



**Relación de variables externas y datos técnicos de diagnóstico de máquinas
en empresas que contratan servicios de mantenimiento predictivo.**

Autor: Jhonatan Mejía Bañol

Universidad Ean

Facultad de Ingeniería

Maestría en Inteligencia de Negocios

Bogotá, Colombia

Marzo de 2026

**Relación de variables externas y datos técnicos de diagnóstico de máquinas en
empresas que contratan servicios de mantenimiento predictivo.**

Autor: Jhonatan Mejía Bañol

Trabajo de grado presentado como requisito para optar al título de:

Magister en Inteligencia de Negocios

Directores:

Paula Echeverry Pérez; Miguel Ángel Zuñiga Gutiérrez

Modalidad:

Artículo de Investigación de la misión académica internacional a china 2025

Universidad Ean

Facultad de Ingeniería

Maestría en Inteligencia de Negocios

Bogotá, Colombia

Marzo 2026

Nota de aceptación:

Firma del jurado

Firma del jurado

Firma del director del trabajo de grado

Bogotá, día/mes/año

Dedicatoria:

A mi familia, a mis socios y amigos, todos
han creído en mí siempre.

Agradecimientos

A los miembros de la junta directiva de A-MAQ S.A., Alejandro Morales Ortiz, Carolina Soto, Natalia Villa, Paula Andrea Isaza, Juan Carlos Valencia y Nicolás González, que me han ayudado a crecer como directivo y me han enseñado un camino en el que cada día me retan a ser mejor líder. A mis socios , compañeros y amigos de A-MAQ S.A., Andrés Ballesteros, Johnatan Castañeda, Andrés Felipe González Elorza, Andrés Guzmán Hincapié y Luis Guillermo Valencia Calderón, porque depositaron su confianza y creyeron en el proyecto planteado para nuestra compañía. Finalmente a la Universidad EAN, por facilitar la misión académica internacional a China 2025, en la cual pude entender la manera de actuar, cultura, políticas y en general la forma en la que una gran superpotencia llega a ser altamente productiva y capaz de cumplir las metas que se traza.

Resumen

Este artículo analiza la influencia de variables externas sobre el comportamiento de máquinas rotativas en una planta de manufactura de empaques que contrata servicios de mantenimiento predictivo. Para ello, se integraron cuatro años de registros de condición vibracional y diagnóstico técnico de 413 máquinas (3708 mediciones en 157 días) con series de temperatura ambiente y del entorno productivo sectorial. La investigación adopta un enfoque cuantitativo, longitudinal y correlacional, e incluye técnicas de imputación de datos mediante Random Forest y modelos de regresión logística para estimar la probabilidad de estados anómalos. Los resultados muestran que la temperatura ambiente y el nivel de actividad industrial se asocian de manera significativa con la prevalencia de diagnósticos de pronta atención y urgencia, evidenciando que las condiciones externas modulan el riesgo operativo de los activos. A partir de estos hallazgos, se propone un sistema de indicadores exógenos e internos y un diseño de tablero de control en Power BI que permite formular recomendaciones prescriptivas sobre programación de turnos y priorización de mantenimiento. El estudio aporta evidencia empírica de campo sobre el valor de integrar variables externas y datos técnicos de diagnóstico en la toma de decisiones de mantenimiento predictivo en la industria de empaques.

Palabras clave: Mantenimiento predictivo; máquinas rotativas; vibración; variables externas; temperatura ambiente; riesgo operativo; manufactura de empaques; inteligencia de negocios.

Abstract

This article analyzes the influence of external variables on the behavior of rotating machinery in a packaging manufacturing plant that contracts predictive maintenance services. To this end, four years of condition monitoring and diagnostic records from 413 machines (3708 measurements across 157 days) were integrated with ambient temperature and sectoral production time series. The study follows a quantitative, longitudinal, correlational design and incorporates data imputation using Random Forest and logistic regression models to estimate the probability of anomalous machine states. The results show that ambient temperature and industrial activity levels are significantly associated with the prevalence of warning and urgent diagnoses, indicating that external conditions modulate the operational risk of assets. Based on these findings, the paper proposes a system of exogenous and internal indicators, together with a Power BI dashboard design, to support prescriptive recommendations for shift scheduling and maintenance prioritization. The study provides field-based empirical evidence of the value of integrating external variables and technical diagnostic data into predictive maintenance decision-making in the packaging manufacturing industry.

Keywords: Predictive maintenance; rotating machinery; vibration; external variables; ambient temperature; operational risk; packaging manufacturing; business intelligence.

Introducción

Desde el nacimiento de los procesos productivos en masa, las compañías de producción de bienes han implementado herramientas de planificación, gestión y optimización de la producción, es así como la tecnología, ha facilitado a través de los años, herramientas para realizar estos procesos productivos de una manera cada vez más rápida. La revolución industrial, introdujo máquinas en las líneas de producción, que potenciaron aún más esta labor principalmente en la industria textil y metalúrgica (Agarwal & Agarwal, 2017). En la actualidad, este enfoque de optimización de la producción trae consigo la necesidad de una búsqueda constante de metodologías, procesos y herramientas, que potencien y mejoren continuamente el desempeño de los activos que realizan los procesos de producción en estas empresas.

Uno de los pilares fundamentales de la gestión y la optimización de los sistemas de producción de bienes, es el mantenimiento de las máquinas que realizan trabajos repetitivos en las líneas de producción, este mantenimiento puede ser de cinco tipos: Correctivo, el cual se enfoca en reemplazar piezas y máquinas que presentaron una falla evidente y perdieron su capacidad de seguir operando en la línea de producción. Preventivo, que plantea una estrategia proactiva de reemplazo periódico de piezas y acciones de prevención en las máquinas, con el fin de prevenir precisamente que puedan llegar a presentar un fallo que las inhabilite. Basado en condición (CBM, por sus siglas en inglés Condition-Based Maintenance), con el cual se automatizan las labores de inspección por medio de sensores, capaces de medir el comportamiento actual de las máquinas, con el fin de determinar su condición y para la planeación de labores de mantenimiento. Predictivo, el cual se basa en el CBM y promueve el uso de datos de

operación, para el comportamiento de los activos y así definir las mejores prácticas y acciones necesarias que deben realizarse sobre las máquinas para evitar fallos repentinos. Prescriptivo, cuyo paradigma más avanzado, pretende establecer acciones anticipadas para abordar los modos de falla de las máquinas, con el fin de anticiparse aún más a su comportamiento. Este último, requiere que las técnicas predictivas y de CBM se encuentren bien consolidadas. (Nunes et al., 2023)

Así pues, el mantenimiento predictivo se vale de herramientas como equipos electrónicos y software enfocados a la recolección de datos, para presentar información y gráficos en los que personas expertas, por lo general ingenieros en el campo de la mecánica, la electrónica, la electricidad o la instrumentación y control, puedan hacer lectura de patrones que lleven a hipótesis del estado de las máquinas, hipótesis que generen un sustento técnico y teórico para proponer una acción que de llevarse a cabo, evite que el activo entre en una condición crítica o catastrófica que le impida seguir operando.

Entre las técnicas predictivas utilizadas en la industria se encuentran el análisis de vibraciones, la termografía infrarroja, el ultrasonido pasivo, el análisis de corriente de motores (MCSA) y el análisis de aceite (Olarte et al., 2010). El presente estudio se concentra en el análisis de vibraciones como principal fuente de diagnóstico, dado que es la técnica con mayor cobertura y profundidad de registros en la base de datos histórica de la compañía A-MAQ S.A, prestadora de servicios predictivos colaboradora de este estudio.

Existen otras técnicas empleadas para la implementación de programas de mantenimiento predictivo en empresas de producción de bienes, como técnicas de análisis acústico, análisis de partículas, análisis de la corrosión, o análisis del rendimiento operativo, el cual combina uno o más métodos de los mencionados (Coandă et al., 2020).

En este sentido, existen empresas que prestan servicios de aplicación de técnicas predictivas, a empresas de producción de bienes que cuentan con máquinas rotativas impulsadas por motores eléctricos para ejecutar sus procesos de manufactura, como lo es A-MAQ S.A.

Por otra parte, con el aumento de la disponibilidad de datos que experimentamos en la actualidad, así como el incremento en el nivel de uso y experiencia de usuario de herramientas para su exploración y tratamiento, los procesos de inteligencia de negocios han incrementado su protagonismo en el escenario de toma de decisiones de las compañías, entendiendo la inteligencia de negocios como una *“evolución a los sistemas de soporte a las decisiones”*, o definido en un contexto moderno como *“el conjunto de metodologías, aplicaciones, prácticas y capacidades enfocadas a la creación y administración de información que permite tomar mejores decisiones a los usuarios de una organización”* (Curto Diaz, 2016), esto con el fin de aprovechar los datos disponibles, para obtener información de valor que le permita tomar las mejores decisiones de negocio posibles, a través de su recolección, centralización, tratamiento y despliegue.

Una de las etapas relevantes dentro del proceso de inteligencia de negocios, es la recolección, estandarización y centralización de los datos, llamado también “Data warehousing”, al ser el repositorio de información (Curto Diaz, 2016), el almacén de datos permite que etapas posteriores del proceso de BI, puedan hacer uso y tratamiento de los datos, para presentar información de valor para el negocio, con la cual, la alta gerencia pueda tomar decisiones estratégicas que permitan el cumplimiento de los objetivos de la organización, esto es lo que llamamos “Data Driven Decisions”.

La integración de las técnicas de mantenimiento predictivo, y los procesos de inteligencia de negocios, es una práctica que viene siendo adoptada cada vez más en aquellas empresas que más provecho sacan de sus datos operativos, debido a que

ambos procesos, promueven un enfoque de toma de decisiones acertadas, agilidad y eficiencia operativa a través de la adopción de herramientas como Power BI para el manejo de grandes conjuntos de datos, integración con modelos de aprendizaje automático, alertas en tiempo, real, entre otros factores que permiten visualizar de manera interactiva, los resultados del mantenimiento predictivo o la identificación de patrones, con el fin de optimizar las operaciones de mantenimiento (Nagarajan & Tayong, n.d.).

El contexto de la metodología actual de la aplicación de técnicas predictivas y su posibilidad de integración con una gestión holística de la inteligencia de negocios en empresas de manufactura nos lleva a la pregunta: ¿Cómo se relacionan las variables externas con la condición de máquinas rotativas impulsadas por motores eléctricos en una planta de manufactura de empaques que contrata servicios de mantenimiento predictivo?

Con base en lo anterior, el objetivo general de esta investigación es analizar la relación entre variables externas seleccionadas y los datos técnicos de diagnóstico de máquinas rotativas en una planta de manufactura de empaques, con el fin de apoyar la toma de decisiones de mantenimiento predictivo mediante un sistema de indicadores e inteligencia de negocios.

En la planta de manufactura de empaques objeto de este estudio, el programa de mantenimiento predictivo opera actualmente bajo un modelo centrado exclusivamente en datos operativos de los activos (vibraciones, temperaturas de componentes, corrientes). Esta aproximación, aunque valiosa, no incorpora información contextual sobre las condiciones ambientales ni sobre el estado económico o productivo del sector, las cuales pueden modular la degradación de los componentes rotativos. La ausencia de esta capa

contextual limita la capacidad de anticipación del programa de mantenimiento y constituye el problema que motiva la presente investigación.

De este objetivo general se derivan cuatro objetivos específicos: 1) caracterizar el proceso de adquisición y diagnóstico de datos técnicos de máquinas impulsadas por motores eléctricos en una empresa de servicios predictivos en Colombia; 2) identificar las variables externas con mayor capacidad explicativa sobre la condición de los activos de una planta de manufactura de empaques mediante juicio de expertos y análisis estadístico; 3) desarrollar un modelo que permita integrar las variables exógenas identificadas con las variables operativas para enriquecer el diagnóstico predictivo de máquinas; y 4) proponer un sistema de indicadores integrados y un tablero de control que articule las variables técnicas y externas validadas para la toma de decisiones prescriptivas.

Como camino para el logro de los objetivos propuestos en esta investigación, se trabajaron las siguientes hipótesis de investigación:

H1 — Las variables externas ambientales (temperatura ambiente) y macroeconómicas sectoriales (Índice de Producción Industrial del sector caucho y plástico) presentan una asociación estadísticamente significativa con el estado de condición de las máquinas rotativas monitoreadas bajo un programa de mantenimiento predictivo.

H0 (Nula) — No existe asociación estadísticamente significativa entre las variables externas consideradas y el estado de condición de las máquinas rotativas.

La contrastación de estas hipótesis se presenta en la sección de resultados, a partir de pruebas de correlación, comparación de medias y regresión logística aplicadas al dataset integrado.

