

Intercambiabilidad y canibalización en mantenimiento industrial: perspectivas para gestión de activos con machine learning, big data e inteligencia artificial

Interchangeability and cannibalization in industrial maintenance: perspectives for asset management with machine learning, big data and artificial intelligence

MSc. Juan David Bermúdez Royero ¹

¹  **Universidad de la Guajira**, Facultad de Ingeniería, Programa de Ingeniería Mecánica - Grupo de Investigación DESTACAR, Riohacha, La Guajira Colombia.

Correspondencia: jdbermudez@uniguajira.edu.co

Recibido: 27 mayo 2026. **Revisado:** 26 junio 2026. **Aceptado:** 31 julio 2026. **Publicado:** 03 agosto 2026.

Cómo citar: J. D. Bermúdez Royero, "Intercambiabilidad y canibalización en mantenimiento industrial: perspectivas para gestión de activos con machine learning, big data e inteligencia artificial", *Revista Colombiana de Tecnologías de Avanzada (RCTA)*, vol. 2, no. 48, pp. 199–208, ago. 2026, doi: [10.24054/rcta.v2i48.4514](https://doi.org/10.24054/rcta.v2i48.4514)

Esta obra está bajo una licencia internacional
Creative Commons Atribución-NoComercial 4.0.



Resumen: El presente estudio constituye un capítulo de reflexión sobre las técnicas de intercambiabilidad y canibalización en el mantenimiento industrial, examinando su implementación en la gestión de activos y su correlación con el Big Data y la Inteligencia Artificial. Mediante un enfoque metodológico cualitativo-descriptivo documental, se analizaron 43 fuentes académicas, priorizando literatura del período 2020-2025 y complementando con referencias seminales que sustentan modelos matemáticos y normativos de base (EOQ, RCM, taxonomía de activos, punto de reorden). Los resultados evidencian que la intercambiabilidad reduce costos de mantenimiento entre 25-30% y disminuye intervenciones correctivas hasta en 70%. La integración de sistemas CMMS con IA demostró precisiones superiores al 98% en la predicción de vida útil residual (RUL). La canibalización, aplicada con modelos predictivos basados en Big Data, mantiene disponibilidades operativas superiores al 90%. Los algoritmos LSTM y Random Forest optimizan inventarios de repuestos y la programación preventiva. Se concluye que la articulación de ambas estrategias con tecnologías emergentes maximiza el valor de los activos e incrementa la rentabilidad empresarial.

Palabras clave: big data, canibalización, gestión de activos, intercambiabilidad, inteligencia artificial, mantenimiento industrial.

Abstract: This study is a reflective chapter on interchangeability and cannibalization techniques in industrial maintenance, examining their implementation within asset management and their correlation with Big Data and Artificial Intelligence. Using a qualitative descriptive documentary methodology, 43 academic sources were analyzed, prioritizing literature from 2020–2025 and complemented with seminal references supporting foundational mathematical and normative models (EOQ, RCM, asset taxonomy, reorder point). Results show that interchangeability reduces maintenance costs by 25–30% and cuts corrective interventions by up to 70%. Integration of CMMS with AI achieved

prediction accuracies above 98% for residual useful life (RUL). Cannibalization, when applied with Big Data-based predictive models, maintains operational availability above 90%. LSTM and Random Forest algorithms optimize spare-parts inventories and preventive-scheduling. The study concludes that articulating both strategies with emerging technologies maximizes asset value and increases business profitability.

Keywords: big data, cannibalization, asset management, interchangeability, artificial intelligence, industrial maintenance.

1. INTRODUCCIÓN

Este capítulo analiza la utilidad industrial de la intercambiabilidad y canibalización de componentes, promoviendo políticas organizacionales que las incorporen por sus beneficios en productividad, rentabilidad y reducción de huella de carbono. El mantenimiento industrial constantemente presenta necesidades de optimización de recursos, sostenibilidad ambiental y eficiencia operacional.

En este contexto, la intercambiabilidad y canibalización de componentes, emergen para ser practicas fundamentales que permiten maximizar el valor de los activos y minimizar impactos ambientales en la industria, teniendo en cuenta que el uso estructurado y con tecnología adecuada para estas prácticas, puede transformar significativamente la gestión del mantenimiento y la confiabilidad de los sistemas productivos.

Aunque históricamente percibida como 'canibalismo' negativo, la Intercambiabilidad y Canibalización demuestra en estudios recientes un impacto positivo en sostenibilidad, confiabilidad, costos operacionales y variables industriales críticas. La predicción de Vida Útil Residual (RUL) es intrínseca a este proceso y fundamental para decisiones en Intercambiabilidad y Canibalización. Está vinculada a métodos Big Data que surgen de técnicas como Monitoreo de Condición (CBM), Machine Learning (ML) e Inteligencia Artificial (AI) [1], [2].

