales. Se identificó que la combinación de sensores inteligentes, protocolos de comunicación interoperables, plataformas de gestión de datos y modelos de análisis avanzados permite anticipar fallas con mayor precisión, disminuyendo tiempos de inactividad y optimizando los costos asociados al mantenimiento tradicional.

El análisis de arquitecturas de monitoreo basadas en IoT y modelos predictivos permitió establecer que existen múltiples enfoques tecnológicos aplicables al diagnóstico de fallas en motores eléctricos. Arquitecturas con procesamiento en el borde, protocolos como MQTT y OPC-UA, y modelos como Random Forest, redes neuronales, LSTM, ARIMA o Prophet, demuestran una alta capacidad para identificar patrones complejos en variables eléctricas y mecánicas. Sin embargo, también se evidenciaron desafíos asociados a la calidad de los datos, la complejidad computacional y la necesidad de personal capacitado, aspectos que condicionan su implementación en contextos industriales reales.

La propuesta metodológica planteada (ver Figura 11) demuestra que es posible estructurar un sistema completo capaz de adquirir, transmitir, procesar y analizar información crítica del motor en tiempo real, generando indicadores como el índice de salud que facilitan la toma de decisiones técnicas. Asimismo, el enfoque adoptado prioriza soluciones viables para contextos como el colombiano, donde las limitaciones presupuestales requieren arquitecturas modulares, hardware accesible y herramientas abiertas que permitan una implementación progresiva y sostenible.

Como aporte principal de este trabajo, se propone una metodología integral que no solo articula de manera coherente las etapas de adquisición, procesamiento, modelado y toma de decisiones, sino que además incorpora criterios de selección tecnológica y adaptación al contexto industrial latinoamericano. A diferencia de otros estudios que abordan estos elementos de forma aislada o en entornos controlados, esta propuesta los integra en un esquema estructurado, validado teóricamente y orientado a su aplicabilidad práctica, considerando restricciones reales como costos, disponibilidad de infraestructura y capacidades técnicas del personal.

De manera global, este trabajo evidencia que la aplicación de IoT y machine learning en motores de inducción trifásicos no solo mejora los procesos de mantenimiento, sino que constituye un paso fundamental hacia la consolidación de prácticas alineadas con los principios de la Industria 4.0. Su adopción permite incrementar la confiabilidad de los activos, promover la continuidad operacional y fortalecer la competitividad industrial, estableciendo un marco conceptual útil para futuras investigaciones y desarrollos tecnológicos en el área.

En este sentido, el valor diferencial de la investigación radica en la integración de componentes técnicos, metodológicos y contextuales en una única propuesta, lo que facilita su replicabilidad y adaptación en diferentes escenarios industriales, especialmente en aquellos con limitaciones tecnológicas y económicas.

Desde la perspectiva del programa de Ingeniería Electrónica y Telecomunicaciones, el desarrollo de esta monografía refleja la integración de conocimientos en electrónica, comunicaciones industriales, sistemas embebidos y análisis de datos aplicados a la solución de problemáticas reales. El trabajo fortalece competencias asociadas al diseño de sistemas inteligentes conectados, la innovación tecnológica y la transformación digital del sector

industrial, evidenciando la pertinencia del enfoque interdisciplinario del programa en escenarios de Industria 4.0.

Recomendaciones

Se recomienda que futuros trabajos orienten sus esfuerzos hacia la implementación práctica de la metodología propuesta, mediante el desarrollo de prototipos o plataformas IoT que permitan recopilar datos reales de operación de motores de inducción trifásicos. Esto facilitaría validar el desempeño de diferentes algoritmos de análisis y fortalecer el diagnóstico predictivo mediante la integración de variables adicionales como vibraciones, temperatura o análisis energético. Asimismo, sería pertinente evaluar el desempeño del sistema en términos de comunicación, procesamiento y confiabilidad, así como realizar estudios de viabilidad técnica y económica que permitan estimar el impacto del mantenimiento predictivo frente a estrategias tradicionales de mantenimiento.