Marco teórico

Evolución del mantenimiento industrial

El mantenimiento industrial ha evolucionado de manera significativa en las últimas décadas, impulsado por el avance de las tecnologías de la información, la automatización y la transformación digital. Tradicionalmente, el mantenimiento se concebía como una actividad reactiva o correctiva, ejecutada solo cuando una máquina fallaba.

Posteriormente, se adoptaron estrategias preventivas que, aunque más eficientes, requerían paradas programadas sin un diagnóstico profundo del estado del activo.

El auge de la Industria 4.0, ha estado caracterizado por la conectividad, el uso intensivo de datos, nuevos dispositivos, la reducción de inventario, la personalización y la producción controlada. En este contexto, el mantenimiento predictivo (PdM por sus siglas en inglés Predictive Maintenance) emerge como un concepto clave para la manufactura y los sistemas de producción sostenibles, introduciendo una versión digital del mantenimiento de máquinas. El incremento exponencial de datos extraídos de los procesos de producción, gracias a la proliferación de tecnologías de sensores, impulsa la aplicación del PdM. A pesar de los desafíos organizacionales, financieros, de fuentes de datos y de reparación de máquinas que enfrenta el Mantenimiento 4.0, este se presenta como un punto fuerte para las empresas que lo adoptan, permitiendo minimizar el tiempo de inactividad de las máquinas y los costos asociados, maximizar su ciclo de vida y mejorar la calidad y el ritmo de la producción. El PdM se caracteriza generalmente por un flujo de trabajo preciso que comienza con la comprensión del proyecto y la recopilación de datos, y finaliza con la fase de toma de decisiones. En este sentido, el PdM ofrece métodos como el Mantenimiento Basado en Condición (CBM), la Gestión de la Salud y el

Pronóstico (PHM: Prognosis and Health Management) y la Estimación de la Vida Útil Restante (RUL: Remaining Useful life) (Achouch et al., 2022).

Diversos estudios como el de Ahmed et al. (2020) destacan cómo el mantenimiento ha pasado de ser una función de soporte a convertirse en una actividad estratégica que influye directamente en la competitividad empresarial. Las organizaciones modernas entienden que el buen funcionamiento de los activos no solo impacta la eficiencia operativa, sino también los costos, la calidad del producto y la satisfacción del cliente.

Es importante resaltar, que entre los métodos que han surgido en la evolución del mantenimiento, se han desarrollado modelos como el de la vida útil resultante, que se define como el período de tiempo que un equipo probablemente operará antes de necesitar reparación o reemplazo, pudiendo representarse en días, millas, ciclos, etc. La predicción de la vida útil proporciona alertas tempranas de fallas y es un componente clave del pronóstico y la gestión de la salud de los sistemas. La estimación del RUL es un desafío, y existen dos tipos principales de métodos para predecir la vida útil del equipo: métodos basados en la física y métodos basados en datos. Los métodos basados en datos exploran la relación potencial entre los datos de los sensores monitoreados y su valor de RUL basándose en datos históricos. En la investigación, ha habido interés en el uso de estimaciones de vida útil restante en las industrias. Existen ejemplos del uso de redes neuronales convolucionales (CNN: Convolutional Neural Networks) y regresión bayesiana jerárquica, así como redes de memoria a corto plazo (LSTM: Long Short-Term Memory) para la predicción (Achouch et al., 2022).

Técnicas de mantenimiento predictivo

Las técnicas de mantenimiento predictivo (PdM) buscan predecir el estado de salud de una máquina basándose en análisis repetidos o características conocidas, permitiendo

realizar el mantenimiento justo antes de que se espere una falla. Por lo tanto, el mantenimiento predictivo es un tipo de mantenimiento basado en condición (CBM) en el que se predice el comportamiento futuro basándose en indicadores actuales e históricos. La aplicación de estas técnicas lleva a una reducción tanto del tiempo de inactividad planificado como del no planificado (Molęda et al., 2023).

Entre las técnicas convencionales de mantenimiento predictivo comúnmente utilizadas se encuentran las siguientes:

- **Monitoreo de vibraciones:** Esta técnica se aplica a toda la maquinaria rotativa y se utiliza ampliamente para funciones de diagnóstico, monitoreo de condición y predicción. Las técnicas predictivas involucran el análisis de tendencias en los niveles de vibración, particularmente en rangos de frecuencia o el análisis del perfil de la señal. El análisis de tendencias se utiliza para determinar la vida útil restante y para evaluar el deterioro de los componentes. El análisis del perfil de la señal brinda la posibilidad de detectar y clasificar eventos no deseados, como fugas o pérdida de material. En el contexto del mantenimiento predictivo, el análisis de vibraciones se ha consolidado como una de las técnicas más efectivas para la detección temprana de fallas en maquinaria rotativa, al permitir identificar desequilibrios, desalineamientos y otros defectos a partir del análisis de la señal en el dominio del tiempo y la frecuencia. (MANDI, 2025; Molęda et al., 2023; Tenali et al., 2017).
- **Termografía:** Esta técnica se utiliza para predecir y diagnosticar la condición de equipos y sistemas basándose en mediciones de temperatura. La instrumentación avanzada permite monitorear las emisiones infrarrojas utilizando cámaras termográficas, termómetros infrarrojos o escáneres de línea. El análisis de los resultados obtenidos (temperatura, sus variaciones y distribución) permite determinar la condición del dispositivo y detectar posibles anomalías. En la práctica, la

- termografía se puede utilizar como un método no destructivo para detectar la reducción del grosor de las paredes causada por la corrosión y la erosión por flujo en tuberías de presión de alta temperatura y para determinar la pérdida de material en los tubos de la pared de agua de la caldera. También se aplica para diagnosticar equipos eléctricos, detectar fugas de aceite y detectar fallas en parques fotovoltaicos (FV). La termografía infrarroja se reconoce como una técnica de ensayo no destructivo para el monitoreo de condición, capaz de obtener imágenes térmicas de componentes en operación y detectar anomalías de temperatura asociadas a fallas incipientes en equipos eléctricos y mecánicos, lo que la hace especialmente adecuada para programas de mantenimiento predictivo. (Bagavathiappan et al., 2013; Huda & Taib, 2013; Molęda et al., 2023).
- Análisis de aceite: El aceite juega un papel vital dentro de una máquina en funcionamiento, siendo responsable de la lubricación, refrigeración, limpieza, protección o sellado. El análisis sistemático de la química y la contaminación del aceite puede proporcionar indicadores del desgaste de los componentes de la máquina y de la calidad de la lubricación. Este análisis hace posible determinar el estado de desgaste de los elementos de la máquina y planificar acciones preventivas, como el cambio de aceite o filtros de manera más efectiva. Las investigaciones pueden incluir pruebas de viscosidad, contaminación, contenido sólido, oxidación, nitración, número de ácido total, número de base total y conteo de partículas. El examen de estas propiedades puede determinar la calidad del rendimiento de la lubricación, detectando fugas, corrosión o desgaste anormal. La espectrografía y la ferrografía también son técnicas complementarias en esta área, que permiten el análisis de contaminantes y aditivos, y realizar análisis de partículas de desgaste

- para determinar los tipos de deterioro, como el desgaste por frotamiento, el desgaste por corte, la fatiga por rodadura y el desgaste por deslizamiento (Molęda et al., 2023).
- **Análisis acústico:** Esta técnica incluye el análisis de señales acústicas, ruido y ultrasonido. Con herramientas relativamente económicas, es posible monitorear la maquinaria rotativa de manera similar al análisis de vibraciones. Al analizar la señal en el dominio de la frecuencia, se pueden detectar anomalías causadas por la fricción y las tensiones que pueden ser síntomas de deterioro. En el caso de la detección de defectos en cajas de engranajes, el análisis acústico puede complementar el monitoreo de vibraciones para la detección de defectos menores. Por otro lado, el análisis ultrasónico se utiliza para detectar fugas en válvulas y tuberías, ya que las fugas generan una firma identificable en la banda de alta frecuencia. Al investigar la forma y las características de la forma de onda ultrasónica, se puede detectar la cavitación en la bomba centrífuga. En este contexto, las técnicas basadas en emisión acústica y ultrasonido se utilizan como métodos complementarios de monitoreo de condición, al permitir detectar cambios sutiles en la fricción, impactos y procesos de deterioro en rodamientos y otros componentes, con alta sensibilidad en etapas tempranas de la falla. (Molęda et al., 2023; Sharma et al., 2024; Sheriff et al., 2020).
 - **Análisis de corriente de motores:** La técnica de Análisis de corriente del Motor Eléctrico (MCSA: Motor Current Signature Analysis) es un método utilizado en el mantenimiento predictivo para analizar y monitorear motores eléctricos de inducción, generadores, transformadores de potencia y otros equipos eléctricos. Esta técnica se basa en el análisis de la corriente de suministro para generar una trazabilidad de corriente a partir de la transformación del espectro de frecuencia. Las fallas en los componentes del motor producen anomalías en el campo magnético y cambian la inductancia mutua y propia del motor, lo que se manifiesta en el espectro de la

corriente de suministro del motor. El MCSA permite detectar fallas como el desgaste del equipo, en la cual la degradación de las partes observada a largo plazo se hace visible como cambios en el espectro de la corriente. El análisis de la firma de corriente del motor (MCSA) se considera una técnica no invasiva de diagnóstico que utiliza el contenido armónico de la corriente del estator para detectar condiciones anómalas eléctricas y mecánicas en motores de inducción, siendo ampliamente estudiada como herramienta de monitoreo de condición y mantenimiento predictivo. (Molęda et al., 2023; Oviedo et al., 2025).

- Análisis de parámetros de proceso: Este enfoque se basa en mediciones actuales para determinar indicadores del rendimiento del proceso o índices de salud. Al monitorear el índice a lo largo del tiempo, se pueden evaluar los cambios en la condición del equipo. Esta técnica se utiliza ampliamente en combinación con el Internet de las Cosas (IoT: Internet of things), el aprendizaje automático y las tecnologías de big data. Es posible utilizar las enormes cantidades de datos generados en los sistemas tecnológicos para tareas de mantenimiento predictivo. Los indicadores de rendimiento se pueden calcular directamente a partir de los datos. Por ejemplo, se puede calcular la eficiencia de una bomba basándose en el flujo, el calor y la potencia, calculando la relación entre la potencia de salida y la de entrada. Otra forma es crear un modelo de índice de salud basado en datos históricos o datos de una máquina similar (Li et al., 2020; Molęda et al., 2023; Sharma et al., 2024).

Además de estas técnicas, la inspección visual sigue siendo importante para evitar fallas no detectadas y puede ser apoyada por tecnologías modernas como la realidad aumentada y aplicaciones móviles (Molęda et al., 2023).

Inteligencia de negocios en la industria del mantenimiento

El uso de la Inteligencia de Negocios (BI) puede ser una herramienta para apoyar el desarrollo del Mantenimiento Basado en Evidencia (EbM: Evidence-Based Maintenance). El objetivo es lograr resultados operacionales comparables a otros métodos de mantenimiento, como el Mantenimiento basado en confiabilidad (RCM: Reliability Centered Maintenance), pero minimizando la sobrecarga inicial, especialmente para las Pequeñas y Medianas Empresas (PYMEs). Esto se logra aprovechando las herramientas proporcionadas por la transformación digital. La inteligencia de negocios puede desempeñar un papel vital en el apoyo al desarrollo de planes de Mantenimiento basado en confiabilidad a través de la integración, procesamiento y visualización de datos de múltiples fuentes. En el ámbito del mantenimiento, la BI se ha asociado principalmente con el CBM y el mantenimiento predictivo. Se han propuesto dashboards para ayudar en la toma de decisiones con respecto a la ejecución de acciones de mantenimiento basadas en el estado de salud actual o futuro estimado del activo (Barbieri et al., 2024).


La Inteligencia de negocios se define como la combinación de procesos, políticas, cultura y tecnologías para recopilar, manipular, almacenar y analizar datos recopilados de fuentes internas y externas, con el fin de comunicar información, crear conocimiento e informar la toma de decisiones. Los sistemas de BI apoyan la toma de decisiones al facilitar la agregación, integración sistemática y gestión de datos estructurados y no estructurados; al manejar grandes cantidades de datos; al proporcionar a los usuarios finales capacidades de procesamiento mejoradas para descubrir nuevo conocimiento; y al ofrecer soluciones de análisis, consultas ad hoc, informes y pronósticos (Barbieri et al., 2024).

