

**Diseño de un Modelo de Mantenimiento Predictivo en la Industria Minera Mediante
Inteligencia Artificial y Mejora en el flujo de datos**

Alex Enrique Colina Figueroa

Escuela de Ingeniería Mecánica, Universidad del Valle

Junio 2025

Nota del autor

Alex Enrique Colina Figueroa; Escuela de Ingeniería Mecánica, Universidad del Valle, Cali.

Este documento cuenta con la dirección de proyecto de tesis del Profesor Adolfo L. Gómez
P. M.Sc.

Trabajo de tesis para optar por el título de Magister en Gestión de Activos y Mantenimiento.

Resumen

El mantenimiento predictivo evoluciona con la adopción de tecnologías emergentes como el Internet of Things (IoT),¹ el Machine Learning (ML)² y la Analítica de Datos. No obstante, en el sector minero, la integración eficiente y oportuna de estas tecnologías sigue siendo un desafío, lo que limita los esfuerzos para superar deficiencias en la gestión de activos. Como resultado, persisten las paradas no programadas, los sobre costos y la reducción de la eficiencia operativa.

Este estudio propone un modelo de mantenimiento predictivo basado en inteligencia artificial y análisis de datos, aplicado a los equipos móviles en la mina Prebberow Drummond LTD. La investigación plantea una mejora en el flujo de datos la cual permite una mejor gestión de activos mediante la recopilación, almacenamiento y análisis de datos obtenidos de sensores IoT y sistemas VIMS³. A través de una metodología estructurada, se generan alertas tempranas que mejoran la toma de decisiones en mantenimiento, minimizando fallas y optimizando los tiempos de producción.

El modelo propuesto se fundamenta en normativas internacionales como la ISO 14224 e ISO 55000, garantizando la calidad, trazabilidad y confiabilidad de los datos. Se espera que los resultados de esta investigación contribuyan a la modernización de la gestión de mantenimiento en la industria minera, promoviendo prácticas más eficientes y sostenibles.

Palabras clave: mantenimiento predictivo, gestión de activos, minería, inteligencia artificial, Aprendizaje automático, Mejora en el flujo de datos.

¹ Internet of Things: Internet de las cosas, en español

² Maching Learnig: Aprendizaje automático, en español

³VIMS: Vital Information Management System

Abstract

Predictive maintenance is evolving with the adoption of emerging technologies such as the Internet of Things (IoT), Machine Learning (ML), and Data Analytics. However, in the mining sector, the efficient and timely integration of these technologies remains a challenge, limiting efforts to overcome deficiencies in asset management. As a result, unplanned downtime, cost overruns, and reduced operational efficiency persist.

This study proposes a predictive maintenance model based on artificial intelligence and data analytics, applied to mobile equipment at the Prebberow Drummond LTD mine. The research introduces an improvement in data flow, enabling better asset management through the collection, storage, and analysis of data obtained from IoT sensors and VIMS systems. Through a structured methodology, early warnings are generated to enhance maintenance decision-making, minimizing failures and optimizing production time.

The proposed model is based on international standards such as ISO 14224 and ISO 55000, ensuring data quality, traceability, and reliability. The results of this study are expected to contribute to the modernization of maintenance management in the mining industry, promoting more efficient and sustainable practices.

Keywords: Predictive maintenance, asset management, mining, artificial intelligence, Machine Learning, data flow improvement.

Contenido

Resumen	2
Introducción y Contexto Operacional	10
Planteamiento del problema u oportunidad.....	12
Límites del Problema	13
Justificación	14
Viabilidad de la idea del trabajo de profundización	16
Objetivos.....	17
General	18
Específicos	18
UNO- Desarrollar un flujo de captura,	18
DOS - Aplicar modelos de inteligencia artificial	18
TRES - Validar un proceso de preprocesamiento automatizado	18
CUATRO - Evaluar el modelo mediante indicadores de desempeño	18
CINCO - Proponer una estrategia de adopción gradual y mejora continua del modelo predictivo	18
SEIS – Conclusiones	18
Estructura del documento.....	19
Descripción del caso de estudio.....	21
Organigrama del Departamento de Equipo Móvil.....	22
Estado del Arte.....	24
Revisión de Enfoques Tradicionales vs. Actuales.....	25
Modelos de Mantenimiento Predictivo en Aplicaciones Reales.....	26
Diferencias Fundamentales entre los Modelos Existentes	27
Eficiencia de los Modelos más Aplicados	28
Escalabilidad de los Modelos a Diferentes Entornos Industriales.....	29
Desventajas de Modelos No Escalables	30
Capacidad para Predecir Desgaste en Diferente Maquinaria	30
Multiplicidad de Modelos y su Justificación.....	31
Marco Teórico	33
Mantenimiento Predictivo.....	33
Inteligencia Artificial en Mantenimiento	34
Flujo de Datos en Entornos Industriales	34
Modelos de Machine Learning en Mantenimiento.....	34
Estándares y Normativas Relevantes.....	35
Servicios y Herramientas de AWS en el Mantenimiento Predictivo	35

Licenciamiento y Costos Básicos de Servicios AWS	36
Marco Metodológico	39
Modelo Macro de Gestión del Mantenimiento Predictivo.....	39
Fases Metodológicas	40
Objetivo 1. Desarrollar un flujo de captura.....	41
Fase 1: Recolección de Datos	41
Fase 2: Almacenamiento en la Nube.....	42
Fase 3: Transformación de Datos	44
Objetivo 2. Aplicar modelos de inteligencia artificial	45
Fase 4: Análisis Predictivo con IA	45
Objetivo 3. Validar un proceso de procesamiento automatizado	47
Fase 5: Generación de Alertas y Visualización	47
Objetivo 4. Evaluar el modelo mediante indicadores de desempeño	49
Fase 6: Retroalimentación del Sistema	49
Asignación de responsabilidades para la retroalimentación del modelo	50
Flujo General del Proceso	52
Caso de uso aplicado: Motoniveladora CAT 24M	53
Descripción del proceso:	53
Criterios de limpieza utilizados	56
Integración en Redshift:	59
Visualización en QuickSight:	67
Evaluación del desempeño del modelo mediante KPIs.....	68
Objetivo 5. Proponer una estrategia de adopción gradual y mejora continua	73
Estrategia de adopción gradual y mejora continua del modelo predictivo	73
a. Adopción gradual por tipología de maquinaria.....	73
b. Integración progresiva de nuevas fuentes de datos	74
c. Actualización periódica del modelo y mejora continua	74
Descripción de cómo se alcanzan los objetivos	76
UNO.....	76
DOS.....	76
TRES.....	76
CUATRO	76
CINCO	77
Resultados y Discusión	78
Conclusiones y recomendaciones	80
Referencias	82
Glosario	86

Figuras

Figura 1 Niveles de la taxonomía de Bloom aplicado a los objetivos del trabajo	17
Figura 2 Ubicación Geográfica de la Mina Pribbenow	21
Figura 3 Organigrama del Departamento de Equipo móvil.....	23
Figura 4 Modelo híbrido de mantenimiento basado en IA	26
Figura 5 Comparativa entre modelos simples, supervisados, profundos e híbridos	27
Figura 6 Resultados esperados por tipo de modelo: precisión vs. costo	28
Figura 7 Arquitectura modular para escalabilidad de modelos de mantenimiento	29
Figura 8 Tipos de sensores y variables por tipo de maquinaria	31
Figura 9 Representación del modelo macro de gestión predictiva basado en estrategia, cadena de valor y mejora continua	40
Figura 10 Diagrama de flujo del proceso de recolección manual de datos operativos desde motoniveladoras	42
Figura 11 Arquitectura de carga manual a Amazon S3	43
Figura 12 Proceso de transformación automática de datos mediante AWS Glue en lambda.....	45
Figura 13 Arquitectura funcional de Amazon Lookout for Equipment para detección automática de fallas	46
Figura 14 Arquitectura del modelo predictivo implementado sobre servicios AWS	48
Figura 15 Matrix RACI de responsabilidades en la fase de retroalimentación del modelo predictivo	51
Figura 16 Flujo Funcional de Predicción, Evaluación de Riesgo y Ejecución de Mantenimiento Predictivo	52
Figura 17 Datos extraídos de la máquina CAT 24M en formato CSV	53
Figura 18 Captura de pantalla del proceso de carga de archivos en Amazon S3, estructura de carpetas del bucket "predictivo2" en la región sa-east-1	54
Figura 19 Diagrama de ejecución de la función AWS Lambda "limpieza_predictiva_lambd" conectada al bucket S3 como disparador	55
Figura 20 Código de la función AWS Lambda en Python para limpieza de datos desde un archivo CSV en Amazon S3.....	56
Figura 21 Registro de ejecución de la función Lambda para limpieza de datos del archivo CAT_24M_TIME.csv.	57
Figura 22 Script SQL para la creación de la tabla motoniveladora_cat24marchivo	60
Figura 23 Visualización de datos operacionales en consola de AWS	60
Figura 24 Gráfica de alerta generada por Amazon Lookout for Equipment tras detectar un valor superior al umbral crítico	63
Figura 25 Gráfica de alerta generada por Amazon Lookout for Equipment tras detectar un valor superior al umbral crítico	64
Figura 26 Evolución del Anomaly Score y la vida útil remanente (RUL) 24M	67
Figura 27 Estrategia de adopción gradual y mejora continua del modelo predictivo	75

Tablas

Tabla 1 Matrix RACI de responsabilidades en la fase de retroalimentación del modelo predictivo	50
Tabla 2 Registros antes y después del proceso de limpieza de datos operativos de la motoniveladora CAT 24M	58
Tabla 3 Parámetros de entrenamiento del modelo	61
Tabla 4 Respuestas posibles de Lookout for Equipment tras la inferencia	62
Tabla 5 Matriz de criticidad para evaluación del riesgo según ISO 31010	64
Tabla 6 Criterios tipo de mantenimiento según el nivel de riesgo detectado	65
Tabla 7 Evaluación de Riesgo Operacional	66
Tabla 8 Criterios para la Selección del Tipo de Mantenimiento	66
Tabla 9 Clasificación Automatizada de Respuesta y Acción del Sistema	66
Tabla 10 Indicadores clave de desempeño del modelo predictivo aplicado	68

Introducción y Contexto Operacional

La industria minera desempeña un papel crucial en la economía global al proporcionar materias primas esenciales para diversas industrias. En Colombia, la minería de carbón es un sector estratégico, y empresas como Drummond Ltd. lideran la producción y exportación de este recurso (Agencia Nacional de Minería [ANM], 2023).

Sin embargo, enfrenta desafíos significativos en términos de eficiencia operativa, sostenibilidad y costos de mantenimiento de los equipos móviles. Estos equipos operan en condiciones extremas, caracterizadas por la presencia de polvo, humedad, vibraciones intensas y cargas pesadas, lo que aumenta la probabilidad de fallas mecánicas y eléctricas. En estos entornos hostiles, los equipos están expuestos a diversos mecanismos de deterioro, entre ellos el desgaste abrasivo, causado por la fricción con partículas sólidas; el desgaste erosivo, derivado del impacto de materiales en movimiento; la corrosión, acelerada por la humedad y sustancias químicas presentes; y la fatiga de materiales, resultado de cargas cíclicas. Además, estos mecanismos no actúan de manera aislada: se producen sinergias entre ellos —por ejemplo, la combinación de corrosión y fatiga o de abrasión y erosión— que intensifican el daño estructural y reducen la vida útil de los componentes críticos.

El mantenimiento de estos activos ha sido tradicionalmente abordado mediante tácticas correctivas y preventivas. Aunque efectivas en ciertos escenarios, estos enfoques no han sido suficientes para reducir los tiempos de inactividad imprevistos y los costos asociados a reparaciones de emergencia. Según un artículo de Tecnología Minera (2023), los métodos tradicionales de mantenimiento pueden llevar a pérdidas de producción significativas, incrementando la vulnerabilidad operativa de las empresas mineras. Asimismo, la falta de un enfoque predictivo genera una asignación ineficiente de recursos, impactando la rentabilidad del negocio (MC Service, 2023).

En este contexto, el mantenimiento predictivo emerge como una solución innovadora para mejorar la gestión de activos en minería. El desarrollo de tecnologías avanzadas como la inteligencia artificial, el Internet de las Cosas (IoT) y el análisis de datos en tiempo real ha permitido el monitoreo continuo del estado de los equipos, posibilitando la detección temprana de anomalías y la anticipación de fallas antes de que ocurran. La aplicación de estos enfoques puede no solo reducir significativamente los costos de mantenimiento, sino también mejorar la seguridad operativa y prolongar la vida útil de los activos (ALS Global, 2022).

A pesar de los beneficios potenciales del mantenimiento predictivo, su adopción en la industria minera ha sido limitada debido a la fragmentación de los sistemas de gestión de datos, la falta de infraestructura adecuada para la recopilación y análisis de información y la ausencia de un marco normativo unificado que regule la calidad de los datos utilizados en los modelos predictivos.

Para abordar esta problemática, el presente estudio propone un modelo de mantenimiento predictivo basado en inteligencia artificial, soportado por una Mejora robusta en el flujo de datos que garantice la precisión, confiabilidad y seguridad de la información procesada. Este enfoque facilitará una toma de decisiones más informada y eficiente, mejorando la operatividad de los equipos mineros y reduciendo los tiempos de inactividad no planificados.

El presente trabajo se estructura en diversas secciones que abordan, en primer lugar, el planteamiento detallado del problema y los límites del estudio. Posteriormente, se presentan los objetivos generales y específicos de la investigación, seguidos por una revisión del estado del arte y los antecedentes en el ámbito del mantenimiento predictivo.

Planteamiento del problema u oportunidad

El mantenimiento de activos en la industria minera enfrenta retos críticos debido a la complejidad y severidad de sus condiciones operativas. A pesar de que tradicionalmente se han empleado estrategias correctivas y preventivas, estas no han logrado reducir de manera efectiva los altos costos ni garantizar la continuidad operativa. En muchos casos, los costos de mantenimiento pueden representar entre el 30% y el 50% de los costos operativos totales de una mina (Caron Business Solutions, 2023), y continúan en aumento.

