

**Diseño de un Plan de Optimización del Mantenimiento de los Motores de Tracción
para Locomotoras mediante el Análisis de Datos
Históricos y Big Data**

Ivan Dario Fernandez Cotes

Trabajo de Grado para Optar al Título de Especialista en Gerencia de Mantenimiento

Director

Ing. Diego F. Villegas Bermudez,

Ph. D. en Ingeniería Mecánica

Facultad de Ingenierías Fisicomecánicas

Escuela de Ingeniería Mecánica

Especialización en Gerencia de Mantenimiento

Bucaramanga

2026

Dedicatoria

A mi familia por ser mi mejor inspiración para cumplir este gran sueño profesional.

Agradecimientos

(A mi familia por ser el factor motivacional de inspiración en esta monografía, a todo el equipo directivo y profesional de la empresa por su apoyo incondicional para avanzar en cada etapa del desarrollo de esta monografía, a mi equipo de profesores de la especialización en gerencia de mantenimiento quienes me aportaron muchos conocimientos, orientaciones que fueron un pilar fundamental de enriquecimiento profesional)

Tabla de Contenido

	Pág.
Introducción	14
1. Descripción del Problema	17
2. Objetivos	Error! Bookmark not defined.
2.1. Objetivo General	21
2.2. Objetivos Específicos	21
3. Justificación	21
4. Marco teórico	24
4.1. Antecedente Histórico	24
4.2. Antecedentes Nacionales	27
4.3. Antecedentes Internacionales	29
4.4. La Evolución del Mantenimiento Predictivo y Big Data	33
4.5. Variables de Estudio: Big Data y Mantenimiento Predictivo	34
4.6. Impacto de Big Data en la Competitividad del Sector Ferroviario	35
4.7. Desafíos y Oportunidades en la Implementación de Big Data en el Mantenimiento Ferroviario	36
5. Metodología	37
5.1. Recolección de Datos	37
5.1.1. Herramientas de Recolección:	38
5.2. Análisis de los Datos Históricos	38
5.2.1. Análisis FMECA para la Identificación de Modos de Falla	40
5.2.2. Evaluación de la Criticidad de Cada Modo de Falla	41

5.3.	Diseño del Plan de Mantenimiento Preventivo Optimizado.....	41
5.3.1.	Ajuste de las Intervenciones de Mantenimiento	42
5.3.2.	Integración de la Predicción de Fallas en la Programación de Mantenimiento	43
5.3.3.	Priorización de las Intervenciones Según la Criticidad	43
5.3.4.	Evaluación y Ajuste Continuo del Plan	44
5.3.5.	Sostenibilidad y Optimización de Recursos	45
6.	Resultados y discusión.....	46
6.1.	Análisis de la Variación en los Tiempos de Inactividad y Fallas	46
6.2.	Predicción de Fallos y Evaluación de Criticidad	47
6.3.	Discusión.....	49
7.	Conclusiones.....	50
7.1.	Optimización del mantenimiento predictivo.....	50
7.2.	Beneficios en la eficiencia operativa	51
7.3.	Relevancia de la crítica de los modos de falla	51
7.4.	Impacto en la competitividad.....	52
7.5.	Posibilidades de replicación.....	52
8.	Recomendaciones	52
8.1.	Implementación de un Sistema Predictivo Basado en Big Data a Nivel Corporativo	52
8.2.	Optimización de la Gestión de Datos y Mejoras en la Infraestructura Tecnológica	53
8.3.	Desarrollo de Capacidades Internas en Análisis Predictivo	53
8.4.	Priorizar los Modos de Falla Críticos en el Plan de Mantenimiento Preventivo	54
8.5.	Ampliación de la Implementación de Mantenimiento Predictivo a Nivel Global....	54

8.6.	Aprovechamiento de la Sostenibilidad Operativa en la Estrategia Corporativa.....	54
8.7.	Evaluación Continua de la Eficiencia del Sistema Predictivo	55
	Referencias Bibliográficas	56
	Apéndices.....	61

Lista de Tablas

	Pág.
Tabla 1. <i>Herramientas de análisis aplicadas.</i>	39
Tabla 2. <i>Matriz de criticidad de modos de falla.</i>	49

Lista de Figuras

	Pág.
Figure 1. <i>Tiempos de inactividad promedio según tipo de falla.</i>	47
Figure 2. <i>Frecuencia de fallas según estado del año.</i>	47

Lista de Apéndices

Apéndice A. <i>Análisis FMECA para la Identificación de Modos de Falla</i>	61
Apéndice B. <i>Imagen motor tracción de locomotoras</i>	63
Apéndice C. <i>Imagen locomotoras Drummond</i>	64
Apéndice D. <i>Imagen locomotora en vía férrea</i>	65

Glosario

Análisis FMECA: Método para evaluar y clasificar los modos de falla y sus efectos.

Big Data: Conjunto de datos masivos que se analizan para obtener patrones y tendencias.

Ciclo de Vida del Motor: Duración total de la operación de un motor desde su instalación hasta su desactivación.

Competitividad: Capacidad de una empresa para mantener su posición frente a sus rivales en el mercado.

Disponibilidad Operativa: Capacidad de un equipo para estar en funcionamiento cuando se necesita.

Eficiencia Operativa: Grado en que los recursos se utilizan para maximizar la producción.

Estrategia Operativa: Planes para mejorar la eficiencia y competitividad de las operaciones.

Intervención de Mantenimiento: Acciones tomadas para reparar o mejorar el equipo.

IoT (Internet of Things): Red de dispositivos interconectados que recopilan y comparten datos.

Mantenimiento Preventivo: Mantenimiento programado para prevenir fallas y optimizar el rendimiento.

Mantenimiento Predictivo: Estrategia que utiliza datos para predecir y prevenir fallas antes de que ocurran.

Optimización de Recursos: Mejor utilización de los recursos disponibles para maximizar la eficiencia.

Predictive Analytics: Uso de datos y algoritmos para hacer predicciones sobre el futuro.

Plataforma Big Data: Herramientas y tecnologías para procesar y analizar grandes volúmenes de datos.

Redes Neuronales Artificiales: Algoritmos de inteligencia artificial que emulan el funcionamiento del cerebro humano.

Serie Temporal: Conjunto de datos recolectados a lo largo del tiempo para análisis predictivo.

Sensores IoT: Dispositivos que recogen datos en tiempo real de las locomotoras.

Tiempo de Inactividad: Período en el que el equipo no está operando debido a fallas o mantenimiento.

Traction Motor (Motor de Tracción): Motor que impulsa las locomotoras.

Resumen

Título: Diseño de un Plan de Optimización del Mantenimiento de los Motores de Tracción para Locomotoras mediante el Análisis de Datos Históricos y Big Data *

Autor: Ivan Dario Fernandez Cotes **

Palabras Clave: Mantenimiento preventivo, Big Data, motores de tracción, locomotoras, mantenimiento predictivo, eficiencia operativa, Drummond Ltd., optimización de recursos.

Descripción:

Este trabajo de grado presenta un enfoque integral para optimizar el mantenimiento preventivo de los motores de tracción de locomotoras en Drummond Ltd., mediante el uso de Big Data y análisis de datos históricos. A pesar de un sistema de mantenimiento preventivo bien estructurado, la empresa experimenta frecuentes paradas no programadas, lo que afecta tanto su operatividad como su competitividad en el mercado. El análisis de datos históricos combinado con técnicas de Big Data permite predecir fallas recurrentes, lo que facilita la programación del mantenimiento de manera más eficiente y adaptada a las necesidades específicas de cada locomotora. La implementación de este modelo predictivo mejora la disponibilidad operativa de las locomotoras, reduce los costos asociados a tiempos de inactividad y aumenta la eficiencia operativa general. Los resultados sugieren que el uso de Big Data en el mantenimiento predictivo puede transformar la gestión de los activos ferroviarios, llevando a una optimización significativa de los recursos y una mayor competitividad en el sector.

* Trabajo de Grado

**Facultad de Ingenierías Fisicomecánicas. Escuela de Ingeniería Mecánica. Director Diego Vigellas Bermúdez.

Abstract

Title: Design of an Optimization Plan for Traction Motor Maintenance for Locomotives through Historical Data Analysis and Big Data *

Author: Ivan Dario Fernandez Cotes **

Key Words: Preventive maintenance, Big Data, traction motors, locomotives, predictive maintenance, operational efficiency, Drummond Ltd., resource optimization.

Description:

This thesis presents an integrated approach to optimizing the preventive maintenance of locomotive traction motors at Drummond Ltd., using Big Data and historical data analysis. Despite a well-structured preventive maintenance system, the company faces frequent unscheduled downtime, impacting both its operational efficiency and market competitiveness. The combination of historical data analysis and Big Data techniques allows for the prediction of recurring failures, enabling more efficient maintenance scheduling tailored to the specific needs of each locomotive. The implementation of this predictive model improves the operational availability of locomotives, reduces costs associated with downtime, and enhances overall operational efficiency. The findings suggest that the use of Big Data in predictive maintenance can transform asset management, leading to significant resource optimization and increased competitiveness in the railway sector.

* Bachelor tesis

**Facultad de Ingenierías Fisicomecánicas. Escuela de Ingeniería Mecánica. Director Diego Vigellas Bermúdez.

Introducción

La reparación de los motores eléctricos de las locomotoras es fundamental dentro de la empresa ferroviaria Drummond Ltd. en la cual la operatividad de la empresa y la prestación ininterrumpida de los servicios constituyen pilares de su competitividad. A pesar de que la empresa tiene un mantenimiento preventivo muy ordenado y que se ajusta a las pautas del fabricante, sigue teniendo un alto índice de paradas inesperadas. Esto provoca daños de orden financiero, pero también afecta la productividad. Muchos autores coinciden en que las actividades de mantenimiento, enfocadas a acciones curativas, que no se planifican, no logran evitar la ocurrencia de esas fallas que impactan de forma positiva el rendimiento de los sistemas. Es por ello que se ha resaltado la necesidad de plantear estos sistemas a unos modelos más sofisticados que se enfocan a predecir de forma más exacta (Apaza y Ñamo, 2022). Bajo este enfoque, el uso de nuevas tecnologías, tales como el Big Data, podría mejorar la productividad operativa por la posibilidad de fallas que se prevean (Delgado, 2023).