La BI no es solo una solución tecnológica para la presentación de informes de la actividad empresarial, sino una combinación de componentes interconectados que

forman un proceso, que incluye la recopilación de datos, la manipulación (ETL), el almacenamiento en data warehouses, el análisis (data mining, OLAP, text mining) y la comunicación a través de interfaces gráficas de usuario (GUIs) como informes y dashboards. Una posible metodología para la apropiación de la inteligencia de negocios en procesos de mantenimiento basado en evidencia podría incorporar pasos adicionales para definir la evidencia necesaria para el proceso, seleccionar y estandarizar los datos relevantes, implementar el proceso de BI y finalmente formular planes de mantenimiento basados en la evidencia recopilada (Barbieri et al., 2024). Ahora bien, la integración de la inteligencia de negocios en las metodologías y programas de mantenimiento predictivo es fundamental para optimizar la gestión de los activos, reducir el tiempo de inactividad de las máquinas y mejorar la eficiencia general del procesos productivo, en ese sentido, el uso de BI dentro del mantenimiento predictivo puede tener entre otros, los siguientes usos y propósitos (Wolniak & Grebski, 2023):

Figura 1.

Propósitos de la integración del BI y el mantenimiento predictivo en industria.



Nota: Adaptado de “Predictive maintenance – the business analytics usage in Industry 4.0 conditions” (Wolniak & Grebski, 2023).

Integración de variables externas y de mantenimiento.

La inteligencia de negocios (BI) juega un papel crucial en el soporte del desarrollo de planes de mantenimiento que aseguren la operación continua de los activos, extiendan su vida útil y minimicen los costos lo más posible. En este contexto, se propone la utilización de BI, apalancándose en las herramientas proporcionadas por la transformación digital, para apoyar el desarrollo del Mantenimiento Basado en Evidencia (EbM). Una implementación efectiva de esto requiere liderazgo y compromiso para garantizar la consistencia a través de la estandarización de vocabulario, formatos y procesos dentro de la organización (Barbieri et al., 2024).

La integración de variables económicas, ambientales o de operación del negocio con datos de mantenimiento predictivo dentro de una estrategia de inteligencia de negocios (BI) son un elemento fundamental para optimizar la gestión de activos, mejorar la toma de decisiones y alcanzar objetivos empresariales más amplios (Wolniak & Grebski, 2023).

La inteligencia de negocios en el mantenimiento predictivo implica la recopilación sistemática de datos en tiempo real de sensores y dispositivos IoT instalados en la maquinaria, que incluyen parámetros operacionales como temperatura, presión, vibración y métricas de funcionamiento. Estos datos operacionales se integran con datos históricos de rendimiento, registros de mantenimiento y factores externos como las condiciones climáticas. Las condiciones climáticas pueden considerarse una variable ambiental que influye en el funcionamiento de los equipos (Wolniak & Grebski, 2023).

La integración de variables económicas, ambientales o de operación y su análisis mediante BI en el mantenimiento predictivo tiene un impacto directo en los resultados del negocio, al permitir anticipar y abordar posibles fallas antes de que provoquen un tiempo de inactividad no planificado (operacional). Esto conlleva a ahorros de costos

(económico) al minimizar los gastos asociados con el mantenimiento reactivo, como reparaciones de emergencia y pedidos urgentes. Además, se logra un rendimiento optimizado de los activos (operacional y económico) al asegurar que los equipos operen con la máxima eficiencia y al extender su vida útil (Wolniak & Grebski, 2023).

El marco conceptual expuesto permite caracterizar tres brechas concretas en el programa de mantenimiento predictivo del cliente de A-MAQ S.A., por una parte si bien las técnicas de análisis de vibraciones y termografía están maduras y alineadas con las normas ISO 20816-1 (2016) e ISO 17359 (2018), su interpretación se realiza sin incorporar variables de contexto ambiental tal como recomienda la norma; además, la inteligencia de negocios (BI) y los principios del Mantenimiento Basado en Evidencia (EbM, (Barbieri et al., 2024)) todavía no se han integrado plenamente en el análisis vibracional, lo que impide consolidar una mirada prescriptiva; y finalmente, no existe, hasta donde se ha revisado, un trabajo empírico que haya integrado series ambientales locales y macroeconómicas sectoriales con datos reales de diagnóstico vibracional de una planta de empaques en Colombia. Estos tres elementos delimitan el aporte específico de la presente investigación.

Metodología

La investigación propuesta, según las fuentes de datos es de tipo cuantitativo con un enfoque correlacional. Este enfoque permite analizar la relación entre variables cuantificables, facilitando la identificación de patrones y tendencias en los datos existentes. Según Hernández (Hernández Sampieri et al., 2014), la investigación correlacional busca medir el grado de asociación entre dos o más variables en un contexto particular.

Además, según el propósito planteado, esta investigación es aplicada, ya que para su desarrollo fueron tomados datos reales capturados en máquinas que operan actualmente en la industria y que pertenecen a uno de los clientes de la empresa A-MAQ S.A., también, según el grado de profundidad fue descriptiva, ya que precisamente con el tratamiento estadístico de datos reales, se busca describir una situación concreta entorno a la relación existente entre las variables del comportamiento de los activos y posibles elementos influyentes en la macroeconomía o medio ambiente.

Por otra parte, debido a la inferencia esperada por los resultados obtenidos con el desarrollo de este trabajo, esta investigación es de tipo deductivo, ya que partiendo de datos concretos, se busca llegar a una conclusión respecto a la relación entre las variables objeto del estudio. Finalmente, por su temporalidad, este trabajo se clasifica como una investigación longitudinal, ya que analiza datos recolectados entre julio de 2021 y julio de 2025.

En ese sentido, en este trabajo se busca encontrar patrones relacionales entre las variables de ingeniería adquiridas por la empresa A-MAQ S.A. sobre las máquinas de sus clientes y al menos dos variables macroeconómicas o de entorno ambiental que puedan tener una afectación sobre el comportamiento de las máquinas. Establecer esta relación permitió reconocer el impacto de factores externos sobre el funcionamiento de las máquinas analizadas y derivar criterios aplicables a empresas prestadoras de servicios predictivos como A-MAQ S.A.

Población y muestra

A-MAQ S.A. es una empresa colombiana con sede en Medellín, fundada hace 25 años, especializada en la prestación de servicios de mantenimiento predictivo y monitoreo de condición (CBM) para equipos rotativos de la industria manufacturera y de

generación de energía. Su portafolio incluye análisis de vibraciones, termografía infrarroja, ultrasonido y análisis de aceite, atendiendo principalmente a los sectores de alimentos, empaques, cementos y generación de energía. La información utilizada en este estudio proviene de las bases de datos operativas de la compañía y de entrevistas con expertos que laboran para la empresa (A-MAQ S.A., 2025). La población de referencia del estudio está compuesta por equipos rotativos impulsados por motores eléctricos monitoreados por A-MAQ S.A. en clientes industriales que contratan servicios predictivos. Estos activos han sido objeto de mediciones periódicas mediante técnicas de mantenimiento predictivo durante el periodo analizado en esta investigación, incluyendo análisis de vibraciones, termografía infrarroja y ultrasonido. La muestra correspondió al conjunto de máquinas monitoreadas de manera sistemática y continua por A-MAQ S.A. en uno de sus clientes del segmento de manufactura de empaques del Área Metropolitana de Medellín. Este segmento, es elegido por ser uno de los sectores estratégicos para la compañía A-MAQ S.A. y según A-MAQ, ser uno de los que más dinero ha invertido en realizar programas de mantenimiento predictivo. Las mediciones de los activos seleccionados deben presentar trazabilidad completa en cuanto a condiciones de operación, fecha de recolección y diagnóstico técnico.

La ficha técnica del estudio contempla como unidad de análisis cada máquina monitoreada; el periodo de observación comprende desde julio de 2021 hasta julio de 2025; las variables de interés corresponden a parámetros técnicos asociados al estado de la máquina (como amplitud de vibración, diagnóstico y recomendaciones) y variables macroeconómicas relacionadas con el entorno operativo del cliente que sean seleccionadas luego de analizar su conveniencia en el desarrollo del trabajo. Esta información fue sometida a análisis estadístico descriptivo, correlacional y de

significancia estadística para identificar patrones de comportamiento y posibles relaciones entre las variables.

El muestreo empleado fue de tipo no probabilístico por conveniencia, con criterio intencional por juicio del investigador y del patrocinador del proyecto (Hernández Sampieri et al., 2014). Los criterios de inclusión fueron: 1. Equipos rotativos impulsados por motores eléctricos, 2. Equipos monitoreados de forma sistemática por A-MAQ S.A. durante al menos dos años, 3. Equipos pertenecientes a un cliente del segmento de manufactura de empaques plásticos del Área Metropolitana de Medellín, y 4. Mediciones con trazabilidad completa en fecha de medición, diagnóstico técnico y recomendaciones. La muestra final quedó constituida por 413 máquinas rotativas con 3.708 mediciones distribuidas en 157 días de monitoreo entre julio de 2021 y julio de 2025.

Instrumentos

El instrumento de medición empleado en esta investigación fue un dataset, diseñado específicamente para estructurar, clasificar y analizar los datos técnicos y exógenos recopilados. Este dataset permitió sistematizar los registros obtenidos de las bases de datos internas de A-MAQ S.A., en los cuales se consignan las variables técnicas de las máquinas monitoreadas, tales como amplitud de vibración, diagnóstico y recomendaciones. Adicionalmente, se incluyeron campos para variables externas relevantes, como indicadores macroeconómicos o ambientales externos previamente identificados. El dataset estuvo compuesto por filas correspondientes a cada máquina o equipo medido, y columnas que representan cada variable cuantitativa de interés, su unidad de medida, fecha de registro y observaciones asociadas. Este instrumento facilitó la preparación de los datos para su posterior análisis estadístico descriptivo y

correlacional, permitiendo identificar patrones de comportamiento, relaciones entre variables y tendencias temporales, en coherencia con los objetivos de la investigación.

Técnicas para el análisis de la información

El análisis de los datos se abordó desde tres enfoques complementarios. En primer lugar, un análisis descriptivo permitió caracterizar las distribuciones de las variables de operación de las máquinas y las externas (medidas de tendencia central, dispersión y distribución por categoría de estado). En segundo lugar, un análisis inferencial fue aplicado para evaluar las hipótesis de asociación, empleando: correlación de Pearson y Spearman, ANOVA de una vía, prueba de Kruskal-Wallis, regresión logística binaria (Normal vs. Anómalo). Finalmente, se aplicaron técnicas de machine learning con el algoritmo Random Forest para la imputación de datos faltantes de temperatura. El procesamiento y análisis se realizó en Python 3.11 utilizando las librerías pandas, NumPy, SciPy, statsmodels y scikit-learn; la propuesta de visualización se estructuró como un prototipo funcional en HTML y se planteó su implementación final en Power BI para su uso en entornos empresariales.

La validación del instrumento de medición se llevó a cabo a través de un proceso de dos etapas, la primera etapa es una validación cualitativa por juicio de expertos en la que se conformó un panel de diez (10) expertos activos del área CBM de A-MAQ S.A., con formación en ingeniería mecánica, electromecánica, mecánica industrial e instrumentación y control, y una experiencia promedio de 7,9 años en monitoreo de condición (Tabla 2). A cada experto se le presentaron seis variables externas candidatas (temperatura ambiente, humedad relativa, contaminación particulada, calidad de la energía eléctrica, Índice de Producción Industrial sectorial y precio promedio del kWh industrial) junto con el sustento físico-mecánico de cada una según la literatura. Cada

experto calificó en una escala Likert de 1 a 5 dos dimensiones: (a) incidencia mecánica sobre los activos y (b) trazabilidad de los datos en Colombia. La selección se realiza aplicando el método del coeficiente de V de Aiken, el cual se utiliza para cuantificar la validez de contenido de ítems en un instrumento de medición, basado en el juicio de expertos. Específicamente, este coeficiente mide el grado de acuerdo entre los jueces sobre la relevancia, claridad o representatividad de los ítems en relación con el constructo que se quiere evaluar (Merino-Soto, 2023). Dos de las dos variables con mayor puntuación promedio en ambas dimensiones y mayor disponibilidad histórica fueron seleccionadas para el estudio: temperatura ambiente (IDEAM, estación Medellín) e Índice de Producción Industrial del sector de caucho y plástico (DANE, CIU 2200).

Luego, en la segunda etapa se realizó una validación cuantitativa estadística: las dos variables seleccionadas fueron sometidas posteriormente a pruebas formales de asociación con el estado de condición de los activos (correlación de Pearson y Spearman, ANOVA, Kruskal-Wallis y regresión logística binaria), cuyos resultados se exponen en la sección de Resultados. Esta segunda validación confirmó la pertinencia de la selección realizada por el panel de expertos.

