

Análisis y predicción de fallas en maquinaria pesada mediante modelos de regresión logística

Analysis and prediction of failures in heavy machinery using logistic regression models

Oscar Cofré Vera¹

 <https://orcid.org/0009-0008-3788-6091>

Valeria Scapini Sánchez^{2, 3*}

 <https://orcid.org/0000-0001-8195-3062>

Recibido 19 de octubre de 2025, aceptado 11 de diciembre de 2025

Received: October 19, 2025 Accepted: December 11, 2025

RESUMEN

Este estudio analiza el comportamiento de fallas en maquinaria pesada utilizada en operaciones mineras, perteneciente a una empresa proveedora de servicios al sector extractivo. Estas fallas generan detenciones no programadas que elevan los costos y afectan la eficiencia operativa. El objetivo principal es identificar tendencias y patrones de fallas a partir del análisis de datos históricos registrados entre enero de 2019 y julio de 2024, con el fin de optimizar la gestión del mantenimiento correctivo. La metodología consistió en un análisis estadístico descriptivo de fallas registradas en el sistema SAP, centrado en cuatro conjuntos críticos: motor, freno, implemento y sistema eléctrico. Posteriormente, se aplicó un modelo de regresión logística para estimar la probabilidad de ocurrencia de fallas, incorporando variables como horómetro, temperatura y condiciones operativas. Los resultados muestran que la frecuencia de fallas aumenta con el uso acumulado de los equipos, especialmente en los sistemas eléctricos e implemento. Se identificaron umbrales de uso a partir de los cuales la tasa de fallas se incrementa significativamente. Estos hallazgos permiten mejorar la planificación de intervenciones, optimizar la gestión de repuestos críticos y reducir tiempos de inactividad. En conclusión, el estudio ofrece una herramienta práctica para la toma de decisiones en mantenimiento, al combinar análisis estadísticos y modelación predictiva. Se recomienda integrar estos modelos con plataformas como SAP para fortalecer la trazabilidad, disponibilidad y confiabilidad de los equipos en entornos mineros exigentes.

Palabras clave: Mantenimiento predictivo, análisis de fallas, maquinaria pesada, regresión logística, gestión de repuestos.

ABSTRACT

This study analyzes the failure behavior of heavy machinery used in mining operations by a company that provides services to the extractive sector. These failures result in unplanned downtime, increasing costs and negatively impacting operational efficiency. The primary objective is to identify trends and patterns in failures by analyzing historical data recorded between January 2019 and July 2024, to optimize corrective maintenance management. The methodology involved a descriptive statistical

¹ Universidad Central de Chile. Facultad de Ingeniería y Arquitectura. Santiago, Chile.

E-mail: oscar.cofre@alumnos.ucentral.cl

² Universidad Central de Chile. Facultad de Economía, Gobierno y Comunicaciones. Santiago, Chile.

E-mail: valeria.scapini@ucentral.cl

³ Universidad de Valparaíso. Escuela de Ingeniería Comercial. Santiago, Chile. Email: valeria.scapini@uv.cl

* Autor de correspondencia: valeria.scapini@ucentral.cl

analysis of failures reported in the SAP system, focusing on four critical subsystems: engine, brake, implement, and electrical system. Subsequently, a logistic regression model was applied to estimate the probability of failure occurrence, incorporating variables such as hourometer readings, temperature, and operational conditions. The results show that failure frequency increases with accumulated equipment usage, particularly in the electrical and implement systems. Usage thresholds were identified, beyond which the failure rate rises significantly. These findings contribute to improved planning of maintenance interventions, better management of critical spare parts, and reduction of downtime. In conclusion, the study provides a practical tool for maintenance decision-making by integrating statistical analysis with predictive modeling. It is recommended to incorporate these models into management platforms such as SAP to enhance the traceability, availability, and reliability of equipment in demanding mining environments.

Keywords: Predictive maintenance, failure analysis, heavy machinery, logistic regression, spare parts managements.

INTRODUCCIÓN

El mantenimiento de maquinaria pesada en la industria minera representa un desafío crítico debido a los altos costos asociados a las fallas imprevistas y a la detención no programada de los equipos. Estas interrupciones no solo afectan el rendimiento operativo de las empresas proveedoras de servicios, sino que también son esenciales para la continuidad y eficiencia operativa y minimizar el tiempo de inactividad [1]-[3]. En este contexto, la gestión adecuada del mantenimiento correctivo y la incorporación de estrategias predictivas se vuelven fundamentales para optimizar el uso de los recursos, minimizar las pérdidas operacionales y aumentar la disponibilidad de los equipos [3]-[5].

Diversos estudios han abordado el problema de la predicción de fallas en maquinaria industrial mediante técnicas estadísticas y modelos de aprendizaje automático, con el fin de anticipar eventos críticos y tomar decisiones informadas [6], [7]. En particular, la regresión logística se ha consolidado como una herramienta eficaz para modelar la probabilidad de ocurrencia de fallas a partir de variables operativas y ambientales, destacando por su facilidad de interpretación y aplicabilidad en contextos donde se requiere claridad en la toma de decisiones [8]-[10]. Este tipo de modelo permite identificar con precisión los factores que incrementan el riesgo de averías, tales como el tiempo de funcionamiento de un equipo, la temperatura o la humedad, lo que resulta clave en ambientes operacionales complejos.

Gran parte de la literatura existente se ha enfocado en sectores manufactureros, automotrices o

energéticos, siendo aún limitada su aplicación sistemática en entornos extremos como la minería de alta montaña. En estos escenarios, factores como las condiciones climáticas adversas, la altitud, o las cargas operativas elevadas introducen variables adicionales de estrés mecánico y eléctrico que complejizan el comportamiento de los equipos [11], [12]. Esto refuerza la necesidad de desarrollar modelos predictivos adaptados a las condiciones particulares de la operación minera, capaces de integrar información histórica y en tiempo real para mejorar la eficiencia del mantenimiento.

Motivado por esta necesidad, el presente trabajo tiene como propósito analizar el comportamiento histórico de fallas en maquinaria pesada utilizada en faenas mineras, con el fin de identificar patrones, tendencias y puntos críticos en el ciclo de vida de los componentes. Para ello, se utilizaron registros extraídos del sistema SAP de una empresa contratista del rubro, correspondientes al periodo comprendido entre enero de 2019 y julio de 2024. El análisis se centró en cuatro conjuntos críticos –motor, freno, implemento y sistema eléctrico– seleccionados por su alta frecuencia de fallas y su relevancia en términos de impacto operativo.