En la industria del Caribe colombiano, codificar máquinas según la ISO 14224, usar herramientas digitales y fomentar mejoras culturales en producción y mantenimiento es clave, como mostró una investigación previa al autor en 2015. Sin embargo, fallas en estos aspectos dificultan la intercambiabilidad y fomentan la canibalización, afectando la rentabilidad. El monitoreo de condición con IA y Big Data ha logrado reducir emisiones en un 6% de la huella de carbono [3]-[6]. La

investigación entonces se centrará en responder la pregunta:

¿Cómo controlar la Intercambiabilidad y Canibalización en la gestión del mantenimiento industrial en el marco de la Gestión de Activos mediante el uso de Machine Learning, Big Data e Inteligencia Artificial?

Como aporte original frente a la literatura revisada, este estudio propone el concepto de Unidad Taxonómica de Máquina (UTM), desarrollado por el autor para operacionalizar los niveles taxonómicos 6 a 9 de la norma ISO 14224 dentro de la gestión de activos digitalizada. El resto del desarrollo conceptual se apoya en la síntesis crítica de la literatura consultada sobre intercambiabilidad, canibalización, mantenimiento predictivo y tecnologías emergentes.

2. FUNDAMENTOS TEÓRICOS

Para contextualizar y comprender la importancia de la intercambiabilidad y canibalización en maquinaria industrial, es clave considerar sus limitaciones en mantenimiento, confiabilidad, gestión de activos, tecnología e inventario, y cómo se relacionan entre sí.

2.1. Intercambiabilidad y canibalización

La intercambiabilidad busca mejorar el rendimiento al usar partes de una máquina al adaptarse a otra, sin pérdida de valor; optimizando inventarios desde el punto de vista de referencias y reduciendo costos. Para aplicarla, se debe analizar el comportamiento de las máquinas y conocer datos como ubicación, códigos, horas trabajadas y variables físicas que respaldan su funcionalidad, es decir; se usa en un contexto de mejora continua [7], [8].

Canibalización se conoce como la acción de respuesta reactiva, es decir en el contexto de mantenimiento correctivo; cuando no hay repuestos en el inventario y se cambia de una unidad a otra;

donde se requiere la función de la parte en cuestión, para que esta unidad siga en el proceso productivo ya que la unidad de donde se desmontó; el correctivo tarda en ser mitigado [9].

2.2. Aspectos generales del mantenimiento

2.2.1. Definición de mantenimiento

El mantenimiento industrial consiste en acciones para conservar o restaurar equipos a su estado operativo y extender su vida útil. Según la ISO 14224, se clasifica en preventivo y correctivo, buscando eficiencia, reducción de costos e integridad de los activos para permitir alto rendimiento a bajo costo [10].

2.2.2. Estrategias de mantenimiento

Una estrategia de mantenimiento es un conjunto de reglas basadas en datos operativos para asegurar el funcionamiento de las máquinas. Las más comunes son: Correctivo, Preventivo, Monitoreo de condición, Mantenimiento Centrado en Confiabilidad (RCM) y Mantenimiento basado en Riesgos.

Las estrategias se basan en políticas de mantenimiento, que forman parte de ellas y definen detalladamente las reglas del mantenimiento, es decir; cuándo planearlo, ejecutarlo, controlarlo y hasta decidir finalizar el ciclo de vida de un activo [11]-[14].

2.2.3. Taxonomía y codificación de máquinas

Según ISO 14224, el orden en mantenimiento inicia con la taxonomía, jerarquizando elementos de máquina según su ubicación, categoría, funciones y características operativas.

Como aporte teórico original de este estudio, se propone el término Unidad Taxonómica de Máquina (UTM) para identificar los niveles taxonómicos del 6 al 9 definidos por la norma ISO 14224, que abarcan desde la unidad de equipo hasta el ítem mantenible o componente de la máquina. Este concepto se construye sobre los principios de clasificación taxonómica y codificación reportados en la literatura [15]-[18], pero constituye una propuesta terminológica y operativa propia del autor para facilitar la trazabilidad del ciclo de vida, en especial de fallas y mantenimientos. La siguiente figura (figura 1) muestra estos niveles, donde la codificación refleja ubicación y función específica, en otras palabras, la morfología del código de la UTM.




Fig 1. Interpretación de la jerarquización taxonómica según ISO 14224. **Fuente:** elaboración propia.

2.2.4. Vida residual de una UTM (RUL)

La vida útil residual (RUL) es el tiempo que una UTM puede operar sin fallas. El reto está en predecirla a tiempo para evitar reparaciones o reemplazos caóticos.

La confiabilidad y la expectativa de vida se relacionan con métodos predictivos como MRL y RMRL, base para calcular la RUL [19]-[25].

En la canibalización, se utilizan del modelo matemáticos para el cálculo de la vida útil restante o RUL; se describe en la expresión matemática (1)

$$RUL(t) = L - t \quad (1)$$

donde L representa la vida útil total del componente y t el tiempo transcurrido desde la puesta en servicio, sin incluir factores del contexto operativo de la UTM. Por otra parte, en contextos de intercambiabilidad, esta ecuación se modifica para considerar factores de degradación acumulativa, debido a la definición de intercambiabilidad, es decir; la Vida Útil Residual Efectiva; y se describe en la expresión matemática (2).

$$RUL_{effective}(t) = L \times \eta(t) - \sum(t_{usage_i} \times k_{degradation_i}) \quad (2)$$

donde $\eta(t)$ es el factor de eficiencia a lo largo del tiempo y (k) degradación i-esima, representan los coeficientes de degradación específicos para cada UTM, que provienen del monitoreo de condición [26].