De forma complementaria, se solicitó al patrocinador del proyecto en A-MAQ S.A. la revisión del instrumento, con el fin de verificar su aplicabilidad práctica en el contexto operativo real y asegurar que la información contenida en los registros técnicos sea tratada de forma adecuada y ética. Este proceso de validación contribuyó a reforzar la confiabilidad del análisis posterior y la solidez metodológica del estudio.

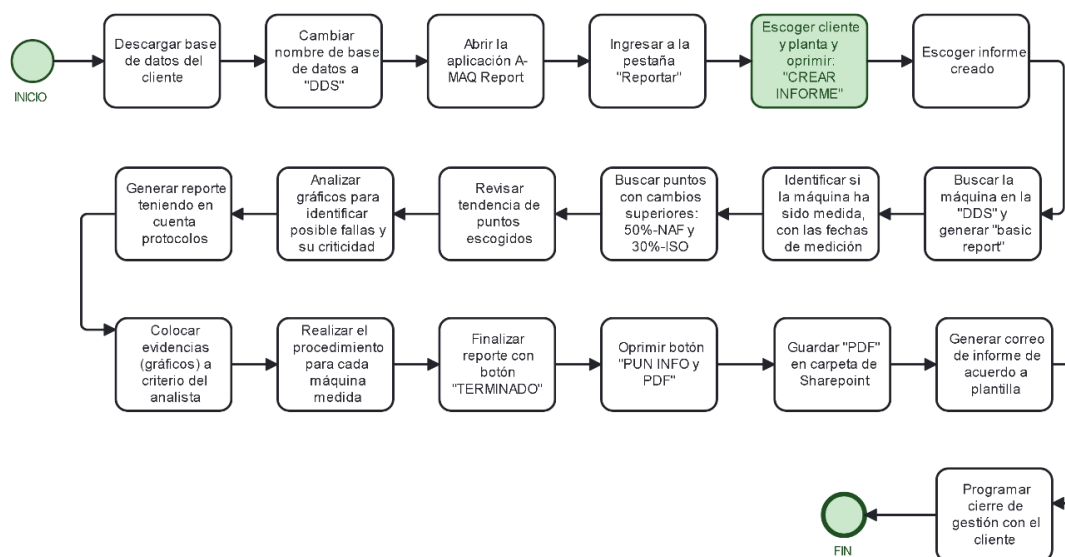
Resultados

Identificación del proceso de medición y diagnóstico por vibraciones en máquinas impulsadas por motores eléctricos

El primer paso de la investigación se enfocó en identificar el proceso de obtención de datos técnicos de diagnóstico y recomendaciones para máquinas impulsadas por motores eléctricos, realizados por una empresa de prestación de servicios predictivos en Colombia. Para este propósito, se entrevistó al Director de Servicios CBM de la compañía A-MAQ S.A. de Medellín. Producto de esta entrevista, se obtuvo a manera de contexto, la explicación de cómo se obtienen estos datos, para posteriormente tener acceso a una base de datos de al menos dos años de condición vibracional, diagnóstico y recomendaciones de máquinas impulsadas por motores eléctricos en la industria manufacturera en Colombia. Para ilustrar mejor como se realiza el proceso de obtención de estos datos, se presenta la figura 2:

Figura 2.

Flujograma de análisis de vibraciones A-MAQ S.A.



Nota: Extraído de la documentación de procesos internos de A-MAQ S.A.

Una vez ejecutado este proceso, los datos quedan almacenados en una base de datos privada de la compañía prestadora de servicios. Para esta investigación, se obtuvo acceso a dicha base de datos. A continuación, se presenta la ficha técnica de la base de datos de máquinas sujetas a este análisis.

- Periodo de análisis de los datos: desde julio de 2021 hasta julio de 2025.
- Cantidad de mediciones realizadas en el periodo de análisis: 3708
- Cantidad única de máquinas: 413, correspondientes a los activos sujetos a medición de vibraciones en el periodo de análisis, en una compañía del sector de manufactura de empaques ubicada en el municipio de Itagüi, Antioquia.
- Cantidad de días en los que se realizaron mediciones dentro del periodo de análisis: 157.

Con base en la catalogación de cada activo, dada por un ingeniero analista CBM de la compañía A-MAQ S.A., con la que categorizaba cada activo en un estado Normal, Pronta Atención o Urgente, se asignó un Score por cada activo y por cada día de análisis, evitando el sesgo que pudiera generar que en unos días se midieran más máquinas que en otros. El cálculo del score está dado por la siguiente ecuación:

Supóngase para un día cualquiera “d”:

N_d = Número de máquinas en estado Normal

P_d = Número de máquinas en estado Pronta Atención

U_d = Número de máquinas en estado Urgente

T_d = Total máquinas medidas en d = $N_d + P_d + U_d$


Se asignaron los pesos 0 para Normal, 0,5 para Pronta Atención y 1 para Urgente. En consecuencia, el score diario se definió como:

$$Score(d) = \frac{0,5 * P_d + 1 * U_d}{T_d}$$

Este indicador resume, para cada día, la proporción ponderada de activos en condición de riesgo (pronta atención o urgente) sobre el total de máquinas evaluadas.

Figura 3.

Histograma del ScoreXDía.



Al analizar la distribución del Score(d), se observó que en el 8,2% de los días el valor del indicador fue mayor o igual a 0,55. Este umbral se interpreta como jornadas con una proporción elevada de activos en estado de pronta atención o urgente, es decir, días con un nivel de riesgo operativo particularmente alto, más que como días exclusivamente “anómalos” en términos binarios.

Tabla 1.

Distribución de estados de los activos en dataset completo.

Estado	N	Porcentaje
Normal	2.141	57,7 %

Estado	N	Porcentaje
Pronta Atención	927	25,0 %
Urgente	640	17,3 %
Total	3.708	100,0 %

El dataset presenta la distribución de estados de condición que se detalla en la Tabla anterior. Se observa que la mayoría de las mediciones (57,7 %) corresponden a activos en estado Normal, seguidos por Pronta Atención (25,0 %) y Urgente (17,3 %). Esta distribución refleja la realidad operativa típica de una empresa de manufactura de empaques, donde la mayor parte del parque de activos se encuentra en condición aceptable, pero una proporción no despreciable requiere intervención.

Selección de variables externas para modelar el comportamiento de máquinas rotativas.

La literatura de mantenimiento basado en condición (CBM) y la normativa técnica coinciden en que la interpretación de variables de condición (vibraciones, ultrasonido, temperatura, entre otras) debe contextualizarse frente a condiciones ambientales y de operación. La norma ISO 17359 establece lineamientos generales para diseñar programas de mantenimiento basado en la condición (CBM), incluyendo la identificación de factores de entorno y operación que afectan la tendencia y los límites de severidad; por su parte, la norma ISO 20816-1 define condiciones y procedimientos para la medición y evaluación de la vibración en máquinas, enfatizando la importancia de mantener condiciones comparables entre mediciones y de documentar variables de contexto (temperatura, carga, etc.). Estas referencias normativas justifican, desde el diseño

metodológico, la incorporación de variables exógenas en modelos explicativos y predictivos del comportamiento vibratorio en líneas de manufactura de empaques (International Organization for Standardization, 2016, 2018).

Con base en dichas guías, en este paso de la investigación, se propone un conjunto candidato de variables externas que cumplen con dos criterios: incidencia física o mecánica (variables que conecten el entorno con la fricción, la lubricación, el deslizamiento, la estabilidad dinámica o el desgaste) y trazabilidad estadística (series de datos confiables con una frecuencia de adquisición o muestreo compatible con los datos que pueden tomarse típicamente en un programa de mantenimiento basado en la condición). La selección contempla seis variables (ambientales y macroeconómicas) que pueden tener un impacto en la evolución de la condición en máquinas rotativas.

Temperatura ambiente (°C): La temperatura ambiente modula la viscosidad del lubricante y, por tanto, el espesor de película y la estabilidad de rodamientos; los cambios de viscosidad alteran la respuesta vibratoria, especialmente en componentes de baja y alta frecuencia. Estudios experimentales muestran variaciones significativas de la vibración de rodamientos al modificar la viscosidad del aceite y la temperatura de operación (Serrato et al., 2007). Asimismo, en condiciones de alta temperatura y humedad se observan incrementos de fricción, desgaste y vibración en rodamientos, reforzando el mecanismo termofísico-lubricante (Yeh et al., 2025). La norma ISO 17359 sugiere que en un programa de CBM, se deben registrar y considerar tales condiciones ambientales al definir límites y análisis de tendencia (International Organization for Standardization, 2018).

Humedad relativa (%): La humedad acelera la corrosión y degradación superficial de componentes mecánicos, compromete la salud del lubricante y puede introducir sesgos en ciertos transductores; su efecto acumulativo eleva la probabilidad de daño y la energía

vibratoria asociada (Yeh et al., 2025). La pertinencia de esta variable, además de su incidencia fisicoquímica, se fundamenta también en su frecuente disponibilidad en datasets de datos meteorológicos locales.

Contaminación particulada (polvo ambiental y/o contaminantes sólidos en lubricante): La ingesta de partículas (polvo en partículas por millón PPM) o la contaminación sólida del lubricante acelera el desgaste, incrementa la fricción y excita componentes de alta frecuencia en el espectro de vibración. Evitar la filtración de partículas a los ambientes de operación de las máquinas prolonga la vida del rodamiento, mientras que mayores niveles de partículas se asocian con fallas prematuras y aumento de vibración (Loewenthal et al., 1978; Loewenthal & Moyer, 1978). Por ello, el nivel de limpieza (ambiental o del aceite) constituye un factor externo que modifica la respuesta vibratoria y la condición de la máquina.

Calidad de energía eléctrica (eventos de sag/dip de tensión y variaciones): Los huecos de tensión (sags) y las variaciones de suministro de electricidad alteran el par y deslizamiento de motores de inducción, pudiendo inducir pulsaciones electromecánicas y fenómenos transitorios que impactan el comportamiento vibratorio de la máquina. De acuerdo con la norma IEEE 1159, un sag es una disminución del voltaje RMS (Root mean Square o valor eficaz de una señal de voltaje) en frecuencia fundamental de la línea de suministro eléctrico (60 Hz para el caso de Colombia) por intervalos breves; la literatura de calidad de energía identifica los sags como uno de los problemas más comunes máquinas críticas (Kazemi et al., 2013). En plantas que cuentan con medición de calidad de la energía (Registro PQM: Power Quality monitor), la tasa de sags constituye factor relevante para explicar cambios esporádicos en la condición de las máquinas (IEEE, 2019).

Ritmo operativo del sector (Índice de Producción Industrial, IPI/Capacidad

Utilizada): La carga y utilización de capacidad inciden en horas de operación, ventanas de mantenimiento y esfuerzo mecánico promedio. El IPI es un indicador mensual estandarizado de salida industrial, utilizado por organismos internacionales (OCDE, Eurostat, Naciones Unidas) como señal oportuna de actividad real (Eurostat, 2024; OECD, 2025). Su variación puede influir en la probabilidad de alarmas y en la tendencia vibratoria.

Precio de la electricidad para uso industrial (COP/kWh): Las variaciones de tarifa eléctrica influyen en programación de turnos y uso de equipos y, afectando perfiles térmicos y dinámicos de las máquinas. En general, los aumentos repentinos en el costo de la energía causan que la producción industrial baje a corto plazo (Chiacchio et al., 2023). A nivel micro, la evidencia indica que precios de la tarifa de energía, cuando son más altos, tienden a reducir la producción y frenan el crecimiento de la productividad laboral en manufactura (Fried & Lagakos, 2020); y, de forma más reciente, que cambios normativos que encarecen la electricidad pueden moderar la actividad manufacturera por la vía de costos (Wolverton et al., 2022). Estos hallazgos respaldan el carácter exógeno-operativo de la tarifa como posible variable relevante para esta investigación con posibles efectos adversos sobre la condición de máquinas.

Tasa de cambio (USD/COP): La tasa de cambio incide de manera sustantiva en los costos de insumos importados y en la formación de precios a lo largo de la cadena productiva. A través del fenómeno de pass-through cambiario, la depreciación del peso se transmite a los precios de importación y, posteriormente, a precios al productor y al consumidor, afectando decisiones operativas (ritmo de producción, turnos, programación de mantenimientos) que modulan la exposición mecánica de los equipos (ciclos, arranques, perfiles térmicos, entre otros). La evidencia internacional encuentra impactos

no triviales de la tasa de cambio sobre la actividad manufacturera con heterogeneidad por sub-rama (bienes más intensivos en comercio exterior reaccionan con mayor sensibilidad). Estas regularidades proveen un mecanismo exógeno y cuantificable que conecta el entorno macro con la carga operativa y, por ende, con la condición de las máquinas (Rincón et al., 2007; Rowland, n.d.). Si bien, esta variable por sí misma puede tener incidencia en la cadena de abastecimiento y por ende, en el comportamiento de las máquinas analizadas, para efectos de este estudio, se tendrá en cuenta como una variable secundaria que puede afectar los índices de productividad del sector.