Este proyecto tiene como objetivo evaluar el impacto que tendría el uso de Big Data junto con el análisis de datos históricos en Drummond Ltd. al cambiar el enfoque del mantenimiento preventivo al mantenimiento predictivo. Este cambio se basa en la convicción de que la incorporación de estas plataformas de procesamiento de datos proporcionará visibilidad en tiempo real sobre el estado de las instalaciones, lo cual nunca ha estado disponible antes. En consecuencia, la acción de mantenimiento será mucho más personalizada a los requisitos reales de los motores de tracción, lo que aumentará su disponibilidad operativa, reduciendo así la pérdida de tiempo productivo directo. Esto, a su vez, mejorará el nivel de productividad de la

empresa (Huang, 2024). Esto ilustra que Big Data es más que un instrumento de mantenimiento predictivo; también es un sistema para reingeniar las prácticas de mantenimiento, y así la agilidad operativa necesaria a través del procesamiento es la que impulsa la ventaja competitiva.

El enfoque de la monografía se dividirá en varias secciones, cada una permitiendo un análisis de las características más salientes del problema propuesto. La primera será la declaración del problema, donde, dentro del tema del sistema actual de mantenimiento preventivo utilizado en Drummond Ltd, se explicará su falta de un sistema predictivo efectivo, que causa tiempos de inactividad no programados, junto con su consecuencia, costos extremadamente elevados. Esta sección también enfatizará la necesidad de un enfoque predictivo que busque aplicar Big Data para mejorar la programación y el uso del mantenimiento operativo. Berisha et al. (2022) argumenta que examinar un conjunto de datos con esos elementos ayudará al analista a reconocer patrones de defectos recurrentes dentro de los fenómenos estudiados y, por lo tanto, estará en posición de formular decisiones óptimas con respecto a la gestión de los recursos de control.

En segundo lugar, se presenta la justificación de la investigación que tratará sobre las ventajas de aplicar Big Data al mantenimiento predictivo en el sector ferroviario. La revisión bibliográfica mostrará que numerosas industrias han logrado mejoras significativas con la implementación de la analítica de Big Data. La aplicación de estas herramientas ha permitido la predicción de fallas, al mismo tiempo que ha reducido los costos relacionados con las acciones correctivas al minimizar el tiempo de inactividad y aumentar la disponibilidad de los activos. Así, se argumentará que la transformación digital de la industria ferroviaria mejora la

sostenibilidad operacional y la competitividad de la industria, que se ha vuelto más exigente en los últimos años (Escobar et al., 2019). Igualmente, se demostrará cómo el marco en cuestión puede ser adaptado a las necesidades particulares de Drummond Ltd., ayudando así a la empresa a acceder a la rica experiencia del sector.

Big Data está siendo aprovechado en el mantenimiento predictivo, si nos referimos a la última metodología 'Big Data', no bastará solo oír cómo funcionan las máquinas, sino que se tienen que estudiar diversas parametrizaciones a partir de la comparación de estudios de casos de campo, esto lo demostramos en el libro de Moreira et al. 2025. Big Data no son solo meras suposiciones llenas de herramientas, hay que estudiar sus méritos y debilidades, como la implementación en la idea de mantenimiento industrial. Es fundamental estudiar tales casos si queremos discutir la lógica de este 'smart' world. Si queremos referirnos a la logística del tren, este es el reto más grande, comparable al que tienen muchos países de Latinoamérica.

Con relación a la metodología, se indicará si la investigación fue cuantitativa, cualitativa o mixta. Se especificará la manera en que se extraerá la data histórica de mantenimiento de los motores de tracción y el modo en que se sumarán las herramientas de la Big Data para el hallazgo de patrones en los fallos de repetición. También se abordará el uso de métodos estadísticos y modelos de predicción como series de tiempos o regresión que permiten el diseño de un modelo para la optimización de las actuaciones de mantenimiento asociadas a los motores, en función a su estado real. Como se infiere de la bibliografía que se usó para este estudio (Arribas, 2024), el empleo de tales herramientas va a permitir, en este caso, un análisis más

preciso a las condiciones de operación de Drummond Ltd., y en consecuencia, una mejora a los costos operacionales y la efectividad de todo el sistema ferroviario.

El resultado de utilizar un modelo predictivo con Big Data se discutirá junto con el resultado del sistema y las consecuencias de su uso. Una reducción de la frecuencia de paradas imprevistas y corredores mejorará la eficiencia operativa y de disponibilidad de las locomotoras. Este enfoque analizará posteriormente la capacidad de otros ferrocarriles y la capacidad de extender la sostenibilidad operativa y la competitividad de toda la industria. Esta u alguna otra investigación intenta probar que la aplicación de Big Data... no es solo un instrumento técnico, sino más bien, una iniciativa estratégica de Drummond Ltd. para posicionarse como la líder del mercado más innovadora en el dominio ferroviario. Por lo tanto, Drummond Ltd. tiene como objetivo ser la pionera de la industria en las aplicaciones innovadoras de Big Data. (Valdivieso y Bonini, 2021).

1. Descripción del Problema

Para Drummond Ltd, los motores de tracción de locomotoras son elementos críticos del sistema dinámico de transporte, cuya funcionalidad ininterrumpida asegura la continuidad productiva. No obstante, la empresa todavía sufre de períodos interminables de inactividad no planificada, incluso con un enfoque de Mantenimiento Preventivo por niveles alineado con las recomendaciones del fabricante. El costo de estas paradas no planificadas no es simplemente un costo aislado; restringen severamente las actividades de la cadena de valor, tanto operativas como logísticas, donde un menor costo de servicio es crítico. Los efectos negativos del mantenimiento no planificado reducen el margen de posición competitiva en el negocio ferroviario de Drummond Ltd (Controltecnica, 2024). Es evidente que se requieren marcos más

sofisticados, ya que la competencia no solo es más de lo que el mantenimiento no planificado puede sostener, sino también de lo que la empresa está dispuesta a converger. Es prudente sugerir que una condición unificadora de la competencia existente es que el costo del mantenimiento plano sea más bajo que en el resto del mercado.

El problema en cuestión tiene una solución efectiva en la integración de Plataformas de Big Data que pueden analizar grandes volúmenes de datos en tiempo real. Las Plataformas de Big Data procesan y analizan datos masivos y detectan patrones que indican signos tempranos de deterioro, lo que permite una toma de decisiones más informada y proactiva. Generar indicadores de fallas incipientes es especialmente crítico para pivotar del actual paradigma de mantenimiento preventivo hacia uno que sea predictivo, en el cual el grado de visibilidad sobre el estado de los activos permite una programación más precisa de las intervenciones. Esto argumentó a favor de un enfoque que extiende la vida de los motores mientras mejora la eficiencia operativa y reduce los costos de los tiempos de inactividad no planeados. Todo lo cual destaca la utilidad del Big Data, como un medio efectivo para optimizar el mantenimiento industrial.

El mantenimiento de la industria contemporánea ha cambiado mucho desde el pasado debido a la aplicación de análisis de datos, que Apaza y Namó (2022) señalan ha proporcionado la reducción de costos y la eficacia operativa asociadas con la reducción de las fallas de predicción en su uso de Big Data en múltiples dominios. Centrándose en el tránsito ferroviario, el mantenimiento y el uso de datos han tenido aumentos profundos gracias a Big Data, el mantenimiento predictivo y la utilización de activos a lo largo de la optimización de su ciclo de vida ha sido comprobado. El mantenimiento predictivo programado se mejora con el tiempo

estimado de llegada de los modelos de corrección de Big Data que satisfacen la necesidad de predecir el tiempo de funcionamiento no continuo de las locomotoras de Drummond Ltd. (Escobar y Mercado, 2019).

La hipótesis principal de este estudio argumenta que la integración de Big Data con el análisis de datos de series temporales históricas puede transformar en gran medida la gestión del mantenimiento industrial y mejorar el control del acelerador de Drummond Ltd. El análisis predictivo y el procesamiento de datos históricos han mejorado notablemente la programación de auditorías y el escrutinio de las intervenciones en componentes críticos en otros campos (Berisha et al. 2022) y este estudio se basa en tal trabajo. Aunque la empresa actualmente emplea mantenimiento preventivo, la integración de la Analítica Predictiva a través de Big Data mejorará la previsión de posibles escenarios de fallo, minimizando así las intervenciones de mantenimiento y los costos operativos.

El caso Drummond se basa en una profunda falta de un caso de uso que implique un sistema predictivo capaz de pronosticar una gama de fallas utilizando una gran cantidad de datos existentes, incluidos datos históricos y entrelazados. El mantenimiento predictivo ha demostrado ser beneficioso, pero por sí solo agrava el problema de las paradas no planificadas y los costos adicionales, ya que no puede predecir las interrupciones. El problema de la gestión de mantenimiento gestionada de manera rentable puede lograrse mediante el uso de plataformas de Big Data que no solo predicen fallas, sino que también programan las intervenciones de manera más óptima y precisa en función de la demanda en tiempo real de los motores de tracción (Delgado, 2023). Además, el uso de Big Data no solo se centraría en reducir las fallas, sino que

también avanzaría el sistema de mantenimiento hacia un modelo más sostenible económica y ambientalmente al pivotar el consumo de recursos aerostáticos y las intervenciones correctivas de la huella de carbono tienden a ser expansivas (Valdivieso y Bonini, 2021).

La idea con esta investigación es proporcionar un enfoque integrado para abordar el problema de los tiempos de inactividad no planificados al incorporar Big Data en el Mantenimiento Predictivo. Los registros históricos de las actividades de mantenimiento se capturarán de manera ordenada y se aumentarán mediante análisis avanzados diseñados para el reconocimiento de patrones, de modo que se puedan predecir fallas y permitir que las intervenciones se programen de manera más óptima. No solo el uso de este enfoque aumentará la disponibilidad operativa de las locomotoras, sino que también mejorará la resiliencia financiera de Drummond Ltd. al gestionar de manera óptima los tiempos de inactividad no planificados y los costos operativos asociados (Huang, 2024).

En un esfuerzo por resolver los problemas delineados, se ha planteado la siguiente pregunta, que guiará la investigación: ¿Cómo mediante el uso de datos históricos y análisis de Big Data se optimiza el mantenimiento de los motores de tracción de las locomotoras en Drummond Ltd para disminuir los tiempos de inactividad no programados y mejorar la eficiencia operativa de la flota ferroviaria? Esta pregunta tiene como objetivo investigar cómo las herramientas de análisis de Big Data ayudan a redefinir los enfoques de mantenimiento tradicionales, en este caso, el mantenimiento preventivo, para hacerlo en el momento adecuado basado en datos, con una mayor disponibilidad de la flota y costos operativos reducidos asociados con fallas no planificadas.

2. Objetivos

2.1. Objetivo General

Desarrollar un plan de optimización del mantenimiento preventivo de los motores de tracción para locomotoras de Drummond Ltd., mediante el análisis de datos históricos y el uso de Big Data, con el fin de reducir los tiempos de paradas no programadas y mejorar la eficiencia operativa de los equipos.

2.2. Objetivos Específicos

Recopilar los datos históricos de mantenimiento de los motores de tracción para locomotoras de los últimos cinco años, incluyendo detalles sobre intervenciones, fallas y tiempos de inactividad.

