



Monitoreado de condición en máquinas rotatorias: tendencias en la aplicación de la Inteligencia Artificial

Condition monitoring in rotating machines: trends on application of Artificial Intelligence

Glenda Gutierrez García¹ , Ailyn Naranjo Navarro² , Evelio Palomino Marín^{2*} 

1. Biocubafarma, Centro de Inmunología Molecular, CIM. La Habana, Cuba.

2. Universidad Tecnológica de La Habana José Antonio Echeverría, Centro de Estudios en Ingeniería de Mantenimiento, CEIM. La Habana, Cuba.

*Autor de correspondencia: evelio.palomino@gmail.com

Este documento posee una [licencia Creative Commons Reconocimiento-No Comercial 4.0 internacional](#)



Recibido: 2 de diciembre de 2024

Aceptado: 12 de enero de 2025

Publicado: 30 de enero de 2025

Resumen

Debido al creciente interés en mejorar la eficiencia y confiabilidad del mantenimiento industrial, el monitoreado de condición ha evolucionado con la integración de técnicas de Inteligencia Artificial. En este contexto, se han desarrollado enfoques avanzados para la detección temprana de fallos en máquinas rotatorias, con énfasis en el análisis de vibraciones como fuente principal de información. El presente artículo presenta la revisión realizada a las tendencias actuales en la aplicación de la Inteligencia Artificial al monitoreado de condición, abordando diferentes técnicas como el aprendizaje automático y el aprendizaje profundo. Se examinaron diversas metodologías, incluyendo el uso de redes neuronales y modelos híbridos, con el objetivo de optimizar la identificación de comportamientos anormales en equipos industriales. Además, se analizaron los

inconvenientes asociados a la implementación de estos sistemas, tales como la interpretabilidad de los modelos, la gestión de grandes volúmenes de datos y la integración de múltiples fuentes de información en el proceso de diagnóstico. Finalmente, se exploraron las perspectivas futuras en la aplicación de estas tecnologías, señalando la importancia de enfoques que combinen la experiencia en ingeniería con modelos basados en datos, con el objetivo de mejorar la precisión y confiabilidad del monitoreado de condición en la industria.

Palabras claves: monitoreado de condición, diagnóstico de fallas mecánicas dinámicas, análisis de vibraciones, aprendizaje automático.

Abstract

Due to the growing interest in enhancing industrial maintenance efficiency and reliability, condition monitoring has evolved through the integration of Artificial Intelligence techniques. In this context, advanced approaches have emerged for early fault detection in rotating machinery, emphasizing vibration analysis as the main information source. This article reviews current trends in applying Artificial Intelligence to condition monitoring, covering techniques such as machine learning and deep learning. Various methodologies are examined, including neural networks and hybrid models, designed to optimize anomaly

identification in industrial equipment. Additionally, challenges related to system implementation are analyzed, including model interpretability, handling large data volumes, and integrating multiple information sources into the diagnostic process. Finally, future perspectives on these technologies are highlighted, stressing the importance of combining engineering expertise with data-driven models to enhance accuracy and reliability in industrial condition monitoring.

Key words: condition monitoring, diagnosis of dynamic mechanical faults, vibration analysis, machine learning.

Cómo citar este artículo, norma Vancouver:

Gutiérrez García G, Naranjo Navarro A, Palomino Marín E. Monitoreado de condición en máquinas rotatorias: tendencias en la aplicación de la Inteligencia Artificial. Ingeniería Mecánica. 2025;28:e702. <https://goo.su/DzTn8l>

1. Introducción

El Monitoreado de Condición y el Mantenimiento Predictivo, este último, aunque no en todos los casos, como una consecuencia del primero, han demostrado a través de múltiples ejemplos, muy concretos y suficientemente avalados, los beneficios y ahorros que ambos acarrearán, lo cual no quiere decir en modo alguno que todas las industrias que tengan implantado Programas de Monitoreado y Predicción, no tengan que demostrar los beneficios económicos sostenibles que estos programas presuponen con lo cual se justifican los costos de inversión y de operación que entrañan estas tecnologías.

Un programa de mantenimiento eficaz mejora significativamente el desempeño de las máquinas rotatorias lo cual redundará en un mejor aprovechamiento de la vida útil de estas, en una reducción de los costos de mantenimiento y en un incremento de la disponibilidad. Esto es particularmente importante en un entorno empresarial cada vez más competitivo, donde a menudo se requiere que los equipos logren más con menos recursos.

Luego entonces, monitoreado y predicción deben formar parte de una estrategia global de mantenimiento, cuidadosamente formulada y extremadamente organizada, debiendo quedar definidos suficientemente y en detalle, los objetivos y el alcance del programa. Y desde luego, tendrá que ser previsto cualquier conflicto potencial con la práctica o con la filosofía vigente en Planta, de conjunto con los cambios que resulten necesarios y suficientes para lograr los objetivos trazados. Una de las contradicciones típicas que se presentan en estos casos resulta del hábito de mantenimiento y/u operación, de explotar la máquina hasta que se presente una falla, en no pocas ocasiones con consecuencias catastróficas. Tal hábito tendrá que ser sustituido por la interrupción oportuna de la producción para ejecutar las acciones correctivas, cuando en principio el monitoreado, aún sin prácticas predictivas, así lo sugiera.

Las máquinas rotatorias incluyen una amplia categoría de equipos, como bombas, compresores, ventiladores, turbinas a vapor y a gas y motores eléctricos, que resultan vitales para el funcionamiento de las instalaciones de proceso a nivel mundial. Por lo que, entender las tecnologías asociadas con estas máquinas, incluido el diseño de las mismas, su lubricación, la dinámica de los fluidos, la termodinámica, la dinámica de sus rotores, el análisis de sus vibraciones y las prácticas de mantenimiento, es esencial para garantizar su funcionamiento confiable y seguro [1, 2].

El monitoreado de condición constituye un enfoque de mantenimiento predictivo que se basa en la recopilación de datos en tiempo real o no, para evaluar el estado de la maquinaria y detectar fallas o comportamientos anormales antes de que provoquen fallas significativas. El objetivo principal del monitoreado de condición es identificar problemas potenciales de manera temprana, evitando así fallas críticas de los activos, reduciendo el tiempo de inactividad no planificado y extendiendo la vida útil de estos [3].

De aquí que, el objetivo del Monitoreado de Condición no sea precisamente establecer históricos a partir de grupos de mediciones, ni demostrar las potencialidades del análisis durante el diagnóstico de problemas complejos. El objetivo del Monitoreado de Condición radica en proporcionar información que permita mantener la máquina en operación, cumpliendo con rigor sus funciones tecnológicas durante el mayor tiempo posible y al menor costo general posible.

Tanto el Monitoreado de Condición como el propio Mantenimiento Predictivo han estado produciendo cambios sobre la óptica del mantenimiento, que a la vez ha estado evolucionando desde acciones costosas de emergencia, hacia procesos eficientes y organizados, sustentados por acciones más precisas y menos costosas.

Este proceso generalmente implica la recopilación continua o periódica de datos a través de sensores de alta tecnología para monitorear varios parámetros tales como los niveles de vibraciones, la temperatura y la presión entre otros, a lo cual se unen otras técnicas de monitoreado de condición, incluyendo el análisis de aceite, el propio análisis de vibraciones, la termografía infrarroja e incluso mediciones ultrasónicas, que contribuyen a detectar cambios en el comportamiento de la máquina [4].

Hasta el momento, el análisis de vibraciones se considera el método más confiable y rentable para el monitoreado de condición de máquinas rotatorias, ya que los fallos en desarrollo a menudo son “visibles” a través de mediciones de vibraciones en primera instancia.

En esencia, el monitoreado de condición consiste en “escuchar” las máquinas y entender sus señales [1, 3]. Al monitorear de cerca parámetros específicos como las vibraciones, la temperatura y la corriente eléctrica entre otros, el personal de mantenimiento puede programar acciones preventivas antes de que los problemas se conviertan en fallas más graves, garantizando así operaciones más seguras, eficientes y productivas [3, 5].

Claro está, es preciso ser muy cuidadoso en la interpretación de esto, pues el Monitoreado de Condición no se puede entender como la respuesta a todos los problemas de las máquinas rotatorias, sino que es imprescindible que esté integrado dentro de una estrategia global de mantenimiento.

De manera que, el objeto de estudio de este artículo de revisión es el Monitoreado de Condición de las máquinas rotatorias y el objetivo del mismo es revisar las tendencias y aplicaciones de la Inteligencia Artificial al Monitoreado de Condición orientado al análisis de vibraciones.

Se considera entonces, que la mayor contribución de este artículo radica en la ~~síntesis integral~~ revisión de las tendencias actuales en la aplicación de la Inteligencia Artificial (IA) al monitoreado de condición de máquinas

rotatorias, con un énfasis especial en el análisis de vibraciones, siendo sus aportes más significativos los siguientes:

1. Visión integral en el procesamiento de señales de vibración

El artículo analiza los diferentes métodos para el análisis de vibraciones, incluyendo el tratamiento de datos en los dominios del tiempo, de la frecuencia y del tiempo-frecuencia, destacando el papel decisivo de los transductores y la importancia de un montaje adecuado de estos para garantizar la calidad de los datos.

2. Revisión de técnicas de IA aplicadas al diagnóstico de fallos

El artículo analiza en profundidad el uso del *Machine Learning* y el *Deep Learning*, incluyendo redes neuronales convolucionales (*Convolutional Neural Networks*) y redes de memoria a corto y largo plazo (*Long Short-term Memory*), explorando la eficacia de los modelos híbridos y su potencial para mejorar la detección temprana de fallos en equipos industriales, específicamente en máquinas rotatorias.

3. Evaluación de los inconvenientes para la implementación de la IA para el monitoreado de condición

Se destacan problemas clave como la interpretabilidad de los modelos, la gestión de grandes volúmenes de datos y la necesidad de combinar experiencia en ingeniería con modelos basados en datos, resaltando la importancia de integrar la Internet de las Cosas IoT (*Internet of Things*) con algoritmos avanzados para optimizar el mantenimiento predictivo.

Perspectivas futuras en el campo del monitoreado de condición

4. Se plantea la necesidad de desarrollar modelos de IA más explicables y confiables, señalando la tendencia hacia sistemas híbridos que combinen modelos físicos con algoritmos de IA, mejorando la precisión en la detección de fallos.

De manera que, este artículo de revisión no solo ofrece una revisión del estatus actual del monitoreado de condición asistido por IA, sino que también identifica las problemáticas y las oportunidades clave para el desarrollo futuro de esta disciplina. Su valor principal radica en integrar conocimientos de ingeniería con avances en inteligencia artificial, proporcionando una visión estratégica para la evolución del mantenimiento predictivo en la industria.

Así mismo, y tomando en cuenta la temática de esta investigación bibliográfica, se han formulado las siguientes preguntas que regirán el curso de la revisión.

Pregunta de Investigación (PI) 1: ¿Cómo influyen los métodos de adquisición y análisis de señales de vibraciones en la detección temprana de fallas en las máquinas rotatorias?

Esta pregunta de investigación propicia el estudio del estado actual del uso de los transductores, el procesamiento de datos mediante análisis en el dominio del tiempo, frecuencia y tiempo-frecuencia y la utilidad de herramientas como la Transformada de Fourier, el análisis de *Cepstrum* (*Spectrum* escrita al revés) y la densidad espectral de potencia.

Pregunta de Investigación (PI) 2: ¿Cuáles son las tendencias actuales en la aplicación de la Inteligencia Artificial al monitoreado de condición de máquinas rotatorias?

La respuesta a esta pregunta de investigación revela el estado actual de la aplicación de la IA al monitoreado de condición, incluyendo el *machine learning*, el *deep learning* y los modelos híbridos.

De manera que, esta investigación tiene un carácter novedoso por cuanto se sustenta en una búsqueda intensiva sobre el estado actual del monitoreado de condición de máquinas rotatorias y la asistencia de la inteligencia artificial con vista a la automatización de los procesos de evaluación de la condición.

2. Enfoque de la investigación. Método

Con el objetivo de identificar los resultados de investigaciones más relevantes, se realizó la búsqueda en las siguientes bases de datos reconocidas: IEEE Xplore, ScienceDirect y Science Citation Index Expanded.

Criterios de selección e inclusión

- Se consideraron artículos publicados en los últimos 5 años en idioma inglés y español.
- Artículos relacionados con el monitoreado de condición de las máquinas rotatorias.
- Artículos relacionados con la aplicación de la inteligencia artificial en el monitoreado de condición de las máquinas rotatorias

Criterios de exclusión

Se excluyeron tesis de todo tipo, revistas sin ISSN y revistas no científicas, libros publicados por editoriales nacionales o universidades, manuales de cualquier índole, catálogos, folletos y boletines. Asimismo, no se contemplaron documentos y trabajos presentados en eventos no reconocidos internacionalmente.