El estudio propone la construcción de un modelo de regresión logística que permita estimar la probabilidad de falla en función de variables operativas relevantes. Asimismo, se integran herramientas de análisis estadístico y técnicas de visualización para facilitar la interpretación de los resultados y su aplicación práctica en la planificación del mantenimiento. Este enfoque se enmarca dentro de una lógica de mantenimiento centrado en la confiabilidad (RCM),

que busca prolongar la vida útil de los equipos y reducir las fallas no planificadas mediante una gestión informada basada en evidencia [5], [13]. En definitiva, el objetivo es contribuir al diseño de estrategias de mantenimiento más eficientes y proactivas, fortaleciendo así la disponibilidad operativa y la competitividad del sector minero.

METODOLOGÍA

La estrategia metodológica adoptada en este estudio se estructura en dos etapas principales. En primer lugar, se lleva a cabo un análisis estadístico descriptivo de las fallas registradas en el sistema SAP de seis equipos de transporte (tres camiones aljibes y tres camiones tolva, todos de la marca Renault), considerando el período comprendido entre enero de 2019 y julio de 2024. Los registros contienen información detallada sobre los incidentes ocurridos en la maquinaria pesada, lo que permite observar y caracterizar las fallas según su frecuencia, severidad y condiciones operativas asociadas. Para el procesamiento y visualización de estos datos, se emplea el lenguaje de programación Python en entornos Colab, utilizando librerías como *pandas*, *NumPy*, *matplotlib*, *kdplot* y *seaborn*. Este análisis permite explorar tendencias y patrones mediante gráficos e indicadores descriptivos, tras un proceso previo de depuración y transformación de datos, que incluye limpieza, tratamiento de valores faltantes y codificación de variables.

En la segunda etapa, se construye un modelo predictivo utilizando técnicas de aprendizaje supervisado, específicamente mediante regresión logística. Este modelo tiene por objetivo estimar la probabilidad de ocurrencia de fallas críticas, incorporando variables relacionadas con el uso de los equipos (como el horómetro y las condiciones operativas), el entorno (factores climáticos como temperatura, humedad y precipitaciones) y la tipología de la falla (mecánica, eléctrica, de frenos o implementos). Estas variables se seleccionan en función de su relevancia técnica y su capacidad para representar causas frecuentes de fallas en la operación de los vehículos.

La regresión logística es una herramienta estadística adecuada para este tipo de análisis, ya que permite modelar eventos binarios, como la ocurrencia o no de una falla. A través de la función logística, también

conocida como función sigmoide, se transforma una combinación lineal de variables explicativas en una probabilidad entre 0 y 1. Esta transformación se expresa matemáticamente de la siguiente manera, ecuación (1) [14]:

$$P(Y = 1|X) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 X_1 + \dots + \beta_k X_k)}} \quad (1)$$

donde $P(Y = 1|X)$ representa la probabilidad de que ocurra una falla, dado el conjunto de variables independientes X_i , y β_i son los coeficientes que reflejan la influencia de cada predictor. El modelo permite clasificar los casos según si la probabilidad estimada supera el umbral de 0,5, lo que indica la presencia del evento.

En este estudio, la especificación general del modelo se presenta como, ecuación (2):

$$\rho_i = P(X_i, Z_i) = \sigma(\beta_o + \beta_X^T X_i + \beta_Z^T Z_i) \quad (2)$$

Con $\sigma(t) = \frac{1}{1 + e^{-t}}$; donde X_i representa un conjunto de variables operativas y de uso de la maquinaria, mientras que Z_i agrupa variables ambientales y otros factores externos. El modelo no solo permite predecir la probabilidad de fallo, sino también identificar las variables con mayor impacto en su ocurrencia.

Entre las ventajas de este enfoque se encuentran su facilidad de interpretación y su bajo costo computacional. No obstante, se debe considerar que su desempeño puede verse afectado si existen relaciones no lineales complejas o alta correlación entre las variables independientes, lo que podría dificultar la convergencia del algoritmo [14].

DATOS

Este apartado presenta y describe el conjunto de datos analizados y utilizados para el desarrollo del modelo predictivo orientado a anticipar fallas en maquinaria pesada. El objetivo central del análisis es identificar patrones y relaciones significativas que permitan predecir con mayor precisión qué equipos requieren tiempos prolongados de detención, lo cual incide directamente en la disponibilidad operativa y genera pérdidas económicas relevantes para el contrato en curso.

La base de datos fue extraída del módulo SAP PM (Plant Maintenance) del sistema de gestión de mantenimiento, una plataforma ampliamente utilizada para registrar, planificar y controlar las actividades de mantenimiento industrial. El período considerado abarca desde enero de 2019 hasta julio de 2024, totalizando cinco años de información operacional y técnica. Esta cobertura temporal permite una caracterización robusta del comportamiento de los equipos, incluyendo eventos de falla y sus condiciones asociadas.

Los datos recolectados incluyen variables tanto dependientes como independientes, registradas en formato de panel, lo que permite el seguimiento longitudinal de cada equipo en estudio. Entre las variables consideradas se encuentran:

Fecha del evento: registro cronológico de cada incidente o actividad.

- Horómetro: horas de funcionamiento del equipo.
- Tipo de falla: categorización de la falla (mecánica, eléctrica, frenos, implementos).
- Condiciones ambientales: temperatura ambiente, precipitaciones y humedad relativa.
- Variables operacionales: número de horas de operación, tipo de servicio, y condiciones de carga.

Esta estructura de datos permite analizar no solo la frecuencia de las fallas, sino también su posible asociación con factores ambientales y operacionales. A partir de esta información, se busca fortalecer la toma de decisiones en el ámbito del mantenimiento preventivo y correctivo, mediante la optimización de recursos técnicos y logísticos. De este modo, se contribuye a prolongar la vida útil de los equipos y mejorar la eficiencia global del sistema de

mantenimiento en un entorno minero altamente exigente.

A continuación, se presenta la Tabla 1, que detalla la fecha de ingreso a faena de cada uno de los equipos incluidos en el análisis:

A continuación, se incorpora un resumen detallado del total de fallas registradas por tipo de conjunto y por equipo, el cual se presenta en la Tabla 2. Esta clasificación contempla cuatro categorías principales: fallas eléctricas, de freno, de implementos y de motor, permitiendo una visualización clara de la distribución de fallas acumuladas a lo largo del período comprendido.

La tabla anterior permite identificar patrones relevantes para la gestión del mantenimiento. Se observa que el Equipo 301 presenta la mayor cantidad total de fallas (259), lo que lo posiciona como una prioridad para intervenciones correctivas y preventivas. En contraste, el Equipo 227 registra el menor número de fallas acumuladas (113), reflejando un desempeño operativo más estable y posiblemente una mayor eficiencia en su mantenimiento.

Tabla 1. Fecha de ingreso a faena de los equipos analizados.

Equipo	Año de Ingreso
225	04-03-2019
226	27-02-2019
227	03-03-2019
301	25-01-2019
302	18-02-2019
512	26-02-2020

Fuente: Elaboración propia.