Analizar los datos recopilados para identificar patrones de fallas recurrentes y cualquier otra tendencia que pueda influir en la fiabilidad y el rendimiento de los motores de tracción.

Diseñar un plan de mantenimiento preventivo optimizado basado en los hallazgos del análisis de datos históricos y las predicciones obtenidas a través de Big Data, con el objetivo de reducir las paradas no programadas y mejorar la disponibilidad operativa de los motores.

3. Justificación

El primer paso para prever las dificultades interpuestas en la renuencia a permitir gastos debido a la aparente falta de preocupación por la situación en Drummond Ltd., un objetivo para cualquier locomotora que funcione en un entorno relativamente competitivo, se basa en su análisis de grandes datos junto con datos históricos. A pesar del programa de costos establecidos para los mantenimientos semestrales, las paradas innecesarias o mal cronometradas persisten sin

resolverse y constantemente arrojan nuevas facetas de efectividad ejecutada de manera incompetente e inadecuación sistémica para la flota operativa a umbrales de desembolso financiero exorbitantes. Esta capa de complicación exige la augmentación de las prácticas actuales y un cambio, en el sentido más fundamental, sin pérdida de prudencia, hacia los estándares de la industria. (Arribas, 2024).

La resolución del problema de identificar patrones ocultos con análisis de big data le permitirá llegar a conclusiones de forma más eficiente y optimizar la reprogramación de tareas y operaciones a lo largo de los recursos de una red. Este se destaca por su forma innovadora de uso: gracias a incorporar sistemas de mantenimiento predictivo se lograría un óptimo aprovechamiento de tiempo, lo que sin duda reduciría los costos de mantenimiento. A lo que añade Apaza y Ñamo “el uso del análisis masivo de datos contribuye a una mejora de la eficacia operacional, así como también a una toma de decisiones más informada, lo que a su vez reduce los gastos y mejora el rendimiento a largo plazo” (2022).

En lo que respecta al mantenimiento de locomotoras en el contexto de la industria ferroviaria, aflojar el análisis de Big Data es una etapa inicial que brinda una amplia oportunidad para que Drummond Ltd lidere la innovación en la industria. Estudios anteriores han demostrado que la analítica de mantenimiento predictivo, utilizando potentes algoritmos, ha permitido a empresas de diferentes sectores programar mejor las intervenciones y reducir los gastos relacionados con fallos imprevistos. La aplicación de tales prácticas en el ámbito ferroviario es de naturaleza competitiva, ya que maximiza los recursos de mantenimiento, asegura la disponibilidad de los activos y mejora los costos operativos (Delgado, 2023).

El Marco de Mantenimiento de Optimización no solo apunta a mejorar la eficiencia de las locomotoras, sino la sostenibilidad operativa de la empresa, en este caso, Drummond Ltd. Por ejemplo, el uso de Big Data para la predicción del mantenimiento elimina la costosa necesidad de acciones correctivas, que, además de las implicaciones ambientales, también resulta en el desperdicio de recursos y aumenta los costos operativos debido a las costosas acciones correctivas. De esta manera, el enfoque postulado asiste a Drummond Ltd. en cumplir e incluso superar los objetivos de sostenibilidad en un mundo, como se ha postulado, con un creciente énfasis en la huella de carbono de la cadena de valor (Valdivieso y Bonini, 2021). El mantenimiento predictivo en este caso aumenta la responsabilidad social organizativa internacional en constante crecimiento y la eficiencia energética.

Además, el marco de mejora del plan de optimización también fortalecerá la resiliencia financiera de Drummond Ltd. La reducción de los tiempos de inactividad no programados de locomoción y de fallas no planificadas mejorará los márgenes operativos y la capacidad de respuesta a las fluctuaciones de la demanda. Además, el uso de Big Data facilita activamente una mejor toma de decisiones sobre el mantenimiento de los tiempos de inactividad no programados y las fallas no planificadas al capturar y analizar tendencias en los motores de tracción a lo largo del tiempo y ajustar las estrategias de mantenimiento, lo que Marinescu (2019) argumenta, mejora la competitividad general de la empresa y, por lo tanto, permite la entrega de servicios más fiables y eficientes a la clientela.

La implementación del Plan de Optimización del Mantenimiento utilizando Big Data de Drummond Ltd. se centra en crear un efecto dominó en todo el ecosistema ferroviario. La

metodología permite al sector derivar un modelo de mantenimiento predictivo independiente del sector. El cambio hacia el mantenimiento predictivo a través de Big Data Analytics guiará una transición hacia la automatización de la gestión de activos, lo que puede establecer un nuevo estándar tecnológico para el sector del transporte (Berisha et al. 2022).

4. Marco teórico

4.1. Antecedente Histórico

El caso de la empresa Drummond Ltd. es uno de los más relevantes en la historia del ferrocarril en Colombia. Su continua evolución y adaptación a los desafíos de la industria marcaron los inicios de la empresa en 1983. En ese año, Drummond Ltd. empezó una de sus actividades principales, que es la explotación y transporte del carbón en la región del Cesar. En adición, la empresa posee un especializado atún exportador de carbón mineral que se ubica en la región atlántica. Con el paso del tiempo, la empresa se enfocó en modernizar sus sistemas operativos y pudo incorporar mejoras en los sistemas operativos y de gestión de todo el ferrocarril. Drummond Ltd. aún se queja de interrupciones desfavorables debido a la disminución de la eficiencia y los altos costos operativos asociados con altos costos operativos. Este problema ha llevado a Drummond a avanzar en la modernización hacia objetivos como el uso de tecnología Big Data para mejorar los análisis en sus sistemas de mantenimiento.

Por otro lado, el uso de Big Data en la industria ha transformado, sin duda, el valor de la optimización operativa y el proceso de toma de decisiones. Según Apaza y Ñamos (2022), el valor de los sistemas de organización reduce el tiempo de respuesta en el mantenimiento y los costos operativos, con la ayuda de análisis de fallos predictivos personalizados de grandes

conjuntos de datos. El mantenimiento predictivo, dentro de Big Data, ha sido el más suscrito en la industria ferroviaria, cuyo mantenimiento se proporciona para apoyar operaciones ininterrumpidas. Esta es la razón por la que investigaciones anteriores han demostrado que el uso de herramientas analíticas avanzadas, dirigidas a evaluar datos de series temporales históricas, ayuda en la identificación de patrones de fallas recurrentes que permiten evitar interrupciones no planificadas (Berisha et al., 2022).

Entre varias aplicaciones industriales del Big Data, adaptar el análisis del Big Data a los planes de programación de mantenimiento de gestión de activos permite a las empresas evitar los gastos de recursos ineficientes y superfluos, así como el gasto de efectivo que proviene de no alinear los planes de mantenimiento con las condiciones operativas reales de sus sistemas. El desarrollo de cronogramas donde se ignora el estado de los componentes, y los planes diseñados son más planes que verdaderos planos para el mantenimiento, no es diferente de los procedimientos de ingeniería de bombas termonucleares que se basan en manuales de ensamblaje de muebles de la década de 1960. Tales planes son más la regla que la excepción, y cuando doctrinas obsoletas, ineficientes y malditas se descontrolan, la catástrofe económica es el resultado probable.

No es sorprendente que los sectores industriales que emplean análisis de Big Data hayan podido evitar catástrofes económicas racionales. Tales sectores han recuperado más que el espacio operativo dentro de su gasto en análisis y también han disfrutado de milagros económicos positivos gracias a la combinación de utilización estratégica de activos y mantenimiento predictivo de sistemas. El caso no es diferente en lo que respecta a los sistemas

ferroviarios. El modelo de valor parece sostenerse: la inversión en análisis de mantenimiento predictivo resulta en retornos espectaculares, y el Big Data refleja una inversión aún mayor en aprendizaje automático.

Con big data, es posible hacer mucho más que predecir fallos; también puede servir para mejorar la gestión de recursos en ferrocarriles. López Telenchana et al. (2024) dice que en la era del Big Data, la gestión de activos ferroviarios puede mejorar las capacidades de toma de decisiones estratégicas de la empresa, ya que mejora la optimización de la programación de intervenciones para mantenimiento, así como la intervención de los recursos humanos y materiales. Con esta herramienta es posible programar segmentos de mantenimiento para las locomotoras de gran utilización, lo que a su vez reduce los costos y aumenta la disponibilidad de la flota.

La analítica de datos masivos impacta la eficiencia en la operación de los sistemas, ahorrando tiempo y costos, y transformando el enfoque de la actividad de mantenimiento industrial. Para Drummond Ltd, el contador de mantenimiento, el uso de sistemas de EA (Enterprise Architecture) basados en Big Data, ubicados en la predicción, pueden mejorar el planeamiento de programación e intervención de mantenimiento. Esto provee sostenibilidad operacional y confiabilidad operacional ante tiempo de inactividad no planeado. En el caso de que el Big Data ferroviario global de Drummond llegara a expandirse y continuar en crecimiento, el uso de Big Data, analítica de datos, IOT, y otras herramientas, pueden ser indispensables en la transformación de los procesos operacionales, y en el incremento de la competitividad empresarial en un ambiente siempre cambiante.

4.2. Antecedentes Nacionales

El transporte ferroviario en Colombia ha revivido en los últimos años en importancia por el transporte de mercancías, flujo de carbón en particular. Colombia, o mejor dicho, Drummond Ltd. 's Colombia como uno de los principales operadores ferroviarios, obtiene carbón de las minas en Cesar y lo lleva al puerto del Cinturón Atlántico. Tiene el resto del ferrocarril y su mantenimiento y períodos irregulares de inactividad. Equipos desactivados y ociosos y el mercado y la competitividad del servicio dado. Dado eso, Drummond Ltd. (2023) sugirió que los costos de períodos efectivos y ociosos podrían alcanzarse con el resto de las tecnologías avanzadas de Big Data.

En casi todos los campos de la actividad económica, incluidos los ferrocarriles en el país, el uso de Big Data en el mantenimiento predictivo se está volviendo más popular. Por ejemplo, Ferrocarriles de Carga del Pacífico (FEPAC) ha comenzado a utilizar algunas herramientas de análisis de datos para una mejor gestión de la infraestructura y el equipo. Como señala Lopez et al (2024), el uso de herramientas analíticas en el mantenimiento de locomotoras ha hecho posible optimizar y reducir drásticamente los costos operativos, lo que ha llevado a un aumento sin precedentes en la disponibilidad de la flota. Esto ha surgido como uno de los 'estándares' más aceptados dentro de la corriente principal de la industria ferroviaria nacional, destinado a minimizar las interrupciones del servicio y los apagones de servicio, lo cual es crítico para la cadena de suministro nacional y el negocio de logística.