Referencias Bibliográficas

Ahmed, T., & Lee, S. (2023). Predictive maintenance of industrial machinery using IoT sensors.

Machines, 7(1), 15. <https://www.mdpi.com/2624-8921/7/1/15>

AIP Publishing. (2023). Fault diagnosis of induction motors using machine learning. *AIP*

Conference Proceedings. <https://pubs.aip.org/aip/acp/article/2769/1/020063>

Aires, F. L., Galeno, G. D., Belchior, F. N., Oliveira, A. M., & Hunt, J. D. (2025).

Enhancing three-phase induction motor reliability with health index and artificial intelligence-driven predictive maintenance. *Royal Society Open Science*, 12(5), 241946.

<https://doi.org/10.1098/rsos.241946>

Alvarado-Hernandez, A. I., Zamudio-Ramirez, I., Jaen-Cuellar, A. Y., Osornio-Rios, R. A.,

Donderis-Quiles, V., & Antonino-Daviu, J. A. (2022).

Infrared thermography smart sensor for the condition monitoring of gearbox and bearings faults in induction motors. *Sensors*, 22(16), 6075. <https://doi.org/10.3390/s22166075>

APS Tech. Series temporales con redes recurrentes. [https://apsl.tech/es/blog/analisis-de-series-](https://apsl.tech/es/blog/analisis-de-series-temporales-usando-redes-neuronales-recurrentes/)

[temporales-usando-redes-neuronales-recurrentes/](https://apsl.tech/es/blog/analisis-de-series-temporales-usando-redes-neuronales-recurrentes/)

Area Tecnología. Motor trifásico. [https://www.areatecnologia.com/electricidad/motor-](https://www.areatecnologia.com/electricidad/motor-trifasico.html)

[trifasico.html](https://www.areatecnologia.com/electricidad/motor-trifasico.html)

Auqui Fajardo, C. H., & Fárez Chasi, C. O. (2024).

Diseño e implementación de un sistema de monitoreo IoT de temperatura y vibración para protección de motores eléctricos (Trabajo de titulación, Universidad Politécnica Salesiana).

<https://dspace.ups.edu.ec/bitstream/123456789/29087/1/UPS-GT005779.pdf>

Azab, M. (2025). A review of recent trends in high-efficiency induction motor drives. *Vehicles*, 7(1), 15. <https://doi.org/10.3390/vehicles7010015>

Bahgat, B. H., Elhay, E. A., Sutikno, T., & Elkholy, M. M. (2023).

Revolutionizing motor maintenance: A comprehensive survey of state-of-the-art fault detection in three-phase induction motors. *International Journal of Power Electronics and Drive Systems (IJPEDS)*.

Disponible en: <https://ijpeds.iaescore.com/index.php/IJPEDS/article/view/23202>

Bhardwaj, N. (2024). K-nearest neighbour (K-NN) algorithm. Blog GopenAI.

<https://blog.gopenai.com/k-nearest-neighbour-k-nn-algorithm-25085df55654>

Borghesi, A., Burrello, A., & Bartolini, A. (2023).

ExaMon-X: A predictive maintenance framework for automatic monitoring in industrial IoT systems. *IEEE Internet of Things Journal*, 10(4), 2995–3005.

<https://doi.org/10.1109/JIOT.2021.3125885>

Cáceres-Amaya, C., Duarte-Forero, J., & Valencia-Ochoa, G. (2020).

Nueva metodología para la detección de fallas en rodamientos en motores de inducción trifásicos. *Respuestas*, 25(3), 142–153.

<https://dialnet.unirioja.es/servlet/articulo?codigo=7885494>

Cedillo Uvidia, J. R., & Samaniego Bueno, V. L. (2021).

Sistema SCADA para variables eléctricas de motores trifásicos mediante buses de campo e IoT (Tesis de grado). Universidad Politécnica Salesiana.

