



Universidad Católica de Santa María

Facultad de Ciencias e Ingenierías Físicas y Formales

Escuela Profesional de Ingeniería de Minas

**Optimización de costos y desempeño de neumáticos en camiones mineros
mediante un modelo predictivo en una mina superficial en el año 2024**

Tesis presentada por:

Carigga Bellido, Jose Emanuel

ORCID: 0009-0007-7160-648X

para optar el Título Profesional de Ingeniero de Minas

Asesor:

Mg. Barreda de la Cruz, Miguel Alberto

ORCID: 0000-0002-9329-4460

Arequipa - Perú

2026

UCSM-ERP

UNIVERSIDAD CATÓLICA DE SANTA MARÍA

INGENIERIA DE MINAS

TITULACIÓN CON TESIS

DICTAMEN APROBACIÓN DE BORRADOR

Arequipa, 25 de Abril del 2026

Dictamen: 016182-C-EPIM-2026

Visto el borrador del expediente 016182, presentado por:

2015222571 - CARIGGA BELLIDO JOSE EMANUEL

Titulado:

**OPTIMIZACIÓN DE COSTOS Y DESEMPEÑO DE NEUMÁTICOS EN CAMIONES MINEROS
MEDIANTE UN MODELO PREDICTIVO EN UNA MINA SUPERFICIAL EN EL AÑO 2024**

Nuestro dictamen es:

APROBADO

Titulo Profesional/Titulo de Segunda Especialidad/Grado Académico a optar:

INGENIERO DE MINAS

**40902304 - LINARES FLORES CASTRO ANTONIO ERICK
DICTAMINADOR**



**40379481 - PAREDES SALAS OMAR WILLY
DICTAMINADOR**



**29635304 - MORALES VALDIVIA JAVIER ANTONIO
DICTAMINADOR**



OPTIMIZACIÓN DE COSTOS Y DESEMPEÑO DE NEUMÁTICOS EN CAMIONES MINEROS MEDIANTE UN MODELO PREDICTIVO EN UNA MINA SUPERFICIAL EN EL AÑO 2024

INFORME DE ORIGINALIDAD

14%	12%	2%	6%
INDICE DE SIMILITUD	FUENTES DE INTERNET	PUBLICACIONES	TRABAJOS DEL ESTUDIANTE

FUENTES PRIMARIAS

1	Submitted to Universidad Católica de Santa María	1%
	Trabajo del estudiante	
2	repositorio.ucsm.edu.pe	1%
	Fuente de Internet	
3	juandomingofarnos.wordpress.com	1%
	Fuente de Internet	
4	www.coursehero.com	1%
	Fuente de Internet	
5	Submitted to Instituto Superior de Artes, Ciencias y Comunicación IACC	1%
	Trabajo del estudiante	
6	luchaconm31.github.io	<1%
	Fuente de Internet	
7	Submitted to Escuela de Posgrado Newman	<1%
	Trabajo del estudiante	
8	repositorio.uncp.edu.pe	<1%
	Fuente de Internet	
9	Submitted to Universidad Andina Nestor Caceres Velasquez	<1%
	Trabajo del estudiante	
10	Submitted to uncedu	<1%
	Trabajo del estudiante	


Dedicatoria

Dedico mi tesis de titulación a mi esposa, Karem Cuadros Manrique, por su amor, comprensión y apoyo incondicional en cada etapa de este camino.

A mis padres, José Carigga y Tatiana Bellido, por su incondicional apoyo, por inculcarme la perseverancia necesaria para nunca rendirme y por ser la base fundamental de mi formación personal y profesional.

A mi hermana, sobrina y abuelos, quienes con su amor, alegría y carisma han sido una fuente constante de motivación, impulsándome siempre a ser mejor.

Este logro es fruto del esfuerzo y la lucha constante, impulsado por el deseo de brindarles siempre lo mejor y retribuir, en parte, todo el apoyo incondicional que me han brindado.




Agradecimientos

Agradezco a Dios por brindarme la fortaleza, sabiduría y perseverancia necesarias para culminar satisfactoriamente esta tesis.

De manera especial, agradezco al Mg. José Carlos Tong Ladrón de Guevara, por su valiosa guía, constante apoyo y orientación académica durante el desarrollo de la presente investigación, aportando con sus conocimientos y experiencia al logro de este importante objetivo.

Asimismo, expreso mi profundo agradecimiento a mi esposa y a mi familia, por su apoyo incondicional, comprensión y motivación constante durante cada etapa de este importante logro profesional.