Finalmente, el modelo matemático para el cálculo de RUL incluyen la Vida Media, es decir el promedio de vida de las UTM, Residual (MRL), la cual se describe en la expresión matemática (3).

$$MRL(t) = E[T - t | T > t] = \frac{\int_t^{\infty} [1 - F(x)] dx}{1 - F(t)} \quad (3)$$

Donde $F(x)$ es la función de distribución acumulativa de fallas y T representa el tiempo de falla de la UTM.

2.2.5. CMMS

Los CMMS son softwares para planificar, gestionar y administrar el mantenimiento, con funciones como programación preventiva, análisis correctivo, gestión de repuestos y órdenes de trabajo. Sin embargo, su alcance es limitado, ya que no integran procesos logísticos ni financieros como sí lo hacen los ERP y EAM [29].

2.2.6. Inventarios de UTM

El inventario de repuestos es clave para respaldar el mantenimiento de cada UTM, sin importar su naturaleza. Su gestión asegura la disponibilidad de piezas necesarias para operar con eficiencia, e incluso alcanzar niveles de disponibilidad competitivos a nivel mundial [30].

La gestión busca asegurar la accesibilidad de las UTM, clasificar su criticidad, codificarlas y vincularlas al CMMS bajo ISO 14224. Requiere modelos estadísticos avanzados basados en características específicas. Aunque la restauración depende de factores funcionales, operativos y financieros, el más crítico es el tiempo logístico, especialmente la disponibilidad del inventario [31], [32].

Los modelos matemáticos tradicionales para la gestión de inventarios incluyen el Economic Order Quantity (EOQ), el cual permite determinar la cantidad optima a pedir de una UTM y esta descrito por la expresión matemática (4).

$$EOQ = \sqrt{\frac{2DS}{H}} \quad (4)$$

donde D es la demanda anual, S es el costo de pedido y H es el costo de mantenimiento de inventario [33].

Así también, el Re-Order Point (ROP) el cual permite fijar el nivel crítico de cantidad de una UTM y esta sea reabastecida y es descrito por la expresión matemática (5); donde d es la demanda promedio diaria, L es el lead time y SS es el stock de seguridad [34], [35].

$$ROP = d \times L + SS \quad (5)$$

Los modelos de optimización para inventarios de repuestos intercambiables y canibalizables; incorporaría la función de costo total; la cual se describe en la expresión matemática (6)

$$TC = \sum \left(H_i \times \frac{Q_i}{2} \right) + \sum \left(S_i \times \frac{D_i}{Q_i} \right) + \sum (C_i P_{failure_i}) \quad (6)$$

Donde H_i representa el costo de mantenimiento de inventario, S_i el costo de pedido, D_i la demanda anual, Q_i la cantidad de pedido y C_i el costo por falla [35].

2.3. Gestión de activos

La norma ISO 55000:2024 define las etapas para desarrollar y mejorar un sistema de gestión de activos. La gestión de activos busca obtener valor equilibrando costos, riesgos y oportunidades frente al rendimiento esperado de los activos. ISO 55001 e ISO 55002 destacan elementos claves del porque y como, respectivamente; hacer en el liderazgo de la alta dirección, planificación estratégica, gestión de riesgos y oportunidades, ciclo de vida de los activos, y evaluación del desempeño para su mejora.

2.4. Big data, machine learning e inteligencia artificial

Big Data es un gran volumen de datos, estructurados o no, generados por personas o grupos, que pueden analizarse rápidamente para entender actividades y comportamientos ya que en el contexto industrial se caracteriza por las 5 V's: volumen, velocidad, variedad, veracidad y valor [36].

El Machine Learning usa algoritmos con datos etiquetados y requiere ajustar parámetros con base en conocimientos matemáticos y estadísticos para vincular entradas y salidas. Ya que los algoritmos de machine learning más comunes utilizados en mantenimiento predictivo incluyen, regresión, clasificación, clustering y redes neuronales como la LSTM y otros modelos [37].

La Inteligencia Artificial (IA) se enfoca en desarrollar sistemas capaces de realizar tareas que normalmente requieren inteligencia humana, como aprender, razonar, tomar decisiones y resolver problemas [38]-[40].

3. METODOLOGÍA

La metodología es una revisión narrativa de la literatura, de enfoque cualitativo descriptivo y documental, centrada en la canibalización e intercambiabilidad en la industria, analizando sus efectos en el mantenimiento, la sostenibilidad y la rentabilidad. El estudio, de tipo descriptivo y documental, y explora las variables del problema sin

medición numérica primaria, usando fuentes como libros y artículos [41].

Este estudio documental se basa en fuentes secundarias y en la experiencia profesional del autor, seleccionando los documentos de manera intencional y no probabilística, priorizando el contenido técnico actualizado relevante para el contexto industrial.

Además, la experiencia del autor es fundamental para interpretar críticamente el material revisado, empleando el análisis documental como un proceso de revisión narrativa de la literatura, lo que confirma que el estudio tiene un diseño no experimental [42].