<http://dspace.ups.edu.ec/handle/123456789/21423>

Clerc, G. (2022). Failure diagnosis and prognosis of induction machines. *Energies*, 15(4), 1483.

<https://doi.org/10.3390/en15041483>

Correa Esquivia, S. (2023). *Diseño e implementación de un sistema descentralizado remoto, basado en tecnologías IoT y de código abierto, para la adquisición de variables eléctricas y control de un motor de inducción trifásico* (Tesis de maestría). Universidad de Antioquia.

<https://bibliotecadigital.udea.edu.co/entities/publication/b4826406-efe4-48ec-807c-70df79acbc4d>

Correa Esquivia, S., Sánchez Prisco, A. F., Rodríguez Serna, J. M., & Barrera Durango, M. de J. (2022).

Sistema inalámbrico basado en IoT para la medición de temperatura y velocidad en un motor de inducción. *Revista CINTEX*, 27(2), 32–42.

<https://doi.org/10.33131/24222208.375>

De Araujo, V. G., Bissiriou, A. O.-S., Villanueva, J. M. M., Llanos Villarreal, E. R., Ortiz

Salazar, A., Texeira, R. A., & Fonsêca, D. A. de M. (2024). Monitoring and diagnosing faults in three-phase induction motors using artificial intelligence techniques. *Preprints*.

<https://www.preprints.org/manuscript/202406.1451>

Debauche, O., Mahmoudi, S., & Guttadauria, A. (2022).

A new edge computing architecture for IoT and multimedia data management.

Information, 13(2), 89. <https://doi.org/10.3390/info13020089>

Drakaki, M., Karnavas, Y. L., Tziafettas, I. A., Linardos, V., & Tzionas, P. (2022). Machine learning and deep learning based methods toward Industry 4.0 predictive maintenance in induction motors: State of the art survey. *Journal of Industrial Engineering and Management*, 15(1), 31–57. <https://doi.org/10.3926/jiem.3597>

Duarte, A. M., Machado, I. S., Santos, J. G., & Silva, T. F. da. (2024).

IoT em motores de indução trifásico (Trabajo de conclusión de curso, Curso Superior de Tecnologia em Automação Industrial, Faculdade de Tecnologia “Adib Moisés Dib”). São Bernardo do Campo.

<http://ric-cps.eastus2.cloudapp.azure.com/handle/123456789/23072>

Elsevier. (2014). Predictive maintenance methodologies for industrial applications. *Journal of Industrial Information Integration*.

<https://www.sciencedirect.com/science/article/pii/S221384631400025X>

Fernandez, C. F. F. M. (2021). *Aplicação de técnicas de machine learning no âmbito do diagnóstico da ocorrência de curtos-circuitos estatóricos em motores de indução trifásicos* (Tesis doctoral). Universidade da Beira Interior, Portugal.

ProQuest Dissertations & Theses.

<https://www.proquest.com/openview/2d7e1c32d9e2b9430a844bd54b91c236>

Garcia Tucci, J. [Jose Luis]. (2025). Diagnóstico de fallas por rotura de barras en motores de inducción trifásicos mediante el uso de modelos de deep learning. Universitat Oberta de Catalunya (UOC). <https://hdl.handle.net/10609/153873>

González, A., & Pérez, L. (2022). Data-driven predictive maintenance for electrical machines in smart factories. *Energies*, 15(23), 8938. <https://www.mdpi.com/1996-1073/15/23/8938>

Gutiérrez-Trejo, S. S., Romero-Guerrero, J. A., & Villa-Villaseñor, N. (2023).

Arquitectura inteligente para motores eléctricos: IIoT y machine learning para la adquisición y análisis avanzado de datos. *ICBI*, 11(22).

<https://doi.org/10.29057/icbi.v11i22.11092>

Hernández Eskenazi, A., Valdés Alfonso, J. R., & Salgado López, G. (2023).