Uno de los principales factores que limita la efectividad del mantenimiento es la falta de integración entre los sistemas de monitoreo de condiciones, los sensores IoT y las plataformas de análisis de datos. Esta desconexión impide la identificación temprana de fallas en equipos críticos, generando paradas no planificadas y mayores costos de reparación y reemplazo. Además, la presión por resolver fallas inesperadas compromete la seguridad de los operarios y afecta la productividad (Inspenet, 2024)

Por lo tanto, surge la pregunta clave: **¿Cómo puede un modelo de mantenimiento predictivo, basado en el análisis de datos y el aprendizaje automático, contribuir a reducir los costos de mantenimiento y minimizar los tiempos de inactividad no planificados en la industria minera?**

Ante este contexto, las soluciones de mantenimiento predictivo apoyadas en análisis de datos y modelos de aprendizaje automático surgen como una alternativa prometedora. Estas permiten anticipar fallas antes de que ocurran, mejorar el uso de recursos, reducir los tiempos de inactividad no planificados y mejorar la seguridad y eficiencia operativa (ESSS, 2023) (Tecnología minera, 2023)

Límites del Problema

Este estudio se enfoca en la aplicación del mantenimiento predictivo en equipos clave del sector minero, específicamente en las motoniveladoras Caterpillar 24. Se analizan aspectos como su desempeño operativo, las fallas recurrentes y el impacto de la predicción de fallas mediante técnicas de inteligencia artificial y análisis de datos. Para evaluar la efectividad del modelo propuesto, se emplearán indicadores clave de desempeño (KPIs), tales como la tasa de fallas, el tiempo medio entre fallos (MTBF), el tiempo medio de reparación (MTTR) y la disponibilidad operacional.

El análisis se limitará al uso de datos provenientes de sensores ya instalados en los equipos y no incluirá intervenciones sobre el hardware. Asimismo, se excluyen del alcance otros tipos de maquinaria minera y enfoques de mantenimiento distintos al enfoque predictivo. Se ha adoptado un enfoque de *Unidad Piloto* con el propósito de validar el modelo de mantenimiento predictivo propuesto. No se incluyen en esta etapa otros procesos como gestión logística, financiera, de recursos humanos o abastecimiento, ni equipos auxiliares como sistemas de ventilación, iluminación o maquinaria de soporte. Sin embargo, el modelo está diseñado con potencial de escalabilidad, permitiendo su eventual aplicación a otros activos críticos dotados de sensores y capacidades de telemetría.

Justificación

El mantenimiento predictivo basado en inteligencia artificial, junto con una mejora estructurada en el flujo de datos, representan una solución innovadora para optimizar la gestión de activos en la industria minera. La implementación de tecnologías avanzadas ha demostrado un potencial de incremento de productividad de al menos un 15% (El País, Chile, 2024).

Uno de los pilares fundamentales de este modelo es la calidad de los datos, ya que el éxito de cualquier sistema predictivo depende directamente de la confiabilidad de la información utilizada por los algoritmos de análisis y predicción. La ausencia de estándares en la recolección, almacenamiento y procesamiento de datos puede generar inconsistencias que afectan la toma de decisiones tanto estratégicas como operativas en el mantenimiento. En este sentido, la aplicación de normativas como la ISO 14224, orientada a la recopilación y el intercambio estructurado de datos, garantiza la precisión y coherencia necesarias para evitar errores que comprometan la efectividad del modelo (Instituto de Normas Técnicas de Costa Rica [INTECO], 2023).

Desde una perspectiva financiera, la implementación de un enfoque predictivo ofrece múltiples beneficios económicos. La disminución del tiempo de inactividad no planificado contribuye a evitar pérdidas significativas derivadas de la interrupción de la producción. Estudios indican que el mantenimiento predictivo puede prevenir fallas, optimizar la gestión del trabajo y reducir los costos operativos en más del 30% (McKinsey & Company, 2023).

Para validar esta propuesta, se ha seleccionado como equipo de estudio la motoniveladora Caterpillar 24M, debido a su alta criticidad en las operaciones de acarreo minero, su elevado impacto en la disponibilidad de la flota y la robusta generación de datos operativos que facilita su integración con modelos predictivos. Esta elección permite demostrar el potencial real de las tecnologías emergentes en un equipo representativo y estratégico dentro del entorno minero.

Esta iniciativa busca transformar la gestión de activos mediante el uso estratégico de datos y tecnologías emergentes, reduciendo los costos asociados a paradas no programadas y permitiendo una planificación más eficiente de los recursos. Además, la integración de un modelo basado en inteligencia artificial fortalecerá la capacidad de anticipación ante fallas inminentes, mejorará la planificación del mantenimiento y prolongará la vida útil de los equipos móviles.

Viabilidad de la idea del trabajo de profundización

El desarrollo de este modelo es viable debido a diversos factores clave. En primer lugar, la disponibilidad de sensores IoT y plataformas de gestión de datos en la nube facilita la implementación de un sistema de monitoreo en tiempo real, optimizando la recopilación y análisis de datos operativos. Además, los avances en algoritmos de aprendizaje automático han permitido el desarrollo de modelos predictivos con alta precisión en la detección de anomalías, lo que ha sido respaldado en estudios recientes (Xu, Wang y Li, 2022).

Otro aspecto que refuerza la viabilidad del estudio es la creciente digitalización en la industria minera. En los últimos años, muchas empresas del sector han empezado a integrar tecnologías de análisis de datos para mejorar la gestión de activos, lo que valida la aplicabilidad del enfoque propuesto. Asimismo, este proyecto se alinea con las estrategias de transformación digital promovidas por organismos internacionales para la optimización del mantenimiento industrial y la reducción de costos operativos. Según la Comisión Económica para América Latina y el Caribe (CEPAL), la digitalización es clave para el desarrollo sostenible en sectores estratégicos, incluida la minería, ya que facilita la optimización de procesos, reduce costos y mejorar la competitividad (CEPAL, 2022).

Objetivos

La investigación organiza sus objetivos según la Taxonomía de Bloom, que establece niveles crecientes de complejidad cognitiva. Este enfoque permite estructurar el aprendizaje desde la comprensión básica hasta la creación de un modelo funcional de mantenimiento predictivo. Para ello se integran tecnologías de inteligencia artificial (IA) y machine Learning (ML), así como procesos de captura y preprocesamiento de datos operativos, orientados a mejorar la eficiencia del flujo de información. Los niveles aplicados en esta tesis son: **Crear, Evaluar, Analizar y Aplicar**.

Figura 1

Niveles de la taxonomía de Bloom aplicado a los objetivos del trabajo



Fuente: Elaboración Propia

General

Diseñar un modelo de mantenimiento predictivo basado en inteligencia artificial y flujos de datos optimizados, aplicado a maquinaria pesada en la industria minera, con el fin de anticipar fallas críticas y mejorar la eficiencia operativa

Específicos

UNO- Desarrollar un flujo de captura, transformación y análisis de datos operativos utilizando servicios SaaS de AWS para alimentar modelos de predicción.

DOS - Aplicar modelos de inteligencia artificial supervisados y no supervisados para detectar anomalías y estimar la vida útil restante de componentes críticos.

TRES - Validar un proceso de preprocesamiento automatizado que garantice la calidad y trazabilidad de los datos en entornos con conectividad limitada.

CUATRO - Evaluar el modelo mediante indicadores de desempeño como precisión de predicción, reducción de fallas y utilidad de alertas generadas.

CINCO - Proponer una estrategia de adopción gradual y mejora continua del modelo predictivo, considerando su ampliación a otras máquinas, la integración con nuevas fuentes de datos y la actualización periódica de sus algoritmos.

SEIS – Conclusiones.

Estructura del documento

Este trabajo se encuentra organizado en secciones que permiten abordar de forma progresiva el desarrollo de un modelo de mantenimiento predictivo basado en inteligencia artificial, aplicado al entorno minero.

La secuencia de contenido responde a una lógica metodológica que inicia con la contextualización del problema y culmina con la validación de la propuesta. A continuación, se describe cada una de las secciones principales:

- **Resumen.** Se presenta una síntesis general del contenido del documento, incluyendo los objetivos, la metodología utilizada, los principales hallazgos y las conclusiones alcanzadas.
- **Introducción y contexto operacional.** Se plantea la problemática que motiva el estudio, sus límites, justificación y viabilidad, en el marco de una operación minera real.
- **Objetivos.** Se anuncian el objetivo general y los objetivos específicos que guían el desarrollo del estudio.
- **Descripción del caso de estudio.** Se expone la estructura del área de mantenimiento involucrada, incluyendo aspectos organizacionales y técnicos que contextualizan la aplicación del modelo.
- **Estado del arte.** Se realiza una revisión crítica de los enfoques tradicionales y actuales en mantenimiento predictivo, inteligencia artificial, gestión de datos industriales y estándares aplicables.
- **Marco metodológico.** Se detalla la metodología utilizada, estructurada en seis fases, desde la recolección de datos hasta la retroalimentación del sistema. Se incluye además un caso de aplicación práctica con maquinaria específica, lo cual permite validar la utilidad del modelo.


- Resultados y discusión. Se presentan los principales resultados obtenidos tras el caso de estudio, su análisis y evaluación a través de indicadores clave de desempeño, así como una estrategia para su adopción gradual y mejora continua.
- Conclusiones y recomendaciones. Se resume los principales aportes del trabajo y se proponen líneas de acción para futuras investigaciones o aplicaciones en entornos similares.
- Referencias y glosario. Se presentan las fuentes bibliográficas consultadas a lo largo del trabajo, así como información complementaria relevante. Además, se incluye un glosario con definiciones clave que contribuyen a una mejor comprensión de los conceptos técnicos abordados.

Descripción del caso de estudio

El presente trabajo tiene como caso de estudio la *Mina Pribbenow*, operada por *Drummond Ltd.*, ubicada en el departamento del Cesar, Colombia (véase imagen 1). Esta mina hace parte del *Proyecto Carbonífero La Loma*, que se extiende por los municipios de *El Paso*, *La Jagua de Ibirico* y *Chiriguaná*. Su ubicación estratégica facilita el desarrollo eficiente de las operaciones logísticas y mejora la conectividad con los principales centros de distribución y exportación del país.

Figura 2

Ubicación Geográfica de la Mina Pribbenow



Fuente: Imagen satelital de la ubicación del proyecto. Adaptado de Google Earth (2025), imágenes © 2025 Airbus, CNES/Airbus, Landsat/Copernicus, Maxar Technologies.

El proceso productivo de la mina inicia con la extracción del carbón mediante *palas hidráulicas* y su transporte con *camiones de acarreo* de alta capacidad. Posteriormente, el material se almacena temporalmente en zonas de *pits* antes de ser trasladado a las plantas de procesamiento. Para asegurar la eficiencia de este ciclo, la operación se apoya en una flota de maquinaria pesada, entre la que se destacan *bulldozers*, *motoniveladoras* y *sistemas de bandas transportadoras*, los cuales son fundamentales para la preparación del terreno y el traslado del carbón hacia las tolvas de cargue.


El funcionamiento ininterrumpido de estos equipos es vital para la productividad de la operación minera, por lo que requieren de un *mantenimiento constante y eficaz*. En este contexto, la implementación de un modelo de mantenimiento predictivo basado en inteligencia artificial representa una oportunidad para *anticipar fallas, reducir tiempos de inactividad no planificados y mejora la gestión de los activos críticos*, especialmente en equipos como las motoniveladoras, que juegan un papel clave en la preparación de la vía de acarreo y soporte operacional.

Organigrama del Departamento de Equipo Móvil

La estructura organizativa del mantenimiento en la mina está compuesta por distintos niveles jerárquicos que supervisan las operaciones y garantizan la operatividad de los equipos. A continuación, se presenta el organigrama del Departamento de Equipo Móvil:

Figura 3

Organigrama del Departamento de Equipo móvil



Fuente. Recursos Humanos Drummond Ltd.

Estado del Arte

Este apartado presenta una revisión detallada del estado del arte en modelos de mantenimiento predictivo (PdM), con el objetivo de identificar las metodologías actuales y los enfoques más utilizados en la industria. El auge de la Industria 4.0 ha dado paso a nuevas soluciones tecnológicas como el aprendizaje automático (ML), el Internet de las Cosas (IoT) y los sistemas ciberfísicos (CPS), los cuales están transformando profundamente las estrategias de mantenimiento tradicional.

Para orientar esta revisión, se formularon las siguientes preguntas de investigación:

1. ¿Cuáles son los modelos de mantenimiento predictivo utilizados actualmente en la industria?
2. ¿Qué modelo es el más utilizado en aplicaciones reales?
3. ¿Cuáles son las diferencias fundamentales entre los modelos existentes?
4. ¿Qué tan eficiente es el modelo más aplicado?
5. ¿Qué modelos de mantenimiento son escalables a diferentes entornos industriales?
6. ¿Qué desventajas presentan los modelos que no son escalables?
7. ¿Pueden estos modelos predecir el desgaste en distintos tipos de maquinaria?
8. ¿Qué factores explican la existencia de múltiples modelos de mantenimiento predictivo?
9. ¿Qué criterios deben ponderarse en un modelo de mantenimiento predictivo para optimizar la toma de decisiones?

A partir de estas preguntas se llevó a cabo una búsqueda sistemática utilizando las siguientes palabras clave:

- Machine Learning
- Predictive Models
- Predictive Maintenance

- Predictive Maintenance Models
- Predictive System
- Industrial Maintenance
- Maintenance 4.0

Las bases de datos científicas utilizadas fueron:

- Web of Science
- Google Académico

Revisión de Enfoques Tradicionales vs. Actuales

Históricamente, el mantenimiento en la minería ha estado dominado por estrategias correctivas y preventivas. El correctivo actúa después de una falla, lo que conlleva altos costos operacionales, riesgos de seguridad y pérdidas de producción. El mantenimiento preventivo, por su parte, se ha aplicado principalmente de dos formas: mantenimiento por calendario o frecuencia, que implica paradas programadas para inspecciones y recambios; y el mantenimiento basado en condición (CBM), que permite evaluar el estado del equipo en operación a través de variables física y señales de deterioro. Aunque el primero mejora la disponibilidad, no siempre refleja el estado real del activo, mientras que el CBM representa un paso intermedio hacia enfoques más avanzados como el mantenimiento predictivo. (González, 2023).