La investigación inició con una revisión bibliográfica centrada en las variables de la pregunta problema y se seleccionó una muestra intencional de 43 fuentes en bases de datos como Scopus, IEEE, múltiples revistas académicas, libros especializados, normas técnicas y repositorios académicos. Los criterios de inclusión fueron: (a) pertinencia temática directa con intercambiabilidad, canibalización, gestión de activos o las tecnologías emergentes abordadas; (b) origen en fuentes indexadas, normativas o institucionales reconocidas; (c) vigencia técnica, priorizando el período 2020-2025, con inclusión de fuentes anteriores cuando sustentan modelos matemáticos o normativos de base. Se excluyeron fuentes no verificables, de divulgación no académica, o sin relación directa con las variables del estudio. Este proceso fue respaldado por la experiencia profesional del autor y estructurado mediante una matriz de sistematización de resultados, que sirvió como soporte para el análisis, la discusión y las conclusiones.

4. RESULTADOS

Aunque el enfoque de esta investigación es cualitativo y descriptivo, se incorporaron resultados numéricos como apoyo al análisis, permitiendo evidenciar tendencias, patrones y relaciones entre las variables de la pregunta del problema. Los valores porcentuales presentados a lo largo de esta sección constituyen una síntesis interpretativa elaborada por el autor a partir de la revisión documental de la literatura consultada [20], [22], [23], [37], [43] y no corresponden a mediciones primarias obtenidas durante el desarrollo de esta investigación.

Estos datos complementan la interpretación cualitativa, para fortalecer las conclusiones sobre la intercambiabilidad y canibalización en el mantenimiento industrial en integración con el Big Data, el Machine Learning y la Inteligencia Artificial en el marco de la gestión de activos:

La norma ISO 14224 brinda un marco común para estandarizar el mantenimiento preventivo y correctivo, permitiendo un lenguaje universal para organizaciones. En la taxonomía es esencial codificar las UTM, debido que es el único medio efectivo de garantizar confiabilidad y trazabilidad en los datos de mantenimiento y operaciones.

La aplicación de cada estrategia depende de decisiones organizacionales; no hay una única mejor opción. Todas están desarrolladas globalmente y se adaptan según las necesidades o pilares que cada industria adopte. El uso de la intercambiabilidad y canibalización brindan resultados estadísticos que permiten tener confiabilidades mayores al 98%, así como también; permiten aumentar la disponibilidad entre un 23 a un 62%.

La integración de CMMS con IA logra resultados destacados, estudios revelan reducciones del 50% en tiempos de respuesta, 30% en costos de mantenimiento y 60% en inactividad no planificada. Mientras que al integrar los EAM y ERP con IA permite gestión holística y contundente de activos con precisión predictiva superior al 90%.

Los métodos de reabastecimiento actuales, como el EOQ y el ROP, carecen de base científica debido que ignoran patrones específicos por UTM del contexto operativo y son recomendaciones de los ERP que vienen por defecto en su algoritmo de desarrollo. En cambio, los modelos matemáticos basados en el contexto operativo afectan directamente los costos de inventario y mantenimiento [43]. La comparación entre sistemas tradicionales evidencia ventajas significativas:

Tabla 1: Resultados comparativos del uso de la inteligencia artificial en los diferentes tipos de soluciones de sistema de control organizacional como CMMS y EAM. Los valores de Tiempo de Respuesta están normalizados respecto a la línea base de 100% correspondiente al CMMS tradicional; un porcentaje menor indica un tiempo de respuesta más rápido.

Sistema	Tiempo de Respuesta	Precisión Predictiva	Reducción de Costos
CMMS TRADICIONAL	100%	65-70%	15-20%

CMMS + IA	550%	85-90%	30-35%
EAM INTEGR ADO	40%	90-95%	35-40%

Fuente: síntesis del autor a partir de la revisión documental de [20], [22], [23], [37], consolidando los rangos reportados en la literatura sobre integración de IA en sistemas CMMS y EAM.

Los sistemas de soporte a la decisión basados en Big Data permiten optimizar las estrategias de canibalización con precisión sin precedentes. Los análisis muestran que la convergencia entre Big Data, Machine Learning e Inteligencia artificial, redefinen los paradigmas tradicionales de mantenimiento industrial.

Los sistemas analíticos avanzados pueden procesar volúmenes de datos superiores a 10TB diarios, identificando patrones de degradación con precisión del 92%. Los algoritmos de Machine Learning demuestran superioridad en la predicción de resultados de mejoramiento de eficiencia con la intercambiabilidad y revelar frecuencias efectivas en el caso de la Canibalización.

Los modelos Random Forest alcanzan precisiones del 97.11% en la detección de fallas, mientras que los algoritmos K-Nearest Neighbors logran 95.2%. Los modelos híbridos que combinan redes LSTM con métodos estadísticos tradicionales muestran las mejores capacidades para predecir patrones de degradación en componentes intercambiables. La precisión en los datos según el modelo utilizado se compara en la tabla 2.

Tabla 2: Tabla 2. Comparativa de precisión según modelo e impacto en la variable de administración en el mantenimiento y gestión de activos.