A todos ellos, mi profunda gratitud por haber sido parte fundamental de este logro profesional y personal.



RESUMEN

La presente investigación tiene como objetivo desarrollar un modelo predictivo para estimar el desgaste de neumáticos en camiones mineros, con el fin de optimizar los costos operativos asociados a su reemplazo. Se recopilaron más de 600 registros diarios que incluyen variables como presión de inflado, temperatura de operación, velocidad promedio, horas trabajadas y modelo de neumático. Mediante análisis exploratorio de datos, estadísticos descriptivos y regresión lineal múltiple, se identificaron correlaciones significativas entre las variables operativas y el desgaste mensual. El modelo predictivo alcanzó un coeficiente de determinación (R^2) de 0.78 y un error cuadrático medio (RMSE) de 0.19 mm, lo que demuestra su capacidad para estimar con precisión el comportamiento del desgaste. Además, se simuló un escenario de optimización que proyecta un ahorro económico anual de USD 42,600. Los resultados permiten tomar decisiones informadas en la gestión de neumáticos, contribuyendo a la eficiencia operativa en contextos mineros.

Palabras clave: desgaste de neumáticos, minería, optimización de costos.

ABSTRACT

This research aims to develop a predictive model to estimate tire wear in mining trucks, with the goal of optimizing operational costs related to tire replacement. Over 600 daily records were collected, including variables such as inflation pressure, operating temperature, average speed, working hours, and tire model. Through exploratory data analysis, descriptive statistics, and multiple linear regression, significant correlations were identified between operational variables and monthly wear. The predictive model achieved a determination coefficient (R^2) of 0.78 and a root mean square error (RMSE) of 0.19 mm, demonstrating its accuracy in estimating wear behavior. Additionally, an optimization scenario was simulated, projecting an annual economic saving of USD 42,600. The results support informed decision-making in tire management, contributing to operational efficiency in mining environments.

Keywords: tire wear, mining, cost optimization.