Tabla 2. Fallas acumuladas por tipo de conjunto y equipo.

Equipo	Eléctrico	Freno	Implemento	Motor	Total
225	59	20	54	33	166
226	84	12	75	46	217
227	49	12	32	20	113
301	96	27	79	57	259
302	56	11	45	22	134
512	87	24	26	54	191
Total	431	106	311	232	1080

Fuente: Elaboración propia.

RESULTADOS

Análisis temporal de fallas

El análisis de fallas revela que el equipo 301 concentra la mayor cantidad de incidentes, especialmente en los sistemas eléctricos y de motor. Sin embargo, con el paso del tiempo, los equipos 226 y 512 adquieren mayor relevancia, al registrar altos niveles de fallas eléctricas, de freno y motor. Las fallas eléctricas se mantienen como las más frecuentes a lo largo de los años, mientras que las fallas de motor afectan principalmente a los equipos de mayor tamaño.

La Figura 1 muestra la evolución de las fallas acumuladas por año durante el período comprendido entre 2019 y 2024. Los datos evidencian una tendencia ascendente en la cantidad de fallas registradas desde 2019, alcanzando su punto máximo en el año 2023, cuando se contabilizaron más de 120 fallas eléctricas, entre otras. Este incremento sugiere un deterioro progresivo en la fiabilidad de los equipos, posiblemente asociado al envejecimiento de los componentes y al aumento acumulado en las horas de operación.

A pesar de que el 2024 se observa una disminución significativa en el número de fallas reportadas, es importante señalar que esta reducción podría estar relacionada con la cobertura parcial del año, ya que los datos disponibles abarcan solo hasta el mes de julio, lo que representa aproximadamente la mitad

del periodo anual. Si la tasa de fallas se mantiene durante el resto de 2024, los valores anuales podrían igualar los de 2023. La disminución observada podría deberse a mejoras en el mantenimiento o a cambios operativos, por lo que será clave seguir monitoreando para confirmar si se trata de una tendencia real o solo temporal.

Diagrama de cajas (Boxplot)

Este diagrama de cajas (Boxplot) muestra la distribución del horómetro en el momento de las fallas, separadas por tipo de conjunto: ELÉCTRICO, MOTOR, FRENO, e IMPLEMENTO. Cada caja resume estadísticamente la dispersión de las lecturas de horómetro asociadas a las fallas de ese conjunto. En el eje vertical se representa el horómetro (uso acumulado), y cada categoría (tipo de falla) presenta su rango de valores. En términos generales, la línea dentro de la caja indica la mediana, el valor central de la distribución, el borde inferior y superior de la caja representan el primer y tercer cuartil (Q1 y Q3), por lo que la caja encierra el 50% central de los datos. Las líneas horizontales (“bigotes”) se extienden hasta el mínimo y máximo sin contar valores atípicos, cualquier punto fuera de los bigotes se considera un valor atípico lo que podemos visualizar en la Figura 2.

La mediana se encuentra aproximadamente por debajo de las 10.000 hrs. en el horómetro, sugiere que la mitad de las fallas eléctricas ocurren antes de las




Figura 1. Acumulación de fallas por tipo.




Figura 2. Tipo de Fallas vs Horómetro.

10.000 horas de trabajo. El rango intercuartílico (Q1-Q3) es amplio, lo que indica una gran variabilidad: algunas fallas eléctricas aparecen a bajos niveles de uso (cerca de 0), mientras que otras se extienden hasta rangos muy altos (cerca de los 20.000). Esto podría significar que las fallas eléctricas pueden suceder tanto al inicio de la vida útil como en etapas posteriores, reflejando sensibilidad a varios factores operativos.

La mediana del motor es mayor que la de Eléctrico e Implemento, situándose cerca o por encima de los 10.000 hrs. Esto indica que típicamente las fallas de motor se concentran en una etapa más avanzada de la vida del equipo. El rango también es amplio, pero se aprecia que la parte central del motor tiende a fallar a un horómetro mayor, lo que sugiere que el desgaste mecánico interno del motor se manifiesta más claramente después de cierta acumulación de horas.

El conjunto Freno presenta una mediana todavía más alta, alrededor de los 12.000 hrs. o más. Esto significa que la mitad de las fallas de freno ocurren después de un uso considerable del equipo. La caja para freno es relativamente alta, indicando que las fallas de freno se concentran en rangos superiores de horómetro. Esto sugiere que los frenos tienden a fallar más tarde, probablemente debido a un desgaste progresivo que se hace crítico tras mayor tiempo de servicio.

La mediana de Implemento es similar a la de Eléctrico, alrededor de valores medios (unos 7.000 a 8.000 hrs), indicando que las fallas del implemento se manifiestan a un horómetro intermedia. El rango intercuartílico no es tan elevado como Freno o Motor, lo que podría indicar que las fallas del implemento se concentran un poco más en un rango acotado de horómetro, pudiendo ser resultado de desgaste mecánico asociado a la tarea principal del equipo, manifestándose antes de que el equipo sea muy veterano.

El gráfico anterior permite ver que los conjuntos Freno y Motor presentan medianas más elevadas que Eléctrico e Implemento, lo que significa que, en promedio, sus fallas ocurren en etapas más avanzadas del uso. Podríamos interpretar que los frenos y el motor requieren más tiempo y desgaste para manifestar fallas, tal vez debido a su robustez inicial o a que su degradación mecánica tarda más en hacerse significativa. Por otro lado, Eléctrico e Implemento muestran medianas más bajas, sugiriendo que sus fallas tienden a ocurrir en etapas menos avanzadas del uso. En el caso de Eléctrico, puede ser que componentes electrónicos y cableados sean más susceptibles a fallar desde el inicio por factores ambientales o de calidad, y en el caso de Implemento, el desgaste temprano puede ser resultado del uso intensivo del componente principal del equipo. El Boxplot muestra un patrón de cómo el horómetro (horas de trabajo) se relaciona con la ocurrencia de fallas en diferentes conjuntos.

Eléctrico e Implemento tienden a fallar a horómetro más bajos (fallas más tempranas en la vida útil), mientras que Motor y sobre todo Freno evidencian fallas mayoritariamente a mayores horómetros, reflejando un desgaste que se hace palpable más adelante. Estos hallazgos pueden guiar las estrategias de mantenimiento preventivo, sugiriendo que las inspecciones eléctricas e implementos deberían ser más frecuentes desde etapas tempranas ya que sufren un proceso de adaptación por las circunstancias a las que se ven sometidas, mientras que las verificaciones de freno y motor podrían intensificarse después de acumular más uso.