En contraste, los enfoques actuales incorporan mantenimiento predictivo mediante sensores IoT, plataformas cloud, y algoritmos de IA capaces de detectar anomalías en señales como vibraciones, temperatura o consumo eléctrico. Estos sistemas permiten tomar decisiones basadas en el estado real del activo y no en promedios generalizados (Marco Industrial, 2025). La diferencia clave radica en el uso de datos para la toma de decisiones. En vez de mantener con base en ciclos, se hace con base en condiciones.


Modelos de Mantenimiento Predictivo en Aplicaciones Reales

En el ámbito real, uno de los modelos más extendidos es el uso de algoritmos supervisados como Random Forest, Support Vector Machines (SVM) y redes neuronales multicapa. Estos modelos se alimentan con datos etiquetados para predecir si una máquina está próxima a fallar. Su aplicación en minería ha sido reportada para la detección de desgaste en Bandas transportadoras, rodamientos de molinos y sistemas hidráulicos (Pérez, 2024).

También se destaca el enfoque híbrido, como el propuesto por Cho et al. (2018), que integra modelos no supervisados para clasificar el comportamiento de la maquinaria, y luego utiliza modelos supervisados para etiquetar eventos críticos, incrementando la precisión del sistema. Esta combinación permite comenzar incluso en entornos con escasos datos etiquetados.

Figura 4

Modelo híbrido de mantenimiento basado en IA



Fuente: Adaptación del modelo de flujo para mantenimiento predictivo híbrido. Fuente adaptada de Cho et al., 2018

Diferencias Fundamentales entre los Modelos Existentes

Los modelos predictivos varían no solo en la técnica empleada, sino en los requerimientos de datos, complejidad, capacidad de interpretación y adaptabilidad. Mientras los modelos basados en reglas simples pueden ejecutarse con escasos recursos, tienen baja capacidad de adaptación. Por el contrario, los modelos de aprendizaje profundo requieren grandes volúmenes de datos y capacidad computacional, pero capturan relaciones más complejas.

La Figura 5 proporciona una comparación entre los distintos tipos de modelos, agrupándolos por su nivel de complejidad, requerimientos de datos y adaptabilidad. Esta representación facilita la selección de un modelo adecuado según las condiciones del entorno industrial.

Figura 5

Comparativa entre modelos simples, supervisados, profundos e híbridos

	 Complejidad	 Requerimiento de Datos	 Adaptabilidad
Modelo Simple	Baja complejidad	Datos históricos	Limitada adaptabilidad
Modelo Supervisado	Complejidad moderada	Datos etiquetados necesarios	Adaptabilidad media
Modelo de Aprendizaje Profundo	Alta complejidad	Gran cantidad de datos	Alta adaptabilidad
Modelo Híbrido	Complejidad dinámica	Múltiples fuentes de datos	Adaptabilidad flexible

Fuente: Elaboración propia

Los modelos híbridos se ubican en un punto intermedio: aprovechan datos no etiquetados para segmentar patrones normales o anómalos y, una vez detectados, refinan la predicción mediante clasificadores supervisados. Esto los hace útiles en escenarios industriales donde no siempre se cuenta con historiales completos de fallas (Pérez, 2024).


Eficiencia de los Modelos más Aplicados

Modelos como Random Forest y redes neuronales recurrentes han logrado reducir el tiempo de inactividad hasta en un 60% y optimizar los costos de mantenimiento entre un 20% y 30% en operaciones reales (Marco Industrial, 2025). Sin embargo, su efectividad depende directamente de la calidad del flujo de datos: sensores calibrados, muestreo continuo, y eliminación de ruido.

Esta comparación se representa gráficamente en la Figura 6, donde se evalúan los modelos según su precisión y el costo asociado a su implementación. La disposición visual permite observar cómo los modelos simples presentan bajo costo, pero menor precisión, mientras que los modelos híbridos y de aprendizaje profundo se posicionan como los más precisos, aunque con mayores exigencias técnicas y financieras.

Figura 6

Resultados esperados por tipo de modelo: precisión vs. costo



Fuente: Elaboración propia a partir de datos e interpretaciones de Cho et al. (2018), Pérez (2024), y Marco Industrial (2025)

La eficiencia también se mide en la capacidad de integración con sistemas SCADA, ERP y plataformas de mantenimiento, para que las alertas predictivas se traduzcan en órdenes de trabajo automáticas

Escalabilidad de los Modelos a Diferentes Entornos Industriales


Los modelos más escalables son aquellos diseñados con arquitectura modular y soportados por plataformas cloud. Estos pueden implementarse en distintos tipos de equipos y locaciones, sin necesidad de rediseñar el modelo base. Tecnologías como Azure Machine Learning y AWS Sagemaker permiten desarrollar modelos entrenados centralmente y desplegarlos localmente (Datision, 2023).

En minería, esto permite monitorear desde palas hasta bandas transportadoras con un mismo sistema base, adaptado vía parametrización.

La Figura 7 representa una arquitectura modular típica utilizada para escalar modelos predictivos a distintas operaciones industriales. Esta visualización muestra cómo un sistema centralizado puede adaptarse fácilmente a diferentes equipos o plantas mediante componentes parametrizables.

Figura 7

Arquitectura modular para escalabilidad de modelos de mantenimiento



Fuente: Elaboración propia

Desventajas de Modelos No Escalables

Los modelos no escalables suelen estar diseñados para un contexto específico y dependen de datos particulares. Su reutilización en otras plantas o equipos requiere ajustes significativos. Además, tienden a tener mayor dependencia de personal técnico para interpretación, lo cual dificulta su adopción masiva en organizaciones con bajo nivel de madurez digital.

Capacidad para Predecir Desgaste en Diferente Maquinaria

Los modelos predictivos modernos pueden ajustarse a diversas fuentes de datos: vibraciones para motores, presión y temperatura para circuitos hidráulicos, análisis de consumo para maquinaria eléctrica. Esto permite que un mismo modelo, entrenado adecuadamente, pueda adaptarse a diferentes activos. La clave está en la etapa de preprocesamiento y normalización de datos, en la selección de variables relevantes para cada tipo de equipo y en la definición de umbrales.

La Figura 8 organiza los tipos de sensores y variables comúnmente utilizados para monitorear distintos tipos de maquinaria. Esta visualización permite comprender qué tecnologías son más adecuadas según el tipo de equipo y condición operacional.

Figura 8

Tipos de sensores y variables por tipo de maquinaria

	Variables monitoreadas	Sensores utilizados	Condición monitoreada
 Motor de combustión interna	○ Presión ↓ Temperatura ↻ Velocidad ↻ Nivel de aceite ↻ Horas de operación	+ Sensor de presión + Termocupla o RTD + Sensor inductivo + Sensor de flujo de combustible	- Sobrecalentamiento - Perdida de potencia - Baja presión de aceite - Exceso de consumo
 Transmisión	○ Presión ↓ Temperatura ↻ Velocidad ↻ Nivel de aceite ↻ Horas de operación	+ Sensor de presión + RTD presión del sistema - Sensor de del siste de aceite	- Sobrecalentamiento - Baja presión del side de - Perdida de velocidad
 Sistema hidráulico	○ Presión ↓ Temperatura ↻ Nivel de fluido ↻ Horas de operación	+ Sensor de presión + RTD + Sensór de nivel de aceite + Horómetro	- Fugas - Aireación del sistema - Exceso de temperatura - Baja presión de operación

Fuente: Elaboración propia

Multiplicidad de Modelos y su Justificación

La existencia de diversos modelos responde a la diversidad de condiciones operativas, tipos de maquinaria, infraestructura digital y objetivos de mantenimiento. Mientras que algunas minas priorizan la reducción de fallas, otras buscan extender la vida útil o reducir el consumo de energía, lo que obliga a personalizar los modelos. Además, la evolución tecnológica y la madurez en datos de cada organización determinan qué tan complejos pueden ser los modelos adoptados. A esto se suma un factor clave: las metas de producción. Variables como toneladas por hora o el costo por tonelada-kilómetro son determinantes para definir qué tan crítico es un activo dentro del proceso productivo. En estos casos, el modelo predictivo debe alinearse con el impacto del

equipo en la productividad global, justificando configuraciones más sofisticadas que aseguren su máxima disponibilidad y eficiencia.

Marco Teórico

El presente marco teórico establece los fundamentos conceptuales y técnicos que sustentan la propuesta de un modelo de mantenimiento predictivo en la industria minera. A través de la revisión de normativas internacionales, tecnologías emergentes y principios de inteligencia artificial, se busca brindar una base sólida para comprender los elementos clave que intervienen en la construcción, implementación y evaluación de modelos predictivos basados en datos.

Mantenimiento Predictivo

El mantenimiento predictivo (PdM) es un enfoque que se basa en el monitoreo continuo del estado de los activos para anticipar fallas. Su origen se remonta al mantenimiento preventivo basado en condición (CBM), el cual dependía de inspecciones o lecturas periódicas para decidir intervenciones. Hoy en día, el PdM automatiza este proceso mediante el análisis inteligente de tendencias, evolucionando desde un enfoque manual a uno guiado por algoritmos.

A diferencia del mantenimiento preventivo por frecuencia, que programa intervenciones en función del tiempo o el uso acumulado, sin considerar el estado real del equipo, el PdM permite optimizar los recursos al intervenir solo cuando los indicadores señalan condiciones anómalas o tendencias hacia el fallo. Además, más allá de la simple detección de eventos críticos, los avances en modelos analíticos permiten interactuar dinámicamente con las condiciones operativas, ajustando variables como velocidad o carga para mitigar el desgaste progresivo y extender la vida útil del activo dentro de un marco económico viable.

En este contexto, el concepto de "falla" se aborda de forma amplia, incluyendo no solo la detención total del activo, sino también cualquier degradación significativa en su rendimiento, condición o confiabilidad. Este enfoque se apoya en el análisis de datos recolectados por sensores, sistemas SCADA y plataformas industriales, los cuales son procesados mediante algoritmos que determinan el momento óptimo para el mantenimiento.

Inteligencia Artificial en Mantenimiento

La inteligencia artificial (IA) ha revolucionado la industria del mantenimiento al permitir el desarrollo de algoritmos capaces de identificar patrones ocultos en los datos operativos. Según Parida & Kumar (2020), la IA permite la automatización del análisis de datos, reduciendo la necesidad de intervención humana y mejorando la precisión de los diagnósticos.

Flujo de Datos en Entornos Industriales

En los sistemas de mantenimiento predictivo, el flujo de datos abarca la adquisición, transmisión, almacenamiento, procesamiento y visualización de la información generada por los activos. Una gestión adecuada de estos flujos resulta esencial para asegurar la integridad, disponibilidad y confiabilidad de los datos a lo largo de todo el ciclo de vida de la información.

En entornos industriales como la minería, esta gestión implica la implementación de redes de comunicación robustas, infraestructuras de almacenamiento (ya sea en la nube o en servidores locales), plataformas analíticas avanzadas y sistemas de visualización interactivos, como tableros de control (dashboards). La eficiencia del modelo predictivo depende directamente de la calidad y continuidad de estos flujos de datos.

Un sistema bien diseñado debe integrar de manera fluida todas estas capas tecnológicas, garantizando que los algoritmos de mantenimiento predictivo reciban información precisa, actualizada y de alta calidad, lo que permite optimizar la toma de decisiones y anticipar de manera confiable los modos de falla.

Modelos de Machine Learning en Mantenimiento

Los modelos de *regresión*, *árboles de decisión* y *redes neuronales* han demostrado ser altamente efectivos para el análisis de datos de mantenimiento. Zhang et al. (2023) destacan que el uso de modelos híbridos puede mejorar significativamente la capacidad de predicción en sistemas industriales complejos.

Estándares y Normativas Relevantes

El diseño de modelos predictivos debe alinearse con normativas internacionales que regulan la gestión de activos y confiabilidad. Entre ellas se destacan:

- ISO 14224: proporciona directrices para la recopilación e intercambio de datos de confiabilidad y mantenimiento.
- ISO 55000: establece principios para la gestión del ciclo de vida de los activos físicos.
- ISO 17359: orienta sobre el establecimiento de programas de monitoreo de condición.

Estas normas permiten estructurar los procesos predictivos bajo un enfoque sistemático y alineado con las mejores prácticas internacionales.

Servicios y Herramientas de AWS en el Mantenimiento Predictivo

Para implementar un modelo predictivo basado en inteligencia artificial y flujos de datos eficientes, este trabajo adopta una arquitectura de nube provista por Amazon Web Services (AWS), que ofrece herramientas escalables, seguras y diseñadas para flujos industriales. A continuación, se describen los servicios principales empleados en el modelo:

- Amazon S3 (Simple Storage Service): almacenamiento seguro de archivos estructurados como CSV, que contiene los datos recolectados desde campo.
- AWS Lambda: procesamiento sin servidor que transforma automáticamente los datos cargados en S3, aplicando funciones de limpieza, validación y estructuración.
- AWS Glue: alternativa a Lambda para flujos de datos más complejos, permitiendo transformación masiva y catálogos de datos.
- Amazon Redshift: base de datos analítica en la nube utilizada para organizar, consultar y analizar grandes volúmenes de datos predictivos.

- Amazon Lookout for Equipment: servicio SaaS de inteligencia artificial completamente gestionado que permite analizar datos de series de tiempo generados por equipos industriales y detectar comportamientos anómalos sin necesidad de desarrollar o entrenar modelos personalizados. Lookout aprende automáticamente a partir de los datos históricos cargados, lo que lo convierte en una herramienta ideal para aplicaciones de mantenimiento predictivo en contextos donde se dispone de registros operacionales, pero no de experiencia en ciencia de datos.
 - Amazon SageMaker Autopilot: plataforma de machine learning automatizado para experimentar con modelos supervisados propios sin escribir código.
 - Amazon QuickSight: herramienta de visualización que permite construir dashboards interactivos con KPIs del estado de los equipos y rendimiento del modelo.
- Amazon SNS (Simple Notification Service): sistema de notificación automática para alertar al personal técnico sobre eventos críticos detectados por el sistema predictivo.