No se tomaron en cuenta documentos con enfoques generales no aplicados a la ingeniería mecánica y la inteligencia artificial aplicada o sin resultados experimentales.

Determinación de los términos de búsqueda

Se realizó un estudio para determinar los términos de búsqueda entre frases y palabras clave y fueron elegidas las presentadas, porque son las que más están relacionadas con el tema de este trabajo.

- Para el monitoreado de condición de las máquinas rotatorias se seleccionó como término de búsqueda principal: "*condition monitoring*" o "*fault diagnostic*", siendo el segundo término de búsqueda "*vibration analysis*". Por lo tanto, la ecuación de búsqueda utilizada fue la siguiente: "*condition monitoring*" OR "*fault diagnostic*" AND "*vibration analysis*".
- Para la inteligencia artificial aplicada, se utilizó el término principal de búsqueda "*artificial intelligence*" o "*machine learning*" o "*deep learning*", siendo el segundo término de búsqueda "*condition monitoring*". Luego entonces, la ecuación de búsqueda utilizada quedó como sigue: "*artificial intelligence*" OR "*machine learning*" OR "*deep learning*" AND "*condition monitoring*"
- Los autores refinaron los términos de búsqueda añadiendo técnicas específicas como *convolutional neural network* (CNN), *support vector machine* (SVM), *long short-term memory* (LSTM), *local interpretable model-agnostic explanation* (LIME) y *shapley additive explanation* (SHAP). Los dos primeros términos de búsqueda se mantuvieron con el objetivo de recuperar los artículos que pudieran haber quedado excluidos en la búsqueda inicial con "*condition monitoring*" o "*fault diagnostic*" y "*vibration analysis*".
- Las ecuaciones de búsqueda quedaron de la siguiente forma: "*convolutional neural network*" OR "CNN" OR "*support vector machine*" OR "SVM" OR "*long short-term memory*" OR "LSTM" OR "*local interpretable model-agnostic explanation*" OR "LIME" OR "*shapley additive explanation*" OR "SHAP" AND "*condition monitoring*", "*convolutional neural network*" OR "CNN" OR "*support vector machine*" OR "SVM" OR "*long short-term memory*" OR "LSTM" OR "*local interpretable model-agnostic explanation*" OR "LIME" OR "*shapley additive explanation*" OR "SHAP" AND "*fault diagnostic*" y "*convolutional neural network*" OR "CNN" OR "*support vector machine*" OR "SVM" OR "*long short-term memory*" OR "LSTM" OR "*local interpretable model-agnostic explanation*" OR "LIME" OR "*shapley additive explanation*" OR "SHAP" AND "*vibration analysis*"

Para responder las dos preguntas de investigación y acopiar los estudios más relevantes en relación con el monitoreado de condición y la asistencia de la Inteligencia Artificial a esta tecnología, los autores cumplieron con el propósito de obtener, al menos, 50 estudios relevantes, lo cual se logró con las publicaciones seleccionadas en bases de datos de primer nivel, de manera que proporcionaran suficiente información en cuanto a categorización y tendencias en la investigación, clasificándose las fuentes bibliográficas en función de los temas tratados acordes con la temática de la revisión.

Las fuentes bibliográficas se agruparon en las 4 categorías recogidas en la tabla 1.

Tabla 1. Categorías para agrupar las fuentes bibliográficas. Fuente: autores

Categoría	Referencias
Revisión y análisis de técnicas para el monitoreado de condición	[1], [5], [7], [8], [10], [11], [12], [13], [14], [15], [16], [20], [21], [22], [23], [24], [28], [29], [30]
Aplicaciones experimentales y en entornos reales de técnicas de monitoreado de condición	[2], [3], [4], [6], [9], [17], [18], [19], [25], [26], [27], [30], [31], [32]
Aplicación de técnicas avanzadas de Inteligencia Artificial y <i>Machine Learning</i>	[14], [33], [34], [35], [36], [37], [38], [39], [44], [46], [48], [50]
Uso de la Inteligencia Artificial y el <i>Machine Learning</i> en el monitoreado de condición y el diagnóstico de fallos	[38], [40], [41], [42], [43], [44], [45], [46], [47], [48], [49], [51], [52]

Finalmente, el número total de artículos fue 68 de los cuales fueron seleccionados 52, algunos de ellos clasificados en más de una categoría nivel.

Se usaron 38 revistas para 52, artículos, solo una revista se usó 7 veces para un 17 %, lo que demuestra la diversidad de las revistas. Todas las revistas están indizadas en BD de primer nivel y los artículos publicados en idioma inglés.

3. Tecnologías para el monitoreado de condición de máquinas rotatorias

Las técnicas comunes para monitorear el estado de las máquinas rotatorias son esenciales para garantizar la confiabilidad y disponibilidad de estas sobre todo si son sistemas críticos. Es por ello que se emplean métodos para detectar problemas potenciales antes de que provoquen fallas, minimizando el tiempo de inactividad y previniendo interrupciones inesperadas.

El monitoreado de condición en máquinas rotatorias se ha convertido en una estrategia fundamental para garantizar la confiabilidad y eficiencia operativa en diversos sectores industriales, pues las tecnologías actuales ofrecen soluciones avanzadas para predecir y prevenir posibles fallos, reduciendo significativamente los costos de mantenimiento y minimizando el tiempo de inactividad.

El análisis de vibraciones constituye un método fundamental para el monitoreado de condición de las máquinas rotatorias. Esta técnica consiste en medir las vibraciones producidas por las máquinas para detectar patrones de comportamientos anormales e identificar desbalances, desalineamientos o desgaste en los componentes entre otros defectos. Al analizar la frecuencia y la amplitud de las vibraciones, los especialistas pueden identificar problemas específicos, como defectos en los cojinetes o desalineamiento en los ejes.

El monitoreado de condición de máquinas rotatorias emplea varios métodos de diagnóstico clave para identificar problemas potenciales antes de que estos devengan en fallas funcionales. Una de las principales técnicas utilizadas además del análisis de vibraciones es la termografía infrarroja, que implica la captura de imágenes térmicas para detectar anomalías en el perfil térmico de los componentes de la máquina [1, 2, 6].

Al visualizar la distribución de temperatura en toda la máquina, esta tecnología contribuye a identificar sobrecalentamientos, lubricación deficiente o fallas en los cojinetes. Esta técnica no invasiva permite monitorear las máquinas en condiciones normales de funcionamiento, lo que brinda información valiosa sobre el rendimiento térmico de estas.

Otra técnica importante para el Monitoreado de Condición es el análisis de aceite, que contribuye a determinar el estado de los lubricantes y a detectar la presencia de contaminantes o partículas de desgaste que puedan indicar la degradación de los componentes. La literatura consultada refiere que este método es especialmente útil para identificar problemas relacionados con la lubricación como tal y puede proporcionar señales tempranas de advertencia sobre posibles fallos, toda vez que al examinar las propiedades físicas y químicas de los lubricantes utilizados en las máquinas y durante el análisis de las partículas y los contaminantes del lubricante de estas, se pueden detectar problemas como residuos de desgaste, contaminación y fallas en la propia lubricación [7, 8, 9].

Sin embargo, resulta necesario precisar que el análisis estándar de los aceites lubricantes no está encaminado a determinar modos de fallos específicos y es por ello que resulta necesario aplicar otras tecnologías para el monitoreado de condición, como parte de los programas de mantenimiento predictivo.

El monitoreado de residuos en el aceite ha desempeñado y desempeña un papel fundamental e insustituible en la evaluación de la condición de las máquinas rotatorias, tal es el caso de motores y cajas de engranajes, por ejemplo. Una de las fuentes bibliográficas consultadas ofrece un análisis detallado de los avances en el monitoreado de residuos en aceite con el propósito expreso de mejorar la supervisión en línea de la condición de las máquinas rotatorias. Para ello, realizan una clasificación de las tecnologías de detección en función de su mecanismo de operación, agrupándolas en diferentes categorías a saber: Tecnologías magnéticas, que incluyen detectores de virutas magnéticas y sensores inductivos, Tecnologías eléctricas, donde se destacan los transductores resistivo-capacitivos y los electrostáticos, Tecnologías ópticas, que abarcan transductores fotoeléctricos y de imagen y las Tecnologías acústicas, que exploran el uso de señales sonoras para la identificación de partículas de desgaste [10].

Pero no confundir, este tipo de análisis está relacionado con el análisis de aceite lubricante sólo en que el análisis se ejecuta también sobre una muestra de aceite lubricante a través de lo cual se determina la condición real del aceite de la muestra y no la condición de la máquina en cuestión, sin dejar de reconocer que el análisis de partículas de desgaste proporciona información directa sobre la condición de desgaste de aquellas zonas de la máquina por las que circula el lubricante.

Las mediciones ultrasónicas por su parte, se emplean para detectar ondas sonoras de alta frecuencia, más allá de los 20 kHz producidas por movimientos mecánicos, lo que puede contribuir a identificar problemas tales como defectos en los cojinetes de rodamientos, problemas de lubricación y fallas en las trampas de vapor. Este método es eficaz para detectar fallas en etapas tempranas y se utiliza a menudo de conjunto con otras técnicas de monitoreado para una evaluación integral del estado de las máquinas [2, 11, 12].

De todo esto se puede inferir que, al emplear estas técnicas comunes para el monitoreado de condición, las industrias pueden lograr incrementos en la eficiencia de sus operaciones, minimizando el tiempo de inactividad y prevenir fallas inesperadas en sus máquinas ya que estos métodos, cuando se utilizan en conjunto, proporcionan un enfoque integral para el monitoreado de condición, permitiendo la detección temprana de fallos potenciales y la prevención de fallas funcionales.

El monitoreado de condición en máquinas rotatorias es una estrategia esencial para garantizar su confiabilidad y eficiencia operativa, permitiendo la detección temprana de fallos y la reducción de costos de mantenimiento. Entre las técnicas más relevantes, el análisis de vibraciones se consolida como la herramienta fundamental para identificar desbalances, desalineamientos y fallos en los cojinetes, proporcionando información clave sobre el estado de los componentes mecánicos.

Otras técnicas complementarias, como la termografía infrarroja y el análisis de aceite, aportan una visión integral del estado de las máquinas. La termografía permite detectar anomalías térmicas asociadas a fallas mecánicas o deficiencias en la lubricación, mientras que el análisis de aceite posibilita la identificación de contaminantes y partículas de desgaste, contribuyendo a la prevención de fallos prematuros.

El monitoreado de residuos en aceite se posiciona como un método avanzado para evaluar el desgaste de los componentes, clasificándose en tecnologías magnéticas, eléctricas, ópticas y acústicas, cada una con

aplicaciones específicas. Asimismo, el uso de mediciones ultrasónicas ha demostrado ser eficaz en la detección temprana de defectos en cojinetes y problemas de lubricación.

En conjunto, la implementación de estas tecnologías dentro de programas de mantenimiento predictivo mejora la confiabilidad de los sistemas industriales, minimiza tiempos de inactividad y optimiza la planificación del mantenimiento. La integración de múltiples técnicas de monitoreado resulta clave para una evaluación precisa del estado de las máquinas rotatorias y la prevención de fallos imprevistos.

4. Monitoreado de condición basado en el análisis de vibraciones

PI No. 1. ¿Cómo influyen los métodos de adquisición y análisis de señales de vibraciones en la detección temprana de fallas en las máquinas rotatorias?

El análisis de vibraciones constituye probablemente, el método más confiable y rentable para el monitoreado de condición de máquinas rotatorias, ya que los fallos resultan detectables e identificables a través de las mediciones. Por ello, la recopilación de datos de las mediciones de vibraciones constituyen un elemento fundamental para el monitoreado de condición y el mantenimiento predictivo, fundamentalmente de las máquinas rotatorias y desempeña un papel sumamente importante en la estrategia de mantenimiento proactivo de una entidad.

Los acelerómetros son los transductores más utilizados para la medición de vibraciones, sobre todo los de tipo piezoeléctrico, debido a su alta sensibilidad y confiabilidad en la captura de los datos. De suma importancia resulta el montaje adecuado del sensor, el cual es crítico para garantizar un registro preciso de los datos, ya que la posición y la fijación de estos pueden afectar significativamente la calidad de las mediciones [4, 13].

Todo lo afirmado por estos autores es absolutamente válido, toda vez que tiene que existir continuidad entre el elemento de máquina donde se localiza el defecto y la superficie donde se coloquen los acelerómetros.