Análisis de distribución de fallas mediante histogramas

Los histogramas presentados en la Figura 3 permiten visualizar la distribución de la densidad de fallas en función del horómetro para cada tipo de conjunto, desagregada por equipo. Esta representación complementa el análisis del boxplot al mostrar no solo los estadísticos de posición y dispersión, sino también la concentración temporal de las fallas a lo largo del ciclo de vida operativo. Cada histograma utiliza intervalos de 500 horas de operación, lo que permite identificar períodos críticos donde la frecuencia de fallas se incrementa significativamente.

El análisis de los histogramas revela patrones diferenciados según el tipo de conjunto. En el caso de fallas eléctricas (430 fallas registradas), se observa una distribución multimodal con picos de densidad concentrados en rangos tempranos (2.000-3.000 horas) y medios (7.000-8.000 horas), principalmente atribuibles al Equipo 226. Este patrón sugiere que el sistema eléctrico presenta vulnerabilidades tanto en etapas iniciales de operación, posiblemente asociadas a problemas de instalación o adaptación a condiciones ambientales, como en períodos intermedios donde el desgaste acumulado de componentes comienza a manifestarse. La presencia de múltiples picos indica que las fallas eléctricas no siguen un patrón uniforme de desgaste, sino que responden a factores específicos que pueden activarse en diferentes momentos del ciclo de vida.

Para el conjunto Motor (231 fallas registradas), la distribución muestra una concentración más clara en el rango de 9.000-10.000 horas, con el Equipo 226 como principal contribuyente. Este patrón unimodal sugiere que las fallas de motor tienden a manifestarse después de un período de operación acumulada, confirmando el comportamiento observado en el boxplot donde la mediana se sitúa en valores superiores. La concentración en un rango específico




Figura 3. Distribución de fallas por tipo de conjunto.

indica que el desgaste mecánico del motor sigue un patrón más predecible, posiblemente relacionado con el ciclo de vida de componentes internos como pistones, válvulas o sistemas de lubricación.

El histograma de fallas de Freno (106 fallas registradas) muestra una distribución más dispersa, con picos menores distribuidos a lo largo de todo el rango de horómetro. Sin embargo, se observa una concentración notable alrededor de 12.000-13.000 horas, principalmente del Equipo 301, y otra en el rango de 4.000 horas, atribuible al Equipo 226. Esta distribución dispersa refleja la mayor variabilidad en el momento de falla de los frenos, lo cual es consistente con su naturaleza de desgaste progresivo que puede verse acelerado por condiciones operativas específicas como frenado intensivo en pendientes o diferencias en la calidad del mantenimiento preventivo.

Finalmente, el histograma de fallas de Implemento (310 fallas registradas) presenta una distribución con picos prominentes en el rango de 10.000-11.000 horas (principalmente Equipo 225) y en 5.000-6.000 horas (Equipo 226). Este patrón bimodal sugiere que las fallas del implemento pueden manifestarse tanto en etapas intermedias como avanzadas, dependiendo de factores como la intensidad de uso, las condiciones de carga y las características específicas de cada equipo. La presencia de períodos con baja densidad (tramos horizontales en las curvas de fallas acumuladas) indica que algunos equipos mantienen períodos prolongados sin fallas, mientras que otros presentan acumulación acelerada en rangos específicos.

En conjunto, los histogramas confirman que cada tipo de falla presenta un perfil de distribución único, lo que refuerza la necesidad de estrategias de mantenimiento diferenciadas. Los sistemas eléctricos requieren atención desde etapas tempranas debido a su susceptibilidad inicial, mientras que motor y freno, aunque más robustos inicialmente, presentan períodos críticos identificables que permiten planificar intervenciones preventivas. El análisis de densidad complementa la información proporcionada por los gráficos de fallas acumuladas al mostrar no sólo cuándo ocurren las fallas, sino también la intensidad de su concentración en períodos específicos, facilitando la identificación de ventanas de oportunidad para intervenciones de mantenimiento.

Análisis de fallas acumuladas

A continuación, se presentan gráficos de fallas acumuladas en función del horómetro (Figuras 4-7), aplicados de manera independiente a cada conjunto analizado. Esta representación permite visualizar la progresión temporal de las fallas a lo largo de la vida útil de los equipos, mostrando cada evento de falla como un punto discreto en una curva escalonada.

Los gráficos de fallas acumuladas fueron separados por tipo de conjunto (ELÉCTRICO, IMPLEMENTO, MOTOR, FRENO) y por equipo (225, 226, 227, 301, 302, 512). Cada línea corresponde a un equipo específico, mostrando cómo se acumulan las fallas a lo largo de la vida útil medida en el horómetro. El eje horizontal representa el horómetro (horas de operación acumuladas), mientras que el eje vertical muestra el número acumulado de fallas registradas hasta ese momento. La pendiente de cada curva indica la tasa de fallas: una pendiente más pronunciada refleja una mayor frecuencia de fallas en ese período (alta tasa de fallas), mientras que tramos horizontales indican períodos sin fallas (alta confiabilidad). Una línea vertical punteada marca la primera falla registrada en cada conjunto, proporcionando un punto de referencia temporal. Cada línea de distinto color representa un equipo, lo que permite comparar cómo varía el comportamiento de fallas entre equipos. Se observan diferentes patrones de acumulación: algunos equipos presentan fallas tempranas con curvas que ascienden rápidamente desde bajos valores de horómetro, mientras que otros muestran un comportamiento más estable con fallas que se manifiestan en etapas más avanzadas de su vida útil (por encima de 10.000 o 15.000 horas). Los cambios de pendiente en las curvas señalan momentos críticos donde la tasa de fallas se modifica, información clave para la planificación de intervenciones preventivas.

Conjunto eléctrico

La Figura 4 muestra la acumulación de fallas eléctricas en función del horómetro para cada equipo, revelando patrones claramente diferenciados. El sistema eléctrico registra 430 fallas totales en el período analizado, siendo el conjunto con mayor incidencia de fallas. El equipo 225 presenta el comportamiento más crítico, con una acumulación temprana y sostenida que inicia a las 488 horas y alcanza 59 fallas hasta las 12.013 horas, mostrando una pendiente pronunciada en el rango de 0-5.000




Figura 4. Fallas acumuladas del conjunto eléctrico.

horas que indica alta vulnerabilidad inicial. El equipo 302 exhibe un patrón similar con 56 fallas, destacando un período crítico entre 8.000-13.000 horas donde la pendiente se intensifica significativamente. El equipo 301 presenta la mayor acumulación con 96 fallas desde las 47 horas hasta las 21.766 horas, mostrando una tasa relativamente constante pero sostenida a lo largo de toda su vida útil. El equipo 512 acumula 86 fallas hasta las 22.225 horas, con una progresión uniforme que sugiere un desgaste gradual del sistema eléctrico. El equipo 226 registra 84 fallas con una aceleración notable en el rango de 8.000-13.000 horas. En contraste, el equipo 227 presenta el mejor desempeño con solo 49 fallas hasta las 9.887 horas, manteniendo una tasa de fallas más controlada. Los tramos horizontales observados en varias curvas indican períodos sin fallas, mientras que las pendientes pronunciadas señalan momentos críticos que requieren atención preventiva. Este análisis confirma que el sistema eléctrico es particularmente susceptible a fallas tempranas, posiblemente debido a la sensibilidad de componentes electrónicos, cableados y conectores a factores ambientales como vibraciones, humedad, polvo y fluctuaciones de voltaje propias del entorno minero.