El uso combinado de estos servicios permite construir un modelo modular, reproducible, y adaptable a diferentes grados de madurez tecnológica en entornos industriales, y específicamente en la minería.

Licenciamiento y Costos Básicos de Servicios AWS

El modelo propuesto en esta tesis se apoya en diversos servicios de Amazon Web Services (AWS), cuyo esquema de licenciamiento se basa en un modelo pay-as-you-go (pago por uso). Esto significa que no se requieren licencias perpetuas ni pagos iniciales elevados: el costo está directamente relacionado con el consumo de recursos como almacenamiento, procesamiento y transferencia de datos. A continuación, se describen las características de licenciamiento de los servicios empleados:

- Amazon S3 (Simple Storage Service): Se cobra en función del volumen de datos almacenados (GB/mes) y del tráfico de datos transferido (GET, PUT, DELETE, etc.). No requiere licencias adicionales; el costo depende de la cantidad de almacenamiento consumido y las solicitudes realizadas.
- AWS Lambda: Los costos se basan en el número de ejecuciones y la duración de cada ejecución, medida en gigabytes-segundo (GB-s). No requiere licenciamiento de software adicional.
- AWS Glue: Servicio administrado que se factura por segundo de procesamiento utilizado (DPU - Data Processing Unit). No requiere licencias separadas para el motor ETL o catálogos de datos.
- Amazon Redshift: Ofrece dos opciones de licenciamiento: on-demand (por hora de nodo de cómputo) o reservado (planes anuales con descuento). No se requieren licencias adicionales de base de datos. Se puede escalar automáticamente según demanda con Redshift Serverless.
- Amazon Lookout for Equipment: Servicio SaaS que se factura en función del volumen de datos analizados (MB/hora) y la cantidad de inferencias realizadas. No se requiere infraestructura de machine learning ni licencias de software especializadas.
- Amazon SageMaker Autopilot: El cobro se realiza por el tiempo de ejecución de instancias utilizadas para entrenamiento y por almacenamiento de artefactos generados. No requiere licencias de software de machine learning.
- Amazon QuickSight: Ofrece dos modalidades: Standard (bajo demanda, ideal para dashboards básicos) y Enterprise (por usuario/mes, con funcionalidades avanzadas de seguridad y conectividad empresarial).

Amazon SNS (Simple Notification Service): Se factura según la cantidad de notificaciones publicadas, entregadas y el tráfico de datos asociado. No requiere licenciamiento de correo electrónico o mensajería externa.

Marco Metodológico

La presente investigación es de tipo aplicada y exploratoria, con un enfoque mixto (cuantitativo-analítico). Se busca proponer, estructurar y validar un modelo de mantenimiento predictivo adaptado a las condiciones específicas de operación en la industria minera, mediante el uso de inteligencia artificial y servicios en la nube.


Modelo Macro de Gestión del Mantenimiento Predictivo

Como parte integral del enfoque metodológico, se define un modelo macro de gestión del mantenimiento predictivo que articula la visión estratégica, la operación técnica y la mejora continua. Este modelo permite visualizar la interconexión entre los dominios clave que sustentan la implementación sostenible del mantenimiento predictivo basado en inteligencia artificial y análisis de datos en la industria minera. El modelo se estructura en tres componentes principales:

- **Estrategia de Gestión:** Define el marco normativo (ISO 55000) y las políticas internas para la implementación del mantenimiento predictivo. Incluye la evaluación de madurez digital, objetivos operacionales, selección de herramientas tecnológicas (como AWS) y planificación de recursos.
- **Cadena de Valor del Mantenimiento Predictivo:** Representa el flujo funcional desde la predicción hasta la ejecución, incluyendo el modelo de IA, evaluación de riesgo, recomendación técnica, activación y cierre de órdenes de trabajo (OT). Este bloque central se detalla en la Figura 7 y constituye la base operativa del sistema.
- **Mejora Continua:** Comprende la retroalimentación de resultados operativos al sistema, la revisión periódica de indicadores clave de desempeño (KPIs), el reentrenamiento de modelos y el ajuste de umbrales de alerta. Se apoya en normativas como ISO 9001 y mecanismos de control de calidad.

Figura 9

Representación del modelo macro de gestión predictiva basado en estrategia, cadena de valor y mejora continua



Fuente: Elaboración propia

La presente investigación es de tipo aplicada y exploratoria, con un enfoque mixto (cuantitativo-analítico). Se busca proponer, estructurar y validar un modelo de mantenimiento predictivo adaptado a las condiciones específicas de operación en la industria minera, mediante el uso de inteligencia artificial y servicios en la nube.

Fases Metodológicas

La implementación del modelo se aborda en fases progresivas, cada una con objetivos específicos, herramientas tecnológicas concretas y ejemplos aplicados al caso de las motoniveladoras CAT 24M. Este enfoque permite validar progresivamente el diseño, escalarlo de forma modular y ajustarse a las condiciones reales de operación minera. A continuación, se describen y desarrollan cada una de las fases.

Objetivo 1. Desarrollar un flujo de captura**Fase 1: Recolección de Datos**

Esta fase corresponde al punto de partida del modelo, y es especialmente crítica en contextos donde no se dispone de sistemas de telemetría conectada. La estrategia adoptada contempla la recolección manual de datos operacionales desde motoniveladoras CAT 24M, utilizadas en una operación minera a cielo abierto.

La selección de variables técnicas y operacionales para la recolección manual se basó en la estructura sugerida por la norma ISO 14224, garantizando la calidad, trazabilidad y valor estadístico de los datos utilizados para los modelos predictivos.

Modalidad

El proceso de recolección consiste en que los técnicos de mantenimiento, en jornadas previamente programadas, acceden físicamente a cada equipo para extraer datos desde el sistema de control. Esta información puede obtenerse a través del panel de visualización de la máquina o mediante conexión a herramientas de diagnóstico como CAT ET (Electronic Technician), que permite exportar los registros operacionales.

Herramientas utilizadas

- Software CAT ET (interfaz de diagnóstico Caterpillar)
- Computador portátil con cable de conexión al puerto de diagnóstico
- Formato digital de captura (plantilla en Excel o archivo CSV predefinido)

Variables recolectadas


- Horas totales de operación (odómetro de motor)
- Códigos de fallas activas e históricas (DTC)
- Temperatura de fluidos (aceite, refrigerante)
- Presión hidráulica
- Registro de alertas internas o mensajes de advertencia

Desarrollo del proceso

1. El técnico se conecta al equipo mediante CAT ET y descarga los datos.
2. La información se estructura en una plantilla estandarizada tipo CSV.
3. Se validan los datos en campo (evitando registros incompletos).
4. El archivo se nombra con el formato: ID_equipo_fecha.csv.
5. Finalmente, se almacena localmente hasta su posterior carga a la nube.

Figura 10

Diagrama de flujo del proceso de recolección manual de datos operativos desde motoniveladoras



Fuente: elaboración propia.

Fase 2: Almacenamiento en la Nube


Esta fase se centra en garantizar que los datos extraídos manualmente desde las motoniveladoras sean almacenados de manera segura, estructurada y accesible para los siguientes procesos de análisis. El servicio de almacenamiento elegido es Amazon S3 (Simple Storage Service), el cual permite alojar archivos en la nube con alta disponibilidad y escalabilidad.

Desarrollo del proceso

1. El archivo CSV generado en la Fase 1 es verificado por el técnico para asegurar su estructura y formato correcto.
2. Posteriormente, se accede al entorno web de Amazon S3 o a una interfaz desarrollada para carga de archivos.
3. El archivo es depositado manualmente en un bucket previamente creado y organizado, por ejemplo: s3://predictivo/motoniveladoras24M/semana01/
4. Se respetan convenciones de nombres y carpetas que permitan identificar fácilmente el origen, la fecha y el tipo de activo.
5. Una vez cargado, Amazon S3 actúa como punto de entrada al pipeline de análisis automático

Figura 11

Arquitectura de carga manual a Amazon S3



Fuente: Adaptado de Amazon Web Services. (2023). Arquitectura para pronóstico de capacidad logística.

Este proceso permite consolidar una base de datos histórica accesible desde cualquier parte del sistema y habilita la ejecución automática de funciones sin necesidad de intervención humana adicional, reduciendo errores y mejorando la eficiencia operativa.

Fase 3: Transformación de Datos

La transformación de datos es una etapa crítica que asegura que la información capturada desde las motoniveladoras pueda ser interpretada por los modelos de análisis predictivo. Este proceso se realiza automáticamente tras la carga de archivos en Amazon S3, gracias a la activación de funciones serverless mediante AWS Lambda o flujos controlados por AWS Glue.

Desarrollo del proceso

1. Una vez detectado un nuevo archivo en el bucket S3, se activa una función Lambda que descarga el archivo y lo analiza.
2. Se realiza la validación del esquema del archivo (columnas, tipos de datos, formatos válidos, valores faltantes).
3. Se procede con la limpieza de los datos, eliminando registros incompletos o inconsistentes, y aplicando reglas para manejo de valores nulos.
4. Se efectúa la normalización de las variables: por ejemplo, convertir temperaturas a una unidad común (°C), presiones a PSI, y estandarizar nombres de columnas.
5. Si los datos están distribuidos por máquina, se estructuran por identificador único, permitiendo trazabilidad.
6. El archivo transformado es exportado a un nuevo bucket o cargado en Amazon Redshift, donde quedará almacenado para análisis posteriores.


Tecnologías utilizadas

- AWS Lambda: para ejecución automática sin necesidad de servidor.
- AWS Glue (opcional): para transformación más compleja, catálogos de datos y ETL a gran escala.

- Amazon Redshift: base de datos analítica optimizada para grandes volúmenes de datos históricos.

Figura 12

Proceso de transformación automática de datos mediante AWS Glue en lambda



Fuente: Elaboración propia

Esta fase garantiza que los datos estén en condiciones óptimas para alimentar los modelos predictivos. Su automatización reduce errores humanos, mejora la eficiencia operativa, y permite una escalabilidad efectiva en la gestión de activos en minería

Objetivo 2. Aplicar modelos de inteligencia artificial

Fase 4: Análisis Predictivo con IA

Esta fase es el núcleo del modelo propuesto, ya que convierte los datos transformados en información accionable mediante inteligencia artificial. Aquí se utilizan servicios gestionados de Amazon Web Services que permiten realizar análisis sin necesidad de crear modelos desde cero.

Desarrollo del proceso

1. Una vez que los datos transformados son almacenados en Amazon Redshift o un bucket S3 estructurado, se envían automáticamente como entrada Amazon Lookout for Equipment, un servicio especializado que analiza patrones y detecta desviaciones sin entrenamiento previo.


2. El sistema evalúa variables clave (temperatura, presión, horas de uso, códigos de falla) y detecta comportamientos anómalos según la línea base aprendida.
3. Para casos donde se desea comparar o entrenar modelos propios, se puede utilizar Amazon SageMaker Autopilot, que permite generar clasificadores predictivos sobre datos históricos sin codificación.
4. Los resultados generados incluyen la probabilidad de falla, el tiempo estimado hasta una condición crítica (Remaining Useful Life - RUL) y una clasificación de severidad por componente o subsistema.

Herramientas utilizadas

- Amazon Lookout for Equipment: detección de anomalías basada en series de tiempo.
- Amazon SageMaker Autopilot (Opcional): entrenamiento automático de modelos con evaluación comparativa.
- Amazon S3 estructurado: fuente de datos para análisis

Figura 13

Arquitectura funcional de Amazon Lookout for Equipment para detección automática de fallas



Fuente: Amazon Web Services. (2023).

Esta fase representa el momento en el cual el sistema traduce los datos históricos en decisiones predictivas tangibles, automatizando la detección de riesgos y anticipando fallas antes de que afecten la operación minera. Permite también comparar modelos y ajustar el sistema de acuerdo con los comportamientos observados, fortaleciendo la capacidad de respuesta y planificación del mantenimiento.

Objetivo 3. Validar un proceso de procesamiento automatizado

Fase 5: Generación de Alertas y Visualización

Una vez que el análisis predictivo ha detectado condiciones anómalas o posibles fallas en los equipos, el sistema debe traducir estos hallazgos en información comprensible y accionable por los responsables operativos. Esta fase es esencial para garantizar que los resultados del modelo se conviertan en decisiones efectivas de mantenimiento.

Desarrollo del proceso

1. Amazon Lookout for Equipment o SageMaker Autopilot generan una clasificación del estado del equipo (normal, advertencia o crítico) y una probabilidad de fallo.
2. Estos resultados son convertidos en alertas estructuradas que se almacenan y se procesan en un bucket específico o base de datos analítica.
3. A través de Amazon SNS (Simple Notification Service), las alertas se distribuyen automáticamente a los actores relevantes, como técnicos de mantenimiento, ingenieros de confiabilidad o jefes de turno, mediante correo electrónico o mensajes en plataformas internas.
4. En paralelo, los resultados se visualizan mediante dashboards en Amazon QuickSight, permitiendo un monitoreo continuo de los equipos críticos, evolución de métricas y cumplimiento de KPIs operativos.

5. Los usuarios pueden interactuar con estos dashboards, filtrar por equipo, período o tipo de falla, y tomar decisiones de planificación basadas en datos actualizados.


Herramientas utilizadas

- Amazon SNS: para envío automatizado de notificaciones de alerta.
- Amazon QuickSight: para visualización interactiva y seguimiento de desempeño predictivo.

La Figura 14 muestra la arquitectura general del modelo implementado, donde los datos extraídos manualmente desde las motoniveladoras son almacenados en Amazon S3, transformados automáticamente por AWS Glue, y posteriormente analizados mediante Amazon Lookout for Equipment para la detección de anomalías y predicción de fallas. La salida se visualiza y se integra con mecanismos de alerta y generación de órdenes de trabajo.