Una vez que se recopilan los datos, estos se deben analizar a través de técnicas que se pueden clasificar en: análisis en el dominio del tiempo, análisis en el dominio de la frecuencia y análisis en el dominio del tiempo-frecuencia. En el dominio del tiempo, se examinan parámetros tales como el Valor Pico, el RMS (*Root Mean Square*), el Factor de Cresta y la Curtosis, los cuales permiten entender las características de las vibraciones de la máquina en cuestión. El monitoreado de estos parámetros estadísticos contribuye a identificar cualquier desviación de las condiciones normales de funcionamiento [3, 12, 14].

Sumamente importante resulta el Valor RMS o valor efectivo, asociado a la energía de la vibración y ~~por ende~~ al desarrollo del defecto y el Factor de Cresta, pues este último es un indicador de la presencia de impactos en el registro de vibraciones toda vez que se determina como el cociente entre el Valor Pico y el Valor RMS.

Por otra parte, el análisis en el dominio de la frecuencia implica transformar los datos originales que están en el dominio del tiempo en datos en el dominio de la frecuencia, utilizando para ello métodos como la Transformada Rápida de Fourier FFT (*Fast Fourier Transform*), el análisis de *Cepstrum* y el análisis de envolvente, todo lo cual contribuye a identificar las frecuencias específicas a las que vibra la máquina, imprescindibles para diagnosticar problemas relacionados con desbalances, desalineamientos o deterioro en los cojinetes [3, 5].

El nombre *Cepstrum* tiene su origen invirtiendo el fonema de la primera sílaba *spec* del vocablo *Spectrum*. Es importante destacar que el empleo de la técnica del *Cepstrum* constituye una herramienta suficientemente desarrollada que contribuye en gran medida a perfeccionar el trabajo del analista. Ha sido definido de diferentes formas pero todas coinciden en considerarlo como el espectro de un espectro logarítmico, de aquí que su mayor utilidad radique en su capacidad para la detección de periodicidades dentro del espectro de vibraciones (por ejemplo, familia de armónicas), resaltando la propia estructura armónica de éste y reduciendo la influencia de algunas aleatoriedades en las vías de transmisión de la señal desde la fuente de vibraciones hasta el transductor, todo lo cual se traduce en que el *Cepstrum* es muy poco sensible a las pequeñas variaciones que inevitablemente tienen lugar en la ubicación del acelerómetro cuando no es posible fijarlo con el perno roscado, fenómeno éste que sí afecta los resultados espectrales convencionales y de las mediciones en general.

Otro parámetro clave en el dominio de la frecuencia es la densidad espectral de potencia PSD (*Power Spectral Density*) pues proporciona información sobre la distribución de energía de las señales de vibraciones en todo el rango de frecuencias de interés [15].

Asimismo, varios autores explican que el análisis en el dominio del tiempo-frecuencia combina la información de tiempo y de frecuencia para proporcionar una comprensión integral del comportamiento de las vibraciones a lo largo del tiempo. Para este propósito refieren que se emplean técnicas como la transformada de Fourier de tiempo corto STFT (*Short Time Fourier Transform*), la transformada WT (*Wavelet Transform*), la distribución de Wigner-Ville WVD (*Wigner Ville Distribution*) y la transformada de Hilbert-Huang HHT (*Hilbert Huang Transform*) [16, 17, 18].

Estas fuentes bibliográficas no explican por qué esta combinación es necesaria en comparación con enfoques puramente en el dominio del tiempo y de la frecuencia. La enumeración de métodos como la STFT, WT, WVD y HHT es adecuada, pero las fuentes bibliográficas carecen de una discusión crítica sobre sus diferencias, ventajas y desventajas. Cada una de estas técnicas tiene aplicaciones específicas y limitaciones particulares. Por ejemplo, la STFT proporciona una representación tiempo-frecuencia, pero su resolución depende del tamaño de la

ventana, lo cual introduce un compromiso entre resolución temporal y frecuencial. Por su parte, la WT ofrece una resolución adaptativa, mejorando la capacidad de análisis de señales no estacionarias, pero su implementación y selección de la función wavelet pueden ser complejas. Así mismo, la WVD proporciona una alta resolución tiempo-frecuencia, pero es susceptible a interferencias cruzadas, lo que puede generar interpretaciones ambiguas y por último, la HHT, aunque es particularmente útil para señales no lineales y no estacionarias, su aplicación depende de la correcta descomposición de la señal en modos intrínsecos, lo cual puede introducir errores.

Sin embargo, a todo esto se une el hecho de que no es nada difícil que el lubricante se contamine, sobre todo en industrias que por su naturaleza propia propician este tipo de problema, tal es el caso por ejemplo de la Industria del Cemento y de la Minería. La contaminación del aceite lubricante tiene lugar debido a la ingestión de partículas externas, todo lo cual representa una de las principales causas de fallo en los cojinetes de rodamientos de las máquinas.

Es muy probable que el lector se esté preguntando, por qué esta problemática de la contaminación del aceite lubricante se ha ubicado en la sección de monitoreado de condición basado en el análisis de vibraciones. Lo cierto es que a través de las técnicas de emisión acústica y monitoreado de vibraciones es posible evaluar el impacto de las partículas contaminantes externas en la lubricación de los cojinetes de rodamiento.

En este contexto, otros autores, además de realizar una evaluación cuantitativa del problema de la contaminación del lubricante con partículas externas, centran la investigación en la clasificación de las características espectrales de las señales de emisión acústica y vibraciones, permitiendo la identificación de parámetros clave para el monitoreado de condición, parámetros estos que resultan fundamentales para detectar de manera temprana la presencia de contaminación en el lubricante y con ello, prevenir fallos catastróficos en las máquinas, abordando de manera exhaustiva diferentes escenarios en los que varían tanto el tamaño como la concentración de las partículas contaminantes, ilustrando los efectos que estas variables tienen sobre el desempeño del cojinete de rodamiento. Finalmente, analizan la capacidad de detección de ambas técnicas, resaltando su eficacia en la identificación de condiciones anormales en los cojinetes de rodamiento [19].

Los hallazgos de esta investigación refuerzan la importancia del uso de técnicas avanzadas de monitoreado de condición, tal es el caso de la emisión acústica para garantizar la confiabilidad de los sistemas de lubricación en entornos industriales. En particular, la combinación de emisión acústica y análisis de vibraciones se perfila como una estrategia efectiva para la detección temprana de contaminación en el aceite lubricante, contribuyendo así a la mejora de las estrategias de mantenimiento y la prolongación de la vida útil de los componentes críticos.

De todo esto se infiere que el análisis de vibraciones es el método, más confiable y rentable para el monitoreado de condición de máquinas rotatorias pues está probada su efectividad para la detección e identificación temprana de fallos. Para ello, por lo general se emplean los acelerómetros piezoeléctricos debido a su alta sensibilidad y confiabilidad, de suma importancia resulta la correcta instalación de estos.

Para el análisis de vibraciones en el dominio del tiempo se evalúan parámetros como el Valor Pico, el Valor RMS, el Factor de Cresta y la Curtosis así como que para el análisis en el dominio de la frecuencia se utiliza el Espectro de Amplitudes ya sea en términos de Aceleración, Velocidad y/o Desplazamiento, análisis de *Cepstrum* sumamente útil para la identificación de defectos en transmisiones por engranajes y el análisis de envolvente, esencial para el monitoreado de condición de cojinetes de rodamientos.

En resumen, el análisis de vibraciones es una herramienta fundamental para la detección y diagnóstico de fallos en máquinas rotatorias, con enfoques complementarios en los dominios del tiempo, de la frecuencia y del tiempo-frecuencia.

Es por ello que, al recopilar y analizar sistemáticamente los datos sobre las vibraciones, las entidades pueden identificar problemas potenciales de manera temprana, reducir el tiempo de inactividad, mejorar la confiabilidad de los equipos y mejorar el rendimiento de las máquinas. Este enfoque garantiza que cualquier comportamiento anormal pueda ser detectado y solucionado con prontitud, lo cual respalda la estrategia general de mantenimiento de cualquier industria.

4.1. Transductores para la medición de vibraciones

Los transductores de vibraciones son dispositivos fundamentales para el monitoreado de condición de las máquinas rotatorias, ya que miden la amplitud de las vibraciones generadas por la máquina, mientras exista algún vínculo entre estos y las superficies de interés en la máquina. Existen varios tipos de transductores para vibraciones que se utilizan en el monitoreado de condición, cada uno de los cuales difiere en términos de sensibilidad, rango de frecuencias y aplicación.

Estos sensores convierten las vibraciones mecánicas en señales eléctricas, que luego de ser acondicionadas, se pueden analizar para evaluar el estado de la máquina. La selección del sensor de vibraciones y su sensibilidad es esencial para monitorear y mantener el equipo de manera efectiva.

Otros autores afirman que en el monitoreado de condición se utilizan distintos tipos de transductores de aceleración de vibraciones, incluidos sensores piezoeléctricos, sensores de sistemas microelectromecánicos, MEMS (*Micro Electro Mechanical System*) y sensores capacitivos. Cada tipo tiene características distintivas que afectan su sensibilidad y condicionan sus aplicaciones. Los sensores piezoeléctricos, por ejemplo, generan una carga eléctrica proporcional a la tensión mecánica que se les aplica, lo que los hace altamente sensibles y

adecuados para aplicaciones de alta frecuencia. Por su parte, los sensores MEMS utilizan microelementos electromecánicos para detectar vibraciones y debido a su tamaño compacto y menor consumo de energía se emplean típicamente en aplicaciones de baja a media frecuencia [20, 21].

Y claro está, la sensibilidad de un transductor de vibraciones es un parámetro crítico que determina su capacidad para detectar bajos niveles vibraciones. En aplicaciones estándar con un rango de vibraciones de hasta 50 gravedades por ejemplo. Los sensores típicos tienen una sensibilidad de alrededor de 100 mili Volt por gravedad (mV/g). Para aplicaciones de bajos niveles de vibraciones, donde el rango puede ser de hasta alrededor de 10 gravedades, se utilizan sensores con mayor sensibilidad, como 500 mili Volt por gravedad (mV/g) por ejemplo, lo cual garantiza mediciones precisas [21].

Esta variación en la sensibilidad permite soluciones de monitoreado personalizadas, asegurando incluso poder detectar cambios mínimos en los niveles de vibraciones y poder actuar en consecuencia.

La utilidad de los acelerómetros también radica en el hecho de que a partir de una señal de aceleración de vibraciones se pueden obtener la señal de velocidad y de desplazamiento aplicando una integración y dos integraciones respectivamente y aunque es cierto que son sensibles a vibraciones de baja frecuencia, se emplean básicamente para monitorear la presencia de defectos que generan vibraciones de alta frecuencia, tal es el caso de los defectos inherentes a pares engranados y cojinetes de rodamiento.

Otro tipo de transductor para vibraciones es el de velocidad, que mide la velocidad de los componentes vibratorios y proporcionan datos que pueden contribuir a identificar vibraciones cuya frecuencia sea de moderada a alta. A menudo se utilizan en aplicaciones en las que la detección de la velocidad de las vibraciones es fundamental para diagnosticar el estado de la maquinaria y prevenir posibles fallos [22].

Es importante precisar que la medición espectral de la velocidad de las vibraciones es sumamente útil cuando se pretende monitorear la condición general de la máquina en todo el espectro de vibraciones.

Por su parte, los transductores de desplazamiento, también conocidos como sondas de proximidad, miden la distancia entre un sensor y la superficie vibratoria de la máquina. Estos autores [23] refieren que tales sensores son particularmente efectivos para monitorear el movimiento relativo de los componentes en escenarios de vibraciones de baja frecuencia, tal es el caso de turbinas y grandes motores donde resulta necesario realizar mediciones precisas del desplazamiento.

Los transductores de proximidad, dentro de los que se encuentran los transductores de corrientes de Eddy, resultan sumamente útiles para turbomáquinas en las que el movimiento de los ejes dentro de los cojinetes de deslizamiento bajo lubricación forzada es crítico.

Estos transductores entregan señales eléctricas proporcionales al movimiento mecánico del rotor, en las cuales se distinguen dos componentes:

1. Una componente de directa, proporcional a la posición promedio del centro del rotor, con respecto a la posición del transductor.
2. Una componente de alterna, proporcional al movimiento oscilatorio relativo del rotor con respecto al transductor.

La componente de directa permite graficar la posición de la línea de centros del rotor y la componente de alterna posibilita construir el conocido ploteo orbital.

Cada tipo de transductor de vibraciones tiene sus ventajas únicas y la elección de este depende de los requisitos específicos de la máquina cuya condición se pretende monitorear.