ÍNDICE GENERAL

DEDICATORIA

AGRADECIMIENTOS

RESUMEN

ABSTRACT

INTRODUCCIÓN 1

CAPÍTULO I: PLANTEAMIENTO DE LA INVESTIGACIÓN..... 2

1.1. Planteamiento del Problema..... 2

1.2. Objetivos de la Investigación 2

1.2.1. Objetivo General 2

1.2.2. Objetivos Específicos 2

1.3. Preguntas de Investigación..... 2

1.4. Línea de Investigación 2

1.5. Palabras Clave 3

1.6. Solución Propuesta 3

1.6.1. Justificación e Importancia 3

1.6.2. Descripción de la Solución 3

1.7. Hipótesis..... 4

1.7.1. Hipótesis General 4

1.7.2. Hipótesis Específicas..... 4

CAPÍTULO II: FUNDAMENTOS TEÓRICOS 5

2.1. Estado del Arte 5

2.1.1. Antecedentes Internacionales..... 5

2.1.2. Antecedentes Nacionales 6

2.1.3. Antecedentes Locales 7

2.2. Bases Teóricas..... 8

2.2.1. Teoría del Ciclo de Vida del Componente 8

2.2.2. Mantenimiento Predictivo..... 9

2.2.3. Modelado y Aprendizaje Automático (Machine Learning)..... 10

2.2.4. Teoría de Fiabilidad y Análisis de Fallos (RAM Analysis) 11


2.2.5. Gestión del Costo Total de Propiedad (TCO)..... 13

2.2.6. Teoría de Optimización de Procesos Mineros 14

2.2.7. Termodinámica Aplicada al Comportamiento del Neumático 15


2.2.8. Mecánica de Materiales y Fatiga del Caucho	16
2.3. Marco Teórico	18
2.3.1. Ciclo de Vida de los Neumáticos en Minería	18
2.3.2. Impacto del Ciclo de Vida de los Neumáticos en la Planificación Operativa Minera.....	19
2.3.3. Mantenimiento Predictivo vs. Preventivo vs. Correctivo.....	20
2.3.4. Modelos Predictivos en Ingeniería Minera.....	21
2.3.5. Factores Operacionales que Afectan el Desgaste.....	23
2.3.6. Termodinámica Aplicada al Comportamiento del Neumático	24
2.3.7. Fatiga de Materiales y Mecánica del Caucho	25
2.3.8. Aplicación del Análisis RAM en la Gestión de Neumáticos Mineros	27
2.3.9. Gestión del Costo Total de Propiedad (TCO).....	28
2.3.10. Optimización de Procesos Mineros.....	29
2.3.11. Sistemas de Monitoreo en Tiempo Real (IoT).....	30
2.3.12. Visión Artificial y Detección de Fallas	32
2.3.13. Impacto Económico de la Optimización Predictiva.....	33
2.3.14. Sostenibilidad y Gestión Basada en Datos	34
2.3.15. Análisis de Fallas y Modos de Falla (FMEA)	35
2.3.16. Minería de Datos en Ingeniería Predictiva	37
2.4. Glosario de Términos.....	38
CAPÍTULO III: MARCO METODOLÓGICO.....	41
3.1. Alcances y Limitaciones	41
3.1.1. Alcance	41
3.1.2. Limitaciones.....	41
3.2. Aporte	42
3.3. Tipo y Nivel de Investigación	42
3.4. Población y Muestra	42
3.5. Métodos, Técnicas e Instrumentos	43
3.6. Plan de Análisis Estadístico	43
CAPÍTULO IV: RESULTADOS Y DISCUSIONES.....	45
4.1. Factores operativos que inciden en el desgaste de neumáticos.....	45
4.2. Modelo Predictivo: Regresión Lineal Múltiple.....	48
4.2.1. Simulación de Escenarios	48
4.2.2. Simulación de Escenarios Comparativos.....	49

4.2.3. Factores Evaluados sin Relevancia Predictiva.....	49
4.2.4. Mapa de calor por zona de operación.....	52
4.2.5. Optimización Económica.....	53
4.3. Análisis e Interpretación de Resultados.....	54
4.3.1. Análisis Exploratorio de Datos (EDA).....	54
4.3.2. Estadísticos Descriptivos	54
4.3.3. Matriz de Correlaciones.....	55
4.3.4. Ahorro potencial tras la implementación del modelo	57
4.4. Discusión Técnica de los Resultados.....	58
CONCLUSIONES	61
RECOMENDACIONES	63
REFERENCIAS BIBLIOGRÁFICAS	64
ANEXOS.....	70




ÍNDICE DE TABLAS

Tabla 1 Criterios de evaluación del análisis FMEA	37
Tabla 2 Operacionalización de Variables.....	44
Tabla 3 Desgaste y costo de neumáticos.....	47
Tabla 4 Coeficientes del Modelo	48
Tabla 5 Correlación con desgaste	50
Tabla 6 Estadísticos descriptivos.....	54
Tabla 7 Matriz de correlaciones.....	55
Tabla 8 Comparación general de escenarios	56
Tabla 9 Comparación de Modelos de Neumáticos	60



ÍNDICE DE FIGURAS

Figura 1 Comparación factores operativos por modelo de neumático.....	45
Figura 2 Correlación entre presión y desgaste.....	50
Figura 3 Código Python: Modelo Predictivo de Desgaste de Neumáticos	51
Figura 4 Visualización que relaciona granulometría con desgaste por zona.....	52
Figura 5 Simulación de ahorro económico anual	53
Figura 6 Análisis de costos de neumáticos.....	57



INTRODUCCIÓN

En las operaciones mineras de gran escala, los neumáticos de los camiones representan uno de los componentes más críticos y costosos del sistema de transporte. Su desgaste acelerado no solo implica gastos elevados en reemplazo, sino también riesgos operativos y pérdida de eficiencia. En este contexto, surge la necesidad de implementar herramientas analíticas que permitan anticipar el comportamiento del desgaste y proyectar escenarios de ahorro económico. De acuerdo con Tecnología Minera (s.f.), la implementación de un enfoque de mantenimiento predictivo reduce los costos de mantenimiento hasta en un 30% y aumentar la disponibilidad de la flota hasta en un 25% en operaciones de gran envergadura.

De esta manera, la presente investigación se enmarca en el desarrollo de un modelo predictivo basado en regresión lineal múltiple, que relaciona variables operativas como presión de inflado, temperatura, velocidad promedio y horas de operación con el desgaste mensual de neumáticos. El estudio se sustenta en datos reales recopilados durante el año 2024 de una empresa minera peruana, correspondientes a una flota de camiones equipados con modelos Michelin XDR3, Goodyear RM4B+ y Bridgestone VRLS.

El objetivo principal es proporcionar una herramienta técnica que permita optimizar la gestión de neumáticos, reducir costos operativos y mejorar la toma de decisiones en contextos mineros. La investigación combina análisis estadístico, modelado predictivo y simulación económica, contribuyendo al fortalecimiento de prácticas basadas en datos dentro del sector.