Diseño e implementación de un sistema IoT para el control y supervisión de motores eléctricos trifásicos.

IEEE. (2022). Fault diagnosis of induction motors using artificial intelligence. IEEE Xplore.

<https://ieeexplore.ieee.org/document/9757372>

IEEE. (2025). Advanced monitoring of induction motors using AI-based models. IEEE Xplore.

<https://ieeexplore.ieee.org/document/10905883>

IEEE. (2025). Intelligent predictive systems for electric machines. IEEE Xplore.

<https://ieeexplore.ieee.org/document/10905762>

Ioannides, M. G., Koukoutsis, E. B., Stamelos, A. P., Papazis, S. A., Stamataki, E. E.,

Papoutsidakis, A., Vikentios, V., Apostolakis, N., & Stamatakis, M. E. (2023).

Design and operation of Internet of Things-based monitoring control system for induction machines. *Energies*, 16(7), 3049. <https://doi.org/10.3390/en16073049>

Jha, U. C., Sai, R. J., Reddy, M. V. B. K., & Singh, A. (2022). Analysis of predictive

maintenance in Industry 4.0: A review. *International Journal of Mechanical Engineering*.

<https://www.ias.org/home/caijme/analysis-of-predictive-maintenance-in-industry-4-0-a-review>

Kaur, J., & Singh, R. (2022). Predictive maintenance of induction motors using machine learning

techniques. *Journal of Failure Analysis and Prevention*. [https://doi.org/10.1007/s11668-](https://doi.org/10.1007/s11668-022-01445-2)

[022-01445-2](https://doi.org/10.1007/s11668-022-01445-2)

Kazmi, M., Shoab, M. T., Aziz, A., Khan, H. R., & Qazi, S. A. (2023).

An efficient IIoT-based smart sensor node for predictive maintenance of induction motors.

Kumar, N. (2019, febrero 24).

Loss functions in machine learning (MAE, MSE, RMSE). The Professionals Point.

<https://theprofessionalspoint.blogspot.com/2019/02/loss-functions-in-machine-learning-mae.html>

Kumar, P., & Sharma, R. (2023). Predictive maintenance in Industry 4.0: Techniques and applications. En A. Singh & B. Verma (Eds.), *Advances in Manufacturing Systems*.

Springer. https://doi.org/10.1007/978-3-031-29860-8_40

Kumar, R. R., Andriollo, M., Cirrincione, G., Cirrincione, M., & Tortella, A. (2022).

A comprehensive review of conventional and intelligence-based approaches for the fault diagnosis and condition monitoring of induction motors. *Energies*, 15(23), 8938.

<https://doi.org/10.3390/en15238938>

Li, X., Zhang, Y., & Wang, J. (2023). Intelligent predictive maintenance strategies for robotic systems. *Machines*, 12(9), 604. <https://www.mdpi.com/2075-1702/12/9/604>

Liu, X., Hong, J., Zhao, K., Sun, B., Zhang, W., & Jiang, J. (2023). Vibration analysis for fault diagnosis in induction motors using one-dimensional dilated convolutional neural networks. *Machines*, 11(12), 1061. <https://doi.org/10.3390/machines11121061>

Londoño Parra, C. M., Lopera Mazo, E. H., & Valencia Arroyave, F. (2013). Standards of Energy Efficiency of Induction Motors: Latin American Context. Proceedings of SICEL 2013 (Simposio Internacional sobre Calidad de la Energía Eléctrica).

[https://www.researchgate.net/profile/Carlos-Londono-](https://www.researchgate.net/profile/Carlos-Londono-3/publication/275643518_Standards_of_Energy_Efficiency_of_Induction_Motors_Latin_American_Context_Full_Paper_SICEL_2013_V52)

[3/publication/275643518_Standards_of_Energy_Efficiency_of_Induction_Motors_Latin_American_Context_Full_Paper_SICEL_2013_V52](https://www.researchgate.net/profile/Carlos-Londono-3/publication/275643518_Standards_of_Energy_Efficiency_of_Induction_Motors_Latin_American_Context_Full_Paper_SICEL_2013_V52)

Londoño, C. (2013). Standards of energy efficiency of induction motors: Latin American context. SICEL Conference. <https://researchgate.net/publication/275643518>

Machine Learning para Todos. Árboles de decisión.