4.2. Análisis de datos en tiempo real

Los métodos de mantenimiento tradicionales suelen basarse en inspecciones programadas y servicios de mantenimiento de rutina, a menudo basados en intervalos de tiempo predeterminados. Estos métodos, si bien son beneficiosos hasta cierto punto, pueden dar lugar a actividades de mantenimiento innecesarias o fallas inesperadas del equipo que no eran evidentes durante las inspecciones, sobre todo si se tiene en cuenta que aún no se ha definido de manera clara una metodología para determinar el intervalo para la realización de las mediciones periódicas.

En este sentido y por el contrario, el análisis de datos en tiempo real como parte del monitoreado de condición utiliza el monitoreado continuo y el análisis de datos para evaluar la condición real de la máquina. Este enfoque recopila el comportamiento de parámetros de rendimiento en tiempo real, datos ambientales y estados operativos para detectar comportamientos anormales y predecir posibles fallas antes de que estas tengan lugar [1, 2].

Al centrarse en el estado del equipo en tiempo real, el mantenimiento predictivo minimiza entonces la necesidad de tareas de mantenimiento innecesarias y permite intervenciones más precisas y oportunas, reduciendo así el tiempo de inactividad y los costos de mantenimiento.

Una de las ventajas significativas del análisis de datos en tiempo real es su capacidad de proporcionar una imagen más dinámica y precisa del estado de la máquina. Las técnicas avanzadas de análisis de datos y aprendizaje automático pueden procesar grandes cantidades de datos procedentes de sensores en tiempo real, identificando patrones y prediciendo fallas con alta precisión. Este nivel de conocimiento no se puede lograr con

los métodos tradicionales, que carecen del flujo de datos continuo y completo, necesario para detectar señales tempranas asociadas a problemas potenciales [24].

A todo esto hay que adicionar el hecho de que el análisis de datos en tiempo real ofrece numerosas ventajas sobre los métodos tradicionales en el contexto del mantenimiento predictivo de las máquinas rotatorias, constituyendo un beneficio significativo la capacidad de realizar un uso más específico y eficiente de los recursos, lo que conduce a una reducción del tiempo de inactividad no planificado y a un aumento tanto de la producción como del rendimiento del equipo.

Sin embargo, el volumen de datos a analizar en tiempo real es grande y no está exento de ruido debido a dificultades presentadas durante el registro de los datos. En torno a esta problemática, el Control Estadístico Multivariable de Proceso MSPC (*Multivariable Statistical Process Control*) ha sido utilizado para poder analizar las variables representativas de la condición de turbinas a vapor de 100 MW en una central termoeléctrica, luego de haber ejecutado procesos de preprocesamiento y acondicionamiento de los datos que incluyó la eliminación de valores perdidos y erróneos, la normalización y transformación de datos y el análisis de valores atípicos y duplicados [25]. Para el análisis de los datos se aplicaron pruebas estadísticas como *Kolmogórov-Smirnov*, *Lilliefors* y *Shapiro-Wilk* para verificar la normalidad de los datos, además de haber realizado un análisis detallado de instancias de medición representativas, identificando períodos operativos estables, todo ello utilizando herramientas de minería de datos para la selección de una muestra patrón fiable [25].

De todo esto se infiere la importancia de aplicar técnicas de análisis de datos y modelado estadístico cuando de monitoreado de condición en tiempo real se trate, lo cual sienta las bases para el logro de un funcionamiento más eficiente y confiable. Desde luego, como se ha señalado anteriormente, los volúmenes de datos a procesar y analizar son suficientemente grandes, todo lo cual dificulta sobremanera el trabajo de los analistas encargados de monitorear la condición de las máquinas.

Es por ello que la implementación de tecnologías para el monitoreado de condición en tiempo real, como dispositivos de Internet de las cosas, (IoT) y modelos avanzados de redes neuronales, mejora aún más la precisión y confiabilidad de la detección de fallas. Estas tecnologías facilitan la recopilación y el análisis de datos sobre parámetros como la velocidad y la aceleración, lo que permite intervenciones oportunas antes de que problemas menores se conviertan en fallas importantes. Por ejemplo, según estos autores [26, 27] las redes neuronales convolucionales CNN han demostrado una alta capacidad de respuesta para identificar diferentes tipos de fallas, aunque la precisión puede variar según las condiciones de carga.

Además, el análisis de datos en tiempo real permite la aplicación de técnicas avanzadas de procesamiento de señales, como el análisis en el dominio tiempo-frecuencia, que puede proporcionar información más detallada sobre el estado de las máquinas. Técnicas como la transformada de Fourier de tiempo corto STFT (*Short Time Fourier Transform*), la transformada wavelet (WT) y la transformada de Hilbert-Huang HHT ofrecen una comprensión integral del comportamiento dinámico de los componentes de la maquinaria, lo que conduce a decisiones de mantenimiento más eficaces [27, 28].

Claro está, el caso específico del análisis de los datos de vibraciones en máquinas rotatorias presupone una serie de procedimientos sistemáticos destinados a evaluar el estado e identificar posibles fallos en la maquinaria.

De aquí que un método muy utilizado para el análisis de registros de vibraciones sea el promediado sincrónico en el tiempo, que aísla las componentes de vibraciones asociadas con un eje o engranaje específico y promedia los demás componentes [29, 30].

Esta técnica es particularmente eficaz cuando se trabaja con cajas de velocidades que tienen múltiples componentes rotatorios, como engranajes, ejes y cojinetes de rodamientos o cuando se tiene la influencia de máquinas vecinas que contaminan los registros de vibraciones de la máquina en cuestión.

Además del promediado sincrónico en el tiempo, se utilizan espectros envolventes para identificar fallas localizadas en los cojinetes de rodamientos, los cuales resultan adecuados para detectar impactos de alta frecuencia causados por fallas dentro de los propios cojinetes de rodamientos [29, 30].

Es menester señalar que el análisis ordinal se emplea para estudiar y visualizar el contenido espectral en maquinarias rotatorias, rastreando y extrayendo componentes ordinales y sus formas de onda en el dominio del tiempo. Este enfoque permite la estimación del espectro promedio de una señal en función del orden de la componente de interés, lo cual es vital para una comprensión integral del estado operativo de la maquinaria.

El análisis modal experimental es otro aspecto crítico, que se centra en la estimación de funciones de respuesta de frecuencia, frecuencias naturales, coeficientes de amortiguamiento y formas modales. Este análisis ayuda a trazar diagramas de estabilización, que son esenciales para comprender el comportamiento dinámico de la maquinaria, lográndose a través de un promediado sincrónico en el tiempo, la eliminación del ruido de manera coherente y analizando además el desgaste a través de los llamados espectros envolventes [31, 32].

Para el diagnóstico de fallas en los cojinetes de rodamiento por ejemplo, se aplican el análisis del espectro de la envolvente y la curtosis espectral en función de las señales de aceleración. Estos métodos son fundamentales para el monitoreado de condición, ya que garantizan la identificación temprana de posibles problemas evitando de esta manera fallas inesperadas en las máquinas a través de intervenciones oportunas para efectuar las correcciones pertinentes.

En conclusión, el monitoreado de condición de máquinas rotatorias es una estrategia esencial para mejorar la confiabilidad y eficiencia operativa en entornos industriales. El análisis de vibraciones, considerado el método más confiable y rentable, permite la detección temprana de fallos mediante el uso de acelerómetros piezoeléctricos y técnicas avanzadas de procesamiento de señales en los dominios del tiempo, frecuencia y tiempo-frecuencia. Métodos como la Transformada Rápida de Fourier (FFT), el análisis de Cepstrum y la Transformada Wavelet ofrecen una caracterización detallada del estado de la maquinaria, permitiendo intervenciones oportunas antes de que ocurran fallos catastróficos.

Además del análisis de vibraciones, se han explorado técnicas complementarias como la termografía infrarroja, el análisis de aceite y las mediciones ultrasónicas, cada una con aplicaciones específicas en la detección de anomalías. La integración de estas metodologías en un enfoque de mantenimiento predictivo permite reducir costos operativos, minimizar tiempos de inactividad y prolongar la vida útil de los equipos.

El avance de tecnologías como el Internet de las Cosas (IoT) y las redes neuronales ha revolucionado el monitoreado de condición en tiempo real, facilitando la recopilación, procesamiento y análisis de grandes volúmenes de datos con mayor precisión. La implementación de modelos de aprendizaje profundo, como las redes neuronales convolucionales (CNN), ha demostrado ser eficaz en la identificación de fallos en máquinas rotatorias, aunque su rendimiento depende de las condiciones de carga y la calidad de los datos adquiridos.

En síntesis, la combinación de técnicas tradicionales y emergentes en el monitoreado de condición constituye una herramienta poderosa para la optimización del mantenimiento industrial. La evolución constante de estas tecnologías contribuirá a una mayor precisión en la detección de fallas, fortaleciendo la gestión de la confiabilidad y garantizando la operatividad de los sistemas industriales en el largo plazo.

Todo lo visto hasta el momento proporciona una respuesta detallada y fundamentada a la primera pregunta de investigación pues se han abordado los diferentes tipos de transductores para la medición de vibraciones resaltando la importancia del montaje correcto de estos.

De igual manera, se revisó todo lo relacionado con el análisis de señales de vibraciones, ya sea en el dominio del tiempo a través de los descriptores estadísticos que permiten identificar desviaciones de las condiciones normales de funcionamiento, lo cual resulta esencial para detectar comportamientos anormales de manera temprana, en el dominio de la frecuencia destacándose el uso de técnicas como la Transformada Rápida de Fourier (FFT), el análisis de *Cepstrum*, el análisis de la densidad espectral de potencia y el análisis de envolvente, todo lo cual permite identificar frecuencias específicas asociadas con problemas como desbalances, desalineamientos o deterioro en los cojinetes y en el dominio del tiempo-frecuencia, exponiéndose las características de la Transformada de Fourier de Tiempo Corto (STFT), la Transformada Wavelet (WT) y la Transformada de Hilbert-Huang (HHT). Estas técnicas combinan información de tiempo y frecuencia.

También se expuso la importancia del análisis de datos en tiempo real, lo cual permite monitorear continuamente el estado de las máquinas y detectar comportamientos anormales antes de que se conviertan en fallas, introduciendo el uso de tecnologías como el Internet de las Cosas (IoT) y modelos avanzados de redes neuronales, que mejoran la precisión y confiabilidad de la detección de fallas.

En resumen, todo lo abordado hasta el momento responde de manera exhaustiva a la primera pregunta de investigación, proporcionando una visión detallada de cómo los métodos de adquisición y análisis de señales de vibraciones influyen en la detección temprana de fallas en las máquinas rotatorias, destacándose tanto las técnicas tradicionales como las avanzadas, enfatizando en la importancia de la integración de tecnologías modernas para mejorar la precisión y eficacia del monitoreo de condición, todo lo cual se traduce en una base sólida para entender cómo el análisis de vibraciones es una herramienta indispensable en el mantenimiento predictivo y la gestión de la confiabilidad en entornos industriales.

En conclusión, el análisis de vibraciones se reafirma como el método más confiable y rentable para el monitoreado de la condición de máquinas rotatorias, permitiendo la detección temprana de fallas y la optimización del mantenimiento predictivo. El uso de acelerómetros piezoeléctricos es clave en la medición precisa de vibraciones, destacándose la importancia de su correcta instalación para garantizar registros confiables.

El procesamiento de señales en los dominios del tiempo, frecuencia y tiempo-frecuencia proporciona una caracterización detallada del estado de la maquinaria. En el dominio del tiempo, se analizan parámetros estadísticos como el Valor Pico, el RMS y el Factor de Cresta, fundamentales para identificar desviaciones en el comportamiento normal de la máquina. En el dominio de la frecuencia, el uso de la Transformada Rápida de Fourier (FFT), el análisis de *Cepstrum* y el análisis de envolvente permite diagnosticar problemas específicos como desbalances, desalineaciones y defectos en los cojinetes. En el dominio tiempo-frecuencia, técnicas como la Transformada Wavelet (WT) y la Transformada de Hilbert-Huang (HHT) ofrecen una visión integral de la evolución dinámica de las fallas.

Se resalta la relevancia del análisis de datos en tiempo real, impulsado por tecnologías como el Internet de las Cosas (IoT) y modelos de aprendizaje profundo, en particular las redes neuronales convolucionales (CNN). Estos avances han demostrado mejorar la precisión y confiabilidad de la detección de fallos, permitiendo intervenciones oportunas y reduciendo los tiempos de inactividad.

Es importante destacar la evaluación del impacto de la contaminación del lubricante en los cojinetes de rodamiento mediante técnicas de emisión acústica y análisis de vibraciones. La combinación de estos métodos

facilita la identificación temprana de la presencia de partículas contaminantes y contribuye a la prevención de fallas catastróficas.