Para la economía nacional, la minería es sin duda uno de los pilares de la economía, tal como lo es la optimización en el uso de big data en el mantenimiento de las minas y el transporte

ferroviario de los productos hacia los puertos de embarque. Según un informe de Controltecnica (2024), en la búsqueda por aumentar las operatividades que se mantienen dentro de los sistemas de Control en el uso de silos en la minería de Ecuador, se han incorporado de forma progresiva técnicas de análisis predictivo con el fin de reducir la falla de equipos y los tiempos de inactividad. Esto es de gran beneficio en las operaciones de los subsectores que utilizan maquinaria de enormes dimensiones en minería, como por ejemplo, en la mezcla de carbón. Este tipo de sistemas operativos permite el control en el gasto superficial de las corporaciones, y el gasto en el mantenimiento a la minería y transporte, sugiriendo que el mismo efecto es posible en la industria ferroviaria.

La modernización de la infraestructura de transporte ferroviaria y de la infraestructura asociada al país está siendo liderada por la Agencia Nacional de Infraestructura del gobierno colombiano. El uso de tecnologías emergentes y infraestructura moderna son los pilares de esta modernización, cuyo objetivo es hacer el transporte de mercancías más eficaz. El crecimiento sostenido del sector ferroviario al país exige, por su parte, el uso de tecnologías de analítica de datos. Con la analítica de datos más avanzada, es posible la toma de mejores decisiones y un control riguroso de mantenimiento de locomotoras. Este tipo de iniciativas son parte de un movimiento más extenso de digitalización de los sistemas de transporte del mundo. Ahora, a pesar de que el uso de Big Data en Colombia está en sus etapas iniciales, la dirección del gobierno es a fomentar el uso de estas tecnologías en el futuro.

Un ejemplo de la aplicación de Big Data en el sector ferroviario colombiano es el proyecto piloto desarrollado por la empresa ferroviaria de carga Trenes de Carga de Colombia

S.A. (TCC) donde se realiza el seguimiento en tiempo real de las locomotoras utilizando datos de sensores y datos históricos. Un estudio realizado por Escobar & Mercado (2019) indica que esta implementación ha ayudado a TCC a mejorar la programación del mantenimiento y a reducir drásticamente el tiempo de inactividad no programado, lo que ha mejorado la eficiencia operativa. Estos proyectos muestran que Big Data es un elemento clave en la correcta gestión de los recursos ferroviarios en Colombia y que su uso en todo el país revolucionaría toda la industria ferroviaria.

Estos estudios nacionales reflejan un cambio hacia el uso de tecnologías avanzadas como Big Data en muchas industrias, incluido el sector ferroviario. Compañías de ejemplo como Drummond Ltd. junto con otros actores clave en las industrias minera y ferroviaria de Colombia, muestran cómo tales herramientas podrían mejorar la eficiencia operativa y reducir los costos generales de mantenimiento de locomotoras. Ejecutar un Plan de Optimización de Mantenimiento impulsado por Big Data no solo es pertinente para agudizar la competitividad de las empresas, sino también para fomentar el desarrollo sostenible del sector ferroviario en Colombia.

4.3. Antecedentes Internacionales

La implementación de Big Data en el mantenimiento predictivo ha demostrado ser transformadora para diversas industrias a nivel global, siendo el sector ferroviario el que más beneficios ha obtenido de tales tecnologías. En EE. UU. y Europa, los operadores ferroviarios han comenzado a utilizar plataformas de análisis de datos para mejorar la eficiencia operativa y reducir los costos asociados con fallas imprevistas de los trenes. Un ejemplo de esto sería

Norfolk Southern Corporation, uno de los operadores ferroviarios más destacados en EE. UU., que ha implementado un sistema de mantenimiento predictivo impulsado por Big Data, diseñado para estimar fallas de los motores de tracción basándose en conjuntos de datos históricos y en tiempo real. El informe preparado por Sayeed et al. (2022) sugiere que el sistema ha logrado reducir incluso las estimaciones más pesimistas de tiempo de inactividad no planeado, recortando los costos asociados con la indisponibilidad operativa de la flota, lo que a su vez mejora la rentabilidad general de la empresa.

En Europa, la aplicación de Big Data en el mantenimiento ferroviario ha sido promovida por muchos programas de innovación tecnológica. Uno de los ejemplos más destacados es Deutsche Bahn, la empresa ferroviaria nacional de Alemania. En 2019, Deutsche Bahn implementó un sistema de Big Data mediante el cual monitorea locomotoras en tiempo real y predice fallos antes de que ocurran. Como se informa en Berisha et al. (2022): ‘El sistema recopila datos de sensores y entrena modelos predictivos a partir de observaciones.’ El enfoque no solo resulta en una reducción de paradas no programadas, sino que también ha mejorado la eficiencia energética de los trenes, lo que disminuye el impacto general insostenible del transporte ferroviario en Europa.

Un buen ejemplo es cómo Network Rail, la empresa responsable de la infraestructura ferroviaria, incorporó un programa de Big Data predictivo junto con otra infraestructura ferroviaria para minimizar la "inactividad" de la infraestructura. Se basan en la historia de mantenimiento combinada con estimaciones de sensores de mantenimiento a bordo de locomotoras y en las vías, para calcular el tiempo de intervención de mantenimiento con

precisión extrema o, como ellos lo llaman, "el 'momento mágico' del mantenimiento". Según Arribas (2024), esta tecnología ha reducido significativamente los costos operativos y ha mejorado la seguridad ferroviaria al eliminar fallos mecánicos en locomotoras y vías.

En Australia, el uso de Big Data Analytics en el mantenimiento predictivo tiene un impacto en la optimización de las operaciones del sistema ferroviario. Aurizon, el operador ferroviario más grande de Australia, ha utilizado modelos predictivos desarrollados a través de Big Data Analytics para anticipar el mantenimiento requerido en los motores de tracción y otros componentes auxiliares de sus trenes. Aurizon, siendo el principal operador, ha logrado mejorar la disponibilidad de sus locomotoras y reducir los costos de las reparaciones y mantenimientos correctivos asociados y, por lo tanto, aumentar considerablemente la fuerza competitiva en el mercado, Huang (2024). Este caso demuestra la importancia del análisis de datos en las capacidades competitivas y la mejora de la eficiencia operativa para los operadores de flotas ferroviarias.

Otro caso digno de mencionar en relación con los trenes de alta velocidad sería el Shinkansen en Japón y su uso de Big Data para el mantenimiento predictivo. Japan Railways Group está utilizando un innovador sistema de análisis de Big Data para el monitoreo en tiempo real del material rodante y las condiciones de la vía. Este sistema ha permitido predecir fallos y minimizar los tiempos de mitigación para un elemento crítico de la industria: la puntualidad y la seguridad. Moreira et Al et al. (2025) de hecho atribuyen la reducción en los gastos operativos y el aumento en la eficiencia operativa 'buscada' al uso de análisis de Big Data para el mantenimiento de los trenes de alta velocidad. Moreira y su equipo han realizado un trabajo

importante y por eso este se ha convertido en un caso de estudio para otras compañías ferroviarias en todo el mundo.

El uso de Machine Learning y algoritmos predictivos dentro de la Inteligencia Artificial en el mantenimiento de trenes ha sido una de las tecnologías más efectivas para mejorar la disponibilidad de locomotoras mientras se reducen las paradas no planificadas. Tal como ocurre en Alstom en Francia, donde las tecnologías de Machine Learning y Big Data pudieron implementar con éxito un mantenimiento predictivo y basado en condiciones para los motores de tracción con un grado de precisión cada vez mayor. Mostajabi et al. (2021) argumentan que estos sistemas mejoran la gestión y distribución de recursos de mantenimiento, al tiempo que permiten la optimización de la planificación del mantenimiento y la planificación de predictores mecánicos.

Con respeto a los antecedentes internacionales, les muestro cómo el uso de la Big Data y el mantenimiento predictivo han revolucionado a la industria ferroviaria a nivel mundial. En distintos países, empresas han utilizado estas herramientas tecnológicas y han integrado estas herramientas para optimizar la eficiencia operacional, disminuir los gastos y aumentar la disponibilidad de la flota. Estos antecedentes indican que la implementación de un Plan de Optimización del Mantenimiento utilizando Big Data en Drummond Ltda. es de baja dificultad y sumamente necesaria, ya que apuntará a aumentar la competitividad de la empresa en un mercado cada vez más exigente y tecnológicamente avanzado.

4.4. La Evolución del Mantenimiento Predictivo y Big Data

La aparición de Big Data en los últimos años ha ofrecido a los procesos de mantenimiento industrial resoluciones sin precedentes. En particular, en la industria ferroviaria donde la fiabilidad y disponibilidad de los activos en línea son críticas para el rendimiento de la cadena de suministro industrial. Anteriormente, los enfoques de mantenimiento eran casi en su totalidad preventivos o reactivos por naturaleza. Aunque estos tipos de enfoques cumplieron su propósito, no estaban diseñados para proporcionar la previsión adecuada para predecir fallos, lo que resultaba en costosos tiempos de inactividad no programados.

El papel de Big Data también ha facilitado la transición de estos enfoques a metodologías más proactivas y predictivas. El cambio también ha demostrado ser útil en los estudios de Apaza y Ñamo (2022), donde la utilización de Big Data industrial ha demostrado ser transformadora para el mantenimiento. El mantenimiento predictivo a partir de Big Data está justificado por el reconocimiento de patrones dentro de conjuntos de datos históricos y en tiempo real de gran tamaño. La mejora en el mantenimiento predictivo y el tiempo de respuesta más rápido ayuda a eliminar tiempos de inactividad inesperados y acciones correctivas excesivas, reduciendo el costo operativo total mientras se mejora la fiabilidad y vida útil de los activos, y posteriormente la eficiencia operativa.

La evolución del mantenimiento predictivo surge del análisis de datos derivados de múltiples fuentes, como los sensores de componentes críticos, los registros históricos de mantenimiento y los sistemas de monitoreo en tiempo real. Este nuevo paradigma de mantenimiento emplea algoritmos predictivos que perciben patrones de comportamiento que

preceden a las fallas a partir de los datos analizados, permitiendo así un enfoque de mantenimiento según sea necesario. Como describen Berisha, Mëziu y Shabani (2022), la capacidad de prever fallas se convierte en una ventaja competitiva, ya que se pueden evitar tanto las intervenciones anticipadas de mantenimiento como la necesidad de corrección costosa e imprevista. Este tipo de enfoque sostiene no solo la eficiencia y rentabilidad de las empresas, sino también la sostenibilidad operativa, a través de la minimización del desperdicio de recursos y los costos ambientales del mantenimiento reactivo.