Implicaciones para el modelo y criterios de priorización

Desde el punto de vista econométrico, estas variables se pueden usar como factores externos en modelos que analizan datos en el tiempo. Según la norma ISO 20816-1, es importante registrar cómo se midieron los datos y asegurarse de que las frecuencias de las variables externas coincidan con las de los datos de condición.

Con base en el contexto anterior, se consultaron 10 personas expertas en el campo del monitoreo de condición, a fin de validar las variables candidatas, y poder seleccionar al menos 2 con las cuales se realizaría el análisis estadístico.

Tabla 2.

Listado de expertos encuestados.


Profesión	Cargo	Años de experiencia
Mecánico Industrial	Analista CBM	8
Ingeniero en Instrumentación y Control	Consultor Comercial CBM	10
Ingeniero Mecánico	Ingeniero Analista CBM	2
Ingeniero Mecánico	Director CBM	25
Ingeniero mecánico	Analista CBM	1,5

Profesión	Cargo	Años de experiencia
Ingeniero mecánico	Ingeniero analista CBM	1 año
Ingeniero electromecánico	Ingeniero consultor comercial CBM	8
Ingeniera Mecánica	Consultora de Servicios CBM	3.5
Ingeniero en Instrumentación y Control	Consultor Comercial CBM	10
Ingeniero Mecánico	Director de Mercadeo y Ventas	4

Se les realizó la pregunta: “Califique de 1 a 5, donde 1 es nulo y 5 es totalmente, cuál considera que es la incidencia de cada una de estas variables externas, sobre la condición de máquinas impulsadas por motores eléctricos que operan en la industria de manufactura de empaques:”

Figura 4.

Respuestas de expertos a pregunta variables candidatas.



Para cuantificar la validez de contenido de las variables externas candidatas se utilizó el coeficiente V de Aiken. En este enfoque, cada experto califica la relevancia de la variable en una escala ordinal de c categorías, y la V de Aiken se define como:

$$V = \frac{\sum s_i}{n(c - 1)}$$

Donde $s_i = r_i - l_0$, r_i es la calificación otorgada por el juez i , l_0 es el valor mínimo de la escala y n es el número de jueces. Este coeficiente permite cuantificar el grado de acuerdo entre jueces sobre la pertinencia de cada variable, produciendo valores entre 0 y 1. Este índice es recomendado para estudios de validez de contenido porque produce valores fácilmente interpretables y permite contrastar empíricamente los juicios de expertos (Ilyana Ismarau Tajuddin et al., 2025). La siguiente tabla presenta el resultado de la cuantificación.

Tabla 3.

Índices V de Aiken para encuesta de variables candidatas.

Variable candidata	V de Aiken
Temperatura ambiente	0,825
Calidad de la energía	0,950
Índice de producción industrial	0,675
Precio de la electricidad	0,525
Humedad relativa	0,800
Contaminación particulada ambiente	0,725

En este contexto, la calidad de la energía y la temperatura ambiente se consolidan como variables ambientales de alta prioridad, siendo elegida para este estudio la segunda, ya que la disponibilidad de datos públicos es total, mientras que el índice de producción industrial, a pesar de presentar un V de Aiken moderado ($V = 0,675$), se conserva en el estudio por su doble papel como indicador del entorno productivo sectorial y como variable macroeconómica clave para un enfoque de inteligencia de negocios, evitando excluir por completo la dimensión macroeconómica del análisis. Así entonces, aunque inicialmente se consideraron varias variables externas (temperatura ambiente,

calidad de la energía, índice de producción industrial, precio de la electricidad, humedad relativa y contaminación particulada), se eligieron la temperatura ambiente y el índice de producción industrial como objeto de análisis. Esta selección obedece a que, además de contar con una validez de contenido aceptable según la V de Aiken, estas dos variables disponían de series históricas con la granularidad y continuidad necesarias para integrarse al dataset de máquinas, mientras que las restantes quedaron delimitadas como candidatas para estudios futuros debido a su menor V de Aiken, limitaciones de acceso o calidad de la información disponible.

Desarrollo de un modelo de integración de diagnósticos de máquinas y variables externas.

Conformación del Dataset.

Para el desarrollo de este modelo, luego de realizar la elección de las variables externas temperatura e índice de producción industrial, se procedió a la integración de los datos hallados en bases de datos que contienen este tipo de variables. En primer lugar, el modelo propuesto establece la consulta en la base de datos del IDEAM, de los datos de temperatura disponibles. Para este caso, se procedió con el siguiente dataset:

Tabla 4.

Caracterización descriptiva de dataset de temperatura máxima diaria en Medellín.

Medida estadística	Valor [°C]
Media	28,15185972
Error típico	0,071239262
Mediana	28,1
Moda	28,8

Medida estadística	Valor [°C]
Desviación estándar	2,185315899
Varianza de la muestra	4,77560558
Curtosis	-0,127073589
Coefficiente de asimetría	-0,123185844
Rango	13,1
Mínimo	20,6
Máximo	33,7
Cuenta	941
Mayor (1)	33,7
Menor(1)	20,6
Nivel de confianza(95,0%)	0,139806402

Nota: Calculado de dataset del INSTITUTO DE HIDROLOGÍA METEOROLOGÍA Y ESTUDIOS AMBIENTALES disponible en la página oficial del IDEAM (IDEAM, 2026).

Se eligió la estación meteorológica más cercana a la ubicación geográfica de las máquinas medidas sujetas al estudio. El dataset de vibraciones cubre el periodo julio de 2021 – julio de 2025, con 157 días de medición distribuidos en ese intervalo. Los datos oficiales de temperatura máxima diaria del IDEAM (estación Medellín) disponibles a la fecha del estudio alcanzan hasta el 26 de abril de 2024, generando un bache de aproximadamente 15 meses respecto al último registro vibracional. Dentro de ese bache, 63 días coinciden con mediciones de vibración que quedaron sin valor oficial de temperatura asociado. Para la imputación de los 63 valores faltantes de temperatura se seleccionó el algoritmo Random Forest, un método de aprendizaje automático basado en

ensambles de árboles de decisión no podados que ha demostrado un desempeño superior frente a técnicas clásicas como k-nearest neighbors (KNN) y la imputación múltiple por ecuaciones encadenadas (MICE: Multiple imputation by chained equations), particularmente en conjuntos de datos donde se sospecha la presencia de interacciones complejas y relaciones no lineales entre las variables (Stekhoven & Bühlmann, 2012). Este método presenta ventajas significativas: no requiere supuestos distribucionales sobre los datos, no necesita especificación de parámetros de ajuste por parte del investigador y es capaz de capturar patrones estacionales y tendencias temporales sin transformaciones previas (Shah et al., 2014; Tang & Ishwaran, 2017). En el presente estudio, se evaluaron comparativamente tres modelos: Regresión Lineal, Random Forest y Gradient Boosting; mediante validación cruzada, excluyendo la variable ScoreDia del conjunto de predictores. Random Forest obtuvo el menor error absoluto medio (MAE = 1.44 °C) y el mayor coeficiente de determinación ($R^2 = 0.446$), confirmando su superioridad para este conjunto de datos. Las variables predictoras utilizadas fueron el mes, el año y transformaciones cíclicas sinusoidales del mes, lo que permitió al modelo capturar tanto la tendencia creciente interanual de la temperatura como su comportamiento estacional. Los valores imputados se situaron dentro del rango observado en los datos originales (27.2 °C – 31.4 °C frente a 21.5 °C – 33.6 °C), lo que respalda la coherencia física de las estimaciones generadas. Estudios comparativos recientes han confirmado que la imputación basada en Random Forest supera consistentemente a otros métodos en escenarios con diferentes tipos y tasas de datos faltantes (Kokla et al., 2019), lo que refuerza la pertinencia de su selección en el presente trabajo.

La siguiente tabla, presenta las estadísticas descriptivas de la temperatura ambiente desagregadas por estado de condición. Se aprecia una tendencia progresiva: conforme

el estado de la máquina empeora, la temperatura media y la mediana bajo la cual fueron medidas tienden a incrementarse. Las máquinas en estado Urgente se midieron, en promedio, bajo temperaturas de 29,48 °C, frente a los 29,24 °C de las máquinas en estado Normal, una diferencia de 0,24 °C que, si bien modesta en términos absolutos, resulta estadísticamente significativa dado el tamaño muestral, como se demostrará en las secciones subsiguientes.

Tabla 5.

Temperatura ambiente por estado de condición (°C).

Estado	N	Media (°C)	Mediana	Desv. Est.
Normal	2.141	29,24	30,00	2,09
Pronta Atención	927	29,37	30,40	2,12
Urgente	640	29,48	30,50	2,07

Adicionalmente, se consultó en la base de datos del DANE, el índice de producción industrial para el sector de fabricación de productos de caucho y plástico. El Índice de Producción Industrial (IPI) es un indicador elaborado por el Departamento Administrativo Nacional de Estadística (DANE) que estima la evolución mensual de la producción real del sector industrial colombiano, expresado como un número índice con base 2018 = 100. Al tratarse de un índice adimensional, su valor no representa unidades físicas ni monetarias, sino una medida relativa de volumen de producción respecto al periodo base: un valor de 120, por ejemplo, indica que la producción real del sector en ese mes fue un 20 % superior al promedio mensual de 2018, mientras que un valor de 95 señalaría una contracción del 5 % frente a dicho referente. En el presente estudio se empleó el IPI correspondiente a la División CIIU 2200: Fabricación de productos de caucho y de plástico (DANE, 2025), que constituye la desagregación más específica

publicada por el DANE y engloba la manufactura de empaques plásticos (Clase CIIU 2229). Este indicador permite incorporar al análisis la dinámica productiva del sector industrial asociado, capturando efectos de ciclos económicos, estacionalidad productiva y choques de oferta que podrían incidir sobre las demás variables del modelo.

La siguiente tabla muestra la tendencia inversa para el Índice de Producción Industrial (IPI) del sector caucho y plástico: a medida que el estado de condición de los activos se deteriora, el IPI promedio disminuye. Las máquinas en estado Urgente fueron medidas en periodos con un IPI promedio de 119,80, inferior al 120,57 del estado Normal.

Tabla 6.

IPI del sector caucho y plástico por estado de condición.

Estado	N	Media	Mediana	Desv. Est.
Normal	2.141	120,57	120,06	7,18
Pronta Atención	927	120,42	120,06	6,98
Urgente	640	119,80	119,62	6,67

Pruebas estadísticas para determinación de relaciones.

Análisis de correlación: Se calcularon los coeficientes de correlación de Pearson y de Spearman entre las variables externas (temperatura ambiente e IPI) y las variables de condición (Estado codificado ordinalmente: Normal = 0, Pronta Atención = 1, Urgente = 2; y ScoreXActivo: 0, 0,5 y 1). Para calcular estas correlaciones, se utilizó el Score calculado para cada activo individualmente, no el ScoreXdía, con el fin de dar mayor granularidad y detalle a los datos dentro del modelo estadístico. Los resultados se presentan en la siguiente tabla.

Tabla 7.

Correlaciones entre Estado/ScoreXActivo y variables externas ($p < 0,05$; ** $p < 0,01$).*

Par de variables	Pearson r	p-valor	Spearman ρ	p-valor
Estado vs Temperatura	0,0453	0,0058**	0,0497	0,0025**
Estado vs IPI	-0,0372	0,0235*	-0,0375	0,0225*

Ambas correlaciones son estadísticamente significativas: Estado vs. Temperatura $p_{\text{valor}} = 0,006$ (**) y Estado vs. IPI $p_{\text{valor}} = 0,024$ (*). Este resultado constituye el hallazgo más relevante de la presente investigación, al preservar la granularidad individual de los 3.708 registros, ambas correlaciones resultaron estadísticamente significativas. La temperatura ambiente exhibe una correlación positiva significativa estadísticamente con el deterioro de la condición ($r = 0,0453$, $p = 0,006$ en Pearson; $\rho = 0,0497$, $p = 0,002$ en Spearman), lo que indica que las máquinas medidas en días más calurosos tienden a presentar peores estados de condición. El IPI, por su parte, muestra una correlación negativa significativa ($r = -0,0372$, $p = 0,024$; $\rho = -0,0375$, $p = 0,023$), indicando que los estados más deteriorados se asocian con periodos de menor producción industrial. La magnitud de los coeficientes es pequeña, lo que es esperable dado que la condición mecánica depende de decenas de factores simultáneos; sin embargo, la significancia estadística con $N = 3.708$ descarta que los efectos observados sean atribuibles al azar (Cohen, 1992, 1988).