<https://machinelearningparatodos.com/arboles-de-decision-en-python/>

Mall, S., Singh, A., & Kumar, R. (2005). Predictive maintenance of electrical machines.

<https://pmc.ncbi.nlm.nih.gov/articles/PMC12115838/>

MathWorks. LSTM networks. <https://la.mathworks.com/discovery/lstm.html>

Moraes, V. A. N. de. (2025).

Identificação de falhas em motores de indução trifásicos usando rede neural transformer convolucional (Dissertação de mestrado em Engenharia Elétrica). Universidade Federal do Espírito Santo.

Mozhi Devan, P. A., Hussin, F. A., Ibrahim, R., Bingi, K., & Khanday, F. A. (2021).

A survey on the application of WirelessHART for industrial process monitoring and control. *Sensors*, 21(15), 4951. <https://doi.org/10.3390/s21154951>

Nagel, R. G., Pires, V. F., Silveira, J. L., Cordeiro, A., & Foito, D. (2023). Financial analysis of household photovoltaic self-consumption in the context of vehicle-to-home (V2H) in Portugal. *Energies*, 16(3), 1218. <https://www.mdpi.com/1996-1073/16/3/1218>

Noriega Vidal, E. M., Cotrina-Teatino, M. A., Anticona Cueva, T. J., & Valdiviezo-Velarde, A.

Y. (2024). *Optimization of rock blasting fragmentation in open pit using predictive models*. ResearchGate. Disponible en: https://www.researchgate.net/figure/El-modelo-de-red-neuronal-artificial-ANN_fig1_379821656

Núñez Mata, Ó. F., Herrera Bolaños, A., & Gutiérrez Vargas, S. (2021).

Monitoreo de condición del sistema de aislamiento de motores eléctricos mediante índice de salud cortado. *Revista Ingeniería*, 31(0). <https://doi.org/10.15517/ri.v31i0.48008>

Odar Chero, B. A. (2023).

Análisis y detección de fallas en motores eléctricos aplicando algoritmos de inteligencia artificial (Tesis de pregrado). Universidad de Piura.

Olivares Quispe, J. M., Arróspide Ponce, J. R., & Salazar Medina, N. F. (2025).

Improving fuel control in a transport company using IoT and machine learning. *LACCEI 2025*. https://laccei.org/LACCEI2025-Mexico/work-in-progress/Contribution_618_final_a.pdf

Orellana Pinzón, C. H. (2023).

Algoritmo de detección de fallas para motores trifásicos tipo jaula de ardilla basado en el análisis de componentes principales (Tesis de grado). Universidad Politécnica Salesiana. <http://dspace.ups.edu.ec/handle/123456789/26724>

oshna S. H. (2023, abril 7). *K-Nearest Neighbors Algorithm*. Intuitive Tutorial.

<https://intuitivetutorial.com/2023/04/07/k-nearest-neighbors-algorithm/>

Puertaz, M. P., & Mazzoletti, M. A. (2024).

Clasificación de estados operativos en motores de inducción utilizando el algoritmo Random Forest. LIDEE – Facultad de Ingeniería, Universidad Nacional de Misiones (UNaM).

Ramírez Velasco, E., Villalobos Piña, F. J., Reyes Malanche, J. A., & Saucedo Zárata, C. H.

(2022).

Detección de fallas de cortocircuito en motores de inducción trifásicos (Short-circuit fault

detection in three phase induction motors). *Pistas Educativas*, 44(143). Disponible en:

<https://pistaseducativas.celaya.tecnm.mx/index.php/pistas/article/view/2962>

Rehman, S. U., Bawa, P. S., Manickam, S., & Praptodiyono, S. (2020).