CAPÍTULO I:

PLANTEAMIENTO DE LA INVESTIGACIÓN

1.1. Planteamiento del Problema

En la operación minera superficial, los camiones constituyen un componente esencial para el transporte de material. Dentro de estos, los neumáticos representan uno de los elementos de mayor costo operativo y de mantenimiento. El desgaste prematuro, fallas por uso inadecuado o condiciones extremas, y la falta de control predictivo incrementan sustancialmente los costos logísticos y de producción. Pese a los esfuerzos de mantenimiento, la mayoría de operaciones carece de herramientas predictivas que anticipen el comportamiento de los neumáticos bajo determinadas condiciones de carga, ciclo de trabajo y clima.

1.2. Objetivos de la Investigación

1.2.1. Objetivo General

Optimizar los costos y el desempeño de los neumáticos en camiones mineros mediante la aplicación de un modelo predictivo en una mina superficial durante el año 2024.

1.2.2. Objetivos Específicos

- Identificar los factores operativos que inciden en el desgaste de los neumáticos.
- Diseñar un modelo predictivo para estimar el desempeño y desgaste de los neumáticos.
- Estimar el ahorro potencial generado por la implementación del modelo.

1.3. Preguntas de Investigación

- ¿Qué variables operativas influyen en el desempeño de los neumáticos?
- ¿Qué modelo predictivo permite anticipar el desgaste de los neumáticos?
- ¿Cuál es el impacto económico de aplicar dicho modelo en la operación minera?

1.4. Línea de Investigación

Optimización de Procesos Mineros.

1.5. Palabras Clave

Neumáticos, Camiones mineros, Costos operativos.

1.6. Solución Propuesta

1.6.1. Justificación e Importancia

La presente investigación busca reducir significativamente los costos operativos relacionados con el desgaste de neumáticos en camiones mineros, mejorando la toma de decisiones mediante la implementación de un modelo predictivo construido sobre una base de datos operativa real. En el contexto actual de la minería superficial, el componente neumático representa uno de los principales gastos de mantenimiento debido a su alto costo de adquisición, su desgaste acelerado y la criticidad de su desempeño en la cadena logística del acarreo.

A través de un modelo predictivo basado en datos recolectados durante el año 2024, la presente tesis anticipa los puntos críticos de desgaste para evitar fallas repentinas, reducir el número de cambios no planificados, y optimizar el uso de recursos como mano de obra, repuestos y tiempo operativo. La solución propuesta busca contribuir a la sostenibilidad del sistema de acarreo minero, alineándose con políticas de eficiencia, productividad y gestión basada en datos.

1.6.2. Descripción de la Solución

La solución propuesta consiste en el desarrollo de un modelo predictivo, construido en Microsoft Excel, que empleará datos históricos y variables operacionales claves como presión del neumático, temperatura, velocidad promedio, horas trabajadas y nivel de desgaste diario. Este modelo permitirá estimar de forma anticipada el comportamiento del neumático y predecir su vida útil restante bajo condiciones reales de operación.

Asimismo, se incluirá un análisis correlacional y de regresión que permitirá identificar qué variables influyen más significativamente en el desgaste. Con esta información, se

establecerán rangos críticos de operación y recomendaciones de control, además de una estimación económica del ahorro potencial generado por mejoras en el control operacional. El modelo será validado con datos de campo y se proyectará su aplicabilidad en otras operaciones con condiciones similares.

1.7. Hipótesis

1.7.1. Hipótesis General

La implementación de un modelo predictivo, basado en datos operacionales, permite optimizar los costos y mejorar el desempeño de los neumáticos en camiones mineros en una operación superficial durante el año 2024.

1.7.2. Hipótesis Específicas

- Las variables operacionales como presión, temperatura y horas de operación tienen una correlación significativa con el desgaste de los neumáticos.
- El modelo predictivo estima con alta precisión el desgaste diario de los neumáticos en función de las condiciones operativas.
- La aplicación del modelo predictivo genera un ahorro económico mensurable en comparación con el sistema actual de mantenimiento correctivo o rutinario.

CAPÍTULO II: FUNDAMENTOS TEÓRICOS

2.1. Estado del Arte

2.1.1. Antecedentes Internacionales

Rahimdel (2023) desarrolló un modelo de predicción del desgaste de neumáticos en una operación minera en Australia, empleando algoritmos de *machine learning* (Random Forest y XGBoost). Las variables consideradas fueron presión de inflado, carga útil, velocidad promedio y temperatura ambiente, recopiladas mediante sensores embarcados. El modelo fue entrenado con validación cruzada y selección de características, logrando reducir en un 18 % los cambios prematuros y extender la vida útil operacional. Se establecieron umbrales críticos para el mantenimiento preventivo, lo que permitió una planificación más eficiente.