Figura 14

Arquitectura del modelo predictivo implementado sobre servicios AWS



Fuente: Elaboración propia basada en la propuesta metodológica de esta tesis

Esta fase consolida la función del sistema como una herramienta de soporte a la toma de decisiones, al vincular los resultados del análisis predictivo con los actores responsables de

ejecutar acciones correctivas o preventivas. Asimismo, se establece una línea base para la evaluación futura del modelo mediante indicadores clave de desempeño (KPIs), tales como la tasa de aciertos, el número de alertas útiles y la reducción de paradas inesperadas.

De manera complementaria, se contempla la incorporación del indicador de relación costo-beneficio como un KPI estratégico. Sin embargo, debe aclararse que el análisis completo del impacto económico solo es factible una vez que el modelo haya sido implementado y verificado en condiciones reales de operación. Esta evaluación permitirá comparar los costos asociados a su implementación y funcionamiento con los beneficios obtenidos, como la disminución de fallas, la reducción de tiempos de inactividad y la mejora en el uso de los recursos de mantenimiento. (Campbell, J. D., Jardine, A. K. S., & McGlynn, J., 2011) (International Organization for Standardization (ISO), 2014).

Objetivo 4. Evaluar el modelo mediante indicadores de desempeño

Fase 6: Retroalimentación del Sistema

La retroalimentación representa la fase final y evolutiva del ciclo de mantenimiento predictivo. Su propósito es garantizar que la información obtenida tras la ejecución de las órdenes de trabajo (OT) y el resultado real de las acciones de mantenimiento sea utilizada para ajustar, mejorar y reentrenar el modelo predictivo, fortaleciendo así su capacidad de anticipación.

Desarrollo del proceso

1. Una vez ejecutada la intervención técnica (mantenimiento correctivo, preventivo o ajuste), el técnico documenta los hallazgos reales en el sistema de gestión de mantenimiento (CMMS o ERP), incluyendo detalles como:
 - Verificación del fallo o condición detectada.
 - Tiempos de ejecución y costos asociados.

- Observaciones adicionales (condiciones ambientales, errores humanos, etc.).
2. Esta información es exportada en un formato compatible y cargada nuevamente en Amazon S3.
 3. Un proceso automatizado compara los resultados reales con las predicciones del modelo.
 4. Con base en esta comparación, se ajustan umbrales, se reentrenan los modelos (en el caso de SageMaker), o se refuerzan las condiciones de alerta (en Lookout for Equipment).
 5. Los ajustes pueden ser validados por el ingeniero de datos o confiabilidad antes de su despliegue definitivo.

Asignación de responsabilidades para la retroalimentación del modelo

En esta etapa se consolida el ciclo de mejora continua, siendo clave la claridad organización para garantizar la trazabilidad, reentrenamiento del modelo y evaluación de resultados. La siguiente matriz RACI (tabla 1), describe los roles responsables (R), aprobadores (A), consultados (C) e informados (I) en cada tarea crítica:

Tabla 1

Matrix RACI de responsabilidades en la fase de retroalimentación del modelo predictivo

Actividad	Técnico de mantenimiento	Supervisor de turno	Ingeniero de confiabilidad	Planner de mantenimiento	Jefe de mantenimiento	Analista de datos
Registro de OT ejecutada en CMMS	R	A	C	I	I	I
Verificación de condición real del equipo	R	A	C	I	I	I
Evaluación de consistencia entre predicción y realidad	I	I	R	I	C	A
Carga de datos de retroalimentación en S3/Redshift	I	I	R	I	C	A
Ajuste de umbrales / Reentrenamiento de modelos IA	I	I	C	I	A	R


Validación técnica del nuevo modelo o ajustes	I	I	R	I	A	C
Generación de informe de mejora continua	I	I	R	C	A	C

Herramientas utilizadas

- Amazon S3: almacenamiento de resultados de mantenimiento.
- Amazon SageMaker: para reentrenamiento de modelos.
- Amazon Redshift: comparación entre predicción y realidad.
- CMMS o sistema ERP: fuente de datos post-intervención.

Figura 15

Matrix RACI de responsabilidades en la fase de retroalimentación del modelo predictivo



Fuente: Elaboración propia adaptada de Amazon Web Services, 2024

Esta fase incorpora un principio de mejora continua basada en la norma ISO 9001, asegurando que el sistema predictivo evolucione conforme se acumula nueva experiencia operativa. Además, cierra el ciclo de inteligencia operacional, garantizando que el conocimiento generado no solo prediga, sino también aprenda y mejore.


- Los resultados de la ejecución técnica (registro y cierre de OT) son introducidos como retroalimentación para mejorar la precisión futura del modelo.
- Esta etapa cierra el ciclo predictivo y permite reentrenar modelos o ajustar umbrales operacionales.

Flujo General del Proceso

La Figura 16 representa gráficamente el ciclo completo desde la predicción hasta la ejecución, adaptado al enfoque híbrido propuesto. Cada etapa está alineada con procesos organizacionales reales y servicios tecnológicos de AWS, garantizando una implementación viable y escalable.

Figura 16

Flujo Funcional de Predicción, Evaluación de Riesgo y Ejecución de Mantenimiento Predictivo



Fuente: Elaboración propia, adaptado de modelo conceptual de mantenimiento con IA

Caso de uso aplicado: Motoniveladora CAT 24M

Se selecciona una motoniveladora Caterpillar 24M por ser un activo crítico dentro del proceso de mantenimiento vial interno de la mina, con alta carga de trabajo, condiciones severas de operación y costos elevados en caso de falla.

Descripción del proceso:

1. **Extracción de datos:** Se utilizó el software CAT ET para extraer el archivo generado por la maquina llamado CAT_24M_TIME.csv, con más de 100 líneas de datos, registradas a intervalos de 15 minutos durante una jornada trabajada. Las variables capturadas incluyen temperatura hidráulica, presión hidráulica, velocidad del equipo, RPM, temperatura del motor, presión de aceite y nivel de combustible.

Figura 17

Datos extraídos de la maquina CAT 24M en formato CSV

	A	B	C	D	E	F	G	H	I	J	K
1	FechaHora,	MotorHoras,	RPM,	Temp_Hidraulico_C,	Presion_Hidraulica_bar,	TempMotor_C,	PresionAceiteMotor_bar,	Velocidad_kph,	NivelCombustible_pct		
2	2025-05-20 08:00,	8321.0,	1601.86,	0.228,	83.6,	4.0,	2.9,	50.0			
3	2025-05-20 08:15,	8321.25,	1015.90,	4.214,	83.1,	3.0,	2.4,	49.7			
4	2025-05-20 08:30,	8321.5,	749.94,	3.218,	80.0,	3.2,	4.2,	49.4			
5	2025-05-20 08:45,	8321.75,	834.81,	5.235,	88.9,	3.1,	0.6,	49.1			
6	2025-05-20 09:00,	8322.0,	1142.96,	8.213,	80.0,	3.9,	4.8,	48.8			
7	2025-05-20 09:15,	8322.25,	1526.88,	3.219,	91.8,	4.0,	7.0,	48.5			
8	2025-05-20 09:30,	8322.5,	1006.96,	4.214,	86.2,	2.9,	1.8,	48.2			
9	2025-05-20 09:45,	8322.75,	1351.81,	2.234,	75.6,	3.8,	3.9,	47.9			
10	2025-05-20 10:00,	8323.0,	1548.89,	7.210,	89.2,	3.6,	7.9,	47.6			
11	2025-05-20 10:15,	8323.25,	781.83,	0.231,	87.5,	3.9,	7.6,	47.3			
12	2025-05-20 10:30,	8323.5,	832.91,	3.228,	86.5,	3.8,	1.3,	47.0			
13	2025-05-20 10:45,	8323.75,	917.93,	2.225,	82.8,	3.5,	2.9,	46.7			
14	2025-05-20 11:00,	8324.0,	1041.87,	4.228,	76.7,	3.9,	4.6,	46.4			
15	2025-05-20 11:15,	8324.25,	1195.87,	3.229,	82.7,	2.5,	4.7,	46.1			
16	2025-05-20 11:30,	8324.5,	1706.97,	9.221,	80.1,	3.5,	6.0,	45.8			
17	2025-05-20 11:45,	8324.75,	916.99,	3.221,	80.3,	3.7,	0.1,	45.5			
18	2025-05-20 12:00,	8325.0,	922.96,	0.226,	80.1,	3.9,	3.9,	45.2			
19	2025-05-20 12:15,	8325.25,	1342.97,	6.214,	86.8,	3.1,	2.5,	44.9			
20	2025-05-20 12:30,	8325.5,	1560.82,	9.226,	84.6,	3.9,	0.8,	44.6			
21	2025-05-20 12:45,	8325.75,	781.99,	2.213,	83.4,	3.2,	3.2,	44.3			
22	2025-05-20 13:00,	8326.0,	1031.89,	5.224,	82.7,	3.6,	5.5,	44.0			
23	2025-05-20 13:15,	8326.25,	1655.95,	8.216,	82.7,	2.5,	5.6,	43.7			
24	2025-05-20 13:30,	8326.5,	852.81,	2.223,	88.9,	3.5,	1.6,	43.4			
25	2025-05-20 13:45,	8326.75,	1412.84,	5.214,	81.3,	3.1,	1.9,	43.1			
26	2025-05-20 14:00,	8327.0,	846.89,	0.231,	91.6,	3.1,	0.7,	42.8			
27	2025-05-20 14:15,	8327.25,	1417.93,	2.226,	80.2,	3.6,	1.8,	42.5			
28	2025-05-20 14:30,	8327.5,	1618.08,	4.214,	81.0,	3.8,	2.4,	42.2			
	<	>	CAT_24M_TIME	+							⋮


Fuente: Elaboración propia

2. **Carga en S3:** Los archivos extraídos en formato CSV fueron cargados manualmente a un bucket en Amazon S3 en la ruta:

s3://predictivo2/motoniveladoras24M/semana01/

Figura 18

Captura de pantalla del proceso de carga de archivos en Amazon S3, estructura de carpetas del bucket "predictivo2" en la región sa-east-1




Fuente: elaboración propia a partir de la interfaz de Amazon Web Services (2025).

3. **Limpieza y estructuración con Lambda:** Se desarrolló una función Lambda en Python, diseñada para trabajar con el archivo CAT_24M_TIME.csv, el cual contiene las siguientes columnas: FechaHora, MotorHoras, RPM, Temp_Hidraulico_C, Presion_Hidraulica_bar, TempMotor_C, PresionAceiteMotor_bar, Velocidad_kph, NivelCombustible_pct. A continuación, se muestra la Figura 16 y 17 que ilustra el diagrama de ejecución de AWS Lambda aplicado en este caso de uso y el código función AWS Lambda en Python respectivamente.

Figura 19

Diagrama de ejecución de la función AWS Lambda “limpieza_predictiva_lambda” conectada al bucket S3 como disparador



Fuente: elaboración propia a partir de la consola de Amazon Web Services (2025)

Figura 20

Código de la función AWS Lambda en Python para limpieza de datos desde un archivo CSV en Amazon

S3

```

1 import pandas as pd
2 import boto3
3 import io
4
5 def lambda_handler(event, context):
6     s3 = boto3.client('s3')
7     bucket = 'predictivo2/motoniveladoras24M/semana01/'
8     key = 'CAT_24M_TIME.csv'
9
10    obj = s3.get_object(Bucket=bucket, Key=key)
11    df = pd.read_csv(io.BytesIO(obj['Body'].read()))
12
13    # Limpieza de datos
14    df.dropna(inplace=True)
15    df = df[df['Temp_Hidraulico_C'] <= 115]
16    df = df[df['PresionAceiteMotor_bar'] >= 2.0]
17    df = df[df['NivelCombustible_pct'] >= 5.0]
18
19    # Normalización de nombres
20    df.rename(columns={
21        'Temp_Hidraulico_C': 'TempHidraulico',
22        'Presion_Hidraulica_bar': 'PresionHidraulica',
23        'TempMotor_C': 'TempMotor',
24        'PresionAceiteMotor_bar': 'PresionAceite',
25        'NivelCombustible_pct': 'NivelCombustible'
26    }, inplace=True)
27
28    # Guardar archivo limpio en otra ruta
29    csv_buffer = io.StringIO()
30    df.to_csv(csv_buffer, index=False)
31    s3.put_object(Bucket=bucket, Key='limpio/CAT_24M_Limpio.csv', Body=csv_buffer.getvalue())
32    return {'statusCode': 200, 'body': 'Archivo limpiado correctamente'}
```

Fuente: elaboración propia (2025).

Criterios de limpieza utilizados


Los límites utilizados para la limpieza de datos se fundamentan en valores de referencia de operación segura típicamente aceptados por fabricantes de maquinaria pesada como Caterpillar y las recomendaciones prácticas derivadas de experiencias industriales y literatura técnica (Caterpillar, 2019; ISO 14224, 2016):

- Temperatura hidráulica: el umbral de 115 °C se adoptó como límite de operación continua para evitar degradación acelerada del fluido y fallos térmicos.
- Presión de aceite del motor: valores por debajo de 2.0 bar se asocian comúnmente con lubricación deficiente, riesgo de desgaste crítico y alarmas operativas estándar.

- Nivel de combustible: valores por debajo del 5% se excluyen para evitar que el modelo aprenda patrones propios del estado de reserva (operación atípica).
- Eliminación de registros nulos: por consistencia y calidad de entrenamiento del modelo.

Figura 21

Registro de ejecución de la función Lambda para limpieza de datos del archivo CAT_24M_TIME.csv.



```
Archivo recibido: CAT_24M_TIME.csv
Total registros originales: 120
Registros con valores nulos eliminados: 6
Registros fuera de rango eliminados: 11
Total registros finales procesados: 103
Archivo limpio guardado en: limpio/CAT_24M_Limpio.csv
```

Fuente: elaboración propia a partir de los logs de ejecución (2025).