Conjunto implemento

La Figura 5 presenta la acumulación de fallas del conjunto Implemento, revelando patrones escalonados claramente diferenciados según el uso de cada equipo.

Con 310 fallas totales registradas, este conjunto representa el segundo en frecuencia de fallas. El equipo 225 muestra el comportamiento más crítico, iniciando con fallas tempranas a las 1.657 horas y acumulando 54 fallas hasta las 11.997 horas, con una pendiente constante que indica desgaste mecánico sostenido. El equipo 226 presenta la mayor acumulación con 75 fallas desde las 1.635 horas hasta las 13.545 horas, exhibiendo períodos de alta intensidad entre 8.000-12.000 horas donde se observan múltiples fallas concentradas. El equipo 301 acumula 78 fallas desde las 47 horas hasta las 22.045 horas, mostrando una progresión relativamente uniforme con algunos tramos horizontales que indican períodos de estabilidad operativa. El equipo 302 registra 45 fallas con inicio a las 336 horas, presentando una aceleración notable en el rango de 8.000-13.000 horas. El equipo 512 destaca por su excepcional confiabilidad inicial: mantiene una tasa muy baja de fallas hasta aproximadamente las 10.000 horas, momento en el cual la pendiente se incrementa, acumulando solo 26 fallas hasta las 22.231 horas, el mejor desempeño del conjunto. El equipo 227 muestra un comportamiento intermedio con 32 fallas distribuidas entre 1.528 y 9.497 horas. Los tramos horizontales prolongados en las curvas de los equipos 512 y 227 sugieren períodos de operación sin fallas, mientras que las pendientes pronunciadas en los equipos 225 y 226 indican momentos críticos de desgaste acelerado. Este comportamiento escalonado confirma que las




Figura 5. Fallas acumuladas del conjunto implemento.

fallas del implemento están fuertemente asociadas al desgaste mecánico por uso intensivo, cargas operativas y condiciones de trabajo, manifestándose de manera más pronunciada después de superar umbrales específicos de operación.

Conjunto motor

La Figura 6 ilustra la acumulación de fallas del conjunto Motor, evidenciando una progresión claramente diferenciada según el uso de cada equipo. Con 231 fallas totales registradas, el motor representa el tercer conjunto en frecuencia de fallas, caracterizado por manifestarse predominantemente en etapas avanzadas de la vida útil. El equipo 301 registra su primera falla a las 611 horas y acumula 57 fallas hasta las 21.520 horas, mostrando una progresión relativamente uniforme con una aceleración notable en el rango de 10.000-15.000 horas, alcanzando una mediana de 13.561 horas. El equipo 302 presenta su primera falla a las 1.300 horas y acumula 22 fallas hasta las 13.016 horas, exhibiendo la tasa más baja de fallas de motor con una mediana de 9.745 horas, lo que sugiere un mantenimiento efectivo o condiciones operativas menos exigentes. El equipo 512 destaca por su excepcional confiabilidad inicial: comienza a fallar a las 831 horas, pero mantiene una tasa muy baja hasta aproximadamente las 15.000 horas, momento en el cual la pendiente se incrementa significativamente, acumulando 54 fallas hasta las 21.923 horas con una mediana de 16.930 horas, la más alta del conjunto. El equipo 225 registra 33 fallas desde las 972 horas,

con una progresión constante y mediana de 9.108 horas. El equipo 226 muestra la mayor acumulación con 46 fallas desde las 900 horas, presentando una pendiente sostenida a lo largo de su vida útil con mediana de 9.748 horas. El equipo 227 presenta el mejor desempeño con solo 19 fallas entre 908 y 9.789 horas, con mediana de 7.486 horas. Los tramos horizontales prolongados observados especialmente en los equipos 512 y 302 indican períodos extensos sin fallas de motor, mientras que las pendientes más pronunciadas en los equipos 301 y 226 señalan períodos de mayor desgaste. Este patrón confirma que las fallas de motor están fuertemente asociadas al desgaste mecánico acumulado, manifestándose de manera más pronunciada en etapas avanzadas de operación, posiblemente influenciado por factores como calidad del combustible, condiciones de carga, temperatura de operación, calidad del mantenimiento preventivo y características específicas del diseño de cada motor.

Conjunto freno

La Figura 7 presenta la acumulación de fallas del conjunto Freno, revelando una secuencia progresiva claramente diferenciada según el uso de cada equipo. Con 106 fallas totales registradas, el sistema de frenos representa el conjunto con menor incidencia de fallas, caracterizado por su mayor robustez y confiabilidad operativa. El equipo 301 registra su primera falla a las 1.554 horas y acumula 27 fallas hasta las 22.069 horas, con una mediana de




Figura 6. Fallas acumuladas del conjunto motor.




Figura 7. Fallas acumuladas del conjunto freno.

16.423 horas, mostrando una progresión escalonada con períodos prolongados sin fallas seguidos de aceleraciones puntuales, lo que indica que las fallas de freno se manifiestan predominantemente en etapas avanzadas de la vida útil. El equipo 512 destaca por su excepcional confiabilidad inicial: no presenta ninguna falla de freno hasta las 11.571 horas, momento a partir del cual acumula 24 fallas hasta las 21.933 horas con una mediana de 17.373 horas, la más alta del conjunto, reflejando que el sistema de frenos se mantiene operativo durante

períodos prolongados antes de requerir intervenciones correctivas. El equipo 302 presenta su primera falla a las 3.273 horas y acumula solo 11 fallas hasta las 13.058 horas, mostrando la tasa más baja de fallas de freno con mediana de 11.141 horas. El equipo 225 registra un comportamiento atípico con su primera falla muy temprana a las 223 horas, acumulando 20 fallas hasta las 12.013 horas con mediana de 7.819 horas, presentando una pendiente pronunciada en el rango de 15.000–22.000 horas que indica un período crítico tardío. El equipo 226 también presenta fallas

tempranas desde las 198 horas, acumulando 12 fallas con mediana de 4.967 horas, la más baja del conjunto. El equipo 227 registra su primera falla a las 153 horas y acumula 12 fallas hasta las 9.453 horas con mediana de 6.256 horas, mostrando una progresión escalonada con largos períodos de estabilidad. Los tramos horizontales prolongados observados en todas las curvas, especialmente en los equipos 512, 301 y 302, indican períodos extensos sin fallas de freno, característica distintiva de este conjunto. Este patrón diferenciado sugiere que el sistema de frenos, en general, presenta mayor robustez mecánica y tiende a fallar en etapas más avanzadas de la vida útil, aunque algunos equipos (225, 226, 227) muestran fallas tempranas que podrían estar asociadas a condiciones operativas específicas como frenado intensivo en pendientes, calidad de componentes, ajustes iniciales inadecuados o diferencias en el mantenimiento preventivo aplicado.