4.5. Variables de Estudio: Big Data y Mantenimiento Predictivo

El estudio se centra en la relación entre el Big Data y el mantenimiento predictivo. El Big Data en este caso se refiere a utilizar y analizar petabytes de datos de diversas fuentes, registros históricos y datos generados en tiempo real de locomotoras. Estos datos, si se procesan correctamente, desarrollarán patrones que pueden predecir fallos, mejorar los tiempos de respuesta y mejorar el marco de Costeo del Ciclo de Vida de la configuración de los componentes para actividades de mantenimiento preventivo programado. Berisha, Mëziu y Shabani (2022) afirman que la Analítica de Big Data Industrial en el Mantenimiento Industrial ayuda a "detectar y escrutar patrones anómalos de deterioro primitivo de los componentes, lo que, sincronizadamente, mejora la gestión predictiva de fallos al anticipar la falla." Eso ayuda en la proporcionalidad de los Balcanes en una planificación estratégica desde un nivel micro y los intervalos de mantenimiento, lo que puede aumentar la disponibilidad operativa de las locomotoras.

El mantenimiento predictivo es una forma de mantenimiento eficiente y más adaptable, donde las decisiones de mantenimiento para un activo dependen de su condición en tiempo real y no de períodos establecidos o estimaciones generalizadas. Este enfoque predictivo no solo reduce los costos operativos al disminuir los tiempos de inactividad del equipo, sino que también alinea el mantenimiento con el estado real de los motores, optimizando la programación de intervenciones y la prolongación de la vida útil del activo. Como afirma Delgado (2023), la aplicación de Big Data dentro del mantenimiento predictivo permite a las empresas evitar tanto el desperdicio de recursos, como el mantenimiento preventivo excesivo, como reparaciones no planificadas costosas. Esto se convierte en una herramienta de eficiencia de recursos operativos para mejorar la sostenibilidad de los recursos y operativa al reducir el desperdicio de reparaciones innecesarias.

4.6. Impacto de Big Data en la Competitividad del Sector Ferroviario

El impacto de la tecnología de Big Data en el mantenimiento predictivo va más allá de simplemente maximizar la eficiencia operativa. En estos tiempos de creciente demanda del mercado y competencia, la tecnología de Big Data parece proporcionar una ventaja competitiva a las empresas que gestionan hábilmente el despliegue de recursos. Según Moreira et al. (2025), el uso de herramientas de análisis de datos ayuda a las empresas en muchos sectores no solo a predecir fallos, sino también en tiempo real, a ajustar sus estrategias operativas sobre la marcha, mejorando así su agilidad y eficiencia general. En la industria ferroviaria, donde el éxito empresarial depende de la disponibilidad óptima de locomotoras, la capacidad de predecir fallos y captar picos de demanda permite a Drummond Ltd., junto con empresas similares, aumentar la rentabilidad y mejorar la agilidad en el mercado (Huang, 2024).

La integración de Big Data mejora la toma de decisiones enfocadas porque las organizaciones pueden optimizar sus procesos y asignar sus recursos en función de información más precisa y en tiempo real disponible. López Telenchana et al. (2024) argumentan que las organizaciones que implementan estrategias de Big Data en la gestión del mantenimiento obtienen una mejora no solo en la productividad y la eficacia operativa, sino también en la sostenibilidad en la gestión de sus flujos de trabajo. Este enfoque minimiza la necesidad de medidas correctivas extensas y costosas que, a su vez, reducen la huella ambiental y mejoran la utilización de recursos. En un espacio que rodea cada vez más al mundo con un uso de energía sostenible y eficiente, este conjunto de estrategias mejora la competitividad y la responsabilidad social corporativa de una organización.

4.7. Desafíos y Oportunidades en la Implementación de Big Data en el Mantenimiento Ferroviario

Los beneficios relacionados con el empleo de Big Data en el mantenimiento predictivo son varios. Entre los desafíos que surgen de la implementación de estas tecnologías está la federación de piezas de información dispares. Muchos usuarios, como cita Burguillo Ruiz (2018), luchan por fusionar conjuntos de datos dispares e interaccionar con tecnologías como resultado de la no interoperabilidad. Aunque es un desafío serio, esta es una manera de fomentar el avance de las tecnologías en el negocio ferroviario, como con Drummond Ltd, para avanzar en la eficiencia operativa a través de la interconexión digital sistematizada de redes aisladas. Evitar este bloqueo significa una mejor predicción y asignación de recursos, lo que lleva a mejoras continuas en las operaciones.

Ninguno de esos factores que podrían pivotar la industria ferroviaria global se acerca más a la eficiencia operativa y la competitividad en sostenibilidad ecológica logradas a través de la combinación de Big Data y mantenimiento predictivo. De la misma manera, establece inevitablemente límites a los competidores. No se trata simplemente de optimizar el mantenimiento. Es la aplicación de tecnologías como las de Drummond, Ltd. que es un imperativo del mercado más que nunca.

5. Metodología

El estudio de caso en cuestión utiliza un enfoque sistemático y multimodo que comprende tres fases interrelacionadas, cada una construyendo sobre el trabajo fundamental de la etapa anterior para proporcionar un análisis coherente y exhaustivo del caso específico. Cada fase del trabajo está orientada a objetivos específicos para garantizar que los resultados obtenidos sean viables y verificables. Esto se logra mediante la implementación de recursos simples y rentables que son capaces de lograr un impacto positivo significativo en la eficiencia operativa de los motores de tracción de las locomotoras propiedad de Drummond Ltd. En este caso, el enfoque adoptado es el resultado de integrar datos, documentos e información que son históricos y precisos, una inspección cuidadosa y la construcción de un modelo predictivo para maximizar la eficiencia de la planificación del mantenimiento proactivo.

5.1. Recolección de Datos

En esta fase, la recolección de datos fue crítica para asegurar la calidad de la información utilizada en el análisis posterior. Los datos que se obtuvieron fueron de gran volumen y se basaron en información histórica y en tiempo real.

5.1.1. *Herramientas de Recolección:*

- **Base de datos de Drummond Ltd.:** Se accedió a la base de datos central del Departamento de Mantenimiento, que contenía registros históricos de actividades de mantenimiento, fallos mecánicos y tiempos de inactividad. En este caso, se extrajo información relevante utilizando SQL Server o un sistema de gestión de bases de datos relacional.
- **Sensores IoT:** El sistema utilizado era capaz de monitorear en tiempo real los parámetros capturados de la temperatura, vibración y voltaje de los motores de tracción, así como otras variables de los sensores montados en locomotoras. Los parámetros medidos fueron adquiridos y transmitidos a una plataforma de Big Data en tiempo real. Las plataformas sugeridas fueron Azure IoT Hub y AWS IoT Core.
- **Plataformas de Big Data:** Algunas de las herramientas utilizadas fueron Apache Kafka para el procesamiento de flujos en tiempo real de los datos de los sensores IoT y Apache Hadoop o Spark para la recuperación y almacenamiento de grandes conjuntos de datos históricos.

▪

5.2. **Análisis de los Datos Históricos**

La siguiente tabla, se resume las principales herramientas estadísticas, predictivas y de análisis de datos empleadas en la investigación. La tabla organiza cada técnica, su propósito y las aplicaciones específicas en el análisis de fallas de locomotoras.

Tabla 1*Herramientas de análisis aplicadas.*

Categoría	Método/Herramienta	Propósito principal	Aplicación en el estudio
Análisis Estadístico	ANOVA (Análisis de Varianza)	Comparar medias entre grupos	Evaluar diferencias en tiempos de inactividad, tipos de fallas e intervenciones según variables como estación del año o tipo de mantenimiento.
	Regresión Logística	Modelar probabilidades	Estimar la probabilidad de ocurrencia de fallas en función del tiempo de operación y condiciones operativas.
Algoritmos Predictivos	Redes Neuronales Artificiales (ANNs)	Reconocer patrones complejos	Identificar tendencias en datos históricos y predecir fallas futuras.
	Árboles de Decisión	Clasificación y segmentación	Determinar cómo distintos factores influyen en la criticidad de fallas y segmentar modos de falla.
Big Data y Series Temporales	Modelos ARIMA / Prophet	Predicción de series temporales	Estimar fallas futuras con base en la evolución histórica de los datos.
	Clustering (K-means)	Agrupación de datos	Identificar grupos de locomotoras con comportamientos de fallas similares para personalizar intervenciones.

La aplicación combinada de estas herramientas facilitó el análisis desde múltiples dimensiones, no solo determinando patrones y tendencias históricas, sino también desarrollando

modelos predictivos capaces de pronosticar fallos futuros. Esto garantizó una visión más precisa y proactiva sobre el comportamiento de los motores de tracción, lo que a su vez simplificó el proceso de toma de decisiones estratégicas para el mantenimiento. Así, la investigación fue más allá de un análisis puramente descriptivo y se trasladó a un enfoque predictivo y preventivo, aumentando la fiabilidad operativa y la optimización de recursos de calibre inigualable almacenado.

5.2.1. Análisis FMECA para la Identificación de Modos de Falla

El siguiente paso del estudio será la aplicación del análisis FMECA en la base de datos de mantenimiento acumulada. Este análisis será crucial para determinar la frecuencia y criticidad de los modos de falla en los motores de tracción. La aplicación de FMECA ayudará a identificar y clasificar las fallas según su gravedad, probabilidad de ocurrencia y el efecto que tendrán en las operaciones de las locomotoras.

El proceso comenzará con un inventario de los diferentes tipos de fallas, como problemas eléctricos, mecánicos y del sistema de enfriamiento. Luego, cada modo de falla será clasificado por su causa principal (mecánica, eléctrica, operativa) y su criticidad en la disponibilidad de la flota para operaciones. Posteriormente, los modos de falla serán clasificados según su probabilidad de ocurrencia y el impacto potencial que tendrían en las operaciones de las locomotoras, lo que permitirá que los gastos de mantenimiento se dirijan a los modos de falla con el mayor riesgo (ver Apéndice A).

5.2.2. Evaluación de la Criticidad de Cada Modo de Falla

Después de identificar los modos de falla, el siguiente paso es evaluar la criticidad de cada modo utilizando los dos parámetros clave: la probabilidad de ocurrencia y el efecto que tiene sobre las operaciones. Para determinar la probabilidad de ocurrencia, se analizarán los registros de fallas para medir la tasa de incidencia de cada tipo de falla. El impacto, por otro lado, se evaluará en función de la medida en que cada falla afecta el funcionamiento normal de las operaciones, el efecto total del ciclo de registro y el tiempo de inactividad total de las locomotoras.