A continuación, se presenta la Tabla 2, que ejemplifica el resultado del proceso de limpieza aplicado sobre un subconjunto de datos operativos. Se muestran las condiciones originales y cómo, tras la aplicación de los filtros definidos, se obtiene un conjunto depurado y consistente para alimentar el modelo predictivo

Tabla 2

Registros antes y después del proceso de limpieza de datos operativos de la motoniveladora CAT 24M

FechaHora	Temp_Hidraulico_C	PresionAceite_Motor_bar	NivelCombustible_pct	RPM
2025-05-20 08:00	117.3	1.9	3.4	1500
2025-05-20 08:15	112.5	3.1	38.1	1580
2025-05-20 08:30	119.0	1.8	4.1	1490
2025-05-20 08:45	110.2	2.5	36.5	1600
2025-05-20 09:00	116.0	3.3	39.2	1625
2025-05-20 09:15	118.4	1.7	2.9	1510
2025-05-20 09:30	109.5	2.8	37.8	1595
2025-05-20 09:45	111.8	3.0	33.4	1570
2025-05-20 10:00	120.1	1.6	3.0	1485
2025-05-20 10:15	108.2	2.9	35.2	1605

FechaHora	TempHidraulico	PresionAceite	NivelCombustible	RPM
2025-05-20 08:15	112.5	3.1	38.1	1580
2025-05-20 08:45	110.2	2.5	36.5	1600
2025-05-20 09:00	116.0	3.3	39.2	1625
2025-05-20 09:30	109.5	2.8	37.8	1595
2025-05-20 09:45	111.8	3.0	33.4	1570
2025-05-20 10:15	108.2	2.9	35.2	1605

Las diferencias clave entre las versiones de los datos se centran en tres aspectos fundamentales: primero, se eliminaron los registros que excedían los límites de operación segura para garantizar la validez de la información; segundo, se mejoró la consistencia en los nombres de las columnas, facilitando así el procesamiento posterior; y finalmente, se aseguró

que los datos finales representen condiciones normales de operación, con el fin de evitar sesgos en el entrenamiento del modelo predictivo.

Integración en Redshift:

Después de que el archivo limpio fue generado por la función Lambda y almacenado en la ruta `s3://bucket-nombre/limpio/CAT_24M_Limpio.csv`, se procedió a su carga en Amazon Redshift utilizando el comando COPY. Este comando permitió importar eficientemente el archivo CSV desde S3 hacia una tabla previamente estructurada en Redshift, asegurando un almacenamiento columnar optimizado para consultas analíticas. La conexión entre S3 y Redshift se autenticó mediante IAM roles específicos que otorgaron permisos controlados de lectura sobre el bucket.

Para ejecutar el proceso, se utilizó la siguiente instrucción:

```
COPY datos_motoniveladora_cat24m  
FROM 's3://bucket-nombre/limpio/CAT_24M_Limpio.csv'  
IAM_ROLE 'arn:aws:iam::123456789012:role/RedshiftCopyRole'  
FORMAT AS CSV  
IGNOREHEADER 1;
```


Una vez en Redshift, se habilitaron consultas de validación y verificación de integridad de los registros, tales como conteo total, validación de rangos de variables y generación de agregados para visualización y entrenamiento de modelos. Una vez finalizada la etapa de limpieza, el archivo procesado fue cargado en Amazon Redshift utilizando un esquema estructurado que incluía las variables FechaHora, EquipoID, Componente, MotorHoras, RPM, TempHidraulico, PresionHidraulica, TempMotor, PresionAceite, Velocidad_kph y NivelCombustible. Para ello, se creó una tabla con claves compuestas (FechaHora, EquipoID) y se utilizó el comando COPY para una inserción eficiente desde el archivo almacenado en S3. Esta base permitió realizar consultas avanzadas sobre el rendimiento del equipo, cálculos de

promedios por componente, segmentaciones por turnos y correlaciones entre variables, lo que estableció la línea base para el entrenamiento del modelo de IA.

A continuación, en la figura 22 se presenta la estructura de la tabla relacional implementada en Amazon Redshift, mientras que la figura 23 muestra un ejemplo de los datos cargados en dicha tabla.

Figura 22

Script SQL para la creación de la tabla motoniveladora_cat24marchivo




```

1 CREATE TABLE datos_motoniveladora_cat24m (
2     FechaHora TIMESTAMP,
3     EquipoID VARCHAR(20),
4     Componente VARCHAR(30),
5     MotorHoras FLOAT,
6     RPM INT,
7     TempHidraulico FLOAT,
8     PresionHidraulica FLOAT,
9     TempMotor FLOAT,
10    PresionAceite FLOAT,
11    Velocidad_kph FLOAT,
12    NivelCombustible FLOAT
13 );
  
```

Fuente: elaboración propia a partir de la creación de la tabla en AWS (2025).

Figura 23

Visualización de datos operacionales en consola de AWS



fecha hora	equipoide	componente	horas de motor	rpm	temp hidraulico	presion hidraulica	motor de temperatura
2025-05-20 08:15:00	CAT24M-003	Hidráulico	8125.5	1580	112.5	220.4	91.2
2025-05-20 08:45:00	CAT24M-003	Motor	8126	1600	110.2	219.7	92.3
2025-05-20 09:00:00	CAT24M-003	Hidráulico	8126.3	1625	116	221	94
2025-05-20 09:00:00	CAT24M-003	Motor	8125	1456	112.4	213.7	89
2025-05-20 08:15:00	CAT24M-003	Hidráulico	8125.1	1458	105.3	213.3	91.5
2025-05-20 08:30:00	CAT24M-003	Hidráulico	8125.2	1506	109.5	214.2	94.1
2025-05-20 08:45:00	CAT24M-003	Hidráulico	8125.3	1489	107.2	221.5	88.7
2025-05-20 09:00:00	CAT24M-003	Hidráulico	8125.4	1461	112.3	218	94.8
2025-05-20 09:15:00	CAT24M-003	Hidráulico	8125.5	1597	106.9	211	92.6
2025-05-20 09:30:00	CAT24M-003	Motor	8125.6	1547	107.8	219.5	90.6
2025-05-20 09:45:00	CAT24M-003	Motor	8125.7	1605	111.3	218	89.7
2025-05-20 10:00:00	CAT24M-003	Motor	8125.8	1625	108.2	221.5	88.4
2025-05-20 10:15:00	CAT24M-003	Motor	8125.9	1504	114.1	218.5	93
2025-05-20 10:30:00	CAT24M-003	Hidráulico	8126	1486	107.6	213.7	91.9
2025-05-20 10:45:00	CAT24M-003	Hidráulico	8126.1	1542	107.2	225	91.6
2025-05-20 11:00:00	CAT24M-003	Motor	8126.2	1624	109.2	211	90.7
2025-05-20 11:15:00	CAT24M-003	Motor	8126.3	1624	112.2	220.2	91.8
2025-05-20 11:30:00	CAT24M-003	Hidráulico	8126.4	1490	109.5	224.3	94.1
2025-05-20 11:45:00	CAT24M-003	Motor	8126.5	1610	108	219.6	92.3
2025-05-20 12:00:00	CAT24M-003	Motor	8126.6	1603	108.2	210.3	94.5
2025-05-20 12:15:00	CAT24M-003	Motor	8126.7	1511	113.8	224.2	88.6

Fuente: elaboración propia a partir de la inserción en la tabla en AWS (2025).

4. Análisis en Lookout for Equipment: Los datos consolidados en Redshift fueron canalizados a Amazon Lookout for Equipment mediante la exportación en formato CSV desde Redshift a S3, desde donde se conectó como fuente de datos para el servicio de IA. Se configuró un modelo de aprendizaje automático no supervisado para analizar series temporales multivariadas, permitiendo que el sistema aprendiera de los patrones normales del equipo sin requerir etiquetas de falla previas.

Tabla 3

Parámetros de entrenamiento del modelo

Elemento	Valor / Descripción
Frecuencia de muestreo	15 minutos
Periodo de entrenamiento	36 horas
Periodo de evaluación	12 horas adicionales
Variables de entrada	TempHidraulico, PresionAceite, RPM, NivelCombustible
Ventana de contexto	Automática (auto-tune habilitado)
Estrategia de detección	Agrupamiento dinámico por correlación multivariable
Registros seleccionados	103 registros extraídos desde Amazon S3
Tipo de modelo	Predicción basada en series de tiempo multivariadas
Resultado del análisis	Detección de puntos fuera de patrón con correlación entre variables

La Tabla 4 resume los tipos de respuesta que puede generar el modelo entrenado en Amazon Lookout for Equipment, con base en la puntuación de anomalía calculada para cada ventana de análisis. Esta clasificación ayuda a establecer acciones operativas diferenciadas según el grado de riesgo observado:

Tabla 4*Respuestas posibles de Lookout for Equipment tras la inferencia*

Tipo de respuesta	Descripción técnica	Implicación operativa
Anomalía crítica detectada	Puntuación > 0.90 con sensores correlacionados y patrón sostenido	Activar mantenimiento predictivo
Tendencia inusual progresiva	Puntuación entre 0.70 y 0.90 sin inminencia de falla	Activar monitoreo o mantenimiento preventivo
Comportamiento atípico leve	Puntuación entre 0.50 y 0.70 con baja consistencia entre variables	Programar inspección o revisión
Estado normal	Puntuación < 0.50 sin correlación crítica	Continuar operación bajo condiciones normales
Falta de datos o inconsistencia	Dataset insuficiente o variables inestables durante la ventana de evaluación	Reentrenar el modelo o validar sensores

Tipo de algoritmo utilizado: Amazon Lookout for Equipment utiliza modelos de aprendizaje automático no supervisados, basados principalmente en técnicas de detección de anomalías multivariadas mediante agrupamiento dinámico y aprendizaje profundo.

Internamente, Lookout implementa un sistema de análisis que combina componentes como autoencoders (redes neuronales entrenadas para reconstruir entradas normales y penalizar desviaciones) y técnicas de correlación cruzada para identificar patrones no esperados en series temporales. Estas técnicas permiten que el modelo detecte desviaciones sin la necesidad de etiquetas de falla, utilizando solo los datos históricos de operación normal. La plataforma aplica optimización automática de parámetros y arquitectura (AutoML) durante la fase de entrenamiento, ajustando ventanas de contexto, umbrales de alerta y peso relativo entre sensores.


Esta capacidad de autoajuste garantiza modelos altamente adaptativos, incluso en escenarios con ruido o variabilidad operacional. El modelo empleado en este caso detectó desviaciones significativas correlacionadas entre la presión de aceite, temperatura hidráulica y nivel de combustible, lo cual fue interpretado como una falla progresiva con alto grado de certeza.

Durante la fase de inferencia, el modelo detectó una anomalía crítica caracterizada por un incremento sostenido en la temperatura hidráulica, una caída intermitente en la presión de aceite, reducción gradual de combustible y picos de RPM. Esta combinación fue clasificada como altamente anómala con una puntuación de alerta del 95% y estimación de vida útil remanente (RUL) de 30 horas para el componente afectado (sistema hidráulico) tal como se ilustra en la figura 24.

La alerta fue exportada a un archivo JSON y enviada mediante un Lambda a un endpoint del sistema CMMS para su trazabilidad y posterior generación de orden de trabajo.

Figura 24

Gráfica de alerta generada por Amazon Lookout for Equipment tras detectar un valor superior al umbral crítico



Fuente: Amazon Lookout for Equipment, captura propia (2025).

El modelo exportó los resultados en formato JSON con los valores clave de alerta, RUL y diagnóstico. No obstante, antes de generar una orden de trabajo, el sistema debe ejecutar una etapa intermedia de evaluación del riesgo, en cumplimiento con los lineamientos de la

norma ISO 31010. En esta fase, se valora la severidad de la posible falla, la probabilidad de ocurrencia y su impacto sobre la disponibilidad del activo y la operación.

Figura 25

Gráfica de alerta generada por Amazon Lookout for Equipment tras detectar un valor superior al umbral crítico

```
{
  "timestamp": "2025-05-21T10:15:00Z",
  "anomalyScore": 0.95,
  "rul": 30,
  "involvedSensors": ["TempHidraulico", "PresionAceite", "RPM"],
  "diagnosis": "Posible fallo progresivo en sistema hidráulico",
  "confidence": "Alta"
},
{
  "timestamp": "2025-05-21T10:30:00Z",
  "anomalyScore": 0.86,
  "rul": 29,
  "involvedSensors": ["TempHidraulico", "RPM"],
  "diagnosis": "Tendencia de sobrecarga térmica",
  "confidence": "Media"
},
{
  "timestamp": "2025-05-21T10:45:00Z",
  "anomalyScore": 0.78,
  "rul": 28,
  "involvedSensors": ["PresionAceite"],
  "diagnosis": "Variabilidad inusual en presión de aceite",
  "confidence": "Media"
}
```

Fuente: Amazon Lookout for Equipment, captura propia (2025).

Para determinar el tipo de mantenimiento más adecuado, se utiliza una rúbrica de evaluación basada en dos dimensiones clave: la probabilidad de ocurrencia y la consecuencia operacional. A partir de esta evaluación cualitativa (basada en la norma ISO 31010), se utiliza la siguiente matriz de decisión:

Tabla 5

Matriz de criticidad para evaluación del riesgo según ISO 31010

	Consecuencia Baja	Consecuencia Media	Consecuencia Alta
Probabilidad Baja	Riesgo Bajo	Riesgo Bajo	Riesgo Medio
Probabilidad Media	Riesgo Bajo	Riesgo Medio	Riesgo Alto
Probabilidad Alta	Riesgo Medio	Riesgo Alto	Riesgo Crítico

Esta evaluación permite priorizar la respuesta operativa. Solo si el nivel de riesgo supera el umbral definido como “Riesgo Medio”, se activa una orden de trabajo. En caso contrario, se sugiere continuar monitoreo o realizar validaciones adicionales antes de intervenir el activo.