Para optimizar la gestión de fallas y mantenimiento, se recomienda: Definir umbrales de horómetro concretos (por ejemplo, 5.000, 8.000, 10.000 y 15.000 horas), identificando los puntos donde las curvas de fallas acumuladas presentan cambios de pendiente significativos, lo que indica períodos críticos de mayor frecuencia de fallas. También implementar mantenimientos preventivos específicos para cada conjunto antes de alcanzar estos umbrales, minimizando el impacto de fallas inesperadas. Por último, analizar si la operación, la carga o las condiciones de uso cambian significativamente en estos rangos críticos, lo que permitiría ajustar la logística y planificar recambios de piezas de manera más eficiente. Con este enfoque, se puede mejorar la fiabilidad operativa y reducir costos asociados a fallas correctivas. En resumen, los gráficos de fallas acumuladas muestran claramente que las fallas aumentan con el uso, y cada equipo presenta un

patrón único de acumulación. La pendiente de estas curvas proporciona información directa sobre la tasa de fallas en cada período, permitiendo identificar momentos críticos donde se requiere mayor atención. Para mejorar la predicción y reducir fallas, es clave reforzar las inspecciones y recambios en los períodos identificados como críticos, maximizando así la disponibilidad de la flota.

Interpretación basada en confiabilidad

Desde un enfoque estratégico, integrar metodologías de confiabilidad en este estudio permite justificar inversiones en mejoras tecnológicas, capacitación del personal y cambios en la gestión de repuestos. Así, el uso de MTBF y otras herramientas de confiabilidad se convierte en un pilar fundamental para la gestión eficiente del mantenimiento en operaciones mineras, asegurando la continuidad y eficiencia del servicio de la flota de camiones y equipos pesados. Aplicar metodologías de confiabilidad es crucial, ya que permite evaluar y predecir el comportamiento de los equipos a lo largo del tiempo, optimizando el mantenimiento y reduciendo costos operativos. En la siguiente Tabla 3 presenta el Mean Time Between Failures (MTBF) promedio en función del horómetro para distintos equipos y conjuntos (Eléctrico, Freno, Implemento y Motor).

El MTBF indica cuánto recorrido (u horas de operación equivalentes) transcurre en promedio entre fallas de un conjunto específico en un equipo. Valores más altos de MTBF destacadas en verde significan que las fallas ocurren con menor frecuencia (más confiabilidad), mientras que valores más bajos destacados en marrón indican mayor frecuencia de fallas (menor confiabilidad).

El análisis del MTBF (Tiempo Medio entre Fallas) basado en el horómetro muestra un patrón consistente

Tabla 3. Promedio de MTBF.

Equipo	Eléctrico	Freno	Implemento	Motor
225	198,7	620,5	198,7	195,0
226	156,9	1077,4	160,9	281,6
227	195,7	845,4	257,0	493,3
301	228,6	789,0	373,3	282,0
302	233,2	978,5	557,9	289,1
512	258,43	450,52	870,04	397,96

Fuente: Elaboración propia.

en el que el sistema de freno es el más confiable en la mayoría de los equipos, con la menor frecuencia de fallas. Esto podría atribuirse a un diseño robusto, menor complejidad operativa o una estrategia de mantenimiento más efectiva. En contraste, el sistema eléctrico suele presentar los valores de MTBF más bajos, indicando que es el subsistema más propenso a fallas, probablemente debido a su sensibilidad a factores ambientales como vibraciones, humedad o fluctuaciones eléctricas. Implemento y motor tienden a ubicarse en posiciones intermedias, aunque con variaciones según el equipo. En la mayoría de los casos, el motor es más confiable que eléctrico e implemento, pero menos que freno, como en el Equipo 302, donde su MTBF de 557,9 supera a Implemento (289,1) y Eléctrico (233,2), pero está por debajo de Freno (978,5). Sin embargo, hay excepciones como el Equipo 512, donde Implemento (870,0) supera incluso al freno, lo que sugiere que factores como condiciones operativas y estrategias de mantenimiento pueden alterar este patrón general. En conjunto, estos datos resaltan la importancia de un mantenimiento diferenciado según el subsistema, priorizando inspecciones y estrategias predictivas especialmente en eléctrico, que se presenta como el punto más crítico en términos de confiabilidad.

Aplicación de modelo de regresión logística

Los hallazgos preliminares sugieren que la metodología basada en regresiones logísticas permite comprender cómo cada variable influye en la probabilidad de ocurrencia de un evento relevante: ya sea la falla operativa en equipos mineros o la capacidad de resiliencia de un sistema ante condiciones adversas. Este enfoque no se limita a la mera predicción, sino que ofrece criterios de interpretación sobre cuáles factores son más determinantes y en qué sentido afectan la probabilidad de que surja un problema o, por el contrario, se mantenga un escenario de estabilidad. En el contexto de mantenimiento predictivo de maquinaria, el modelo facilita la toma de decisiones al estimar la probabilidad de falla en función de variables como el uso acumulado (horómetro), las condiciones climáticas o la época del año, y el subsistema afectado (por ejemplo, motor, freno, eléctrico). Dicho enfoque ayuda a diseñar estrategias de mantenimiento específicas, atendiendo a los picos de riesgo en períodos con mayor estrés operacional o bajo entornos ambientales más agresivos. Del mismo

modo, en la gestión de escenarios complejos, las regresiones logísticas ofrecen una visión más amplia de los factores que inciden en el desempeño de un sistema. Así, la interpretación de los coeficientes y su signo (positivo o negativo) ayuda a discernir qué condiciones promueven un mayor grado de confiabilidad y cuáles incrementan la posibilidad de disrupciones. En definitiva, la capacidad de interpretar las relaciones entre variables operativas, ambientales y de comportamiento (como el tiempo de uso, la severidad de las condiciones externas o la estacionalidad) brinda herramientas para la optimización de recursos, ya sea en la reducción de paradas no planificadas o en la planificación de medidas para reforzar la continuidad operativa. El valor principal radica en transformar datos e indicadores en conocimiento accionable, que respalde la toma de decisiones tanto en el ámbito de fallas mecánicas como en otros entornos donde se requiera comprender la probabilidad de éxito o fracaso frente a factores externos.