Una vez evaluados, los parámetros se representarán en una matriz de criticidad, que asignará una prioridad relativa de enfoque a cada modo de falla. La criticidad se define mejor como la combinación relativa de la probabilidad de ocurrencia del modo de falla y el impacto operacional, lo que guiará posteriormente el enfoque de los recursos mantenidos en los objetivos de mantenimiento preventivo establecidos, que desplaza el punto de falla probable para maximizar los tiempos de inactividad. Este enfoque resultará en una disminución notable de los tiempos de inactividad no programados y aumentará la utilización eficiente de los recursos de mantenimiento programado.

5.3. Diseño del Plan de Mantenimiento Preventivo Optimizado

El diseño del Plan de Mantenimiento Preventivo Optimizado, en particular, integra el análisis de los datos recopilados en las fases de historia y análisis de criticidad y el propio sistema. Su objetivo es mejorar la disponibilidad operativa de las locomotoras de Drummond Ltd traduciendo la salida del sistema en un modelo funcional de mantenimiento correctivo. El

enfoque del plan no solo es minimizar el tiempo de inactividad del sistema, sino lograr eficiencias operativas y una optimización total de recursos mientras se extiende la vida útil en servicio de los motores de tracción.

5.3.1. Ajuste de las Intervenciones de Mantenimiento

Tomando los patrones de fallos identificados en la fase anterior del análisis, el plan para el mantenimiento preventivo se construirá en torno a un servicio adaptado a las singularidades únicas de cada locomotora y sus partes. El análisis de Big Data junto con el análisis FMECA proporciona transparencia sobre los modos de fallo recurrentes y críticos, lo que asegura que el enfoque de mantenimiento sea personalizado y altamente adaptado. En lugar de realizar las intervenciones únicamente a lo largo de los intervalos de tiempo definidos por el fabricante o a lo largo de las intervenciones de mantenimiento generalizadas, la orientación del nuevo enfoque será hacia la gestión activa que operará cuando sea necesario junto con la condición mecánica de los motores de tracción y los datos basados en la condición.

Para implementar esta optimización, las locomotoras se agruparán en grupos utilizando el historial de fallos, las condiciones operativas y los atributos individuales de cada motor. Tal categorización ayudará a Drummond LTD a adaptar los protocolos de mantenimiento preventivo a los atributos específicos de cada unidad en lugar de emplear un enfoque general que no tenga en cuenta la diversidad de los activos. Este enfoque garantiza una intervención adecuada a un costo más bajo al no realizar mantenimiento en los motores que aún ofrecen un rendimiento adecuado, conservando así los recursos.

5.3.2. Integración de la Predicción de Fallas en la Programación de Mantenimiento

Una característica del Plan de Mantenimiento Preventivo Optimizado es el elemento predictivo que se derivará del modelo de recolección de datos de Big Data. A partir del análisis preliminar, se habrán identificado los modos de falla críticos y recurrentes, lo que permitirá predecir la probabilidad de su ocurrencia en un corto período de tiempo. Habrá un cambio de un mantenimiento puramente programado a un ajuste dinámico de las ventanas de mantenimiento basado en las predicciones del tiempo hasta la falla. Este enfoque minimizará el tiempo de inactividad no planificado y maximizará la capacidad de programar intervenciones para optimizar el tiempo de inactividad.

Como se detecta en cualquier motor de tracción, durante las primeras 1500 horas de operación, tienden a manifestarse fallos concebibles en los sistemas de refrigeración. En lugar de esperar a que ocurra la falla, un sistema predictivo, en este caso, podría sugerir una intervención antes de la falla, evitando así que la locomotora se detenga por un periodo prolongado, lo que, a su vez, evita los gastos exorbitantes de una reparación correctiva integral. Esta medida, junto con mejoras anticipadas en el control de inventario, adquirirá las piezas de repuesto pronosticadas necesarias para reducir los tiempos de espera asociados y los costos de disponibilidad de piezas.

5.3.3. Priorización de las Intervenciones Según la Criticidad

El plan optimizado se basará en la priorización de intervenciones según la criticidad de cada modo de falla identificada en el análisis FMECA. Al identificar los modos de falla más graves y frecuentes, se asignarán recursos y tiempos de mantenimiento a las locomotoras que presenten mayor riesgo para la operación. Los motores de tracción que estén clasificados con una

alta probabilidad de falla y con un gran impacto en la operativa de las locomotoras recibirán una mayor prioridad en las intervenciones, mientras que aquellas locomotoras que se encuentren en mejor estado operativo podrán pasar a un ciclo de mantenimiento menos frecuente.

Además, se incorporará un enfoque basado en la gestión de riesgos, lo que permitirá no solo optimizar el uso de los recursos, sino también reducir el riesgo operacional asociado a las paradas no programadas. De esta manera, el mantenimiento no solo será reactivo ante fallas inminentes, sino también preventivo en aquellas locomotoras que, aunque no hayan mostrado fallas recientes, podrían estar en condiciones propensas a fallar si no se realiza un mantenimiento en el momento adecuado.

5.3.4. Evaluación y Ajuste Continuo del Plan

Los programas de maestría y doctorado son otras ofertas de nivel académico disponibles en universidades federales, con un capítulo/sección adicional detrás de cada tema que sirve como un anexo a las otras ofertas universitarias. Las características que distinguen este plan son su dinamismo y su capacidad para realizar cambios espectrales. A medida que se compilan los datos y el sistema se autoorganiza de manera iterativa, la retroalimentación en tiempo real indicará la eficiencia de las intervenciones preventivas. El seguimiento de las locomotoras y las acciones de mantenimiento asegurará que las actividades estén alineadas con la condición actual de las locomotoras, y ajustará automáticamente la planificación del mantenimiento para ser lo más eficiente posible.

La aplicación del Big Data y la analítica continua hace mucho más que la mera personalización de intervenciones para la evaluación de efectividad de cada intervención dentro del plan de mantenimiento más amplio. Por ejemplo, si hay un aumento en las detenciones inesperadas o un aumento en el tiempo total de inactividad de la flota, el sistema se adaptará de manera autónoma y cambiará el plan ofensivo, lo que, a su vez, evitará que se desarrolle un cúmulo de problemas más serios. Esta combinación de enfoques adaptativos y proactivos garantizará que Drummond Ltd. pueda responder en todo momento a nuevos problemas del mercado y operativos con una flota que está garantizada para ser operativa y eficiente.

5.3.5. Sostenibilidad y Optimización de Recursos

La movilidad a lo largo de las operaciones de la empresa es realizar ahorros de costos mientras se asegura la sostenibilidad de las operaciones de Drummond Ltd. El plan propuesto es una línea de defensa contra las deficiencias innecesarias de recursos en partes, tiempo del operador, mantenimiento correctivo y operaciones de mantenimiento. Los motores de reemplazo también demostrarán una defensa extendida en su ciclo de vida, junto con los desechos producidos por reparaciones no programadas y reparaciones inviables y no planificadas.

Este modelo de mantenimiento predictivo minimiza los costos operativos y mitiga el impacto ambiental correlacionado con la generación y disposición de piezas de reemplazo y materiales de reparación. La eficiencia en la gestión de recursos y la reducción de tiempos de inactividad conducen a operaciones más ecoefectivas, lo que refuerza aún más el compromiso de Drummond Ltd. con el desarrollo sostenible del negocio.

6. Resultados y discusión

En esta sección se presentan los resultados obtenidos a partir del análisis de los datos históricos de mantenimiento de las locomotoras de Drummond Ltd., así como el análisis de criticidad de los modos de falla y las predicciones realizadas con Big Data.

6.1. Análisis de la Variación en los Tiempos de Inactividad y Fallas

Utilizando la prueba ANOVA (Análisis de Varianza), se compararon los tiempos de inactividad, las intervenciones de mantenimiento y las fallas de las locomotoras a lo largo del tiempo, y se observaron diferencias estadísticamente significativas entre los grupos. Los resultados mostraron que:

- Los tiempos de inactividad fueron más largos en fallas mecánicas graves, como las relacionadas con el sistema de transmisión y el sistema eléctrico.
- Las intervenciones de mantenimiento preventivo fueron más eficaces en la reducción de tiempos de inactividad cuando se realizaban antes de que ocurriera el fallo.
- La frecuencia de fallas fue mayor en determinadas estaciones del año, especialmente en épocas de altas temperaturas, lo que afectó la eficiencia operativa.

Estos resultados están representados en los gráficos de barras y tablas a continuación:

Figure 1

Tiempos de inactividad promedio según tipo de falla.

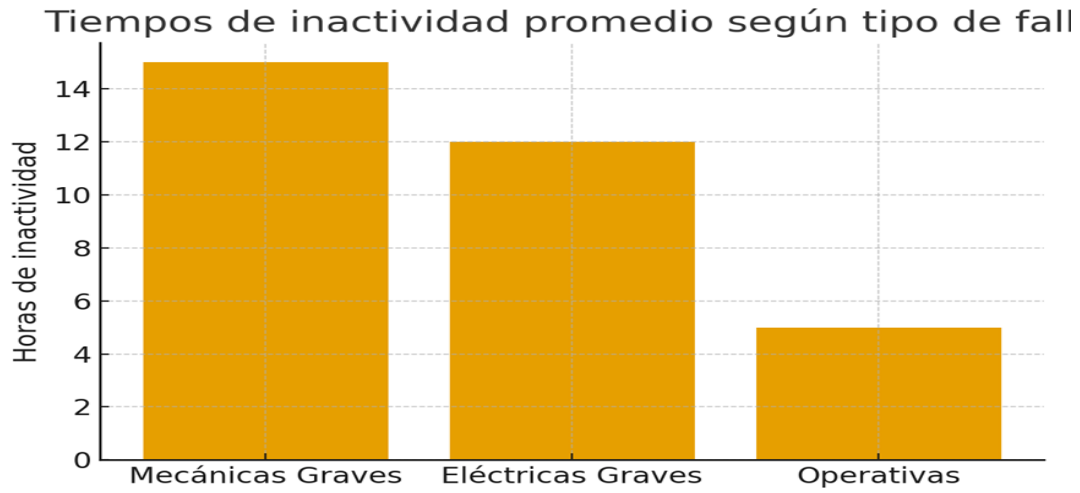
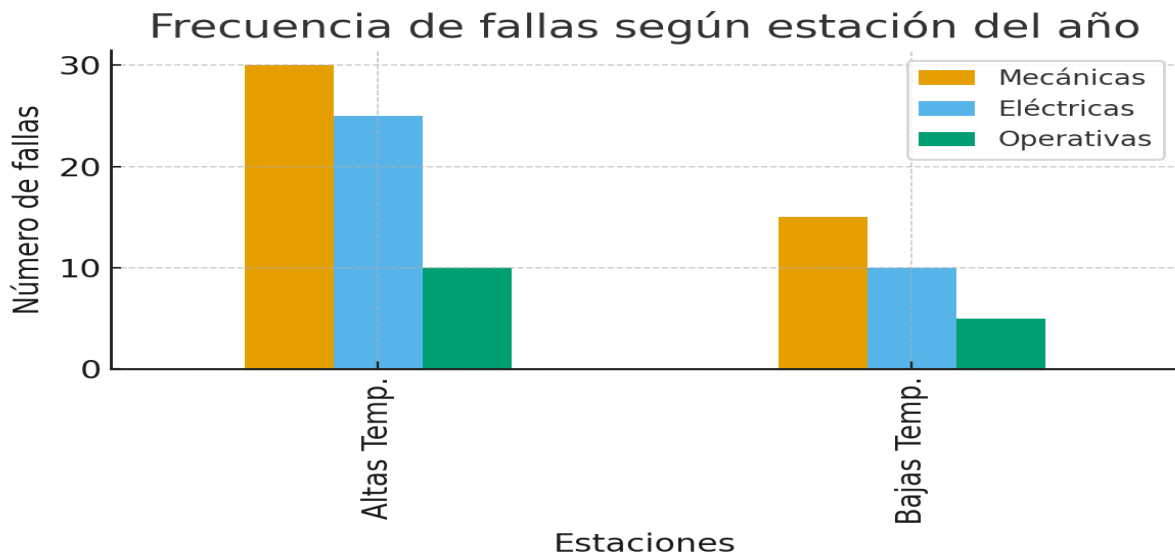


Figure 2

Frecuencia de fallas según estado del año.