En síntesis, la integración de enfoques tradicionales y emergentes en el monitoreado de condición fortalece la estrategia de mantenimiento predictivo, reduciendo costos operativos y prolongando la vida útil de los equipos. El desarrollo continuo de estas tecnologías garantizará una mayor precisión en la identificación de fallas, mejorando la confiabilidad y la operatividad de los sistemas industriales a largo plazo.

5. Inteligencia Artificial y monitoreado de condición

PI No. 2. ¿Cuáles son las tendencias actuales en la aplicación de la Inteligencia Artificial al monitoreado de condición de máquinas rotatorias?

El avance de la Inteligencia Artificial (IA) ha revolucionado el campo del monitoreado de condición e incluso, del mantenimiento predictivo, permitiendo la detección temprana de fallos con mayor precisión y eficiencia. El desarrollo de modelos basados en redes neuronales convolucionales CNN y redes de memoria a corto y largo plazo LSTM (*Long Short-Term Memory*) ha permitido realizar análisis más detallados de las señales de vibraciones, mejorando significativamente la identificación de comportamientos anormales.

En esta sección se expondrán los resultados de la revisión realizada en torno a las principales técnicas de Inteligencia Artificial aplicadas al monitoreado de condición, abordando los enfoques más relevantes de aprendizaje automático *Machine Learning* y del aprendizaje profundo *Deep Learning*, sus ventajas y limitaciones, así como su impacto en la mejora del mantenimiento predictivo de sistemas industriales.

5.1. Algoritmos comunes de aprendizaje automático

Los algoritmos de aprendizaje automático son fundamentales para mejorar la precisión del monitoreado de condición de las máquinas rotatorias, toda vez que permiten la detección temprana de fallas. Entre los algoritmos más utilizados se encuentran los árboles de decisión DT (*Decision Trees*), las máquinas de soporte vectorial SVM (*Support Vector Machine*) y las redes neuronales NN (*Neural Network*). Por su simplicidad e interpretabilidad se prefieren los árboles de decisión, lo que los hace adecuados para diagnósticos iniciales y evaluaciones rápidas. Igualmente, la literatura consultada insiste en que las máquinas de soporte vectorial son efectivas en tareas de clasificación, distinguiendo con alta precisión entre condiciones de funcionamientos normales y anormales. Asimismo, se plantea que las redes neuronales, en particular los modelos de *deep learning*, se destacan en el manejo de grandes conjuntos de datos y patrones complejos, ofreciendo soluciones precisas para la detección temprana de fallas. Estos algoritmos contribuyen de conjunto, a tomar decisiones más confiables y oportunas en torno al mantenimiento, reduciendo así el tiempo de inactividad y los costos de mantenimiento [33, 34].

Resumiendo, se puede afirmar que los algoritmos de *machine learning* mejoran la precisión del monitoreado de condición de máquinas rotatorias, facilitando la detección temprana de fallas, siendo los árboles de decisión los más utilizados en estos menesteres, debido a su simplicidad e interpretabilidad para diagnósticos iniciales junto a las máquinas de soporte vectorial SVM, de demostrada eficacia en la clasificación de condiciones normales y anormales y el *deep learning*, que puede manejar grandes volúmenes de datos y patrones complejos. En conjunto, estos algoritmos optimizan la toma de decisiones para el mantenimiento predictivo, reduciendo el tiempo de inactividad y los costos operativos.

5.2. Algoritmos para el monitoreado de condición y la detección temprana de fallos

El monitoreado de condición de máquinas rotatorias aprovecha algoritmos avanzados de *machine learning* para mejorar la precisión en la detección temprana de fallos. Entre estos, las redes neuronales convolucionales CNN y las redes de memoria a corto y largo plazo LSTM se utilizan de manera frecuente y efectiva. La literatura señala que las CNN son particularmente efectivas para analizar señales de vibraciones y extraer características que indiquen fallos potenciales, toda vez que su capacidad para procesar grandes conjuntos de datos e identificar patrones, las hacen adecuadas para el monitoreado de condición de las máquinas rotatorias. Se afirma además que las redes LSTM, son expertas en el manejo de datos secuenciales y pueden identificar dependencias temporales dentro de las señales de vibraciones. Esta capacidad permite a las LSTM predecir fallos en función de las tendencias de los datos históricos [35, 36].

Otros autores demuestran que tanto las CNN como las LSTM contribuyen significativamente al campo del mantenimiento predictivo, mejorando la detección temprana de fallas, reduciendo así el tiempo de inactividad y los costos de mantenimiento relativos a las máquinas rotatorias [37, 38].

De todo esto se infiere que las redes neuronales convolucionales y las redes de memoria a corto y largo plazo resultan los algoritmos más efectivos para el monitoreado de condición y la detección de fallos incipientes en las máquinas rotatorias.

5.3. Monitoreado de condición basado en *Machine Learning*

Como ya se ha planteado en otras secciones de este artículo, el monitoreado de condición es una práctica esencial en la industria moderna para garantizar la operación segura y eficiente de las máquinas críticas. La integración de técnicas de *machine learning* ha permitido una detección más temprana y precisa de fallos

potenciales. Estas técnicas analizan grandes volúmenes de datos operativos para identificar patrones que preceden a fallos, facilitando el mantenimiento predictivo y reduciendo tiempos de inactividad no planificados.

Algoritmos como el llamado Memoria a Corto y Largo Plazo LSTM y el Bosque Aleatorio RF (*Random Forest*) se aplican a datos procedentes de transductores y resultan efectivos para predecir fallos con alta precisión. Igualmente, se afirma que debido al enfoque basado en múltiples transductores y algoritmos avanzados, estos modelos para el monitoreado de condición y el mantenimiento predictivo pueden aplicarse en distintos tipos de máquinas, desde sistemas netamente hidráulicos hasta motores eléctricos, teniendo presente que el uso de algoritmos de *machine learning* mejora la interpretación de los datos provenientes de los transductores, permitiendo a los sistemas adaptarse a variaciones en las condiciones de operación sin requerir ajustes manuales reiterados [39].

Bosque Aleatorio es el término en español para referirse al algoritmo *Random Forest*, el cual es una traducción directa y ampliamente aceptada en la literatura científica y técnica en idioma español. El Bosque Aleatorio se refiere al conjunto de Árboles de Decisión DT (*Decision Tree*) que conforman el modelo, donde la aleatoriedad juega un papel clave en la selección de muestras y características para mejorar la precisión, siendo el análisis de vibraciones una de las aplicaciones más destacadas del *machine learning* para el monitoreado de condición.

Durante la revisión de las fuentes bibliográficas se identificaron autores que propusieron un enfoque basado en *deep learning* para el monitoreado de condición basado en análisis de vibraciones. Su metodología emplea una combinación de redes neuronales convolucionales CNN alimentadas con respuestas en frecuencia procesadas a través de diversas funciones, mejorando la precisión en la detección de comportamientos anormales [40].

Sin dudas, este enfoque integrador aborda desafíos comunes en el diseño y ajuste de hiperparámetros de arquitecturas de aprendizaje profundo, ofreciendo una mayor capacidad de generalización.

Según otros autores, la incorporación de principios físicos en los modelos de *machine learning* ha ganado mucha atención recientemente, destacándose una mejora en la precisión y la interpretabilidad de los modelos a través de la integración de leyes físicas conocidas en los algoritmos que los sustentan [41].

Esta fusión de conocimiento basado en datos y principios físicos permite una mejor generalización y confiabilidad en aplicaciones de monitoreado de condición.

Por otra parte, la gestión de datos incompletos constituye otro desafío en el monitoreado de condición. Para abordar este problema, otros autores han propuesto la integración de *autoencoders* variacionales con descriptores de registros en el tiempo, todo lo cual permite la detección de fallas y la asignación de un índice de condición relativo, incluso cuando los datos de fallas son limitados o inexistentes. Al comparar la desviación de cada muestra respecto a una distribución de referencia de condición normal en el intervalo registrado, el modelo identifica con precisión condiciones de fallo no detectadas previamente, mejorando la fortaleza del monitoreado en entornos industriales [42].

Asimismo, la comparación entre métodos tradicionales de *machine learning* y enfoques de *deep learning* es esencial para determinar la mejor estrategia de monitoreado. En este sentido, otros autores llevaron a cabo una comparación exhaustiva entre *Auto Machine Learning* AML y métodos de *deep learning* para tareas de monitoreado de condición. Sus experimentos revelaron que, aunque ambos enfoques logran alta precisión en escenarios de validación cruzada aleatoria, no existe una preferencia clara por alguno de ellos en el caso de escenarios de validación más realistas [43].

Lo anterior indica la presencia de cambios de dominio en aplicaciones del mundo real y resalta la importancia de seleccionar el método adecuado según el contexto específico.

En resumen, la aplicación de técnicas de *machine learning* en el monitoreado de condición ha demostrado ser una herramienta poderosa para mejorar la detección temprana de fallas y optimizar las estrategias de mantenimiento. La selección del enfoque adecuado, ya sea mediante métodos tradicionales de *machine learning*, *deep learning* o una combinación de ambos, depende de las características específicas del sistema monitoreado y de la naturaleza de los datos disponibles. La integración de principios físicos y el manejo efectivo de datos incompletos son áreas prometedoras que continúan impulsando avances en este campo.

5.4. Aplicación de las redes neuronales artificiales (ANN)

El monitoreado de condición es una práctica esencial en la industria moderna para garantizar la operatividad y eficiencia de las máquinas. Las redes neuronales artificiales ANN (*Artificial Neural Network*) han emergido como herramientas prominentes en este ámbito, debido a su capacidad para modelar y predecir comportamientos complejos a partir de datos procedentes de diversos tipos de transductores.

Los modelos basados en ANN aplicados al monitoreado de condición a través del análisis de vibraciones, toman en cuenta no sólo señales de vibraciones sino también otros parámetros para clasificar la condición de la máquina en normal o anormal.

La literatura refiere el desarrollo de un método integral para monitorear y diagnosticar fallos en motores de inducción, con un enfoque específico en fallos de rodamientos, que constituyen el tipo de fallo más frecuente en este tipo de máquina rotatoria, consistente de un sistema de monitoreado basado en técnicas de inteligencia artificial y una red neuronal multicapa, lo cual difiere de otros sistemas que sólo utilizan las técnicas de inteligencia

artificial para el monitoreado de condición sin llegar a la identificación de las causas del cambio de condición. Los autores de la investigación demostraron cómo los indicadores de vibraciones obtenidos del análisis de estas, sirvieron como entradas a la red neuronal permitiendo la identificación de la presencia o la ausencia de fallos. Los resultados obtenidos demostraron la influencia significativa de los parámetros y datos de entrenamiento y prueba en el rendimiento de la red neuronal [44].

La investigación realizada por estos autores proporciona información valiosa sobre la aplicación de redes neuronales artificiales en el diagnóstico de fallas de motores de inducción, ofreciendo un enfoque confiable para el mantenimiento proactivo y mejorando la confiabilidad general de los sistemas de motores industriales.

Por otro lado, es menester destacar que sin dudas, los fallos más importantes en las turbinas eólicas resultan costosos de reparar y causan pérdida de ingresos debido al largo tiempo de inactividad. Continuamente se desarrollan nuevos métodos para mejorar el sistema de monitoreado de condición de este tipo de máquina. Tal es el caso referido por la fuente bibliográfica revisada en el que se demuestra la efectividad de las redes neuronales artificiales ANN para aplicaciones de monitoreado de condición basadas en sistemas SCADA (*Supervisory Control And Data Acquisition*). Los autores de la investigación presentan un método para superar los errores de los modelos ANN debido a la discontinuidad de los datos en el sistema SCADA [45].

Por su parte, otros autores realizaron un estudio sobre la aplicación de las CNN en el análisis de vibraciones de cojinetes de rodamientos en motores, destacando varios hallazgos clave que refuerzan su potencial transformador en este ámbito. En primer lugar, el modelo de CNN propuesto por los autores permite la detección temprana de fallos, ya que es capaz de analizar las mediciones de vibraciones en bruto y detectar signos iniciales de daño incipiente en los componentes. Esto posibilita la implementación de acciones de mantenimiento oportunas antes de que se produzcan fallos severos, reduciendo así el riesgo de paradas imprevistas y costosos tiempos de inactividad. Asimismo, demuestran que las CNN pueden clasificar con precisión los estados funcionales de los elementos de máquina, lo cual permite identificar de manera efectiva fallos potenciales en los cojinetes de rodamientos. Esta capacidad de diagnóstico avanzado es especialmente relevante, por ejemplo para la industria naviera, donde la confiabilidad de los sistemas mecánicos es fundamental para garantizar la seguridad y el cumplimiento de los cronogramas operativos [46].