Comparación de medias por estado (ANOVA y Kruskal-Wallis): Para evaluar si las diferencias observadas en las medias de temperatura e IPI entre los tres estados de condición son estadísticamente significativas, se aplicaron pruebas de comparación de medias, tanto paramétricas (ANOVA de una vía) como no paramétricas (Kruskal-Wallis),

dado que la distribución de las variables no cumple estrictamente los supuestos de normalidad. Los resultados se presentan en la siguiente tabla.

Tabla 8.

Pruebas de comparación de medias entre estados de condición ($p < 0,05$; ** $p < 0,01$).*

Variable	ANOVA F	p-valor	Kruskal-Wallis H	p-valor
Temperatura	3,837	0,022*	9,274	0,010**
IPI	2,935	0,053 (marginal)	6,272	0,043*

La temperatura muestra diferencias significativas entre estados tanto en la prueba paramétrica ($F = 3,837$, $p = 0,022$) como en la no paramétrica ($H = 9,274$, $p = 0,010$). El IPI resulta marginalmente significativo en el ANOVA ($p = 0,053$) pero alcanza la significancia convencional en la prueba de Kruskal-Wallis ($H = 6,272$, $p = 0,043$), lo que sugiere que la relación es más evidente cuando se relajan los supuestos de normalidad y homocedasticidad (Variabilidad de errores no necesariamente constante).

Regresión logística binaria (Normal vs. Anómalo): Se ajustó un modelo de regresión logística binaria donde la variable dependiente fue el estado binario del activo (0 = Normal, 1 = Anómalo, es decir, Pronta Atención o Urgente) y las variables independientes fueron la temperatura ambiente y el IPI del sector caucho y plástico. La siguiente tabla presenta los resultados del modelo.

Tabla 9.

Modelo de regresión logística binaria ($p < 0,05$; ** $p < 0,01$).*

Variable	Coef.	Error Est.	z	p-valor	OR	IC 95 %
Constante	-1,197	1,092	-1,10	0,273	0,302	[0,036; 2,566]

Variable	Coef.	Error Est.	z	p-valor	OR	IC 95 %
Temperatura	0,038	0,019	1,99	0,047*	1,039	[1,001; 1,078]
IPI	-0,002	0,006	-0,34	0,737	0,998	[0,987; 1,009]

El modelo revela que la temperatura ambiente es un predictor estadísticamente significativo de la probabilidad de estado anómalo ($z = 1,99$, $p = 0,047$). El odds ratio (OR) de 1,039 indica que, por cada grado centígrado de incremento en la temperatura ambiente, la probabilidad de que un activo se encuentre en estado de Pronta Atención o Urgente aumenta un 3,9 % (intervalo de confianza del 95 %: 0,1 % a 7,8 %). Si bien el efecto es modesto en magnitud, su significancia estadística en un modelo multivariante confirma que la temperatura aporta información predictiva independiente sobre la condición de las máquinas.

El IPI no alcanza la significancia en el modelo logístico binario ($p = 0,737$), lo que sugiere que su efecto es más sutil y se manifiesta con mayor claridad en pruebas no paramétricas y categóricas que en este modelo logístico.

Análisis por tipo de diagnóstico: Para profundizar en la comprensión de los patrones encontrados, se desagregó el análisis por tipo de diagnóstico principal, evaluando las medias de temperatura e IPI asociadas a cada categoría diagnóstica. La siguiente tabla presenta los resultados para los diagnósticos con mayor frecuencia.

Tabla 10.

Temperatura e IPI promedio por diagnóstico principal.

Diagnóstico	N	Temp. Media (°C)	IPI Media
Normal (Línea Base)	2.141	29,24	120,57

Diagnóstico	N	Temp. Media (°C)	IPI Media
Soltura Estructural	123	30,77	115,47
Soltura/baja rigidez estructural	161	30,52	117,07
Desbalanceo	131	30,43	117,24
Holgura rotativa	205	29,32	120,36
Lubricación inadecuada	83	29,26	122,40
Desgaste de rodamiento	169	29,00	120,67
Debilidad estructural	85	27,82	125,13
Holgura no rotativa	106	27,68	124,59

El análisis por tipo de diagnóstico revela un patrón diferenciado de notable interés. Los diagnósticos asociados a esfuerzos dinámicos (soltura estructural (30,77 °C), soltura/baja rigidez estructural (30,52 °C) y desbalanceo (30,43 °C)) presentan temperaturas medias significativamente superiores la línea base de las máquinas normales (29,24 °C), acompañadas de un IPI inferior (115,47 a 117,24 vs. 120,57). Este patrón sugiere que estos modos de falla se concentran en periodos de alta temperatura y menor actividad industrial.

En contraste, los diagnósticos de debilidad estructural (27,82 °C) y holgura no rotativa (27,68 °C) muestran el patrón inverso: temperaturas medias inferiores a la línea base y un IPI superior (124,59 a 125,13 vs. 120,57), asociándose con periodos más fríos y de mayor producción. Este hallazgo sugiere que los mecanismos mediante los cuales las variables externas influyen en la condición de los activos no son uniformes, sino que

operan diferencialmente según el modo de falla, abriendo líneas de investigación específicas para cada tipo de diagnóstico.

Análisis de resultados

La adopción del enfoque desagregado (N = 3.708 registros individuales) constituyó una decisión metodológica determinante en esta investigación. Al preservar la granularidad individual de cada medición de activo, el análisis reveló relaciones estadísticamente significativas que permanecían ocultas en los datos consolidados por día de medición o por periodo de análisis superior. Este hallazgo tiene implicaciones tanto para la validez de los resultados obtenidos como para la práctica futura del análisis de datos en mantenimiento predictivo.

La temperatura como un predictor significativo: El odds ratio de 1,039 ($p = 0,047$) obtenido en la regresión logística binaria confirma la hipótesis de que la temperatura ambiente influye en la condición de las máquinas rotativas. Este resultado puede interpretarse en términos del mecanismo causal más evidente: la composición del lubricante. A mayor temperatura ambiente, la composición del lubricante cambia, reduciendo la película protectora entre superficies metálicas y, en consecuencia, incrementando la fricción, el desgaste y los niveles de vibración.

Este hallazgo es consistente con la literatura especializada. (Serrato et al., 2007) documentaron experimentalmente el efecto de la temperatura sobre los niveles de vibración en rodamientos, demostrando que incrementos de temperatura producen cambios medibles en los espectros de vibración. Más recientemente, (Yeh et al., 2025) confirmaron que la relación temperatura-humedad-fricción es un factor relevante en la degradación de componentes mecánicos. El presente estudio aporta evidencia empírica

de campo, sobre datos operativos reales, de que esta relación se manifiesta a escala del parque de activos de una empresa de manufactura de empaques.

Patrones diferenciados por tipo de diagnóstico: El análisis por tipo de diagnóstico reveló que no todos los modos de falla responden de igual manera a las variables externas, constituyendo un hallazgo de especial valor para la práctica del mantenimiento predictivo. Los diagnósticos de soldadura estructural y desbalanceo se concentran en periodos de alta temperatura y baja producción (IPI bajo), mientras que los diagnósticos de holgura no rotativa y debilidad estructural se asocian con periodos más fríos y de mayor actividad productiva.

Este patrón diferenciado sugiere al menos dos mecanismos de acción distintos. Por un lado, los esfuerzos dinámicos (soldadura, desbalanceo) podrían verse maximizados por la reducción de viscosidad del lubricante en condiciones de alta temperatura, lo que incrementa las vibraciones y facilita la detección de estos modos de falla. Por otro lado, los diagnósticos de tipo estructural (debilidad, holgura no rotativa) podrían estar más asociados a fatiga mecánica acumulada durante periodos de alta carga productiva (IPI elevado), manifestándose con mayor frecuencia cuando la producción es intensa y las máquinas operan más horas o con mayor esfuerzo.

Estos hallazgos abren la puerta a modelos predictivos específicos por modo de falla, donde las variables externas se incorporen como predictores con pesos diferenciados según el tipo de diagnóstico esperado.

Respuesta a la pregunta de investigación.

Con base en los resultados obtenidos a nivel de activo individual ($N = 3.708$), se confirma que las variables externas sí influyen estadísticamente en la condición de las máquinas rotativas. La temperatura ambiente es un predictor significativo del estado anómalo ($OR = 1,039$, $p = 0,047$ en regresión logística binaria), las diferencias de

temperatura entre estados son significativas (ANOVA $p = 0,022$; Kruskal-Wallis $p = 0,010$), y el IPI sectorial diferencia significativamente los estados de condición en pruebas no paramétricas (Kruskal-Wallis $p = 0,043$).

La integración de estas variables externas con los datos técnicos de diagnóstico de máquinas genera valor agregado cuantificable para las empresas prestadoras de servicios predictivos, proporcionando una capa adicional de información contextual que enriquece la interpretación de las condiciones de los activos y permite diseñar estrategias de monitoreo más inteligentes y proactivas.

Propuesta de solución a la problemática

Situación actual: Las empresas prestadoras de servicios de mantenimiento predictivo, como A-MAQ S.A., operan actualmente un modelo de análisis centrado exclusivamente en los datos técnicos de las máquinas: vibraciones, temperaturas de componentes, corrientes eléctricas y otros parámetros de condición medidos directamente en los activos. Las recomendaciones de mantenimiento se emiten con base en el análisis de estos datos internos, sin considerar el contexto ambiental o macroeconómico bajo el cual operan las máquinas.

Sin embargo, los resultados de la presente investigación demuestran (con significancia estadística) que variables externas como la temperatura ambiente ($p = 0,047$ en regresión logística, $OR = 1,039$) y el Índice de Producción Industrial del sector (Kruskal-Wallis $p = 0,043$) se asocian con el estado de condición de los activos. Esta evidencia abre la oportunidad de incorporar información contextual que hasta ahora ha permanecido desaprovechada en la toma de decisiones de mantenimiento.

Oportunidades identificadas: Los hallazgos estadísticos de esta investigación revelan tres oportunidades concretas para mejorar la gestión del mantenimiento predictivo:

1. La temperatura como predictor significativo ($OR = 1,039$) permite construir alertas basadas en pronósticos meteorológicos. Si se pronostica una ola de calor, la empresa puede anticipar un incremento en la probabilidad de estados anómalos y programar verificaciones adicionales de lubricación y monitoreo de activos críticos.
2. La relación IPI-condición (Kruskal-Wallis $p = 0,043$) permite ajustar las frecuencias de monitoreo según el ciclo productivo del sector. En periodos de alta producción, el estrés mecánico sobre los activos se incrementa, justificando un monitoreo más frecuente.
3. Los patrones diferenciados por diagnóstico abren la puerta a modelos predictivos específicos por modo de falla, donde las variables externas se incorporen como predictores con pesos diferenciados según el tipo de anomalía. Esto no se aborda a profundidad en esta investigación.

Propuesta Índice de riesgo operativo (IROI): Se propone la creación de un sistema de indicadores denominado Índice de Riesgo Operativo Integrado (IROI), compuesto por tres indicadores complementarios que integran los datos técnicos de diagnóstico con las variables externas validadas estadísticamente en esta investigación. Cada indicador responde a una dimensión específica del riesgo operativo y, en conjunto, proporcionan una visión holística de la condición del parque de activos. Para evitar falsas alarmas, el IROI se construye con ponderación asimétrica (60% SCP + 25% IEA + 15% IPP) y con reglas jerárquicas: la recomendación de parada de planta sólo se activa cuando el SCP supera el umbral crítico ($> 0,5$) y al menos uno de los indicadores contextuales confirma la tendencia durante tres días consecutivos. Los indicadores contextuales cumplen una función de anticipación y priorización, pero nunca sustituyen al SCP como árbitro final de la decisión operativa.

Indicador 1: Score de Condición Ponderado (SCP): El Score de Condición

Ponderado corresponde al ScoreDia ya calculado en el dataset, que sintetiza el estado de todos los activos medidos en un día específico en un único valor entre 0 y 1. Un SCP de 0 indica que todos los activos se encontraron en estado Normal; un SCP de 1 indicaría que todos se encontraron en estado Urgente. Se propone una visualización tipo semáforo:

- Verde ($SCP < 0,30$): condición general satisfactoria.
- Amarillo ($0,30 \leq SCP \leq 0,50$): nivel de alerta moderado.
- Rojo ($SCP > 0,50$): situación crítica.