Kim et al. (2021) implementaron un sistema IoT en una mina de carbón en China para monitorear en tiempo real la presión y temperatura de los neumáticos. Las variables se integraron en un *dashboard* predictivo con alertas automatizadas. Se aplicó análisis de series temporales y regresión logística para anticipar fallas. El sistema mejoró la capacidad de respuesta ante desviaciones operativas y optimizó los costos en un 12 %, evidenciando la utilidad de la conectividad en tiempo real.

Rahimdel (2023) diseñó un modelo de mantenimiento predictivo en una mina de cobre en México, basado en datos históricos de fallas y condiciones operativas. Se aplicó análisis de supervivencia y minería de datos para identificar patrones de desgaste. Las variables clave fueron horas de operación, tipo de terreno y presión de inflado. El modelo permitió reducir el tiempo de inactividad en 21 horas promedio al mes, mejorando la disponibilidad de la flota.

Malinowska et al. (2020) utilizaron análisis multivariable en una operación minera en Alemania para correlacionar variables operacionales con la tasa de desgaste. Se aplicó regresión múltiple y análisis de sensibilidad, considerando presión, carga útil, velocidad y

temperatura. Se identificaron presiones críticas que aceleraban el deterioro, lo que permitió ajustar protocolos de inflado y carga, reduciendo el desgaste prematuro.

Alla et al. (2020) emplearon visión artificial en Japón para analizar deformaciones estructurales en neumáticos de flotas mineras. Se utilizaron redes convolucionales (CNN) para detectar anomalías en imágenes térmicas y visuales. Las variables incluidas fueron deformación lateral, temperatura superficial y patrón de desgaste. El sistema logró una precisión del 90 % en la detección temprana de fallas estructurales, anticipando intervenciones antes de que se generaran incidentes.

2.1.2. Antecedentes Nacionales

Quispe y Rojas (2023) implementaron un sistema automático de control de presión y temperatura en neumáticos en la mina Toquepala. Se monitorearon presión interna, temperatura ambiente y carga transportada. El análisis estadístico incluyó control de calidad y regresión lineal, mostrando una reducción del 30 % en fallas catastróficas durante el primer semestre. El sistema demostró alta efectividad en condiciones de exigencia operativa.

Ramos (2022) evaluó el ciclo de vida de neumáticos en la unidad minera Antamina, relacionándolo con rutas operativas y condiciones de carga. Se aplicó análisis de varianza (ANOVA) y simulación de escenarios. Las variables consideradas fueron distancia recorrida, tipo de ruta, carga útil y presión. Se propusieron ajustes en la distribución de ciclos, logrando extender la durabilidad en un 14 % y optimizar la rotación de flota.

Huamán (2022) realizó un análisis estadístico en Apurímac sobre el rendimiento de neumáticos en camiones CAT 793F. Se aplicó regresión lineal y análisis de correlación, considerando presión de inflado, horas de operación y tipo de terreno. Se concluyó que presiones por debajo de 100 psi reducían significativamente la vida útil, lo que llevó a recomendaciones de calibración periódica y ajustes en los protocolos de mantenimiento.

Vargas y Soto (2021) desarrollaron un sistema predictivo en Las Bambas usando redes neuronales artificiales (ANN) para anticipar la tasa de desgaste. Las variables incluidas fueron velocidad, carga útil, presión y temperatura. El modelo permitió optimizar el mantenimiento preventivo, reduciendo intervenciones no programadas y mejorando la planificación operativa mediante alertas predictivas.

Paredes (2020) aplicó un modelo de regresión múltiple en Cerro Verde para estimar el desgaste según carga útil y temperatura. También se incluyeron velocidad y presión como variables complementarias. El modelo permitió reducir el costo mensual por neumático en un 11 %, evidenciando la utilidad de los modelos estadísticos para la toma de decisiones operativas.

2.1.3. Antecedentes Locales

Mamani y Ticona (2023) desarrollaron un sistema de monitoreo continuo de presión en una operación minera de Moquegua. Se utilizaron sensores conectados a un sistema de alertas tempranas. Las variables monitoreadas fueron presión, temperatura y frecuencia de calibración. El sistema redujo el riesgo de fallas durante el acarreo, mejorando la seguridad operativa y la eficiencia en la gestión de neumáticos.