Desde una perspectiva económica y técnica, el estudio realizado por estos autores destaca que el uso de las CNN en estrategias de monitoreado de condición y mantenimiento predictivo ofrece ventajas significativas en comparación con los métodos tradicionales de mantenimiento preventivo, pues al optimizar los cronogramas de mantenimiento y reducir intervenciones innecesarias, se logra minimizar el tiempo de inactividad no planificado y mejorar la eficiencia operativa, lo cual se traduce en una reducción considerable de los costos.

Otro resultado relevante de la investigación llevada a cabo por estos autores resulta la adaptabilidad de esta tecnología en las prácticas de mantenimiento. A diferencia de los enfoques convencionales que requieren la detención de la maquinaria para realizar inspecciones, las CNN permiten un monitoreado continuo mientras el equipo continúe en operación, todo lo cual no solo mejora la capacidad de respuesta ante posibles fallos, sino que también evita interrupciones en la producción, un factor clave en entornos industriales donde la disponibilidad operativa es prioritaria. Por último, los autores enfatizan en que el monitoreado de condición basado en las CNN reduce el desperdicio de recursos, al evitar el reemplazo prematuro de componentes aún en buen estado técnico [46].

En conclusión, los hallazgos de esta investigación ponen de manifiesto el impacto positivo de las CNN en el mantenimiento de las máquinas rotatorias pues su capacidad para mejorar la seguridad, eficiencia y sostenibilidad en las operaciones industriales confirma la importancia de seguir explorando e implementando estas tecnologías en el ámbito del mantenimiento industrial.

Así mismo, es menester señalar que la combinación de redes neuronales convolucionales CNN y el llamado bosque aleatorio RF mejora significativamente la precisión en el diagnóstico de fallos a través de varios mecanismos clave.

Otros autores se refieren a la extracción automática de características de los datos de entrada a la red neuronal, lo cual se logra debido a que el modelo CNN tiene la capacidad de extraer automáticamente características en múltiples niveles a partir de los datos de entrada, que en el caso de la investigación llevada a cabo por estos autores [47] son imágenes bidimensionales en escala de grises, generadas a partir de señales de vibraciones en el dominio del tiempo mediante la Transformada Wavelet Continua CWT (*Continuous Wavelet Transform*), todo lo cual elimina la necesidad de una selección manual y permite que el modelo aprenda características sensibles y representativas que son básicas para la detección de fallos.

Otro de los elementos aportados por estos autores [47] para mejorar la precisión del diagnóstico lo constituye el llamado aprendizaje conjunto (*ensemble learning*) el cual incrementa la capacidad de generalización del sistema de diagnóstico de fallos, mejorando la precisión al combinar las predicciones de varios clasificadores, lo que permite capturar diferentes aspectos característicos de los datos.

Un elemento extremadamente importante aportado por estos autores [47] lo constituye el hecho de que el método desarrollado está diseñado para ofrecer un alto rendimiento incluso cuando los conjuntos de datos de entrenamiento y prueba han sido recopilados bajo diferentes condiciones operativas, cosa que resulta

particularmente importante en aplicaciones del mundo real, donde la distribución de características puede variar en función de las condiciones operativas de la máquina.

En general se puede concluir que la integración de las CNN para la extracción de características y el RF para la clasificación, se traduce en una herramienta de diagnóstico poderosa, que supera a los métodos tradicionales y mejora la precisión en la detección de fallos en cojinetes de rodamientos, siendo un aspecto muy importante el hecho de que las CNN correctamente entrenadas por supuesto, tienen la capacidad de extraer automáticamente características de espectros obtenidos a través de la Transformada Wavelet Continua por ejemplo, suministrados como datos de entrada en forma de imágenes bidimensionales en escala de grises.

Así mismo, se identifican referencias de otros autores [48] afirmando que los modelos basados en redes neuronales artificiales permiten determinar el tiempo óptimo de mantenimiento/operación lo cual conduce a minimizar los costos en comparación con otras estrategias de mantenimiento, contribuyendo a reducir el tiempo de inactividad de los equipos y las pérdidas de producción, detectando fallos antes de que estos tengan lugar.

También se asegura que una vía para la aplicación de modelos de ANN se basa en la utilización de la herramienta de redes neuronales NNTool (*Neural Networks Tool*) de MATLAB, demostrando su viabilidad en entornos de ingeniería, todo lo cual redundo en que la Inteligencia Artificial puede impactar en la evaluación de las vibraciones, el consumo de energía, la temperatura, el ruido, la composición química, el contenido de residuos y el volumen de material por ejemplo [48].

Es necesario tener en cuenta que debido a que el modelo de ANN es entrenado con múltiples parámetros de la máquina a saber, vibraciones y parámetros tecnológicos, entonces es capaz de procesar grandes volúmenes de datos y detectar correlaciones no evidentes en los métodos tradicionales, lo cual no contrasta con su adaptación a diferentes tipos de máquinas industriales, sobre todo si se tiene en cuenta que el modelo se basa en datos operacionales genéricos (vibraciones, temperatura y energía entre otros), todo lo cual le otorga un alto grado de flexibilidad.

5.5. Deep learning en el monitoreado de condición

El *deep learning* o aprendizaje profundo como se le conoce en idioma español, ha emergido como una herramienta esencial para el monitoreado de condición de sistemas industriales, ofreciendo soluciones avanzadas para la detección temprana de fallos y el mantenimiento predictivo. Su capacidad para procesar grandes volúmenes de datos y extraer patrones complejos ha revolucionado la forma en que actualmente se supervisan y mantienen las máquinas rotatorias y otros equipos críticos.

En este sentido, en [49] se explica que a diferencia de otras arquitecturas de aprendizaje profundo, el SDAE (*Stacked Denoising Autoencoder*) posee una estructura de red estable y capaz de extraer características relevantes de los datos de vibraciones, dejando claro que la combinación con GAN (*Generative Adversarial Network*) o red generativa antagónica como se le conoce en idioma español, mejora la generalización del modelo. Afirman que en entornos industriales, es común la escasez de datos relativos a los fallos en cuyo caso, el método GAN-SDAE genera datos realistas para poder aumentar así el volumen de datos utilizados para el entrenamiento del modelo, paliando el problema de desequilibrio en las muestras y mejorando la capacidad de este para reconocer fallos aún con datos limitados. Según estos autores, el método GAN-SDAE fue probado con éxito en la detección de fallos en rodamientos y engranajes, demostrando versatilidad en distintos escenarios de monitoreado de condición que unido a la técnica de *data augmentation*, el modelo evita el sobreajuste y mejora su rendimiento en datos no registrados previamente, todo lo cual se traduce en una mayor confiabilidad en la predicción de fallos.

En el análisis de vibraciones, el *deep learning* se ha aplicado también en el monitoreado acústico de máquinas. Un estudio ya publicado da cuenta sobre el uso de redes neuronales profundas para el monitoreado acústico de una máquina, demostrando que este enfoque puede detectar emisiones acústicas con una precisión mínima del 79 % [50].

Estos hallazgos resaltan la eficacia del *deep learning* en la identificación de anomalías basadas en señales acústicas, ampliando las posibilidades del monitoreado de condición para detectar grietas internas en paletas de turbinas a vapor, por ejemplo.

La capacidad del *Deep Learning* para manejar datos cíclicos procedentes de transductores también ha sido objeto de investigación, pues se ha estudiado el uso de redes neuronales convolucionales profundas para analizar datos cíclicos procedentes de transductores vinculados al monitoreado de condición. Los autores de tal investigación [50] compararon diferentes modelos y destacaron la importancia de abordar las complejidades de los sistemas multitransductores en el monitoreado de condición.

Los resultados sugieren que, si bien es cierto que los modelos convencionales pueden lograr bajas tasas de error, las CNN enfrentan múltiples desafíos debido a las diversas características de los transductores, lo cual indica la necesidad de enfoques más sofisticados para mejorar la precisión.

En el contexto de señales de alta complejidad para el monitoreado de condición, la literatura refiere la propuesta de un enfoque que combina el aprendizaje automático no supervisado con la clasificación de una clase exclusiva para la detección de fallos. El método introducido por estos autores [51] utiliza para el entrenamiento, datos representativos de condiciones normales y emplea una combinación de máquinas de aprendizaje extremo, *extreme learning machine* y *autoencoders* para el aprendizaje de las características de los datos [51].

Este enfoque integrado mejora la capacidad de detección de fallos, especialmente en casos donde los datos del monitoreado contienen varias señales no informativas asociadas a ruido y malfuncionamientos de la instrumentación empleada para el monitoreado.

En resumen, el *deep learning* ofrece enfoques prometedores para el monitoreado de condición, proporcionando soluciones precisas y eficientes para la detección temprana de fallos en sistemas industriales. Sin embargo, la selección adecuada del modelo y la arquitectura, resulta decisiva y debe basarse en las características específicas de los datos y las necesidades de la aplicación. La investigación continua en este campo es esencial para abordar los inconvenientes actuales y mejorar aún más la eficacia de las técnicas de *deep learning* en el monitoreado de condición.

5.6 Otros modelos de IA para asistir al monitoreado de condición

Uno de los principales desafíos en la adopción de modelos de IA en el ámbito del monitoreado de condición y el mantenimiento predictivo es su carácter de "caja negra", lo cual dificulta la comprensión de las causas que están detrás de sus predicciones. Por ello, para abordar esta limitación, se emplean diversas metodologías que permiten interpretar y explicar el comportamiento de estos modelos.

Un estudio realizado [52] analiza diversas técnicas clave de Inteligencia Artificial aplicadas al monitoreado de condición y el mantenimiento predictivo, con un enfoque particular en la mejora de la interpretabilidad de los modelos utilizados en el monitoreado de condición de las máquinas rotatorias.

Uno de los estudios realizados en torno a esta problemática destaca en primer lugar, el uso de la llamada explicación local e interpretable independiente del modelo LIME (*Local Interpretable Model-agnostic Explanation*), técnica esta que facilita la interpretación de las predicciones generadas por modelos de aprendizaje automático. LIME funciona aproximando localmente el modelo con representaciones más comprensibles, lo que permite a los ingenieros de mantenimiento entender de manera intuitiva qué factores están influyendo en una determinada predicción [52].

Otra metodología abordada en el estudio es la denominada explicación aditiva de Shapley SHAP (*SHapley Additive exPlanation*), la cual proporciona una visión detallada sobre la contribución de cada variable en la decisión tomada por el modelo. Los autores del estudio afirman que a través de los valores SHAP, se puede determinar el peso de cada característica en la predicción final, lo que no solo facilita la interpretación de los resultados, sino que también ayuda a detectar posibles sesgos o inconsistencias en el modelo [52].

Asimismo, en el estudio se examina el uso de los llamados gráficos de dependencia parcial PDP (*Partial Dependence Plots*), que son gráficos que permiten visualizar la relación entre una variable de entrada y la salida del modelo. A manera de ejemplo, en la figura 1 se muestra el PDP de la característica IF_Z3 [52] para la Clase Soltura Mecánica. El eje horizontal representa el rango de valores de la característica que se está analizando mientras que el eje vertical presenta el efecto de la característica en la predicción del modelo. La línea horizontal en el gráfico PDP (generalmente en el valor de PDP = 0) representa la tasa base. La curva muestra cómo las predicciones se desvían de esta tasa base a medida que cambia la característica IF_Z3. Si la curva PDP tiene pendiente hacia arriba a medida que se transita a lo largo del eje horizontal, esto indica que aumentar el valor de la característica conduce a predicciones del modelo más altas. Por el contrario, si la curva tiene pendiente descendente, sugiere que aumentar el valor de la característica conduce a menores predicciones del modelo. Una curva PDP plana significa que la característica tiene poco o ningún impacto en las predicciones del modelo. Las PDP ayudan a comprender cómo llega el modelo a sus predicciones y pueden guiar la ingeniería de las características y la mejora del modelo [52].

No hay dudas de que esta herramienta es especialmente útil para comprender cómo cambios en una característica específica pueden afectar las predicciones, proporcionando información valiosa sobre la dinámica del sistema monitoreado.

Por último, en el estudio también se identifican los ploteos llamados expectativa o esperanza condicional individual ICE (*Individual Conditional Expectation*), que amplían el concepto de PDP al mostrar cómo varía la predicción cuando se modifica un solo atributo, pero a nivel individual para cada instancia de los datos [52]. Esta técnica permite un análisis más detallado y preciso del impacto de cada variable en los resultados del modelo, brindando a los ingenieros una comprensión más profunda de su comportamiento, figura 1.