El análisis confirma que el horómetro es el principal factor en la aparición de fallas, con un coeficiente positivo y altamente significativo en todos los modelos, lo que indica que, a mayor uso acumulado, mayor probabilidad de falla, independientemente del conjunto. En contraste, las variables ambientales muestran efectos menos consistentes y varían según el subsistema: en el conjunto eléctrico, el viento y la lluvia tienen coeficientes negativos débiles, lo que sugiere una posible correlación espuria; en el motor, la temperatura y la lluvia tienen un efecto positivo, aumentando la probabilidad de falla; mientras que, en implemento, la temperatura tiene un efecto negativo, reduciendo las fallas. Estos hallazgos refuerzan la importancia del mantenimiento predictivo basado en el desgaste y en el monitoreo del uso, aunque ciertas condiciones ambientales pueden afectar fallas específicas en algunos subsistemas, para mejor interpretación visualizamos los outputs del modelo en la Tabla 4.

El análisis revela que el horómetro es el factor más determinante en la ocurrencia de fallas, con una correlación positiva en todos los conjuntos, mientras que las variables ambientales muestran efectos mixtos y menos consistentes, con la temperatura como la única con un impacto claro (positivo en Motor, negativo en Implemento). También se detecta cierta estacionalidad, con mayor probabilidad de fallas en

Tabla 4. Outputs regresión logística general.

Variable	General	Electrico	Freno	Motor	Implemento
Horómetro	0,0001***	0,0000***	0,0002***	0,0001***	0,0001***
Presión	-0,0003	-0,0007	-0,0065	-0,0020	0,0007
Humedad	0,0019	0,0001	0,0085	0,0035	0,0023
Viento	-0,0418	-0,0992*	-0,0378	0,0132	-0,0306
Lluvia	-0,0051	-0,0604*	-0,0139	0,0283*	-0,0134
Nieve	-0,0052	0,0393	-0,0558	-0,0250	-0,0026
Temperatura	0,0077	0,0157	0,0168	0,0501**	-0,0330*
Febrero	0,0744	0,3595	-0,0977	0,0736	-0,5367
Marzo	0,0901	0,3383	-0,2847	-0,0821	-0,0211
Abril	0,3114*	0,2564	0,5743	0,5743*	0,0164
Mayo	0,3867**	0,5394*	0,2763	0,1630	0,4232
Junio	0,2817	0,0656	0,3369	0,2032	0,5065
Julio	0,2677	0,1769	-0,0349	0,3345	0,4024
Agosto	0,3726*	0,3793	-0,0648	0,3064	0,5302
Septiembre	0,1182	0,4267	-0,6050	-0,1814	0,0805
Octubre	0,1565	0,2724	0,6232	0,0058	-0,0266
Noviembre	0,3761**	0,6276**	0,4779	0,1451	0,2165
Diciembre	0,1607	0,3920	-0,7274	0,0180	0,2472
Equipo 226	0,2420**	0,3496**	-0,6217*	0,2785	0,3149*
Equipo 227	-0,2726**	-0,1189	-0,1874	-0,3470	-0,4348*
Equipo 301	-0,1133	0,1823	-1,0590***	-0,3511	-0,0653
Equipo 302	-0,3107***	-0,1090	-0,7931**	-0,5508**	-0,2617
Equipo 512	-0,3764***	0,1263	-1,1797***	-0,3682	-1,1610***
Constant	-3,7093***	-3,2078***	-11,504	-4,0305**	-4,3869***
Observaciones	48,936	12,234	12,234	12,234	12,234
Pseudo R-squared	0,0508	0,0220	0,0928	0,0674	0,0460

Errores estándar robustos entre paréntesis.

*** $p < 0,01$, ** $p < 0,05$, * $p < 0,1$.

mayo y noviembre en el modelo general y en el mes 11 para Eléctrico, lo que sugiere posibles condiciones operativas o ambientales específicas. Además, se observan diferencias entre equipos, donde algunos presentan mayor confiabilidad en ciertos conjuntos, como el Equipo 227 en Implemento o el 301 en Freno, mientras que el 226 es más propenso a fallas eléctricas. Sin embargo, el pseudo R^2 bajo (0,0220-0,0928) indica que otros factores no medidos (calidad del mantenimiento, carga de trabajo, condiciones específicas de operación) también influyen en la probabilidad de fallas. Estos hallazgos refuerzan la necesidad de priorizar la vigilancia sobre el sistema eléctrico (el más sensible), considerar la influencia del uso y las condiciones ambientales en motor e implemento, y planificar acciones preventivas en los meses críticos para optimizar la disponibilidad y confiabilidad de los equipos.

CONCLUSIONES

Los resultados obtenidos en los gráficos de interpretación o econométricos reflejan una tendencia preocupante: las fallas continúan en aumento sin señales de estabilización, lo que indica que, sin intervención, el problema seguirá agravándose. El análisis de patrones, como el predominio de fallas en los conjuntos Eléctrico e Implemento, la aceleración de fallas tras ciertos años de uso y las diferencias entre equipos, permite orientar las estrategias de mantenimiento hacia acciones clave, como la priorización de inspecciones y recambios preventivos en estos conjuntos antes de que sus fallas se disparen, el desarrollo de planes de acción basados en la antigüedad del equipo para intervenir antes de alcanzar puntos críticos y el ajuste de políticas de operación y conservación tomando como

referencia los equipos que han logrado retrasar la aceleración de fallas.

Los hallazgos más relevantes confirman un crecimiento continuo y sostenido de las fallas, con los conjuntos Eléctrico e Implemento liderando este incremento, la existencia de puntos de inflexión donde las fallas se aceleran y diferencias sutiles entre equipos, lo que refuerza la necesidad de una gestión de mantenimiento más proactiva y personalizada para minimizar el impacto de la acumulación de fallas. A pesar de las limitaciones en la cantidad y consistencia de los datos disponibles para alimentar el modelo de regresión logística, la investigación logró cumplir con sus objetivos al identificar tendencias de fallas en los conjuntos críticos, evidenciando un desgaste progresivo que se intensifica con el aumento del uso (u horas de operación), lo que confirma la importancia de fortalecer los planes de mantenimiento preventivo y predictivo. Asimismo, se observaron variaciones significativas en la susceptibilidad al desgaste según el tipo de equipo, como en los camiones tolva, que mostraron una mayor sensibilidad al desgaste mecánico, mientras que algunos camiones aljibe presentaron un comportamiento menos explicado por las variables analizadas, permitiendo diseñar estrategias de mantenimiento más específicas y optimizar la asignación de recursos y repuestos.