Nina (2023) aplicó control estadístico de variables operativas en una cantera de Arequipa para identificar tendencias de desgaste acelerado. Se analizaron presión, carga útil, velocidad y tipo de terreno mediante gráficos de control y análisis de tendencia. El estudio permitió rediseñar los ciclos de carga y descarga, reduciendo el desgaste en zonas críticas y mejorando la distribución de esfuerzos.

Flores (2022) implementó una app de inspección diaria en Quellaveco que registraba variables como presión, temperatura, deformación visual y carga. La retroalimentación en tiempo real a los operadores permitió ajustes operativos inmediatos. Se aplicó análisis

descriptivo y control de calidad, reduciendo eventos de desgaste acelerado y mejorando la trazabilidad de decisiones.

Gutiérrez y Salas (2022) probaron sensores conectados a software predictivo en una mina superficial en Tacna. Se monitorearon presión, temperatura y vibración, integrados en un sistema de análisis multivariable. El sistema evitó 7 incidentes de reventón en el segundo semestre, validando el enfoque predictivo en condiciones locales y demostrando su aplicabilidad en operaciones de mediana escala.

Lazo (2021) aplicó un modelo predictivo simple en una unidad minera del sur del Perú, basado en regresión lineal. Se consideraron presión, carga útil y horas de operación. El modelo fue validado con datos de campo, demostrando su utilidad operativa y facilidad de implementación en entornos con recursos limitados, sirviendo como base para futuras mejoras metodológicas.

2.2. Bases Teóricas

Para el desarrollo de la presente investigación se considera un conjunto de fundamentos teóricos que sustentan la comprensión del desgaste de neumáticos en contextos mineros, así como los enfoques predictivos para optimizar su desempeño y reducir costos operativos.

2.2.1. Teoría del Ciclo de Vida del Componente

La gestión del ciclo de vida en activos mineros trasciende el enfoque tradicional de reemplazo por tiempo de uso. En la actualidad, se considera una visión integral que incorpora el diseño de ingeniería, la selección de materiales y las condiciones de operación desde la fase de adquisición. Esta aproximación permite identificar oportunidades de mejora en cada etapa, desde la especificación técnica inicial hasta la disposición final, generando valor agregado para la organización (Shao & Kumral, 2024).

Un aspecto crítico en la teoría del ciclo de vida es la evaluación del desempeño durante la fase de uso, que requiere sistemas de monitoreo continuo para capturar datos en tiempo real.

La información generada por sensores de presión, temperatura y carga útil permite construir curvas de degradación específicas para cada componente. Estos datos, al ser analizados, proporcionan la base para la toma de decisiones estratégicas, como la calibración de frecuencias de mantenimiento o la selección de proveedores basada en desempeño demostrado (Morales Navarro, 2020).

La fase de disposición ha cobrado relevancia en los últimos años debido a la creciente presión regulatoria y social hacia la economía circular. La teoría del ciclo de vida ahora incorpora criterios de reciclabilidad, reutilización y valorización energética como parte del análisis de costo total. En el caso de los neumáticos OTR, programas de recauchutado certificados permiten extender su vida útil hasta en un 30%, reduciendo significativamente la huella ambiental y generando ahorros económicos que justifican inversiones iniciales más altas en neumáticos de mayor calidad (Blanco Hinostrero, 2016).

El ciclo de vida de los neumáticos en minería incluye etapas de adquisición, uso, mantenimiento y disposición. Cada una implica costos y estrategias asociadas. Según Shao y Kumral (2024), gestionar el ciclo de vida permite optimizar la durabilidad, minimizar los costos y reducir las interrupciones operativas. Esta teoría permite analizar los puntos críticos de desgaste e intervención preventiva.

2.2.2. Mantenimiento Predictivo

El mantenimiento predictivo se fundamenta en el principio de que toda falla está precedida por un período de degradación detectable. Esta filosofía contrasta con el mantenimiento preventivo, que opera bajo la premisa de que la falla ocurre al final de un ciclo preestablecido, y con el correctivo, que actúa después del evento. La detección temprana de patrones de desgaste anómalo, mediante análisis de tendencias de variables como temperatura y vibración, permite intervenir en el momento óptimo, maximizando la vida útil y minimizando las interrupciones operativas (Mobley, 2019).