Indicador 2: Índice de Exposición Ambiental (IEA): El Índice de Exposición

Ambiental cuantifica el nivel de estrés térmico al que están expuestos los activos, basándose en la temperatura ambiente normalizada. La fórmula propuesta sería:

$$IEA = \frac{T_{actual} - T_{mín}}{T_{máx} - T_{mín}}$$

donde $T_{mín}$ y $T_{máx}$ corresponden a los valores extremos del rango histórico de temperaturas registrado en la estación meteorológica de referencia. Este indicador está respaldado estadísticamente por el odds ratio de 1,039 ($p = 0,047$) obtenido en la regresión logística, que confirma que cada incremento de temperatura se asocia con un aumento en la probabilidad de estado anómalo. Cuando el IEA supera 0,75, se sugiere la activación de protocolos de verificación del programa de lubricación y el aumento de la frecuencia de monitoreo de activos con diagnósticos previos de soldadura estructural o desbalanceo.

Indicador 3: Índice de Presión Productiva (IPP): El Índice de Presión Productiva

cuantifica el nivel de actividad industrial del sector, basándose en el IPI normalizado del sector caucho y plástico. La fórmula propuesta sería:

$$IPP = \frac{IPI_{actual} - IPI_{min}}{IPI_{max} - IPI_{min}}$$

Un IPP elevado ($> 0,75$) indica que el sector se encuentra en un periodo de alta producción, lo que implica mayor carga operativa sobre los equipos, mayor número de horas de funcionamiento y, potencialmente, menor disponibilidad de ventanas de mantenimiento. En estos periodos, los resultados de la investigación muestran una mayor prevalencia de diagnósticos de debilidad estructural y holgura no rotativa, lo que justifica un monitoreo más frecuente y focalizado.

Dashboard en Power BI: Se propone la implementación de los tres indicadores en un dashboard interactivo desarrollado en Power BI, con los siguientes componentes:

- Panel central con indicadores tipo KPI: Visualización simultánea del SCP, IEA e IPP con indicadores tipo semáforo y tendencias de los últimos 30 días.
- Serie temporal del IROI combinado: Gráfico de líneas que muestre la evolución histórica de los tres indicadores superpuestos, permitiendo identificar patrones estacionales y correlaciones visuales entre picos de temperatura, ciclos de producción y deterioro de la condición.
- Tabla de alertas condicionadas: Sistema de alertas inteligentes basado en combinaciones de indicadores. Por ejemplo: si el IEA es alto Y el SCP muestra tendencia ascendente, se genera una alerta de verificación del programa de lubricación. Si el IPP es alto Y hay activos con diagnóstico previo de debilidad estructural, se genera una alerta de monitoreo prioritario.
- Desglose por tipo de diagnóstico: Panel filtrable que muestre la distribución de diagnósticos por rangos de temperatura e IPI, permitiendo al analista identificar los modos de falla más sensibles a las condiciones externas.

- Matriz de recomendaciones prescriptivas: Tabla dinámica que, en función de los valores actuales de los tres indicadores, sugiera acciones específicas: ajuste de intervalos de lubricación, incremento de frecuencia de monitoreo, revisión de activos con diagnósticos sensibles a temperatura, entre otras.

La implementación de este dashboard permitiría a A-MAQ S.A. y a empresas similares transitar de un modelo reactivo-descriptivo ("¿cuál es el estado actual de la máquina?") hacia un modelo proactivo-prescriptivo ("¿qué condiciones externas podrían afectar la condición de los activos y qué acciones preventivas deben tomarse?"), aprovechando la evidencia estadística generada en esta investigación para fundamentar cada recomendación. Las imágenes a continuación presentan una propuesta de diseño de dashboard abordada con los datos disponibles en el dataset de este estudio:

Figura 5.

Propuesta de diseño de dashboard en PowerBI indicadores exógenos.




Figura 6.
Propuesta de diseño de dashboard en PowerBI indicadores de estado y recomendaciones.



El sistema de indicadores propuesto, que articula el score diario de condición de las máquinas con el índice exógeno de actividad (temperatura e índice de producción industrial) y con la productividad de la planta, materializado en un tablero de control diseñado en Power BI, al integrar en una sola vista la información técnica de diagnóstico, las variables externas y los indicadores de desempeño, puede facilitar la identificación de jornadas de alto riesgo operativo y la priorización de decisiones sobre programación de turnos y mantenimiento.

Discusión y Conclusiones

Discusión: El hallazgo principal de esta investigación es que la granularidad del análisis importa de manera determinante: al nivel de activo individual, se revelaron relaciones estadísticamente significativas entre variables externas (temperatura

ambiente, IPI sectorial) y el estado de condición de las máquinas rotativas, relaciones que el análisis agregado por día había ocultado completamente. Este resultado tiene implicaciones metodológicas que trascienden el presente estudio y que aplican a cualquier investigación que vincule variables contextuales con datos de condición de activos industriales.

La decisión de priorizar la temperatura ambiente y el índice de producción industrial responde no solo a su validación por expertos, sino también a la necesidad de mantener una conexión explícita con el entorno macroeconómico y productivo del sector, coherente con la naturaleza de un estudio de maestría en inteligencia de negocios.

La temperatura como predictor significativo ($OR = 1,039$, $p = 0,047$) confirma lo reportado por (Serrato et al., 2007) sobre el efecto de la temperatura en los niveles de vibración de rodamientos, quienes demostraron experimentalmente que incrementos de temperatura producen cambios medibles en los espectros vibracionales. Asimismo, es consistente con los hallazgos de (Yeh et al., 2025) sobre la relación entre temperatura, humedad y fricción en componentes mecánicos. El presente estudio aporta la validación empírica de campo de estos mecanismos, sobre datos operativos reales de 413 máquinas rotativas monitoreadas durante cuatro años, extendiendo la evidencia de laboratorio al contexto industrial.

El IPI del sector caucho y plástico, como variable macroeconómica, mostró significancia estadística en las pruebas no paramétricas (Kruskal-Wallis $H = 6,272$, $p = 0,043$), aunque no alcanzó significancia en la regresión logística binaria ($p = 0,737$). Esta aparente inconsistencia se explica por la naturaleza del efecto: la relación entre el IPI y la condición no es lineal, sino que se manifiesta con mayor claridad cuando se analizan las distribuciones completas de los estados mediante pruebas de rango o categóricas. Este resultado confirma la pertinencia de incluir el ritmo de producción sectorial como variable

de contexto operativo, aunque con la precaución de que su efecto se modela mejor mediante enfoques no paramétricos que mediante regresión logística convencional.

La condición de un activo rotativo es el resultado emergente de la interacción de factores intrínsecos (diseño, materiales, edad), operativos (carga, velocidad, ciclos) y de mantenimiento (intervalos, calidad de lubricación, alineación). En este contexto, la identificación de un efecto significativo para una variable ambiental individual constituye un avance en la comprensión de los determinantes externos de la condición mecánica.

Limitaciones del estudio: La presente investigación presenta limitaciones que deben considerarse al interpretar sus resultados:

- Pseudorreplicación: las observaciones no son estrictamente independientes, dado que un mismo activo fue medido en múltiples ocasiones (promedio de 9 mediciones por activo). Aunque este promedio relativamente bajo mitiga la severidad de la pseudorreplicación, un enfoque más riguroso requeriría modelos de efectos mixtos que controlen por la estructura anidada de los datos (mediciones dentro de activos).
- Frecuencia irregular de muestreo: las mediciones no se realizaron con periodicidad fija, sino según la programación operativa y disponibilidad de las máquinas del cliente de A-MAQ S.A., lo que introduce variabilidad en los intervalos entre observaciones de un mismo activo.
- Muestra de una sola empresa: los datos provienen exclusivamente de A-MAQ S.A. y de uno de sus clientes del sector de manufactura de empaques en el Área Metropolitana de Medellín, lo que limita la generalización de los resultados a otros sectores, regiones o empresas.
- Variables intermedias no medidas: el mecanismo causal postulado (temperatura → propiedades del lubricante → vibraciones → condición) implica variables intermedias

que no fueron medidas directamente, como la viscosidad real del lubricante, la carga del motor al momento de la medición o la calidad de la energía eléctrica.

- Periodo limitado de variables externas: la temperatura e IPI cubren el mismo periodo del dataset, pero la resolución temporal difiere (temperatura diaria, IPI mensual), lo que implica que el IPI se repite para todos los días de un mismo mes.

Conclusiones.

Conclusión 1 — Objetivo Específico 1: Proceso de obtención de datos: Se documentó el proceso completo de obtención de datos técnicos de diagnóstico por análisis de vibraciones, identificando el flujo desde la medición en campo con equipos portátiles hasta el almacenamiento y procesamiento de la información, para una base de 413 activos rotativos monitoreados entre julio de 2021 y julio de 2025. El proceso comprende la programación de rutas de monitoreo, la adquisición de señales de vibración, el procesamiento espectral y la emisión de diagnósticos según criterios normalizados (International Organization for Standardization, 2016, 2018), generando un registro estructurado que incluye el estado de condición (Normal, Pronta Atención, Urgente) y el diagnóstico técnico de cada activo.

Conclusión 2 — Objetivo Específico 2: Identificación de variables externas: Se identificaron y validaron, mediante el juicio de 10 expertos en monitoreo de condición (CBM), la temperatura ambiente y el Índice de Producción Industrial (IPI) del sector caucho y plástico como las variables externas para integrar con los datos técnicos de diagnóstico. El análisis a nivel de activo individual ($N = 3.708$) confirmó que ambas variables presentan relaciones estadísticamente significativas con el estado de condición de las máquinas: la temperatura con $p = 0,006$ (Pearson) y $p = 0,002$ (Spearman), y el IPI con $p = 0,024$ (Pearson) y $p = 0,023$ (Spearman). La validación estadística de ambas

variables en el dataset de campo refuerza la pertinencia de la selección realizada por los expertos.

Conclusión 3 — Objetivo Específico 3: Modelo de integración: Se desarrolló un modelo de integración que unifica 3.708 registros individuales de diagnóstico de máquinas con series temporales de temperatura ambiente (IDEAM, estación Medellín) e IPI del sector caucho y plástico (DANE), utilizando la fecha como campo de enlace y preservando la granularidad individual de cada medición. La regresión logística binaria identificó la temperatura como predictor significativo del estado anómalo ($OR = 1,039$, $p = 0,047$, IC 95 % [1,001; 1,078]), confirmando que por cada grado centígrado de incremento en la temperatura ambiente, la probabilidad de encontrar una máquina en estado de Pronta Atención o Urgente aumenta un 3,9 %. Las pruebas de comparación de medias confirmaron diferencias significativas de temperatura (Kruskal-Wallis $p = 0,010$) e IPI (Kruskal-Wallis $p = 0,043$) entre estados de condición, y el análisis por diagnóstico reveló patrones diferenciados según el modo de falla. La metodología propuesta para la construcción de este modelo abre la puerta para implementar un dataset escalable a más mediciones, máquinas, industrias y demás parámetros o variables analizadas como candidatas o que sean identificadas como elementos de valor para enriquecer los planes de mantenimiento de las empresas de manufactura.

Conclusión 4 — Objetivo Específico 4: Herramienta de visualización: Se diseñaron tres indicadores de valor respaldados por los hallazgos estadísticos de la investigación: el Score de Condición Ponderado (SCP), el Índice de Exposición Ambiental (IEA) y el Índice de Presión Productiva (IPP). Estos indicadores constituyen el Índice de Riesgo Operativo Integrado (IROI), y se propuso su implementación en un dashboard Power BI con alertas condicionadas, serie temporal combinada, desglose por diagnóstico y matriz de recomendaciones prescriptivas. La herramienta permite transitar de un

enfoque descriptivo del mantenimiento predictivo hacia un enfoque prescriptivo que incorpora el contexto ambiental y macroeconómico.

Conclusión general: Desde la perspectiva de negocio, los hallazgos de esta investigación habilitan a A-MAQ S.A. para transitar de una oferta de servicios predictivos centrada en datos técnicos internos hacia una propuesta de valor premium que integra inteligencia contextual (ambiental y macroeconómica). La evidencia estadística obtenida ($OR = 1,039$, $p = 0,047$ para temperatura; $p = 0,043$ para IPI en Kruskal-Wallis) permite sustentar cuatro puntos sobre implicaciones prácticas para el cliente, el primero de ellos es la anticipación de modos de falla específicos como la soldadura estructural y desbalanceo durante olas de calor; el segundo es la optimización del calendario de monitoreo en función del ciclo productivo sectorial; otro de los beneficios es la reducción proyectada del tiempo de parada no planificada gracias a alertas condicionales del IROI; y finalmente diferenciación frente a competidores locales al ofrecer un tablero prescriptivo que no se limita a describir el estado actual, sino que recomienda acciones con base en el contexto. Para A-MAQ S.A., esto representa una oportunidad para fortalecer su propuesta de valor y avanzar hacia un modelo de servicio con mayor diferenciación en el segmento de manufactura de empaques.