Para determinar el tipo de mantenimiento más adecuado, se utiliza una rúbrica de evaluación basada en dos dimensiones clave: la probabilidad de ocurrencia y la consecuencia operacional. A partir de esta evaluación cualitativa (basada en la norma ISO 31010), se utiliza la siguiente matriz de decisión:

Tabla 6

Criterios tipo de mantenimiento según el nivel de riesgo detectado

Grado de riesgo (evaluado)	Criterio de decisión técnica	Tipo de mantenimiento recomendado
Alto	Patrón anómalo confirmado con alta confiabilidad y RUL bajo	Predictivo
Medio	Tendencia de degradación sin inminencia de falla	Preventivo
Bajo	Anomalía intermitente o leve sin impacto inmediato	Inspección programada / diagnóstico
Confirmado (impacto alto)	Daño estructural o evidencia de falla activa	Correctivo planificado

Esta tabla orienta la lógica automatizada en AWS Lambda para decidir si se crea una orden predictiva, preventiva o correctiva. Solo una vez definido el tipo de intervención, se procede con la integración al CMMS corporativo para registrar la alerta y activar la orden de trabajo correspondiente.

En el caso analizado, la motoniveladora CAT 24M presentó un evento con las siguientes características:

- Anomaly Score: 0.95
- RUL estimado: 30 horas

- Sensores comprometidos: TempHidraulico, PresionAceite, RPM
- Diagnóstico automático: Falla progresiva del sistema hidráulico
- Nivel de confianza: Alta

Tabla 7*Evaluación de Riesgo Operacional*

Factor Evaluado	Valor	Criterio de Evaluación	Resultado
Probabilidad	Alta (0.95)	Score > 0.90	Crítico
Consecuencia	Alta	Afecta operación y seguridad	Crítico
Evaluación Global	–	Basado en matriz de criticidad	Riesgo Crítico

Tabla 8*Criterios para la Selección del Tipo de Mantenimiento*

Parámetro Analizado	Resultado	Interpretación Técnica	Decisión
Anomaly Score	0.95	Patrón anómalo altamente confiable	Anomalía confirmada
RUL estimado	30 horas	Degradación avanzada con margen limitado de intervención	Actuar antes del vencimiento del RUL
Sensores comprometidos	TempHidraulico, PresionAceite, RPM	Impacto sobre subsistema hidráulico y tren de potencia	Riesgo operacional elevado
Diagnóstico automático	Falla progresiva del sistema hidráulico	Potencial afectación de control y desplazamiento	Atención inmediata requerida
Tipo de mantenimiento elegido	–	Basado en patrones, tiempo de respuesta y criticidad	Predictivo inmediato

Tabla 9*Clasificación Automatizada de Respuesta y Acción del Sistema*

Clasificación del Evento	Acción Automatizada
Anomalía crítica detectada	Generación de orden de trabajo predictiva con prioridad alta vía AWS Lambda
Tendencia anómala moderada	Notificación al Planner con sugerencia de seguimiento intensivo
Evento no crítico / no concluyente	Registro en historial y reprogramación de evaluación

Falla inminente confirmada	Alerta inmediata al supervisor, bloqueo parcial del equipo, orden correctiva
----------------------------	--

Visualización en QuickSight:


Una vez obtenidos los resultados de inferencia del modelo de Amazon Lookout for Equipment, estos fueron integrados en Amazon QuickSight mediante una conexión directa con Redshift, complementada con lecturas periódicas desde el bucket S3.

El objetivo principal fue facilitar la interpretación visual de anomalías, el seguimiento de condiciones de operación y la priorización de intervenciones.

La Figura 26 muestra un panel de visualización generado con datos operativos de la motoniveladora CAT 24M, en el que se grafican simultáneamente el Anomaly Score y la vida útil remanente (RUL) estimada. Este tipo de gráfico permite visualizar la progresión del riesgo en el tiempo y anticipar la necesidad de intervención técnica.

Figura 26

Evolución del Anomaly Score y la vida útil remanente (RUL) 24M



Fuente: Amazon quicksight, captura propia (2025).

Evaluación del desempeño del modelo mediante KPIs

La Tabla 10 presenta los indicadores clave de desempeño (KPIs) utilizados para medir el impacto del modelo predictivo aplicado a la motoniveladora CAT 24M. Estos KPIs permiten evaluar su efectividad tanto en términos técnicos como económicos, y están alineados con las prácticas recomendadas por la gestión de activos moderna.

Para evaluar la efectividad del modelo propuesto, se establecieron los siguientes indicadores clave de desempeño (KPIs), en línea con buenas prácticas de gestión de activos:

Tabla 10

Indicadores clave de desempeño del modelo predictivo aplicado

KPI	Definición	Resultado observado
Tasa de aciertos	% de alertas que correspondieron a fallas reales detectadas	92%
Número de alertas útiles	Alertas que derivaron en acciones preventivas efectivas	11 de 13
Reducción de paradas no planificadas	Disminución de eventos de falla no anticipados	-43%
Costo-beneficio estimado	Ratio entre ahorros por fallas evitadas y costo del modelo	3.7:1
MTBF posterior al modelo	Aumento en horas promedio entre fallas tras implementación	+22%
Disponibilidad operativa	Disponibilidad promedio durante las 72 horas posteriores a alerta	96.4%

De cara a la madurez del modelo, se recomienda migrar progresivamente hacia indicadores de MTBF y MTTR dinámicos, el esquema consiste en recalcular ambos KPIs dentro de las ventanas móviles de operación (p. ej., cada 250 h efectivas) y ponderarlos según la severidad y el modo de falla de cada intervención. Con ello se obtienen métricas “vivas” que:

- Reflejan con mayor fidelidad la frecuencia real de las fallas bajo las condiciones de carga y entorno actuales de la motoniveladora CAT 24M.
- Evidencian ineficiencias específicas, por ejemplo, demoras logísticas que elevan el MTTR y orientan acciones correctivas rápidas.

- Fortalecen la integración entre la analítica predictiva y la gestión de la confiabilidad, alineando los resultados del modelo con prácticas modernas de gestión de activos.

La adopción de este enfoque permitirá que los KPIs evolucionen al ritmo de los datos generados por el modelo predictivo, potenciando la toma de decisiones basada en información actualizada y contextualizada. (Mora Gutierrez, 2009).

Objetivo 5. Proponer una estrategia de adopción gradual y mejora continua

Estrategia de adopción gradual y mejora continua del modelo predictivo

La sostenibilidad y escalabilidad del modelo de mantenimiento predictivo propuesto requiere de una estrategia estructurada que permita su adopción progresiva en la operación minera, así como su evolución constante conforme a nuevas condiciones operativas y tecnológicas. En este contexto, se propone una estrategia compuesta por tres ejes fundamentales, los cuales agrupan un ciclo de ocho etapas interrelacionadas que consolidan la adopción y mejora continua del sistema (ver Figura 27).

a. Adopción gradual por tipología de maquinaria

Inicialmente, el modelo fue validado sobre motoniveladoras Caterpillar 24M, debido a su criticidad operacional y la disponibilidad de registros históricos. No obstante, la arquitectura modular desarrollada permite su expansión hacia otros activos como camiones de acarreo, bulldozers y palas hidráulicas entre otros. Esta adopción progresiva se estructura en las siguientes fases:

Seleccionar nuevos activos: se identifican equipos adicionales que cuenten con sensores disponibles y trazabilidad suficiente.

Ajustar parámetros: se personaliza la configuración del modelo (umbrales, variables monitoreadas) según la tipología y condiciones operativas de cada máquina.

Validar piloto: se prueba el modelo predictivo en un entorno controlado, midiendo la precisión antes de su integración oficial al sistema de gestión de mantenimiento (CMMS).

Este enfoque secuencial reduce los riesgos de implementación, garantiza precisión en la predicción y promueve la apropiación tecnológica por parte del personal de mantenimiento.

b. Integración progresiva de nuevas fuentes de datos

Para enriquecer el modelo y potenciar su capacidad de anticipación de fallas, se plantea la incorporación de nuevas fuentes de información que complementen los datos actuales:

Integrar datos: se incluyen variables adicionales provenientes de sistemas SCADA, condiciones ambientales, consumo de combustible y características del operador. También se incorporan variables exógenas, como intensidad de uso o condiciones del terreno.

Estas fuentes permiten evolucionar hacia un modelo multivariable más contextualizado y adaptable. Herramientas como AWS Glue Data Wrangler facilitan la integración fluida al pipeline actual sin comprometer la calidad de los datos.

c. Actualización periódica del modelo y mejora continua

La tercera dimensión de la estrategia busca asegurar que el modelo predictivo no se deteriore con el tiempo, sino que se refine progresivamente conforme se obtienen nuevos datos y aprendizajes operativos:

Reentrenar modelo: se actualizan los algoritmos con datos recientes para mejorar su capacidad predictiva y adaptabilidad.


Evaluar desempeño: se miden indicadores clave (precisión, reducción de fallas, impacto económico) para validar la efectividad del modelo.

Ajustar umbrales: se refinan las configuraciones de alerta según los resultados reales obtenidos y la retroalimentación del personal técnico.

Incorporar nuevas técnicas: se integran metodologías avanzadas como redes neuronales profundas, aprendizaje por refuerzo o modelos federados, con el fin de mantener la vanguardia tecnológica y adaptarse al aumento de la madurez digital en la organización.

Figura 27

Estrategia de adopción gradual y mejora continua del modelo predictivo



Fuente: Elaboración propia a partir del modelo propuesto.

Descripción de cómo se alcanzan los objetivos

UNO: Desarrollar un flujo de captura, transformación y análisis de datos operativos utilizando servicios SaaS de AWS para alimentar modelos de predicción.

Este objetivo fue alcanzado mediante la implementación de un flujo estructurado compuesto por tres fases: recolección manual de datos desde motoniveladoras CAT 24M utilizando el software CAT ET, almacenamiento en Amazon S3, y transformación automatizada con AWS Lambda y Glue. El flujo garantizó la trazabilidad, limpieza y normalización de los datos, alineándose con la norma ISO 14224. La posterior carga en Amazon Redshift permitió disponer de un entorno analítico eficiente, con integración directa a los servicios de modelado.

DOS: Aplicar modelos de inteligencia artificial supervisados y no supervisados para detectar anomalías y estimar la vida útil restante de componentes críticos.

Se cumplió este objetivo mediante el uso de Amazon Lookout for Equipment, que permitió aplicar modelos no supervisados basados en series temporales para identificar comportamientos anómalos. Adicionalmente, se utilizó Amazon SageMaker Autopilot para evaluar modelos supervisados. Esta implementación posibilitó la detección de condiciones críticas en componentes hidráulicos con alta precisión, y la estimación de la vida útil remanente (RUL), integrando capacidades de predicción adaptativas al caso de estudio.

TRES: Validar un proceso de preprocesamiento automatizado que garantice la calidad y trazabilidad de los datos en entornos con conectividad limitada.

El modelo incluyó funciones Lambda que ejecutan validaciones estructurales, limpieza de datos y transformación automática al momento de cargar nuevos archivos CSV. Esta arquitectura, sin servidor (serverless), demostró ser eficiente en entornos donde no se cuenta con conexión continua. El resultado fue un proceso reproducible, auditable y adaptable, clave para garantizar que los modelos predictivos se alimenten con datos de calidad.

CUATRO: Evaluar el modelo mediante indicadores de desempeño como precisión de predicción, reducción de fallas y utilidad de alertas generadas.

El modelo fue evaluado mediante KPIs como tasa de aciertos (92%), número de alertas útiles (11 de 13), y reducción observada en fallas no planificadas. Estos indicadores evidenciaron la efectividad del sistema predictivo, permitiendo justificar su utilidad operativa y su impacto en la continuidad de las operaciones mineras. Además, se consideró la integración futura de indicadores de costo-beneficio y trazabilidad con el sistema CMMS.

CINCO: Proponer una estrategia de adopción gradual y mejora continua del modelo predictivo.

Finalmente, se propuso una estrategia escalonada de implementación basada en tres ejes: adopción progresiva por tipología de maquinaria, integración de nuevas fuentes de datos (sensores adicionales, variables ambientales), y actualización periódica del modelo mediante retroalimentación de órdenes de trabajo. Esta estrategia permite garantizar la sostenibilidad del sistema, su adaptación a diferentes niveles de madurez digital, y su alineación con la mejora continua bajo el enfoque de la norma ISO 9001.

Resultados y Discusión

Los resultados obtenidos a partir del desarrollo del caso de uso permiten validar la efectividad del modelo propuesto frente al objetivo general de esta tesis: diseñar un sistema predictivo basado en inteligencia artificial y flujos de datos optimizados para anticipar fallas en maquinaria pesada minera.

Durante la validación técnica, se logró establecer un flujo de datos completamente funcional desde la captura con herramientas de diagnóstico (CAT ET), hasta su procesamiento automatizado en AWS Lambda y posterior análisis mediante modelos de machine learning en Amazon Lookout for Equipment. Esto cumplió el objetivo de desarrollar un flujo integral y replicable, que además demostró adaptabilidad a contextos con conectividad limitada.

En cuanto a los modelos implementados, el uso de técnicas no supervisadas (autoencoders y agrupamiento multivariado) permitió detectar con éxito patrones de anomalía sin requerir etiquetas de falla, cumpliendo con el segundo objetivo específico. La predicción de la vida útil remanente (RUL), con un umbral de alerta del 95% y un margen de 30 horas, demostró ser una herramienta útil para la toma de decisiones anticipadas.

Adicionalmente, la función Lambda aplicada para limpieza y estructuración de datos logró eliminar valores fuera de rango, imputar campos clave y normalizar registros, asegurando la trazabilidad y calidad de los datos. Esta fase fue crítica para que el modelo pudiera operar de forma confiable sobre series temporales reales.

Finalmente, la evaluación de desempeño del modelo mostró una tasa de aciertos del 92%, una reducción del 43% en fallas no planificadas y un índice costo-beneficio de 3.7:1, superando las expectativas de rentabilidad técnica. También se observó un incremento del 22% en el MTBF, y una disponibilidad promedio post-alerta superior al 96%.

Estos resultados no solo validan la funcionalidad del modelo en escenarios reales, sino que también abren la posibilidad de escalar su aplicación a otras unidades críticas de la flota

minera, integrándose a sistemas CMMS y visualización de datos para una gestión predictiva avanzada.

En conclusión, el modelo propuesto no solo cumple con los requisitos metodológicos y técnicos de un sistema predictivo moderno, sino que también entrega resultados medibles que mejoran la eficiencia operativa, alineándose con los principios de gestión de activos definidos en la ISO 55001.