La implementación exitosa del mantenimiento predictivo requiere una infraestructura tecnológica robusta que incluya sensores de campo, sistemas de adquisición de datos y plataformas de análisis. En minería, los equipos están expuestos a condiciones extremas de vibración, polvo y temperatura, lo que exige sensores industrializados con alta confiabilidad. Además, la conectividad en áreas remotas puede representar un desafío, por lo que se utilizan soluciones de comunicación mixtas (radiofrecuencia, LTE, satelital) para garantizar la transmisión continua de datos (Tecnología Minera, s.f.).

El cambio organizacional necesario para adoptar el mantenimiento predictivo es tan importante como la tecnología misma. La transición de un enfoque reactivo a uno proactivo implica capacitar al personal en interpretación de datos, establecer nuevos flujos de trabajo basados en alertas predictivas y redefinir indicadores de desempeño (KPIs). Las organizaciones que han logrado esta transformación reportan no solo reducciones en costos de mantenimiento, sino también mejoras en la moral del personal, al pasar de apagar incendios a gestionar activos de manera inteligente (Santillán, 2024).

Es un enfoque proactivo que utiliza datos y herramientas analíticas para anticipar fallas antes de que ocurran. Según Mobley (2019), el mantenimiento predictivo busca maximizar el tiempo útil de los equipos, reduciendo reparaciones no planificadas. En el caso de neumáticos, sensores de presión, temperatura y carga pueden alimentar algoritmos para anticipar fallas o desgaste anómalo.

2.2.3. Modelado y Aprendizaje Automático (Machine Learning)

El aprendizaje supervisado constituye la categoría de algoritmos más utilizada en la predicción de desgaste de componentes. En este enfoque, se entrena un modelo con un conjunto de datos históricos que incluye tanto las variables de entrada (características operativas) como la salida deseada (desgaste). Una vez entrenado, el modelo puede predecir el desgaste para nuevas condiciones operativas. Algoritmos como regresión lineal, árboles de decisión y redes

neuronales ofrecen diferentes balances entre interpretabilidad y precisión, permitiendo al ingeniero elegir el más adecuado según el contexto (Bishop, 2021).

La selección de características es un paso crítico en la construcción de modelos predictivos efectivos. No todas las variables operativas contribuyen por igual a la predicción del desgaste; algunas pueden ser redundantes, mientras que otras pueden introducir ruido. Técnicas como el análisis de correlación, la importancia de características basada en Random Forest o la eliminación recursiva de características permiten identificar el subconjunto óptimo de variables. Este proceso no solo mejora la precisión del modelo, sino que también reduce los costos de recolección y almacenamiento de datos (Amat Rodrigo, 2017).

El desafío de la generalización es uno de los principales obstáculos en la aplicación de *machine learning* en minería. Un modelo entrenado con datos de una mina específica puede no ser directamente aplicable a otra con diferentes condiciones geológicas, climáticas o equipos. Por ello, se recomienda un enfoque de *transfer learning* (aprendizaje por transferencia), donde un modelo base se ajusta con datos locales para adaptarse a las condiciones específicas. Este enfoque reduce la cantidad de datos históricos necesarios y acelera la implementación en nuevas operaciones (FasterCapital, s.f.).

El uso de modelos estadísticos y algoritmos de aprendizaje automático permite analizar grandes volúmenes de datos operacionales para generar predicciones. Algoritmos como regresión lineal múltiple, Random Forest y XGBoost se han aplicado con éxito en minería para estimar la vida útil de componentes. Según Bishop (2021), los modelos supervisados pueden entrenarse con datos históricos para proyectar el comportamiento de variables clave como el desgaste.

2.2.4. Teoría de Fiabilidad y Análisis de Fallos (RAM Analysis)

El análisis RAM (*Reliability, Availability, Maintainability*) permite evaluar el desempeño de sistemas mineros mediante indicadores cuantificables: (Jardine et al., 2006)

- Confiabilidad (R): probabilidad de que un equipo funcione sin fallas.
- Disponibilidad (A): porcentaje de tiempo en que el equipo está operativo.
- Mantenibilidad (M): facilidad y rapidez con que se puede reparar un equipo.

Aplicado a flotas mineras, el RAM permite identificar “actores críticos” que generan indisponibilidad y orientar recursos hacia su mejora. Impacta directamente en la planificación de mantenimiento, optimizando la frecuencia de intervenciones y reduciendo paradas no programadas (Smith & Hinchcliffe, 2004).