Modelo	Precisión	Impacto
Random Forest	97.11%	Detección de fallas
LSTM Networks	96.3%	Predicción RUL
K-Nearest Neighbors	95.2%	Clasificación de UTM
Support Vector Machines	94.5%	Análisis de compatibilidad

Fuente: síntesis del autor a partir de la revisión documental de [20], [22], [23], considerando los rangos y tendencias de desempeño reportados para cada modelo en la literatura consultada sobre mantenimiento predictivo.

Los modelos predictivos analizados demuestran capacidad para reducir inventarios hasta 25% mientras mantienen niveles de servicio superiores al 95%. El impacto del Machine Learning en sistemas de inventario se manifiesta en mejoras promedio del 35% en precisión de pronósticos de demanda y reducciones del 28% en costos totales de inventario.

El uso de estas técnicas permitiría el uso de todas UTM de las unidades que están detenidas en taller porque entrarían al inventario durante el tiempo que pernecten en este, ya sea por un preventivo o correctivo; con su RUL disponible.

Muchos cálculos de repuestos carecen de base científica y priorizan almacenar sin evaluar demanda o costo por ausencia, enfocándose solo en la criticidad. Al integrar mantenimiento e inventario, se mejora la confiabilidad, se reducen costos y se optimizan recursos mediante modelos como Markov (MDP), aumentando la disponibilidad de las máquinas.

5. DISCUSIÓN

Los hallazgos discutidos a continuación constituyen una interpretación del autor a partir de la síntesis documental realizada, y no de mediciones primarias obtenidas durante esta investigación.

Interpretación crítica de los hallazgos. Los resultados obtenidos revelan una transformación significativa en la gestión del mantenimiento industrial a partir de la integración de intercambiabilidad y canibalización con tecnologías emergentes. La convergencia entre estas estrategias y el Big Data, el Machine Learning y la Inteligencia Artificial permite superar las limitaciones estructurales de los métodos tradicionales de gestión de activos, particularmente en la trazabilidad de componentes mediante el concepto de UTM propuesto en este estudio. La capacidad de los algoritmos de Machine Learning para procesar variables complejas del contexto operativo explica, en gran medida, por qué estos métodos superan consistentemente el desempeño de los procesos manuales de decisión en intercambiabilidad y canibalización.

Contraste con investigaciones recientes. Los avances en disponibilidad operativa identificados en este estudio (23-62%) representan una mejora sustancial frente a los márgenes reportados en la literatura previa a la adopción masiva de IA en mantenimiento industrial, típicamente asociados a rangos de 10-15% [20], [22], [23]. Esta discrepancia no debe interpretarse como una contradicción metodológica entre estudios, sino como evidencia del salto tecnológico que representan los avances recientes en capacidad de procesamiento y en algoritmos de aprendizaje automático, que han superado barreras computacionales históricas y aprovechan la disponibilidad masiva de datos

industriales para construir modelos predictivos más precisos que los disponibles en la literatura de referencia anterior a 2020. Asimismo, la precisión predictiva de los algoritmos de Machine Learning documentada en este estudio (superior al 95%) es consistente con la tendencia reportada por revisiones recientes sobre estimación de vida útil residual mediante inteligencia artificial [22], [23], reforzando la validez externa de los hallazgos sintetizados.

Limitaciones del estudio. Este trabajo presenta limitaciones que condicionan el alcance de sus conclusiones. En primer lugar, al tratarse de una revisión narrativa de la literatura con muestreo intencional y no probabilístico (según se definió en la Metodología), los hallazgos numéricos presentados constituyen una síntesis interpretativa y no evidencia empírica primaria generada por el autor, por lo que no deben interpretarse como resultados de un estudio experimental o de campo. En segundo lugar, persisten desafíos de implementación no resueltos por la literatura consultada, particularmente en la gestión de datos heterogéneos entre sistemas CMMS, EAM y ERP de distintos proveedores, y en la interpretabilidad de los modelos de Machine Learning para la toma de decisiones operativas por parte de personal no especializado en ciencia de datos. Finalmente, la adopción de estas tecnologías enfrenta barreras organizacionales documentadas en la literatura de gestión del cambio, incluyendo dificultades de integración de sistemas y resistencia organizacional, además de requerimientos de inversión inicial considerables cuyo retorno, según la literatura consultada, se materializa en el mediano plazo.

Brechas en la literatura y líneas de investigación futura. Se identifican brechas relevantes que abren líneas prioritarias de investigación futura, entre ellas: el desarrollo de IA explicable (explainable AI) aplicada al mantenimiento industrial, que permita a los equipos operativos comprender y confiar en las recomendaciones de los modelos predictivos; la definición de estándares de interoperabilidad entre sistemas de gestión de activos que resuelvan el desafío de datos heterogéneos identificado en esta discusión; y la profundización en la gestión de UTM temporales en inventario durante los periodos de inactividad del activo por mantenimiento, como extensión aplicada del concepto propuesto en este estudio.

6. CONCLUSIONES

La conclusión principal de la integración de intercambiabilidad y canibalización en combinación con los métodos analíticos de datos en este estudio permite concluir que los principales hallazgos cualitativos revelan mejoras operacionales sustanciales y consistentes en múltiples dimensiones.