Fig. 1. Ejemplo de ploteo PDP para la característica IF_Z3. Fuente: [52]

En la figura 2 se muestra el gráfico ICE de la característica IF_Z3 para múltiples clases a saber, solturas mecánicas, desalineamiento, condición normal, desbalance de masa en un plano y desbalance de masa en dos planos, utilizando para ello un modelo de *random forest*. Cuando de clasificación multiclase se trata, existe una curva ICE para cada clase. En el gráfico de la figura 2, el eje horizontal representa la característica, mientras el eje vertical muestra la probabilidad de asignación de una clase específica al variar dicha característica, manteniendo las demás constantes [52].




Fig. 2. Ejemplo de ploteo ICE a partir del modelo *random forest* para la característica IF_Z3 y para todas las clases definidas para la investigación. Fuente: [52]

Cada curva ICE ilustra cómo cambia la probabilidad pronosticada de su clase correspondiente, al variar la característica de interés. Las curvas típicamente se centran alrededor de una tasa base, que representa la probabilidad pronosticada cuando las demás características se mantienen constantes en su valor promedio u otro valor de referencia [52].

Si la curva ICE es ascendente esto indica que valores más altos de la característica se asocian con mayor probabilidad para esa clase. Si la curva es descendente, sugiere que valores más altos se asocian con menor probabilidad. Una curva plana indica que la característica tiene poca influencia en la probabilidad pronosticada para esa clase [52].

Cuando las curvas ICE se cortan, esto estará indicando que la importancia relativa de la característica analizada cambia a lo largo de su rango. Esto sugiere que la característica tiene efectos diferentes sobre las probabilidades de cada clase en distintos puntos. En otras palabras, en ciertos valores específicos, la probabilidad pronosticada para una clase supera la probabilidad pronosticada para otra [52].

No hay dudas de que el empleo de estas metodologías contribuye significativamente a mejorar la interpretabilidad de los modelos de IA aplicados al monitoreado de condición y al mantenimiento predictivo, toda vez que propician que los procesos de toma de decisiones de los algoritmos sean más transparentes, lo cual fomenta una mayor confianza entre los ingenieros de mantenimiento y facilita la adopción de estas tecnologías

en entornos industriales. Con ello, se superan las barreras asociadas a la “opacidad” de los modelos avanzados, promoviendo su integración en estrategias de mantenimiento más eficientes y confiables.

En conclusión, la aplicación de la Inteligencia Artificial (IA) al monitoreado de condición ha demostrado ser una estrategia altamente efectiva para la detección temprana de fallos en máquinas rotatorias, optimizando el mantenimiento predictivo y reduciendo costos operativos. La integración de técnicas de Machine Learning y Deep Learning ha permitido mejorar la precisión en el análisis de señales de vibraciones, facilitando la identificación de anomalías con mayor rapidez y fiabilidad.

El uso de algoritmos de aprendizaje automático, como los árboles de decisión, las máquinas de soporte vectorial (SVM) y las redes neuronales artificiales (ANN), ha proporcionado herramientas versátiles para la clasificación y diagnóstico de fallas. Particularmente, las redes neuronales convolucionales (CNN) y las redes de memoria a corto y largo plazo (LSTM) han mostrado un desempeño superior en la extracción de características de señales complejas y en la identificación de tendencias de fallo a partir de datos históricos.

El Deep Learning ha revolucionado el monitoreado de condición al permitir el análisis de grandes volúmenes de datos con una precisión sin precedentes. Modelos como las autoencoders variacionales, las redes generativas antagónicas (GAN) y los stacked denoising autoencoders (SDAE) han sido implementados con éxito en el diagnóstico de fallas en cojinetes, engranajes y motores, demostrando su capacidad para mejorar la predicción y la toma de decisiones en el mantenimiento industrial.

Sin embargo, la interpretabilidad de estos modelos sigue siendo un desafío. Para abordar esta limitación, se han desarrollado metodologías como LIME, SHAP y los gráficos ICE y PDP, que permiten una mayor comprensión de las predicciones realizadas por los modelos de IA. Esto es fundamental para fomentar la confianza en estas tecnologías y facilitar su adopción en entornos industriales.

De manera que, se puede afirmar que la Inteligencia Artificial ha transformado el monitoreado de condición, ofreciendo soluciones más precisas, adaptables y eficientes. No obstante, su implementación debe ir acompañada de un análisis crítico que permita validar su eficacia y optimizar su aplicación en función de las características específicas de cada sistema industrial. La investigación en este campo continuará evolucionando, impulsando nuevas mejoras en la fiabilidad y sostenibilidad de los procesos industriales.

La Inteligencia Artificial (IA) ha transformado el monitoreado de condición y el mantenimiento predictivo, mejorando la detección temprana de fallos en máquinas rotatorias con mayor precisión y eficiencia. Los algoritmos de aprendizaje automático, como los árboles de decisión (DT), las máquinas de soporte vectorial (SVM) y las redes neuronales (NN), han optimizado la clasificación de condiciones normales y anormales, reduciendo costos y tiempos de inactividad.

Dentro del aprendizaje profundo (Deep Learning), las redes neuronales convolucionales (CNN) y las redes de memoria a corto y largo plazo (LSTM) han demostrado ser herramientas clave para el análisis de vibraciones. Mientras que las CNN destacan en la extracción de características a partir de grandes volúmenes de datos, las LSTM son especialmente útiles para identificar patrones temporales en señales de vibraciones, permitiendo predicciones más precisas sobre comportamientos futuros.

El uso de modelos híbridos ha mejorado aún más la precisión en el diagnóstico de fallas. La combinación de CNN con algoritmos como el Bosque Aleatorio (RF) ha mostrado resultados superiores, permitiendo la extracción automática de características y el uso de aprendizaje conjunto para una mejor generalización del sistema de diagnóstico. Además, la integración de principios físicos en modelos de IA ha mejorado la interpretabilidad y confiabilidad de las predicciones.

Uno de los principales obstáculos para la adopción de la IA en el monitoreado de condición ha sido la carencia de interpretabilidad de los modelos, problema este que se ha abordado con técnicas como LIME, SHAP y gráficos PDP e ICE. Estas herramientas han permitido una mejor comprensión de las decisiones de los algoritmos, aumentando la confianza en su implementación en entornos industriales.

Finalmente, el uso de técnicas avanzadas como las redes generativas antagónicas (GAN) ha permitido mejorar la detección de fallas en escenarios con datos limitados, resolviendo problemas de desbalance en las muestras y aumentando la fortaleza de los modelos. A su vez, el deep learning aplicado al monitoreado acústico ha ampliado las capacidades de diagnóstico, permitiendo detectar grietas internas en componentes críticos.

En síntesis, la integración de IA en el monitoreado de condición ha demostrado ser una estrategia altamente efectiva para mejorar la confiabilidad y eficiencia operativa en la industria. El desarrollo de modelos cada vez más precisos y explicables permitirá su adopción masiva, optimizando las estrategias de mantenimiento y prolongando la vida útil de los equipos industriales.

Conclusiones

Como resultado de la revisión de las tendencias y aplicaciones de la Inteligencia Artificial en el monitoreado de condición de máquinas rotatorias, con un enfoque particular en el análisis de vibraciones, se han obtenido respuestas fundamentadas a las preguntas científicas planteadas.

Se confirma que el análisis de vibraciones es el método más confiable y rentable para el monitoreado de condición de máquinas rotatorias, permitiendo la detección temprana de fallas a través de diversas técnicas. La

selección y correcto montaje de los transductores, especialmente los acelerómetros piezoeléctricos, son factores determinantes en la calidad de las mediciones. Se ha evidenciado la relevancia de analizar las señales en los dominios del tiempo, frecuencia y tiempo-frecuencia, mediante herramientas como la Transformada Rápida de Fourier (FFT), el análisis de *Cepstrum*, la Transformada *Wavelet* y la Transformada de *Hilbert-Huang*, las cuales permiten detectar fallos específicos como desbalances, desalineaciones y defectos en cojinetes de rodamientos. Adicionalmente, el análisis de datos en tiempo real, soportado por técnicas estadísticas y de minería de datos, facilita el monitoreado continuo y la detección más precisa de anomalías operativas.

La Inteligencia Artificial ha mejorado sensiblemente los resultados del monitoreado de condición mediante la integración de algoritmos de *Machine learning* y *Deep learning*. Las redes neuronales convolucionales (CNN) y las redes de memoria a corto y largo plazo (LSTM) han demostrado ser herramientas clave para la clasificación y predicción de fallos en máquinas rotatorias, al extraer patrones complejos de las señales de vibraciones. Modelos híbridos que combinan CNN con algoritmos como *Random Forest* han mejorado significativamente la precisión en el diagnóstico, incluso en entornos con variaciones operativas. Además, el uso de los *autoencoders* y redes generativas antagónicas (GAN) ha permitido abordar problemas como la escasez de datos sobre las fallas, mejorando la confiabilidad del diagnóstico. Finalmente, la implementación de metodologías de interpretabilidad como LIME, SHAP e ICE contribuye a una mayor transparencia en los modelos de IA, facilitando su adopción en la industria.

En síntesis, la revisión realizada confirma que la combinación de técnicas tradicionales y emergentes en el análisis de vibraciones, junto con la integración de la Inteligencia Artificial, representa un avance significativo en la optimización del mantenimiento predictivo lo cual satisface el objetivo propuesto. La continua evolución de estas tecnologías fortalecerá la gestión de la confiabilidad en los sistemas industriales, permitiendo una mayor precisión en la detección temprana de fallas y una reducción en los costos de operación y mantenimiento.

Referencias

1. Tiboni M, Remino C, Bussola R, Amici C. A review on vibration-based condition monitoring of rotating machinery. *Applied Sciences*. 2022;12(3):972. <http://doi.org/10.3390/app12030972>
2. Mousavi SA, Taghipour M. Turbine vibration condition monitoring in region 3. *Mechanical Engineering Advances*. 2023;1(1). <http://doi.org/10.59400/mea.v1i1.219>
3. Moghadam FK, Nejad AR. Online condition monitoring of floating wind turbines drivetrain by means of digital twin. *Mechanical Systems and Signal Processing*. 2022;162:108087. <http://doi.org/10.1016/j.ymssp.2021.108087>
4. Niu D, Guo L, Zhao W, Li H. Operation performance evaluation of elevators based on condition monitoring and combination weighting method. *Measurement*. 2022;194:111091. <http://doi.org/10.1016/j.measurement.2022.111091>
5. Nithin S, Hemanth K, Shamanth V, Mahale RS, Sharath P, Patil A. Importance of condition monitoring in mechanical domain. *Materials Today: Proceedings*. 2022;54:234-9. <https://doi.org/10.1016/j.matpr.2021.08.299>
6. Khadersab A, Shivakumar S. Vibration Analysis Techniques for Rotating Machinery and its effect on Bearing Faults. *Procedia Manufacturing*. 2018;20:247-52. <http://doi.org/10.1016/j.promfg.2018.02.036>
7. Martin M, Chong A, Biljecki F, Miller C. Infrared thermography in the built environment: A multi-scale review. *Renewable and sustainable energy reviews*. 2022;165:112540. <http://doi.org/10.1016/j.rser.2022.112540>
8. Bagavathiappan S, Lahiri BB, Saravanan T, Philip J, Jayakumar T. Infrared thermography for condition monitoring – A review. *Infrared Physics & Technology*. 2013;60:35-55. <http://doi.org/10.1016/j.infrared.2013.03.006>
9. Zhao J, Wang D, Zhang F, Liu Y, Chen B, Wang ZL, et al. Real-time and online lubricating oil condition monitoring enabled by triboelectric nanogenerator. *ACS nano*. 2021;15(7):11869-79. <http://doi.org/10.1021/acsnano.1c02980>
10. Sun J, Wang L, Li J, Li F, Li J, Lu H. Online oil debris monitoring of rotating machinery: A detailed review of more than three decades. *Mechanical Systems and Signal Processing*. 2021;149:107341. <http://doi.org/10.1016/j.ymssp.2020.107341>
11. Yu Y, Safari A, Niu X, Drinkwater B, Horoshenkov KV. Acoustic and ultrasonic techniques for defect detection and condition monitoring in water and sewerage pipes: A review. *Applied Acoustics*. 2021;183:108282. <http://doi.org/10.1016/j.apacoust.2021.108282>
12. Iliyas Ahmad M, Yusof Y, Daud ME, Latiff K, Abdul Kadir AZ, Saif Y. Machine monitoring system: a decade in review. *The International Journal of Advanced Manufacturing Technology*. 2020;108(11):3645-59. <http://doi.org/10.1007/s00170-020-05620-3>
13. Riaboff L, Shalloo L, Smeaton AF, Couvreur S, Madouasse A, Keane MT. Predicting livestock behaviour using accelerometers: A systematic review of processing techniques for ruminant behaviour prediction from raw accelerometer data. *Computers and Electronics in Agriculture*. 2022;192:106610. <http://doi.org/10.1016/j.compag.2021.106610>
14. Xu Y, Liu J, Wan Z, Zhang D, Jiang D. Rotor fault diagnosis using domain-adversarial neural network with time-frequency analysis. *Machines*. 2022;10(8):610. <http://doi.org/10.3390/machines10080610>
15. Zhou H, Huang X, Wen G, Lei Z, Dong S, Zhang P, et al. Construction of health indicators for condition monitoring of rotating machinery: A review of the research. *Expert Systems with Applications*. 2022;203:117297. <http://doi.org/10.1016/j.eswa.2022.117297>
16. Guo T, Zhang T, Lim E, Lopez-Benitez M, Ma F, Yu L. A review of wavelet analysis and its applications: Challenges and opportunities. *IEEE Access*. 2022;10:58869-903. <http://doi.org/10.1109/ACCESS.2022.3179517>
17. Xin G, Li Z, Jia L, Zhong Q, Dong H, Hamzaoui N, et al. Fault diagnosis of wheelset bearings in high-speed trains using logarithmic short-time Fourier transform and modified self-calibrated residual network. *IEEE Transactions on Industrial Informatics*. 2021;18(10):7285-95. <http://doi.org/10.1109/TII.2021.3136144>
18. Diao Y, Jia D, Liu G, Sun Z, Xu J. Structural damage identification using modified Hilbert–Huang transform and support vector machine. *Journal of Civil Structural Health Monitoring*. 2021;11:1155-74. <http://doi.org/10.1007/s13349-021-00509-5>
19. Poddar S, Tandon N. Detection of particle contamination in journal bearing using acoustic emission and vibration monitoring techniques. *Tribology International*. 2019;134:154-64. <http://doi.org/10.1016/j.triboint.2019.01.050>
20. Binali R, Demirpolat H, Kuntoğlu M, Makhesana M, Yaghoubi S, Sayin Kul B. A Comprehensive Review on Low-Cost MEMS Accelerometers for Vibration Measurement: Types, Novel Designs, Performance Evaluation, and Applications. *Journal of Molecular & Engineering Materials*. 2024;12(3). <http://doi.org/10.1142/S225123732430002X>