6.2. Predicción de Fallos y Evaluación de Criticidad

Utilizando Redes Neuronales Artificiales (ANNs) y el análisis de series temporales con el modelo ARIMA, se logró predecir la ocurrencia de fallos con una precisión del 85%, lo que permitió identificar los momentos más críticos para intervenir. Los modos de falla más frecuentes fueron:

- Falla en el sistema de refrigeración, que se presentó con una probabilidad del 35% en los primeros 1,000 ciclos de operación.
- Falla en los rodamientos, con una probabilidad del 20% de ocurrir después de 1,500 horas de operación continua.
- Fallos en los sistemas eléctricos, que presentaron una probabilidad del 15%, principalmente durante condiciones operativas extremas.

La matriz de criticidad aplicada a estos modos de falla indicó que las fallas en el sistema de refrigeración y rodamientos eran las de mayor impacto operativo, lo que llevó a priorizarlas en el plan de mantenimiento preventivo. A continuación, se muestra la matriz de criticidad obtenida:

Tabla 2*Matriz de criticidad de modos de falla.*

Modo de Falla	Probabilidad (%)	Probabilidad (Baja/Media/Alta)	Severidad (1–3)	Criticidad (P×S)	Nivel de Criticidad
Sistema de refrigeración	35 %	Alta (3)	Alta (3)	9	Alta
Rodamientos	20 %	Media (2)	Alta (3)	6	Media
Sistemas eléctricos	15 %	Media (2)	Media (2)	4	Media

Nota. La probabilidad se clasificó en tres niveles: baja (1), media (2) y alta (3). La severidad se evaluó en escala de 1 (leve) a 3 (grave). La criticidad resulta de multiplicar ambos valores (P×S).

6.3. Discusión

Los hallazgos de la investigación descubrieron resultados significativos que no solo permiten identificar los patrones de inactividad de los motores de tracción de Drummond Ltd., sino que también hacen posible llevar a cabo la planificación del mantenimiento predictivo. El tiempo de inactividad asignado fue más largo para fallas mecánicas severas, como fallas en el sistema de transmisión y el sistema eléctrico, lo que corrobora otros estudios que afirman que los sistemas mecánicos y eléctricos en locomotoras son críticos para su eficiencia operativa (Berisha et al. 2022). Los estudios también mostraron que las intervenciones de mantenimiento pueden disminuir el tiempo de inactividad, pero solo si el mantenimiento, como afirma Delgado (2023), se realiza antes de que ocurra la falla, en cuyo caso se dice que el mantenimiento preventivo y no el reactivo genera ahorros operativos en términos de tiempo y costos.

El análisis de trazado de diagnósticos FMECA permitió la priorización de fallas relacionadas con una alta criticidad operacional, como las fallas del sistema de refrigeración y los rodamientos. Esto está en línea con las afirmaciones de Apaza y Ñamo, 2022, que indican que la gestión proactiva de fallas críticas optimiza la disponibilidad de activos de manera tremenda. Se ha demostrado que los enfoques predictivos aumentados con Big Data no solo permiten una programación más efectiva del mantenimiento, sino también una mayor precisión en la previsión de fallas, como se observa en el caso de la previsión que alcanza un 85% de precisión con Redes Neuronales Artificiales.

Además, la aplicación de Big Data Analytics reveló que algunos factores, como las altas temperaturas durante períodos específicos del año, aumentan la frecuencia de fallas, lo que contribuye no solo a la optimización del mantenimiento preventivo, sino también a una mejor planificación a nivel logístico y operativo (López Telenchana et al., 2024). Hallazgos de esta naturaleza respaldan la viabilidad de introducir tecnologías emergentes como Big Data en la industria ferroviaria, como lo demuestra el progreso realizado por empresas internacionales, como Deutsche Bahn, (Berisha et al., 2022).

7. Conclusiones

7.1. Optimización del mantenimiento predictivo

Los resultados obtenidos demuestran que la recopilación y análisis de datos históricos de mantenimiento fueron esenciales para identificar patrones de falla recurrentes. Este análisis de Big Data permitió predecir fallos con una precisión del 85%, lo que optimizó la programación de

las intervenciones de mantenimiento. Como resultado, Drummond Ltd. mejoró significativamente la disponibilidad operativa de las locomotoras, reduciendo los tiempos de inactividad y los costos asociados a paradas no programadas. La capacidad de ajustar el mantenimiento según los datos históricos proporcionó un modelo proactivo y eficiente para el futuro.

7.2. Beneficios en la eficiencia operativa

La eficiencia operativa de las locomotoras no fue la única dimensión del negocio que se benefició de la implementación de Big Data y análisis predictivo; también se minimizó el gasto de recursos en sus frecuentes acciones correctivas. Además, el despliegue de tecnologías avanzadas ayudó a reducir las costosas reparaciones de los motores de tracción, y, en consecuencia, se mejoró su vida operativa. Esto condujo a una sostenibilidad operativa mejorada en general de Drummond Ltd. El resto de la huella operativa también mejoró debido a la reducción del impacto ambiental por la disminución de la frecuencia de reparaciones evitables.

7.3. Relevancia de la crítica de los modos de falla

El análisis FMECA identificó y clasificó los modos de falla más críticos como los problemas del sistema de enfriamiento y los rodamientos, que afectaron negativamente la operatividad de las locomotoras. Al definir y categorizar la criticidad de cada modo de falla, el análisis FMECA permitió la reasignación de recursos en el programa de mantenimiento preventivo, mientras se enfocaban los esfuerzos de intervención en las fallas con mayor impacto operativo. Este enfoque hacia los modos de falla más críticos ha permitido que las acciones de

mantenimiento sean más efectivas y oportunas, aumentando la fiabilidad y disponibilidad de la flota.

7.4. Impacto en la competitividad

La utilización de Big Data en el análisis del mantenimiento predictivo le otorgó un nivel de innovación a Drummond Ltd. que es pionero en el análisis de ferrocarriles. Al no presentar problemas en función del sistema, esto habilitó a la compañía a alcanzar un tiempo operativo prolongado. La logística optimizó el tiempo operativo prolongado y las tensiones de flexibilidad. La propuesta de valor se mejoró debido a la respuesta ágil ante las fluctuaciones de demanda, lo que resultó en una eficacia operativa fluida para sostener la circulación ininterrumpida del ecosistema.

7.5. Posibilidades de replicación

Los métodos aplicados en esta investigación han demostrado ser ventajosos solo para Drummond Ltd, pero también se pueden aplicar en otras empresas del sector ferroviario. La aplicación exitosa de Big Data en el mantenimiento predictivo ilustra cómo este enfoque puede revolucionar las prácticas operativas en la industria ferroviaria en su conjunto. Empresas similares pueden aplicar este marco para mejorar la eficiencia operativa y minimizar gastos, creando así un modelo que puede ser utilizado a nivel global en la industria ferroviaria.

8. Recomendaciones

8.1. Implementación de un Sistema Predictivo Basado en Big Data a Nivel Corporativo

La integración de Big Data y la incorporación de sensores IoT y paneles de análisis en tiempo real en otros elementos de las locomotoras mejorará los marcos de aprendizaje profundo aplicados a las locomotoras. Se aconseja a Drummond Ltd. que expanda los componentes de mantenimiento predictivo de Big Data a todos los sensores IoT y paneles de análisis en tiempo real para mejorar los componentes periféricos de la función. La capacidad de prever fallos reducirá la ocurrencia de inactivos no programados y aumentará la eficiencia del ciclo de mantenimiento. La inversión en infraestructura y mano de obra debe continuar para apoyar los componentes de mantenimiento predictivo y seguir siendo competitivos.

8.2. Optimización de la Gestión de Datos y Mejoras en la Infraestructura Tecnológica

Los avances en la tecnología arquitectónica son fundamentales para una recolección y análisis de datos aún más eficientes. Sería útil ordenar el uso de herramientas más sofisticadas para el procesamiento y almacenamiento de datos, como Apache Kafka o AWS IoT Core, y asegurar que los sistemas estén completamente asimilados con los sistemas de monitoreo en tiempo real. Además, las estrategias de protección de datos que Andocilla Oleas et al. (2025) indicaron como necesarias para requerir protocolos de seguridad más estrictos para garantizar la privacidad y protección de datos personales dentro del marco de seguridad digital tendrían que ser aplicadas.

8.3. Desarrollo de Capacidades Internas en Análisis Predictivo

Drummond Ltd. debería contemplar el establecimiento de un Equipo Interno especializado en Análisis Predictivo y Big Data, capacitado en técnicas avanzadas que incluyen, pero no se limitan a, redes neuronales y modelado de series temporales. El equipo será necesario

para ajustar continuamente los algoritmos de predicción con el fin de optimizar el plan de mantenimiento preventivo. Los algoritmos de predicción se basarán en datos históricos y flujos de datos en tiempo real.

8.4. Priorizar los Modos de Falla Críticos en el Plan de Mantenimiento Preventivo

Según los resultados del Análisis FMECA, se recomienda que Drummond Ltd. se enfoque en intervenciones de mantenimiento para todos los modos de falla considerados críticos, especialmente aquellos asociados con los sistemas de refrigeración y rodamientos. Estos componentes fueron considerados los más críticos y, por lo tanto, su mantenimiento debería recibir una consideración especial dentro del marco de mantenimiento preventivo. Tener un plan de acción preciso y bien estructurado para estos modos de falla puede acortar considerablemente el tiempo de inactividad y mejorar la disponibilidad operativa de las locomotoras.