Se destaca una reducción de costos de mantenimiento entre un 25 y 30% gracias a la implementación de Machine Learning (ML).

En cuanto a disponibilidad, la combinación de estrategias de canibalización con inteligencia artificial permite mantener niveles superiores al 90%. Así como también que la Intercambiabilidad no implica confiabilidad al igual que la canibalización, esta solo mejora el rendimiento.

Los sistemas CMMS potenciados con IA demuestran una precisión predictiva excepcional de pronóstico la vida útil de activos con más del 95% de exactitud. Los algoritmos de optimización de inventarios basados en IA logran reducir los niveles de stock en un 25% sin comprometer el servicio.

Como aporte teórico por parte del autor, se tiene el concepto de Unidad Taxonómica de Máquina (UTM) como concepto para mejorar la comprensión del nivel taxonómico que se está trabajando, para así codificar más fácilmente; sin alejarse de las recomendaciones de la ISO 14224, asegurando trazabilidad y control de componentes para eliminar ineficiencias en modelos tradicionales aplicados en mantenimiento.

El único efecto negativo que la canibalización posee es que aumenta la carga de trabajo y se pueden inducir daños en las máquinas por la manipulación mecánica de las UTM.

Así como también la propuesta de política poner en disposición en inventarios temporales en el sistema de control digital de las UTM de las unidades de máquina que estén en espera de finalización de un mantenimiento con su RUL respectivo, según su tipo de mantenimiento de forma que así aumenta la disponibilidad; haciendo la salvedad que estas decisiones incluyen datos integrales como la logística.

Teniendo en cuenta que las principales causas de la canibalización tienen sus orígenes en problemas logísticos de abastecimiento y problemas

financieros de flujo de caja, es muy razonable pretender que la IA nos ayude a procesar el gran volumen de información que emana de los procesos de mantenimiento (MBD - Maintainance Big Data), dentro de una estructura de machine learning, donde los resultados muestren un nivel asertivo de inventarios estandarizados de refacciones que favorezcan a la intercambiabilidad sobre la canibalización.

Se recomienda desarrollar programas de capacitación, aplicar los cambios de forma gradual y establecer marcos éticos para implementar la transformación digital, integrando la intercambiabilidad, canibalización y su fusión con nuevas tecnologías.

Como conclusión, se establece que la integración de la intercambiabilidad, la canibalización, el machine learning, el Big Data y la inteligencia artificial; transforman el mantenimiento industrial de manera positiva ya que generan ventajas reales en los procesos productivos. Esta convergencia no solo mejora las operaciones, sino que aumenta la maximización del valor de los activos, alineándose con la reducción de la huella de carbono y al aumento de la rentabilidad.

REFERENCIAS

- [1] A. Garcia-Garcia, J. Samuel Baixauli-Soler, M. A. Prats, T. Schmidt, and P. M. Mirete-Ferrer, "Citation: Mirete-Ferrer A Review on Machine Learning for Asset Management," 2022, doi: 10.3390/risks.
- [2] M. D. Ramere and O. TimothyLaseinde, "Improving the reliability of power distribution substations equipment for life extension by considering Condition Based Maintenance," in *Procedia Computer Science*, Elsevier B.V., 2024, pp. 2289–2301. doi: 10.1016/j.procs.2024.02.048.
- [3] N. I. Vatin, G. Singh Negi, S. Yellanki, C. Mohan, and N. Singla, "Sustainability Measures: An Experimental Analysis of AI and Big Data Insights in Industry 5.0", doi: 10.1051/bioconf/20248601072.
- [4] Milton Roberto Enríquez Segovia and Yanelis Ramos Alfonso, "Análisis de la gestión del mantenimiento en el motor Hyundai Himsen H21/32," *Reincisol*, 4(7), pp. 2757–2769, Apr. 2025, doi: [https://doi.org/10.59282/reincisol.V4\(7\)2757-2769](https://doi.org/10.59282/reincisol.V4(7)2757-2769).
- [5] Marco Flores Ramírez, Miguel Silva Coronel, and Neicer Campos Vasquez, "Influencia del Aprendizaje Automático en el Mantenimiento Predictivo de Sistemas HVAC," May 2025, doi: <https://doi.org/10.70414/cyt.v23i2.107>.
- [6] Bermudez, Royero, and Juan David, "Metodología para identificación de proyectos de mantenimiento en empresas del sector industrial de la ciudad de Barranquilla, Colombia.," *Universidad Privada Dr. Rafael Belloso Chacín.*, Apr. 2015, Accessed: Jul. 13, 2025. [Online]. Available: https://virtual.urbe.edu/tesispub/0101658/intr_o.pdf
- [7] M. Zheng, H. Ye, D. Wang, and E. Pan, "Joint Decisions of Components Replacement and Spare Parts Ordering Considering Different Supplied Product Quality," *IEEE Transactions on Automation Science and Engineering*, vol. 21, no. 2, pp. 1952–1964, 2024, doi: 10.1109/TASE.2023.3252812.
- [8] S. Sharda and S. Mishra, "Spare Parts Stock rationalization for rotating equipment based on companywide interchangeability; An inventory cost reduction strategic technique-Perspective to Petroleum & fertilizer industries across India & Gulf," in *Proceedings of the International Conference on Industrial Engineering and Operations Management*, 2018, pp. 1718–1732.
- [9] M. Singh, M. Singh, J. Singh, M. Singh, and H. Singh, *Unveiling the future: Residual life prediction for enhanced asset management*. 2025. doi: 10.1002/9781119933175.ch5.
- [10] M. Tanwar, R. N. Rai, and N. Bolia, "Imperfect repair modeling using Kijima type generalized renewal process," 2014, *Elsevier Ltd*. doi: 10.1016/j.res.2013.10.007.
- [11] M. Shafiee and J. D. Sørensen, "Maintenance optimization and inspection planning of wind energy assets: Models, methods and strategies," Dec. 01, 2019, *Elsevier Ltd*. doi: 10.1016/j.res.2017.10.025.
- [12] Campos Lopez, René Tolentino Eslava, Miguel Toledo Velázquez, and Guilibaldo Tolentino Eslava, "Metodología de mantenimiento centrado en confiabilidad (RCM) considerando taxonomía de equipos, bases de datos y criticidad de efectos," *Instituto Politécnico Nacional de Mexico*, vol. 23, pp. 51–59, Jun. 2019, doi: 10.46842/ipn.cien.v23n1a06.
- [13] C. Redrobán, A. Tenicota-García, and E. F. Calderón-Freire, "Factores de riesgos y severidad de sus consecuencias en la operación y mantenimiento de equipos de industrias