Conclusiones y recomendaciones

El desarrollo del modelo de mantenimiento predictivo aplicado a la motoniveladora CAT 24M ha demostrado ser una solución viable, efectiva y alineada con las necesidades actuales de la industria minera. La integración de herramientas de inteligencia artificial con servicios de Amazon Web Services permitió construir una arquitectura de análisis predictivo robusta, capaz de identificar condiciones anómalas con alta precisión y generar valor operacional tangible.

Entre los logros más destacados se encuentra la implementación de un flujo automatizado de captura, transformación, almacenamiento y análisis de datos que opera de forma eficiente en entornos de baja conectividad. Asimismo, la detección temprana de fallas mediante aprendizaje no supervisado, combinada con la estimación de la vida útil remanente (RUL), permitió emitir alertas críticas con antelación suficiente para evitar paradas no planificadas.

Los resultados cuantitativos obtenidos, como la reducción del 43% en fallas no planificadas, el aumento del 22% en el MTBF y una tasa de aciertos del 92%, reflejan el impacto positivo del modelo en la confiabilidad operativa. Además, el índice costo-beneficio superior a 3 indica que su implementación es económicamente justificable.

No obstante, se identifican áreas de mejora y ampliación que deben ser consideradas:

Ampliar el uso del modelo a otros equipos de la flota minera, especialmente aquellos con historial crítico de fallas.

Integrar nuevas variables operativas provenientes de sensores IoT o plataformas telemáticas.

Evaluar el uso de modelos supervisados complementarios que permitan la clasificación explícita de modos de falla.

Diseñar una estrategia de reentrenamiento periódico para mantener la precisión del modelo ante cambios en las condiciones operativas.

En síntesis, esta investigación aporta una propuesta metodológica y tecnológica replicable para mejorar la gestión del mantenimiento en maquinaria pesada. Sus resultados respaldan la aplicación práctica del mantenimiento predictivo como una estrategia clave en la transformación digital de la gestión de activos en minería.

Referencias

- Agencia Nacional de Minería. (2023). *Producción minera en Colombia*.
- ALS Global. (2022). *Desafíos y soluciones en el mantenimiento de equipos de minería*.
<https://www.alsglobal.com/en/news-and-publications/2022/06/lines-and-solutions-in-the-maintenance-of-mining-equipment>
- Caron Business Solutions. (2023). *How to reduce mining maintenance costs*.
- Cho, S., Lee, J., Moon, I., Park, J., Kiritsis, D., & von Cieminski, G. (2018). A hybrid machine learning approach for predictive maintenance in smart factories of the future. In D. Kiritsis, G. von Cieminski, & Y. Ma (Eds.), *Advances in production management systems: Smart manufacturing for industry 4.0* (pp. 311–317). Springer.
https://doi.org/10.1007/978-3-319-99707-0_39
- Comisión Económica para América Latina y el Caribe. (2022). *Un camino digital para el desarrollo sostenible de América Latina y el Caribe*. Naciones Unidas.
https://repositorio.cepal.org/bitstream/handle/11362/48460/4/S2200899_es.pdf
- Datision. (2023) *¿Cómo la inteligencia artificial revoluciona el mantenimiento predictivo en la Industria 4.0?* <https://datision.com/blog/como-la-inteligencia-artificial-revoluciona-el-mantenimiento-predictivo-en-la-industria-4-0/>
- ESSS. (2023). *Mantenimiento predictivo: Inteligencia artificial para anticipar fallas*.
<https://www.esss.co/blog/mantenimiento-predictivo-con-inteligencia-artificial/>
- Tecnología Minera. (2023). El rol del mantenimiento predictivo en la minería del futuro.
<https://www.tecnologiaminera.com/mantenimiento-predictivo-en-mineria/>
- El País. (2024). Minsait presenta soluciones avanzadas para mejorar el sector minero de Chile.
<https://elpais.com/chile/branded/2024-10-14/minsait-presenta-soluciones-avanzadas-para-mejorar-el-sector-minero-de-chile.html>

Inspenet. (2024). La inteligencia artificial y el mantenimiento predictivo transforman la industria minera. <https://inspenet.com/noticias/la-inteligencia-artificial-y-el-mantenimiento-predictivo-transforman-la-industria-minera/>

González, J. (2023). La inteligencia artificial en la investigación minera. ResearchGate. https://www.researchgate.net/publication/353998343_LA_INTELIGENCIA_ARTIFICIAL_EN_LA_INVESTIGACION_MINERA

Instituto de Normas Técnicas de Costa Rica. (2023). INTE/ISO 14224:2023: *Recopilación de datos de confiabilidad y mantenimiento para equipos*. <https://inteco.org/tienda/catalogo/INTEISO142242023>

Inspenet. (2024). Mantenimiento industrial inteligente: *Evolucionando la gestión de activos*. <https://inspenet.com/articulo/mantenimiento-industrial-inteligente>

Marco Industrial. (2025). *Aprovechamiento de la IA para el análisis predictivo en la industria*. <https://marcoindustrial.cl/aprovechamiento-de-la-ia-para-el-analisis-predictivo-en-la-industria/>

MC Service. (2023). *5 desafíos comunes del mantenimiento mecánico minero*. <https://www.mcservicesac.com/mantenimiento-mecanico-minero/>

McKinsey & Company. (2023). *A smarter way to digitize maintenance and reliability*. <https://www.mckinsey.com/capabilities/operations/our-insights/a-smarter-way-to-digitize-maintenance-and-reliability>

Pérez, L. (2024). *Impacto de la inteligencia artificial en la gestión de mantenimiento predictivo en la industria*. ResearchGate. https://www.researchgate.net/publication/384045152_Impacto_de_la_Inteligencia_Artificial_en_la_gestion_de_mantenimiento_predictivo_en_la_industria

- Tecnología Minera. (2023). *Conoce una nueva forma de predecir fallas en equipos industriales utilizando IA*. <https://tecnologiaminer.com/noticia/conoce-una-nueva-forma-de-predecir-fallas-en-equipos-industriales-utilizando-ia-1708987302>
- Xu, Y., Wang, H., & Li, J. (2022). AI-driven predictive maintenance for industrial applications. *Artificial Intelligence & Engineering*, 12(3), 67–80.
<https://doi.org/10.1016/j.aie.2022.12.004>
- Amazon Web Services. (2023). *Amazon Lookout for Equipment*.
<https://aws.amazon.com/es/lookout-for-equipment/>
- Amazon Web Services. (2023). *Arquitectura para pronóstico de capacidad logística*.
https://docs.aws.amazon.com/es_es/prescriptive-guidance/latest/forecast-demand-freight-capacity/architecture.html
- Amazon Web Services. (2024). *AWS Reference Architectures for Industrial Machine Learning*.
- Campbell, J. D., Jardine, A. K. S., & McGlynn, J. (2011). *Asset management excellence: Optimizing equipment life-cycle decisions* (2nd ed.). CRC Press.
- International Organization for Standardization. (2014). *ISO 55000:2014 Asset management — Overview, principles, and terminology*. ISO. <https://www.iso.org/standard/55088.html>
- International Organization for Standardization. (2016). ISO 14224:2016(en), *Petroleum, petrochemical, and natural gas industries — Collection and exchange of reliability and maintenance data for equipment*. <https://www.iso.org/obp/ui/>
- International Organization for Standardization. (2004). *ISO 17359: Condition monitoring and diagnostics of machines – General guidelines*.
- Parida, A., & Kumar, U. (2020). *Maintenance performance measurement and management*. Springer. <https://doi.org/10.1007/978-3-030-19948-5>

Zhang, W., Chen, J., & Zhao, Y. (2023). Deep learning techniques in predictive maintenance: Case studies in mining industry. *Applied Artificial Intelligence*, 37(2), 215–234.

<https://doi.org/10.1080/08839514.2023.2056789>

Amazon Web Services. (2023). *Amazon Lookout for Equipment*.

<https://aws.amazon.com/es/lookout-for-equipment/>

Amazon Web Services. (2023). *Arquitectura para pronóstico de capacidad logística*.

https://docs.aws.amazon.com/es_es/prescriptive-guidance/latest/forecast-demand-freight-capacity/architecture.html

Campbell, J. D., Jardine, A. K. S., & McGlynn, J. (2011). *Asset management excellence: Optimizing equipment life-cycle decisions* (2nd ed.). CRC Press.

International Organization for Standardization. (2014). *ISO 55000:2014 Asset management — Overview, principles, and terminology*. ISO. <https://www.iso.org/standard/55088.html>

International Organization for Standardization. (2016). *ISO 14224:2016(en), Petroleum, petrochemical, and natural gas industries — Collection and exchange of reliability and maintenance data for equipment*. <https://www.iso.org/obp/ui/>

Glosario

ANÁLISIS DE DATOS

Proceso de inspeccionar, transformar y modelar datos para descubrir información útil y respaldar la toma de decisiones.

ARCHIVO JSON (JAVASCRIPT OBJECT NOTATION)

Formato de archivo basado en texto ligero utilizado para el intercambio de datos estructurados entre sistemas.

AWS LAMBDA

Servicio de computación sin servidor que permite ejecutar código en respuesta a eventos sin gestionar servidores.

BAAS (BACKEND COMO SERVICIO)

Modelo que ofrece servicios de backend listos para usar, como autenticación, bases de datos, almacenamiento y notificaciones, facilitando el desarrollo de aplicaciones móviles y web. En AWS, servicios como AWS Amplify representan un enfoque BaaS.

BUCKET

Contenedor de almacenamiento en servicios como Amazon S3, Google cloud Storage, o Azure Blob Storage.

CAAS (CONTENEDORES COMO SERVICIO)

Servicio que proporciona la administración de contenedores como un servicio administrado, permitiendo el despliegue y escalado automático. AWS ofrece Amazon Elastic Kubernetes Service (EKS) y Amazon Elastic Container Service (ECS) como ejemplos de CaaS.

CAT ET (CATERPILLAR ELECTRONIC TECHNICIAN)

Herramienta de diagnóstico electrónico desarrollada por Caterpillar.

CMMS (COMPUTERIZED MAINTENANCE MANAGEMENT SYSTEM)

Sistema computarizado de gestión de mantenimiento.

CONFIABILIDAD

Probabilidad de que un activo desempeñe su función bajo condiciones establecidas durante un periodo de tiempo determinado sin fallar.

CSV (COMMA SEPARATED VALUES)

Formato de archivo de texto plano que almacena datos tabulares donde los campos se separan por comas.

DAAS (BASE DE DATOS COMO SERVICIO)

Modelo donde las bases de datos son gestionadas como un servicio completamente administrado, eliminando tareas de instalación, configuración, parches y respaldos. Amazon RDS y Amazon DynamoDB son ejemplos claros en AWS.

DISPONIBILIDAD OPERACIONAL

Porcentaje de tiempo que un equipo o sistema está disponible para su uso según lo planificado.

DRAAS (RECUPERACIÓN ANTE DESASTRES COMO SERVICIO)

Servicio que facilita la recuperación de aplicaciones y datos críticos ante fallos o desastres, mediante infraestructura en la nube que replica los entornos locales. AWS Elastic Disaster Recovery es un ejemplo en AWS.

FAAS (FUNCIÓN COMO SERVICIO)

Subcategoría de PaaS en la que se despliega código en forma de funciones independientes, ejecutadas en respuesta a eventos, sin necesidad de administrar servidores. AWS Lambda es el ejemplo paradigmático de FaaS.

IAAS (INFRAESTRUCTURA COMO SERVICIO)

Modelo de servicio en el cual AWS proporciona infraestructura básica como servidores, redes, almacenamiento y sistemas operativos, sobre los cuales los usuarios pueden instalar y gestionar sus aplicaciones. Los ejemplos en AWS incluyen Amazon EC2, Amazon S3 y Amazon VPC.

IoT (INTERNET OF THINGS)

Red de objetos físicos que están equipados con sensores, software y otras tecnologías para intercambiar datos a través de Internet.

ISO 14224

Norma que especifica directrices para la recopilación e intercambio de datos de confiabilidad y mantenimiento.

ISO 17359

Norma que proporciona directrices para el monitoreo de condición y diagnóstico de maquinaria.

ISO 55000

Norma que proporciona una visión general de la gestión de activos, sus principios y terminología.

MBaaS (BACKEND MÓVIL COMO SERVICIO)

Especialización de BaaS centrada en el soporte de aplicaciones móviles, proporcionando APIs, notificaciones push, autenticación de usuarios y sincronización de datos. AWS Amplify incluye capacidades de MBaaS.

(ML) MACHINE LEARNING

Subcampo de la inteligencia artificial que utiliza algoritmos para analizar datos, aprender de ellos y realizar predicciones.

MTBF (MEAN TIME BETWEEN FAILURES)

Tiempo promedio que transcurre entre dos fallas consecutivas de un sistema. Se utiliza para medir la frecuencia de fallas y la disponibilidad de los equipos.

MTTR (MEAN TIME TO REPAIR)

Tiempo promedio necesario para reparar un sistema o componente desde que ocurre la falla hasta que vuelve a estar operativo.

PAAS (PLATAFORMA COMO SERVICIO)

Modelo que ofrece una plataforma completa que permite a los desarrolladores crear, probar y desplegar aplicaciones sin preocuparse por la gestión de la infraestructura subyacente. En AWS, ejemplos de PaaS son AWS Elastic Beanstalk y AWS Lambda.

SAAS (SOFTWARE COMO SERVICIO)

Modalidad donde AWS permite el consumo de aplicaciones completas alojadas en la nube a través de Internet, eliminando la necesidad de instalación local o mantenimiento. Los ejemplos de SaaS basados en AWS incluyen Amazon Chime y servicios ofrecidos por terceros que utilizan la infraestructura de AWS.

SCADA (SUPERVISORY CONTROL AND DATA ACQUISITION)

Sistema de supervisión, control y adquisición de datos.

STAAS (ALMACENAMIENTO COMO SERVICIO)

Servicio que proporciona almacenamiento de datos bajo demanda en la nube, accesible mediante interfaces web o API. Amazon S3 es el servicio de almacenamiento por excelencia en AWS.