La aplicación del modelo de regresión logística ha permitido identificar que el horómetro es la variable clave en la predicción de fallas, lo que confirma que el desgaste por uso es el principal factor de riesgo en todos los conjuntos analizados. Este hallazgo sugiere que la estrategia de mantenimiento más efectiva debe centrarse en planes basados en intervalos de uso, estableciendo umbrales específicos de horas de operación para ejecutar inspecciones y recambios preventivos, especialmente en los conjuntos Motor, Freno y Eléctrico. Aunque las variables ambientales como la temperatura y la lluvia presentan una influencia significativa en ciertos equipos y condiciones específicas, su impacto es menor en comparación con el uso acumulado, por lo que su incorporación en la planificación de mantenimiento debe ser complementaria y enfocada en los equipos más sensibles a estos factores. Asimismo, la detección de patrones estacionales en algunos subconjuntos sugiere que ajustar la

programación de mantenimiento en meses críticos podría ayudar a reducir la incidencia de fallas.

Otro hallazgo relevante es la diferencia en el comportamiento de fallas según el tipo de equipo, lo que indica que no es viable aplicar una estrategia de mantenimiento única para toda la flota, sino que es necesario diseñar planes diferenciados según las particularidades operativas y estructurales de cada grupo de maquinaria. En definitiva, estos resultados refuerzan la necesidad de evolucionar hacia un modelo de mantenimiento predictivo basado principalmente en el monitoreo del horómetro, complementado con ajustes según la estacionalidad y las condiciones ambientales específicas de cada equipo. Con la implementación de estas estrategias, se espera reducir la tasa de fallas, optimizar la planificación de repuestos y mejorar la disponibilidad operativa de los equipos, maximizando la eficiencia en la gestión de activos.

En conclusión, la investigación permitió describir patrones de fallas, validar la regresión logística como herramienta diagnóstica y generar lineamientos para optimizar la toma de decisiones en mantenimiento preventivo y correctivo, aunque la falta de datos homogéneos limitó el alcance del modelo predictivo, dejando abierta la posibilidad de mejorar la recopilación y calidad de la información.

Para mejorar la gestión de repuestos a futuro, se recomienda ampliar la base de datos y perfeccionar la metodología de análisis. Esto implica aumentar la frecuencia y cantidad de registros en SAP, incorporar un mayor número de equipos para mejorar la eficiencia del modelo y unificar la categorización de los tipos de maquinaria para lograr una segmentación más precisa de las fallas. Además, la inclusión de variables operativas como el modo y ciclos de trabajo, junto con factores ambientales específicos como la altitud, la presencia de polvo o la condición del terreno, permitiría captar mejor las condiciones reales de operación. Con una base de datos más robusta, se podría explorar el uso de algoritmos de machine learning, Random Forest o redes neuronales, capaces de detectar patrones no lineales y relaciones complejas entre variables. El fortalecimiento de los algoritmos de predicción respaldado por datos más robustos permitiría optimizar la gestión de activos en futuras etapas del proyecto, anticipando fallas, reduciendo costos

operativos y aumentando la disponibilidad de los equipos mediante estrategias de mantenimiento basadas en análisis predictivos más precisos.

REFERENCIAS

- [1] F.J. Altamirano García and D. Rodríguez Salgado, "An Approach for Predictive Maintenance Decisions for Components of an Industrial Multistage Machine That Fail Before Their MTTF: A Case Study," *Systems*, vol. 10, no. 5, Art. no. 175, pp. 175-175, 2022, doi: 10.3390/systems10050175.
- [2] M. Shaikh, P. Patil, P.V. Thokal, and D.B. Pardeshi, "Implementing machine learning for predictive maintenance in industrial machinery," in *2024 15th International Conference on Computing Communication and Networking Technologies (ICCCNT)*, Kamand, India, 2024, pp. 1-6, doi: 10.1109/ICCCNT61001.2024.10724004.
- [3] S. Maataoui, G. Bencheikh, and G. Bencheikh, "Predictive maintenance in the industrial sector: A CRISP-DM approach for developing accurate machine failure prediction models," in *2023 Fifth International Conference on Advances in Computational Tools for Engineering Applications (ACTEA)*, Zouk Mosbeh, Lebanon, 2023, pp. 223-227, doi: 10.1109/ACTEA58025.2023.10193983.S.
- [4] R.K. Mobley, *An Introduction to Predictive Maintenance*, 2nd ed. Oxford, UK: Butterworth-Heinemann, 2002.
- [5] J. Moubray, *Reliability-Centered Maintenance*, 2nd ed. New York, USA: Industrial Press, 1997.
- [6] M. Ben-Daya, U. Kumar, and D.N.P. Murthy, *Handbook of Maintenance Management and Engineering*, 1st ed. Cham, Suiza: Springer, 2009.
- [7] R. Kansal, M. Mishra, and D. Goyal, "Data-Driven Predictive Maintenance for Complex Industrial Systems: Review and Framework," *Journal of Industrial Information Integration*, vol. 11, pp. 1-14, 2018.
- [8] I. Kabasakal, F. Demircan Keskin, A. Koçak, and H. Soyuer, "A prediction model for fault detection in molding process based on logistic regression technique," in *Proceedings of the International Symposium for Production Research 2019. Lecture Notes in Mechanical Engineering*, N. Durakbasa and M. Gençyılmaz, Eds., 2019, pp. 351-360, doi: 10.1007/978-3-030-31343-2_31.
- [9] M. Agarwal, K.S. Gill, S. Malhotra, and S. Devliyal, "Logistic regression utilization for electrical fault identification and classification using machine learning," in *2024 Asia Pacific Conference on Innovation in Technology (APCIT), MYSORE, India, 2024*, pp. 1-5, doi: 10.1109/APCIT62007.2024.10673522.
- [10] D.W. Hosmer, S. Lemeshow, and R.X. Sturdivant, *Applied Logistic Regression*, 3rd ed. Hoboken, NJ, USA: Wiley, 2013.
- [11] L. Pintelon and A. Parodi-Herz, "Maintenance: An Evolutionary Perspective," in *Complex System Maintenance Handbook*, London, UK: Springer, 2008, pp. 21-48.
- [12] R. Smith and R. Keith Mobley, *Rules of Thumb for Maintenance and Reliability Engineers*, 1st ed. Oxford, UK: Elsevier, 2005.
- [13] M. Zegarra, "Indicadores para la gestión del mantenimiento de equipos pesados", *Ciencia y Desarrollo*, vol. 19, no. 1, pp. 25-37, 2016, doi:10.21503/cyd.v19i1.1219.
- [14] J.M. Wooldridge, *Econometric Analysis of Cross Section and Panel Data*, 2nd ed. Cambridge, MA, USA: MIT Press, 2010.