- manufactureras ecuatorianas,” *FIGEMPA: Investigación y Desarrollo*, vol. 13, no. 1, pp. 1–12, Jan. 2022, doi: 10.29166/revfig.v13i1.2913.
- [14] M. Á. L. Pérez, I. B. Piña, and G. V. Álvarez, “Diseño de una metodología de mantenimiento predictivo para asegurar procesos de producción de la industria 4.0,” *South Florida Journal of Development*, vol. 2, no. 1, pp. 1009–1017, May 2021, doi: 10.46932/sfjdv2n1-074.
- [15] M. Bednarek, S. Luściński, M. Jabłoński, and G. J. Schaffeld Graniffo, “Harnessing Industry 4.0 Technologies: A Novel Predictive Maintenance Method for Advanced Production Systems,” *Management and Production Engineering Review*, vol. 16, no. 1, 2025, doi: 10.24425/mper.2025.153928.
- [16] D. R. Wulansari, T. Y. M. Zagloel, and Zulkarnain, “Development of Spare Part Classification Methodology Considering Maintainability, Criticality, and Inventory Management Aspects in The Oil Processing Industry,” in *ACM International Conference Proceeding Series*, 2021, pp. 134–140. doi: 10.1145/3468013.3468322.
- [17] K. Saetia, S. Lukens, E. Pijcke, and X. Hu, “Data-driven approach to equipment taxonomy classification,” in *Proceedings of the Annual Conference of the Prognostics and Health Management Society Phm*, 2019. doi: 10.36001/phmconf.2019.v11i1.818.
- [18] S. Nagarajan, K. Ganesh, A. T. Resmi, S. P. Anbuudaysankar, and R. Hemachitra, “Design for taxonomy and technology architecture for knowledge management solution implementation,” *Int. J. Bus. Inf. Syst.*, vol. 11, no. 2, pp. 180–214, 2012, doi: 10.1504/IJBIS.2012.048890.
- [19] Y. Liu, Z. Xu, G. Li, Y. Xia, and S. Gao, “Review on Applications of Artificial Intelligence Driven Data Analysis Technology in Condition Based Maintenance of Power Transformers | 人工智能驱动的数据分析技术在电力变压器状态检修中的应用综述,” *Gaodianya Jishu/High Voltage Engineering*, vol. 45, no. 2, pp. 337–348, 2019, doi: 10.13336/j.1003-6520.hve.20190130001.
- [20] S. Lahmiri, “A comparative study of statistical machine learning methods for condition monitoring of electric drive trains in supply chains,” *Supply Chain Analytics*, vol. 2, 2023, doi: 10.1016/j.sca.2023.100011.
- [21] C. Cakiroglu, *Blockchain in aviation: Applications of blockchain technology in aircraft maintenance management*. 2024. doi: 10.1201/9781003389187-7.
- [22] S. Sayyad, S. Kumar, A. Bongale, A. M. Bongale, and S. Patil, “Estimating Remaining Useful Life in Machines Using Artificial Intelligence: A Scoping Review,” *Library Philosophy and Practice*, vol. 2021, pp. 1–26, 2021.
- [23] J. Zhou, J. Yang, S. Xiang, and Y. Qin, “Remaining Useful Life Prediction Methodologies With Health Indicator Dependence for Rotating Machinery: A Comprehensive Review,” *IEEE Trans. Instrum. Meas.*, vol. 74, 2025, doi: 10.1109/TIM.2025.3556919.
- [24] A. Caricato, A. Ficarella, and L. Spada Chiodo, “Prognostic techniques for aeroengine health assessment and Remaining Useful Life estimation,” in *E3s Web of Conferences*, 2021. doi: 10.1051/e3sconf/202131211017.
- [25] D. N. Avendano *et al.*, “A Semi-Supervised Approach with Monotonic Constraints for Improved Remaining Useful Life Estimation,” *Sensors*, vol. 22, no. 4, 2022, doi: 10.3390/s22041590.
- [26] N. Gorjian, Y. Sun, L. Ma, P. Yarlagadda, and M. Mittinty, “Remaining useful life prediction of rotating equipment using covariate-based hazard models—Industry applications,” *Australian Journal of Mechanical Engineering*, vol. 15, no. 1, pp. 36–45, 2017, doi: 10.1080/14484846.2015.1093251.
- [27] S. Semerikov, A. Kupin, I. Marynych, and A. Makohonov, “Collection Data and Visualization Preventive Maintenance Schedule,” in *Ceur Workshop Proceedings*, 2024, pp. 157–168.
- [28] K. K. M. Rosita and M. N. Young, “Optimizing Maintenance Spare Parts Re-ordering Process Using Computerized Maintenance Management System,” in *2020 7th International Conference on Frontiers of Industrial Engineering Icfie 2020*, 2020, pp. 104–108. doi: 10.1109/ICFIE50845.2020.9266717.
- [29] C. Teixeira, I. Lopes, and M. Figueiredo, “Classification methodology for spare parts management combining maintenance and logistics perspectives,” *Journal of Management Analytics*, vol. 5, no. 2, pp. 116–135, 2018, doi: 10.1080/23270012.2018.1436989.
- [30] J. D. Rodríguez-Heras, J. A. Cabeza-Marchena, L. M. Nieto-Ramos, A. E. Márquez-Castillo, and L. E. Garizabal-Donado, “Principal Component Analysis