A partir de los hallazgos obtenidos, y de las limitaciones identificadas, también pueden proponerse algunas líneas de profundización futura: (1) Desarrollar modelos predictivos específicos por modo de falla, donde las variables externas se incorporen con pesos diferenciados según el tipo de diagnóstico esperado; (2) Incorporar variables externas adicionales como humedad relativa, contaminación particulada y eventos de calidad de la energía (sags y swells), según la disponibilidad de registros PQM; (3) Replicar el estudio en múltiples empresas y sectores para validar la generalización de los hallazgos; (4) Explorar una granularidad horaria del dataset para evaluar efectos durante el día de la

temperatura sobre la condición; y (5) Integrar variables operativas internas al modelo, tales como horas acumuladas de operación, carga, fecha del último mantenimiento y edad del activo, con el fin de detectar y aplicar otros predictores significativos para el modelo. Con ello, se fortalecería el modelo propuesto y se ampliaría su capacidad para soportar decisiones prescriptivas sobre la operación y el mantenimiento de los activos.

Referencias bibliográficas

- Achouch, M., Dimitrova, M., Ziane, K., Sattarpanah Karganroudi, S., Dhouib, R., Ibrahim, H., & Adda, M. (2022). On Predictive Maintenance in Industry 4.0: Overview, Models, and Challenges. In *Applied Sciences (Switzerland)* (Vol. 12, Number 16). MDPI. <https://doi.org/10.3390/app12168081>
- Agarwal, H., & Agarwal, R. (2017). *Saudi Journal of Humanities and Social Sciences First Industrial Revolution and Second Industrial Revolution: Technological Differences and the Differences in Banking and Financing of the Firms*. <https://doi.org/10.21276/sjhss.2017.2.11.7>
- A-MAQ S.A. (2025). *Portafolio de servicios de mantenimiento predictivo*. <https://www.a-maq.com>
- Bagavathiappan, S., Lahiri, B. B., Saravanan, T., Philip, J., & Jayakumar, T. (2013). Infrared thermography for condition monitoring – A review. *Infrared Physics & Technology*, 60, 35–55. <https://doi.org/10.1016/j.infrared.2013.03.006>
- Barbieri, G., Laserna, J., & Mateus, L. M. (2024). Towards a Business Intelligence Application for Evidence-based Maintenance. *IFAC-PapersOnLine*, 58(8), 37–42. <https://doi.org/10.1016/j.ifacol.2024.08.047>

- Chiacchio, F., De Sanis, R. A., Gunnella, V., & Lebastard, L. (2023). How have higher energy prices affected industrial production and imports? *European Central Bank Economic Bulletin*, (1).
- Coandă, P., Avram, M., & Constantin, V. (2020). A state of the art of predictive maintenance techniques. *IOP Conference Series: Materials Science and Engineering*, 997(1). <https://doi.org/10.1088/1757-899X/997/1/012039>
- Cohen, J. (1992). A power primer. *Psychological Bulletin*, 112(1), 155–159. <https://doi.org/10.1037/0033-2909.112.1.155>
- Cohen, Jacob. (1988). *Statistical power analysis for the behavioral sciences*. Psychology Press, Taylor & Francis Group. <http://www.utstat.toronto.edu/~brunner/oldclass/378f16/readings/CohenPower.pdf>
- Curto Diaz, J. (2016). *Introducción al business intelligence*. Editorial UOC. <https://elibro.net/es/lc/bibliotecaean/titulos/101030>
- DANE. (2025). *Índice de producción industrial (IPI) Históricos*. <https://www.dane.gov.co/index.php/estadisticas-por-tema/industria/indice-de-produccion-industrial-ipi/indice-de-produccion-industrial-ipi-historicos>
- Eurostat. (2024). *Industrial production (volume) index overview*.
- Fried, S., & Lagakos, D. (2020). *NBER WORKING PAPER SERIES ELECTRICITY AND FIRM PRODUCTIVITY: A GENERAL-EQUILIBRIUM APPROACH* (27081). <http://www.nber.org/papers/w27081>
- Hernández Sampieri, R., Fernández Collado, C., María del Pilar Baptista Lucio, D., & Méndez Valencia Christian Paulina Mendoza Torres, S. (2014). *Metodología de la Investigación* (6th ed.). Mc Graw Hill Education.
- Huda, A. S. N., & Taib, S. (2013). Application of infrared thermography for predictive/preventive maintenance of thermal defect in electrical equipment. *Applied*

Thermal Engineering, 61(2), 220–227.

<https://doi.org/10.1016/j.applthermaleng.2013.07.028>

IDEAM. (2026, February 12). *Consulta y Descarga de Datos Hidrometeorológicos*.

<http://dhime.ideam.gov.co/atencionciudadano/>

IEEE. (2019). *IEEE Recommended Practice for Monitoring Electric Power Quality*. IEEE.

<https://doi.org/10.1109/IEEESTD.2019.8796486>

Ilyana Ismarau Tajuddin, N., Abas, U.-H., Azhar Aziz, K., Nor Haizan Nor, R., Aziyatul

Izni, N., Nuruddin Sudin, M., Aqilah Hazirah Mohd Anim, N., & Md Noor, N. (2025).

Content Validity Assessment Using Aiken's V: Knowledge Integration Model for

Blockchain in Higher Learning Institutions. *IJACSA) International Journal of*

Advanced Computer Science and Applications, 16(6), 601–608.

www.ijacsa.thesai.org

International Organization for Standardization. (2016). *International Standard ISO20816-*

1 - Mechanical vibration-Measurement and evaluation of machine vibration-Part 1:

General guidelines. www.iso.org/standard/68816.html

International Organization for Standardization. (2018). *International Standard ISO 17359*

- Condition monitoring and diagnostics of machines-General guidelines. [www.iso.org](http://www.iso.org/standard/68816.html)

Kazemi, A., Mohamed, A., Shareef, H., & Zayandehroodi, H. (2013). Review of Voltage

Sag Source Identification Methods for Power Quality Diagnosis. *PRZEGLĄD*

ELEKTROTECHNICZNY.

Kokla, M., Virtanen, J., Kolehmainen, M., Paananen, J., & Hanhineva, K. (2019).

Random forest-based imputation outperforms other methods for imputing LC-MS

metabolomics data: a comparative study. *BMC Bioinformatics*, 20(1), 492.

<https://doi.org/10.1186/s12859-019-3110-0>

- Li, Y., Peng, S., Li, Y., & Jiang, W. (2020). A review of condition-based maintenance: Its prognostic and operational aspects. *Frontiers of Engineering Management*, 7(3), 323–334. <https://doi.org/10.1007/s42524-020-0121-5>
- Loewenthal, S. H., & Moyer, D. W. (1978). *FILTRATION EFFECTS ON BALL BEARING LIFE AND CONDITION IN A CONTAMINATED LUBRICANT* (1161). <https://ntrs.nasa.gov/citations/19790039233>
- Loewenthal, S. H., Moyer, D. W., & Sherlock, J. J. (1978). *Effect of Filtration on Rolling-Element-Bearing Life in a Contaminated Lubricant Environment* (1272). <https://ntrs.nasa.gov/citations/19780020514>
- MANDI, M. (2025). Predictive Maintenance Approach, Vibration Analysis and Fault Detection in an Industrial Fan Motor. *International Journal of Research and Scientific Innovation*, XII(IV), 292–302. <https://doi.org/10.51244/IJRSI.2025.12040029>
- Merino-Soto, C. (2023). Aiken's V Coefficient: Differences in Content Validity Judgments. *MHSalud*, 20(1). <https://doi.org/10.15359/mhs.20-1.3>
- Moleǵda, M., Małysiak-Mrozek, B., Ding, W., Sunderam, V., & Mrozek, D. (2023). From Corrective to Predictive Maintenance—A Review of Maintenance Approaches for the Power Industry. In *Sensors* (Vol. 23, Number 13). Multidisciplinary Digital Publishing Institute (MDPI). <https://doi.org/10.3390/s23135970>
- Nagarajan, V., & Tayong, A. (n.d.). *Data Visualization and Predictive Analytics in Manufacturing: A New Paradigm in Maintenance*. <https://doi.org/10.1109/ICPIDS65698.2024.00025>
- Nunes, P., Santos, J., & Rocha, E. (2023). Challenges in predictive maintenance – A review. In *CIRP Journal of Manufacturing Science and Technology* (Vol. 40, pp. 53–67). Elsevier Ltd. <https://doi.org/10.1016/j.cirpj.2022.11.004>

OECD. (2025). *Industrial production (Indicator)*. OECD Data.

<https://data.oecd.org/industry/industrial-production.htm>

Olarte, W., Botero, M., & Cañon, B. (2010). Técnicas de mantenimiento predictivo utilizadas en la industria. *Scientia et Technica Año XVI*, 45.

Oviedo, S., Quiroga, J., & Borrás, C. (2025). Motor current signature analysis and negative sequence current based stator winding short fault detection in an induction motor. *DYNA: Revista de La Facultad de Minas. Universidad Nacional de Colombia. Sede Medellín*, 78, 214–220.

Rincón, H., Caicedo, E., & Rodríguez, N. (2007, June). EXCHANGE RATE PASS-THROUGH EFFECTS: A DISAGGREGATE ANALYSIS OF COLOMBIAN IMPORTS OF MANUFACTURED GOODS. *Ensayos Sobre Política y Economía*, Vol. 25, Num. 54.

Rowland, P. (n.d.). *Exchange Rate Pass-Through to Domestic Prices: The Case of Colombia* (254). Retrieved December 14, 2025, from <https://www.banrep.gov.co/en/borrador-254>

Serrato, R., Maru, M. M., & Padovese, L. R. (2007). Effect of lubricant viscosity grade on mechanical vibration of roller bearings. *Tribology International*, 40(8), 1270–1275. <https://doi.org/10.1016/j.triboint.2007.01.025>

Shah, A. D., Bartlett, J. W., Carpenter, J., Nicholas, O., & Hemingway, H. (2014). Comparison of random forest and parametric imputation models for imputing missing data using MICE: A CALIBER study. *American Journal of Epidemiology*, 179(6), 764–774. <https://doi.org/10.1093/aje/kwt312>

Sharma, J., Mittal, M. L., & Soni, G. (2024). Condition-based maintenance using machine learning and role of interpretability: a review. *International Journal of System*

Assurance Engineering and Management, 15(4), 1345–1360.

<https://doi.org/10.1007/s13198-022-01843-7>

Sheriff, K. A. I., Hariharan, V., & Mathan Kumar, B. (2020). Review On Condition

Monitoring Of Rotating Machines. *INTERNATIONAL JOURNAL OF SCIENTIFIC & TECHNOLOGY RESEARCH*, 9(2), 2343–2346. www.ijstr.org

Stekhoven, D. J., & Bühlmann, P. (2012). Missforest-Non-parametric missing value imputation for mixed-type data. *Bioinformatics*, 28(1), 112–118.

<https://doi.org/10.1093/bioinformatics/btr597>

Tang, F., & Ishwaran, H. (2017). Random forest missing data algorithms. *Statistical Analysis and Data Mining*, 10(6), 363–377. <https://doi.org/10.1002/sam.11348>

Tenali, N., Babu, D. P. R., & Kumar, K. Ch. K. (2017). Vibrational Analysis in Condition Monitoring and faults Diagnosis of Rotating Shaft - Over View. *International Journal of Advanced Engineering Research and Science*, 4(1), 216–220.

<https://doi.org/10.22161/ijaers.4.1.35>

Wolniak, R., & Grebski, W. (2023). Predictive maintenance – the business analytics usage in Industry 4.0 conditions. *Scientific Papers of Silesian University of Technology Organization and Management Series*, 2023(187).

<https://doi.org/10.29119/1641-3466.2023.187.37>

Wolverton, A., Shadbegian, R., & Gray, W. B. (2022). *The U.S. Manufacturing Sector's Response to Higher Electricity Prices: Evidence from State-Level Renewable Portfolio Standards* (30502). <http://www.nber.org/papers/w30502>

Yeh, J. C., Lee, Y. C., Huang, C. H., Li, M. Y., & Wei, C. C. (2025). Study of Corrosion, Power Consumption, and Wear Characteristics of Herringbone-Grooved Fan Bearings in High-Temperature and High-Humidity Environments. *Lubricants*, 13(6).

<https://doi.org/10.3390/lubricants13060245>