Towards sustainable IoT ecosystem. Conference paper.

Disponible en: https://www.researchgate.net/figure/Basic-three-layered-IoT-architecture_fig1_346555860

Robayo Villarroel, M. C. (2025).

Análisis comparativo de algoritmos... (Tesis de posgrado). Universidad Nacional de Chimborazo. <http://dspace.unach.edu.ec/handle/51000/15742>

ScienceSoft. IoT predictive maintenance guide. <https://www.scnsoft.com/blog/iot-predictive-maintenance-guide>

Seitz, S., Arnold, M., Tetzlaff, R., & Holstein, P. (2023).

Self-supervised health index curve generation for condition-based predictive maintenance. *Electronics*, 12(24), 4941. <https://doi.org/10.3390/electronics12244941>

Shaked, D., & Holdengreber, E. (2022). Efficiency improvement of an electric-grid transformer using the diamagnetism characteristics of a bulk superconductor. *Energies*, 15(19), 7146. <https://doi.org/10.3390/en15197146>

Silva, S. A. C. da, Pereira, F. H., & Dias, C. G. (2025).

Motores de indução, diagnóstico de falhas, análise de vibração, seleção de características, aprendizado de máquina e manutenção preditiva. *Cuadernos de Educación*, (18)1. <https://doi.org/10.55905/cuadv18n1-040>

- Smith, J., & Brown, K. (2021). An overview of predictive maintenance applications in manufacturing. *Journal of Industrial Engineering and Management*.
<https://www.jiem.org/index.php/jiem/article/view/3597>
- Soares, L. de O., Pinto, L. A., & Lobão, D. A. (s.f.).
Aplicação de machine learning e descritores estatísticos para diagnóstico de falhas em rolamentos de motores elétricos industriais. Instituto Federal do Espírito Santo.
- Springer. (2024). Predictive maintenance in smart industrial environments.
<https://link.springer.com/article/10.1007/s44291-024-00012-3>
- Sridhar, H. S., Harsha, V., Kruthi, N., & Chandana, M. S. (2024).
Design of online industrial motor monitoring system using Industrial Internet of Things (IIoT). *AIP Conference Proceedings*, 3111, 030023. <https://doi.org/10.1063/5.0221444>
- Vargas Fernández, Á. (2021).
Detección de anomalías en un motor eléctrico mediante inteligencia computacional (Trabajo de grado en Ingeniería Eléctrica). Universidad de Valladolid.
- Villena Chico, A. A. (2024).
Internet de las cosas aplicado a la manipulación de variador de frecuencia (Trabajo de grado en Ingeniería Electromecánica). Universidad Técnica de Cotopaxi.
<https://repositorio.utc.edu.ec/handle/123456789/12349>
- Xie, Y., Huang, X., Li, J., & Liu, T. (2023). Computing power network: Multi-objective optimization based routing. *Sensors*, 23(15), 6702. <https://www.mdpi.com/1424-8220/23/15/6702>
- Yu, W., Liu, Y., Dillon, T., & Rahayu, W. (2023).
Edge computing-assisted IoT framework with an autoencoder for fault detection in

manufacturing predictive maintenance. *IEEE Transactions on Industrial Informatics*, 19(4), 5701–5710. <https://doi.org/10.1109/TII.2022.3178732>

Zapata Álvarez, G. L., Andrade Cortegoso, R., & Bernal de Lázaro, J. M. (2025).

Un análisis no intrusivo de condiciones anómalas en motores trifásicos mediante señales de corriente y técnicas de inteligencia artificial. *Revista Científica de Ingeniería Electrónica, Automática y Comunicaciones*, 46(0), 1–17.

Zhang, W., & Li, H. (2023). IoT-based predictive maintenance for industrial systems.

Information, 14(6), 329. <https://www.mdpi.com/2078-2489/14/6/329>