21. Clevenger KA, Montoye AH. Systematic review of Accelerometer Responsiveness to change for measuring physical activity, sedentary behavior, or Sleep. *Journal for the Measurement of Physical Behaviour*. 2023;6(4):250-63. <http://doi.org/10.1123/jmpb.2023-0025>
22. Romanssini M, de Aguirre PCC, Compassi-Severo L, Girardi AG. A review on vibration monitoring techniques for predictive maintenance of rotating machinery. *Eng*. 2023;4(3):1797-817. <http://doi.org/10.3390/eng4030102>
23. Fahmi A-TWK, Kashyzadeh KR, Ghorbani S. A comprehensive review on mechanical failures cause vibration in the gas turbine of combined cycle power plants. *Engineering Failure Analysis*. 2022;134:106094. <http://doi.org/10.1016/j.engfailanal.2022.106094>
24. Mohd Ghazali MH, Rahiman W. Vibration analysis for machine monitoring and diagnosis: a systematic review. *Shock and Vibration*. 2021;2021(1):9469318. <http://doi.org/10.1155/2021/9469318>
25. de la Torre Silva FA, Palomino Marín E, Díaz Concepción A, Alfonso Álvarez A, Guillen García J, García Toll AE. Modelado de datos para análisis conjunto de variables síntomas en turbinas a vapor 100 MW. *Ingeniería Mecánica*. 2024;27(2):e696.
26. Manhertz G, Bereczky A. STFT spectrogram based hybrid evaluation method for rotating machine transient vibration analysis. *Mechanical Systems and Signal Processing*. 2021;154:107583. <http://doi.org/10.1016/j.ymssp.2020.107583>
27. Zhang X, Rane KP, Kakaravada I, Shabaz M. Research on vibration monitoring and fault diagnosis of rotating machinery based on internet of things technology. *Nonlinear Engineering*. 2021;10(1):245-54. <http://doi.org/10.1515/nleng-2021-0019>
28. Feng K, Ji J, Ni Q, Beer M. A review of vibration-based gear wear monitoring and prediction techniques. *Mechanical Systems and Signal Processing*. 2023;182:109605. <http://doi.org/10.1016/j.ymssp.2022.109605>
29. Althubaiti A, Elasha F, Teixeira JA. Fault diagnosis and health management of bearings in rotating equipment based on vibration analysis—a review. *Journal of Vibroengineering*. 2022;24(1):46-74. <http://doi.org/10.21595/jve.2021.22100>
30. Popescu TD, Aiordachioaie D, Culea-Florescu A. Basic tools for vibration analysis with applications to predictive maintenance of rotating machines: an overview. *The International Journal of Advanced Manufacturing Technology*. 2022;1-17. <http://doi.org/10.1007/s00170-021-07703-1>
31. Pacheco-Chérrez J, Cárdenas D, Probst O. Experimental detection and measurement of crack-type damage features in composite thin-wall beams using modal analysis. *Sensors*. 2021;21(23):8102. <http://doi.org/10.3390/s21238102>
32. Yang R, Zhang Z, Chen Y. Analysis of vibration signals for a ball bearing-rotor system with raceway local defects and rotor eccentricity. *Mechanism and Machine Theory*. 2022;169:104594. <http://doi.org/10.1016/j.mechmachtheory.2021.104594>
33. Afshari SS, Enayatollahi F, Xu X, Liang X. Machine learning-based methods in structural reliability analysis: A review. *Reliability Engineering & System Safety*. 2022;219:108223. <http://doi.org/10.1016/j.ress.2021.108223>
34. Roy A, Chakraborty S. Support vector machine in structural reliability analysis: A review. *Reliability Engineering & System Safety*. 2023;233:109126. <http://doi.org/10.1016/j.ress.2023.109126>
35. Bang J-S, Lee M-H, Fazli S, Guan C, Lee S-W. Spatio-spectral feature representation for motor imagery classification using convolutional neural networks. *IEEE Transactions on Neural Networks and Learning Systems*. 2021;33(7):3038-49. <http://doi.org/10.1109/TNNLS.2020.3048385>
36. Sony S, Dunphy K, Sadhu A, Capretz M. A systematic review of convolutional neural network-based structural condition assessment techniques. *Engineering Structures*. 2021;226:111347. <http://doi.org/10.1016/j.engstruct.2020.111347>
37. Li S, Li S, Laima S, Li H. Data-driven modeling of bridge buffeting in the time domain using long short-term memory network based on structural health monitoring. *Structural Control and Health Monitoring*. 2021;28(8):e2772. <http://doi.org/10.1002/stc.2772>
38. Ye Z, Yu J. Health condition monitoring of machines based on long short-term memory convolutional autoencoder. *Applied Soft Computing*. 2021;107:107379. <http://doi.org/10.1016/j.asoc.2021.107379>
39. Gaunkar S, Kotalwar A, Gabale S. Predictive maintenance of industrial machines using machine learning. *International Research Journal of Engineering and Technology*. 2021;8(11).
40. Yaghoubi V, Cheng L, Van Paepegem W, Keremans M. Vibration-Based Condition Monitoring By Ensemble Deep Learning. *IEEE Transactions on Instrumentation and Measurement*. 2022;71. <http://doi.org/10.48550/arXiv.2110.06601>
41. Wu Y, Sicard B, Gadsden SA. A review of physics-informed machine learning methods with applications to condition monitoring and anomaly detection. *arXiv preprint arXiv:240111860*. 2024. <http://doi.org/10.48550/arXiv.2401.11860>
42. Ahang M, Abbasi M, Charter T, Najjaran H. Condition Monitoring with Incomplete Data: An Integrated Variational Autoencoder and Distance Metric Framework. *arXiv preprint arXiv:240405891*. 2024. <http://doi.org/10.48550/arXiv.2404.05891>
43. Goodarzi P, Schütze A, Schneider T. Comparing AutoML and Deep Learning Methods for Condition Monitoring using Realistic Validation Scenarios. *IEEE Transactions on Industrial Informatics*. 2023;20(6). <http://doi.org/10.48550/arXiv.2308.14632>
44. Guerti N, Khoualdia T, Khoualdia Z, editors. A Reliable Neural Network Approach for Monitoring and Diagnosing Bearing Faults in Induction Motors. 2023 International Conference on Decision Aid Sciences and Applications (DASA). 2023. <http://doi.org/10.1109/DASA59624.2023.10286761>
45. Bangalore P, Letzgus S, Karlsson D, Patriksson M. An artificial neural network-based condition monitoring method for wind turbines, with application to the monitoring of the gearbox. *Wind Energy*. 2017;20(8):1421-38. <http://doi.org/10.1002/we.2102>
46. Apeiranthitis S, Zacharia P, Chatzopoulos A, Papoutsidakis M. Predictive Maintenance of Machinery with Rotating Parts Using Convolutional Neural Networks. *Electronics*. 2024; 13(2). <http://doi.org/10.3390/electronics13020460>
47. Xu G, Liu M, Jiang Z, Söffker D, Shen W. Bearing fault diagnosis method based on deep convolutional neural network and random forest ensemble learning. *Sensors*. 2019;19(5):1088. <http://doi.org/10.3390/s19051088>
48. Jenab K, Rashidi K, Moslehpour S. An intelligence-based model for condition monitoring using artificial neural networks. *International Journal of Enterprise Information Systems (IJEIS)*. 2013;9(4):43-62. <http://doi.org/10.4018/ijeis.2013100104>
49. Fu Q, Wang H. A novel deep learning system with data augmentation for machine fault diagnosis from vibration signals. *Applied Sciences*. 2020;10(17):5765. <http://doi.org/10.3390/app10175765>
50. Goodarzi P, Robin Y, Schütze A, Schneider T. Deep convolutional neural networks for cyclic sensor data. *IEEE Transactions on Instrumentation and Measurement*. 2024;73. <http://doi.org/10.48550/arXiv.2308.06987>
51. Michau G, Hu Y, Palmé T, Fink O. Feature learning for fault detection in high-dimensional condition monitoring signals. *Proceedings of the Institution of Mechanical Engineers, Part O: Journal of Risk and Reliability*. 2020;234(1):104-15. <http://doi.org/10.1177/1748006X19868335>
52. Gawde S, Patil S, Kumar S, Kamat P, Kotecha K, Alfaro S. Explainable Predictive Maintenance of Rotating Machines Using LIME, SHAP, PDP, ICE. *IEEE Access*. 2024;12:29345-61. <http://doi.org/10.1109/ACCESS.2024.3367110>

Editor:

Alberto Julio Rodríguez Piñeiro.

Universidad Tecnológica de La Habana José Antonio Echeverría

Conflicto de intereses

Los autores declaran que no existen conflictos de intereses

Contribución de los autores**Glenda Gutierrez García.**

Definir los objetivos de la revisión, selección de las bases de datos, establecimiento de la estrategia de búsqueda, realizar la búsqueda de la bibliografía, selección de los documentos a utilizar. Organización de la información seleccionada. Diseño del guión. Organización y discusión del contenido sobre Monitoreado de condición basado en el análisis de vibraciones. Organización y discusión del contenido sobre Inteligencia Artificial y monitoreado de condición. Participó en la revisión crítica de su contenido, redacción y aprobación del trabajo final.

Ailyn Naranjo Navarro.

Definir los objetivos de la revisión, selección de las bases de datos, establecimiento de la estrategia de búsqueda, realizar la búsqueda de la bibliografía, selección de los documentos a utilizar. Organización de la información seleccionada. Diseño del guión. Organización y discusión del contenido sobre Monitoreado de condición basado en el análisis de vibraciones. Organización y discusión del contenido sobre Inteligencia Artificial y monitoreado de condición. Trabajó en la revisión crítica de su contenido, redacción y aprobación del trabajo final.

Evelio Palomino Marín.

Definir los objetivos de la revisión, selección de las bases de datos, establecimiento de la estrategia de búsqueda, realizar la búsqueda de la bibliografía, selección de los documentos a utilizar. Organización de la información seleccionada. Diseño del guión. Organización y discusión del contenido sobre Monitoreado de condición basado en el análisis de vibraciones. Organización y discusión del contenido sobre Inteligencia Artificial y monitoreado de condición. También participó en la revisión crítica de su contenido, redacción y aprobación del trabajo final.