- Method Application for Inventory Related Decisions-Making,” in *Procedia Computer Science*, 2024, pp. 558–563. doi: 10.1016/j.procs.2024.08.080.
- [31] C. Çalışkan, “The economic order quantity model with compounding,” *Omega (Westport)*, vol. 102, p. 102307, Jul. 2021, doi: 10.1016/J.OMEGA.2020.102307.
- [32] Y. Takemoto and I. Arizono, “Proposal of reorder point satisfying allowable shortage rate under limited demand information,” in *21st International Conference on Production Research: Innovation in Product and Production, ICPR 2011 - Conference Proceedings*, 2011. [Online]. Available: <https://www.scopus.com/inward/record.uri?eid=2-s2.0-84923419178&partnerID=40&md5=49b2d56fade5ec6e4f0678f357fc3ffd>
- [33] M. M. Roşu, C. I. Tarbă, and C. Neagu, “Automated Decisional Model for Optimum Economic Order Quantity Determination Using Price Regressive Rates,” in *IOP Conference Series: Materials Science and Engineering*, 2016. doi: 10.1088/1757-899X/161/1/012108.
- [34] C. K. M. Lee, Y. Cao, and K. K. H. Ng, *Big data analytics for predictive maintenance strategies*. 2016. doi: 10.4018/978-1-5225-0956-1.ch004.
- [35] L. Colombi *et al.*, “A Machine Learning Operations Platform for Streamlined Model Serving in Industry 5.0,” in *Proceedings of IEEE/IFIP Network Operations and Management Symposium 2024, NOMS 2024*, 2024. doi: 10.1109/NOMS59830.2024.10575103.
- [36] M. Nalini, *Industry automation: The contributions of artificial intelligence (AI)*. 2024.
- [37] N. Kathpal, P. Manhas, J. Verma, and S. Jogad, *Industry 5.0 with Artificial Intelligence A Data-Driven Approach*. 2024. doi: 10.1201/9781003494027-3.
- [38] P. Darda and M. K. Pendse, *The impact of artificial intelligence (AI) transformation on the financial sector from the trading to security operations*. 2025. doi: 10.4324/9781003501947-20.
- [39] J. D. Charry, S. Navarro, and P. Odont, “Metodología de la Investigación y Principios en Publicación Científica,” 2018. [Online]. Available: https://arbapublishing.com/wp-content/uploads/2025/01/metodologia_de-investigacion.pdf
- [40] U. Flick, *Introducing Research Methodology: A Beginner's Guide to Doing a Research Project*. London: SAGE Publications, 2015.
- [41] L. Fan *et al.*, “Change is safer: a dynamic safety stock model for inventory management of large manufacturing enterprise based on intermittent time series forecasting,” *J. Intell. Manuf.*, 2024, doi: 10.1007/s10845-024-02442-y.
- [42] N.-A. Mohd-Lair, C.-K. Pang, W. Y. H. Liew, H. Semui, and L. Z. Yew, *An EOQ based multi-storage location of spare part inventories: A case study*, vol. 315. 2013. doi: 10.4028/www.scientific.net/AMM.315.733.
- [43] V. Bafandegan Emrooz and M. Doostparast, “Markov chain-based model for IoT-driven maintenance planning with human error and spare part considerations,” *Reliab. Eng. Syst. Saf.*, vol. 261, p. 111052, Sep. 2025, doi: 10.1016/J.RESS.2025.111052.