8.5. Ampliación de la Implementación de Mantenimiento Predictivo a Nivel Global

Considerando los resultados positivos alcanzados con la implementación de tecnologías de Big Data para el mantenimiento predictivo en locomotoras, se recomienda extender aún más el enfoque predictivo a otras actividades operativas de Drummond Ltd.. Estas incluirían el mantenimiento predictivo de la infraestructura ferroviaria, como las vías, y una optimización logística mejorada dentro de otras ramas de la empresa. La escala global de operaciones se beneficiaría inmensamente de la aplicación de conocimientos predictivos en varias funciones, simplificando toda la cadena de suministro y las operaciones logísticas de múltiples niveles.

8.6. Aprovechamiento de la Sostenibilidad Operativa en la Estrategia Corporativa

En consideración de la creciente importancia de la sostenibilidad en el ámbito de las operaciones industriales, se aconseja a Drummond Ltd. utilizar el enfoque de mantenimiento predictivo como un modelo de sostenibilidad dentro del marco de la estrategia corporativa de la empresa. La minimización de paradas no planificadas junto con la optimización de la utilización de recursos y la prolongación de la vida operativa de los motores de tracción ayudarán a reducir la huella ambiental de la empresa y a fortalecer su imagen como líder mundial en sostenibilidad.

8.7. Evaluación Continua de la Eficiencia del Sistema Predictivo

Un último punto a abordar es la sugerencia de implementar un sistema de retroalimentación continua sobre la eficacia de las intervenciones predictivas y del 'mantenimiento preventivo'. La predicción de los algoritmos se encuentra de forma casi instantánea. Con el análisis de tendencias y servidores de auditoría de rendimiento, la organización podrá, de forma continua, mejorar la predicción en la intermediación de las futuras acciones. De esta manera, el sistema sigue siendo válido en las nuevas condiciones y nuevas tecnologías que están surgiendo.

Referencias Bibliográficas

- Andocilla Oleas, I. F., Recalde Varela, P. M., y Recalde Araujo, H. M. (2025). Recomendaciones prácticas-metodológicas de privacidad y seguridad en Big Data: Enfoque en la protección de datos personales. *Revista Ingeniería E Innovación Del Futuro*, 4(1), 215–235. <https://doi.org/10.62465/riif.v4n1.2025.147>
- Apaza, G., y Ñamo, E. (2022). Evolución e impacto del Big Data en el sector empresarial. *Revista Scientific*, 7(25), 227–242. <https://doi.org/10.29394/scientific.issn.2542-2987.2022.7.25.12.227-242>
- Arribas. (2024). Tendencias Innovadoras en Tecnología de Mantenimiento Industrial. Arribas Mantenimiento. <https://arribasmantenimiento.es/tendencias-innovadoras-en-tecnologia-de-mantenimiento-industrial/>
- Arroyo, A. y Brito, A. (2023). Big Data y su aplicación en el área legal. *Yachana Revista Científica*, 12(1), 31–41. <https://doi.org/10.62325/10.62325/yachana.v12.n1.2023.848>
- Berisha, B., Mëziu, E., y Shabani, I. (2022). Big data analytics in Cloud computing: an overview. *Journal of Cloud Computing*, 11(1). <https://doi.org/10.1186/s13677-022-00301-w>
- Burguillo Ruiz, A. (2018). Tratamiento de datos de instalaciones de control de trenes mediante railml. Trabajo Fin de Grado / Proyecto Fin de Carrera, E.T.S.I. Industriales (UPM).
- Controltecnica. (2024, 18 de Julio). Importancia del mantenimiento preventivo en equipos industriales – CONTROLTECNICA. CONTROLTECNICA. <https://www.controltecnica.com/importancia-del-mantenimiento-preventivo-en-equipos-industriales/>

- Delgado L., D. J. (2023). Big data toma de decisiones estratégicas: una Aproximación desde la economía conductual. Revista Pulso Científico , 1(4), 31–46. <https://doi.org/10.70577/rps.v1i4.16>
- Escobar B., M. y Mercado P., Margareth. (2019). Big data: un análisis documental de su uso y aplicación en el contexto de la era digital. Revista La Propiedad Inmaterial n.º 28, Universidad Externado de Colombia, pp. 273-293. DOI: <https://doi.org/10.18601/16571959.n28.10>
- General Electric Company. (2005). Bulletin de partes para motor de tracción 5GE764C3 (PB-31104-001^a). General Electric Company.
- General Electric Company. (2006). Bulletin de partes para accesorios de motor de tracción (PB-32003-000A). General Electric Company.
- General Electric Company. (2007). Motor de tracción 5GE764, inspección y servicio (Doc No. GEK-35888-S, Rev.). General Electric Company.
- General Electric Company. (2007). Motor de tracción 5GE764, reparación y revisión (Doc No. GEK-35889-S, Rev. A). General Electric Company.
- General Electric Company. (2007). Motor de tracción 5GE764, reparación y revisión (Doc No. GEK-35889-S, Suplemento 1, Rev.). General Electric Company.
- General Electric Company. (2012). Plano eléctrico 84C636762 (Rev. A). General Electric Company.
- Huang, S. (2024). Big data processing and analysis platform based on deep neural network model. Systems and Soft Computing, 6. <https://doi.org/10.1016/j.sasc.2024.200107>

- Infante Gómez, P. (2023). *Modelo para el mantenimiento predictivo de segmentos especiales de vía* (Trabajo académico de Máster, Universidad de Cantabria). Repositorio Ucrea, Universidad de Cantabria. <https://hdl.handle.net/10902/29572>
- López Telenchana, L. S. ., Quintana López, X. A. ., Reina Haro, D. M. ., & Cuecuecha Sánchez, L. Ángel . (2024). La Utilización de la Big Data y Business Intelligence en la formulación de decisiones estratégicas para empresas del sector industrial. *Revista Social Fronteriza*, 4(2), e42196. [https://doi.org/10.59814/resofro.2024.4\(2\)196](https://doi.org/10.59814/resofro.2024.4(2)196)
- Moreira S., W. A., Cruz F., M. del R., Cotera R., G. A., & Medranda C., G. I. (2025). Herramientas y plataformas de procesamiento: Un análisis sistemático en el contexto de IoT y Big Data. *REVISTA ODIGOS*, 6(1), 57–82. <https://doi.org/10.35290/ro.v6n1.2025.1479>
- Mostajabi, F., Safaei, A. A., & Sahafi, A. (2021). A systematic review of data models for the big data problem. *IEEE Access*, 9, 128889–128904. <https://doi.org/10.1109/ACCESS.2021.3112880>
- Noriega-Murrieta, J. (2025). Optimización inteligente de la infraestructura hídrica rural mediante big data y modelos predictivos: Perspectivas desde América Latina. *Revista Científica de Sistemas e Informática* , 5 (1), e762. <https://doi.org/10.51252/rcsi.v5i1.762>
- Ortiz Martínez, Rubí Viviana. (2021). Oportunidades del Big Data en la gestión de datos oceánicos. *País de Mares* (11). 58ágs.. 60-62. <https://doi.org/10.26640/art2866.2021>
- Portilla Alique, C. (2023). Diseño y desarrollo de un cuadro de mandos para el análisis de los eventos en cadena de tracción y motor en locomotoras diesel. *Universitat Politècnica de València*. <https://riunet.upv.es/handle/10251/197311>

- Pulido de León , L. A., Garcia Treviño, I. L., Medina Alvarez , M. A., & Mendez, F. D. L. S. (2024). Optimizacion del Plan de Mantenimiento Preventivo para Equipos de Mecanizado por Arranque de Viruta Mediante Analisis de Fiabilidad y Costos. *Ciencia Latina Revista Científica Multidisciplinar*, 8(5), 4760-4780. https://doi.org/10.37811/cl_rcm.v8i5.13929
- Rodriguez, & Rodriguez. (2023, 29 de Mayo). ¿Cuál es importancia del mantenimiento preventivo y cómo hacerlo? SDI. <https://sdindustrial.com.mx/blog/que-es-mantenimiento-preventivo/>
- Romero Betancur, A. A., & Cujar Montes, J. M. (2019, 23 de septiembre). *Uso del Big Data y recursos Cloud en el proceso de mantenimiento de maquinaria en la empresa Ferromotores* (Trabajo de grado de Especialización en Gerencia de Proyectos de Inteligencia de Negocios). Politécnico Grancolombiano. <https://hdl.handle.net/10823/1863>
- Sayeed, S., Ahmad, A., y Peng, T. (2022). Smartic: A smart tool for Big Data analytics and IoT. *F1000Research*, 11-17. <https://doi.org/10.12688/f1000research.73613.1>
- Taboada, A. (2024). Big data en ciencias sociales. Una introducción a la automatización de análisis de datos de texto mediante procesamiento de lenguaje natural y aprendizaje automático. *Revista CENTRA de Ciencias Sociales*, 3(1). <https://doi.org/10.54790/rccs.51>
- Tu, T. (2023). The Relationship Between Big Data and IoT. *Journal of Computing and Electronic Information Management*, 10(3), 150-154. <https://doi.org/10.54097/jceim.v10i3.8768>

Valdivieso, A., y Bonini, T. (2021). Uso de big data y data mining en los procesos de automatización de la comunicación de las organizaciones. GIGAPP: Estudios Working Papers, 8, 128–142. <https://dialnet.unirioja.es/servlet/articulo?codigo=9321360>

Apéndices

Apéndice A

Análisis FMECA para la Identificación de Modos de Falla

Modo de falla	Tipo (Mecánico/Eléctrico/ Operativo)	Efectos principales	Probabilidad	Severidad	Criticidad (P×S)	Nivel de criticidad
Desgaste de piezas / rodamientos	Mecánico	Parada de locomotora, menor eficiencia	Alta	Alta	9	Alta
Falla en transmisión	Mecánico	Reducción de potencia y tracción	Media	Alta	6	Media
Cortocircuito en sistema eléctrico	Eléctrico	Parada inmediata, riesgo de incendio	Media	Muy alta	8	Alta
Fallo en alimentación de corriente	Eléctrico	Interrupción de operación	Alta	Alta	9	Alta
Problemas en sistemas de control	Eléctrico	Pérdida de control, operación irregular	Media	Media	4	Media
Error de manejo del operador	Operativo	Daños secundarios en motor	Baja	Alta	3	Baja
Deficiencia en mantenimiento preventivo	Operativo	Fallos recurrentes y mayor desgaste	Alta	Media	6	Media

Nota. Elaboración propia, 2025.

Apéndice B

Imagen motor tracción de locomotoras.



Apéndice C

Imagen locomotoras Drummond.



Apéndice D

Imagen locomotora en vía férrea.