La confiabilidad (R) en el contexto de los neumáticos se mide como la probabilidad de que un neumático cumpla su función de transporte sin fallas durante un período de tiempo especificado bajo condiciones de operación definidas. Al aplicar modelos de distribución de Weibull a los datos históricos de fallas, es posible caracterizar la “infancia” (fallas tempranas por defectos), la “vida útil” (fallas aleatorias) y el “desgaste” (fallas por envejecimiento) del neumático. Esta caracterización permite establecer periodos de garantía y planes de inspección focalizados (Ebeling, 2010).

La disponibilidad (A) es un indicador clave de la productividad de la flota. Un bajo rendimiento en disponibilidad debido a cambios no programados de neumáticos puede generar efectos en cascada en la cadena de acarreo, afectando la alimentación de la planta de procesamiento. El análisis RAM ayuda a cuantificar el impacto de las fallas de neumáticos en la disponibilidad general de los camiones, justificando la inversión en sistemas predictivos al demostrar su contribución directa al cumplimiento de los objetivos de producción (Jardine et al., 2006).

La mantenibilidad (M) se refiere a la facilidad y rapidez para reemplazar un neumático. En minería, esto implica no solo el tiempo de mano de obra, sino la disponibilidad de grúas, herramientas especializadas y personal entrenado. Optimizar la mantenibilidad a través de procedimientos estandarizados, áreas de cambio acondicionadas y disponibilidad de repuestos

es tan importante como predecir la falla. Una falla predictiva es valiosa solo si la intervención correctiva puede ejecutarse de manera eficiente para minimizar el tiempo de inactividad (Smith & Hinchcliffe, 2004).

2.2.5. *Gestión del Costo Total de Propiedad (TCO)*

Esta teoría evalúa todos los costos asociados a un activo desde su adquisición hasta su retiro, incluyendo operación, mantenimiento y disposición. En minería, considerar el TCO de los neumáticos permite evaluar el verdadero impacto financiero de su desempeño. Según Kaplan et al. (2010), este enfoque ayuda a justificar inversiones en tecnologías predictivas y estrategias de gestión basadas en datos.

Estas bases teóricas serán aplicadas para desarrollar un modelo predictivo técnico-económico que permita mejorar la toma de decisiones respecto al uso, mantenimiento y reemplazo de neumáticos en operaciones mineras superficiales.

La estructura de costos en el TCO de un neumático minero va más allá del precio de compra. Incluye costos de almacenamiento (espacio, manejo, seguro), costos de instalación (mano de obra, grúas, herramientas), costos operativos (combustible por resistencia al rodamiento), costos de mantenimiento (reparaciones, inflado) y costos de disposición (transporte, reciclaje). Cada uno de estos componentes puede representar entre un 5% y un 15% del TCO total, por lo que optimizar solo el precio de compra puede resultar en una gestión subóptima (Michelin, s.f.).

El cálculo del TCO por unidad de producción (ej. USD/tonelada-km) es el indicador más relevante para la toma de decisiones. Este indicador normaliza el costo por el servicio efectivamente prestado, permitiendo comparar neumáticos de diferentes precios y durabilidades. Un neumático con un costo unitario superior puede tener un TCO por tonelada-km menor si su durabilidad es significativamente mayor. Este enfoque alinea los intereses de

las áreas de compras y operaciones, promoviendo decisiones basadas en valor y no solo en costo inicial (Kaplan et al., 2010).

La incorporación del riesgo en el análisis TCO representa una evolución metodológica importante. Eventos como fallas catastróficas, paradas no programadas o daños colaterales tienen costos asociados que deben ser considerados. Una forma de incorporar el riesgo es a través del análisis de escenarios, donde se calcula el TCO esperado bajo diferentes supuestos de ocurrencia de fallas. Esto permite a las empresas mineras cuantificar el valor de las tecnologías predictivas que reducen la probabilidad de estos eventos de alto impacto (Shao & Kumral, 2024).

2.2.6. Teoría de Optimización de Procesos Mineros

La optimización matemática aplicada a procesos mineros utiliza modelos que representan las restricciones físicas, operativas y económicas del sistema. En el contexto del acarreo, variables como la asignación de camiones a rutas, la secuenciación de cargas y la programación de mantenimientos pueden ser optimizadas mediante técnicas como programación lineal, algoritmos genéticos o simulación de eventos discretos. Estos modelos permiten encontrar soluciones que maximizan la producción o minimizan los costos dentro de las restricciones operativas (Shao & Kumral, 2024).

La integración de la variable desgaste de neumáticos en los modelos de optimización de acarreo es un avance significativo respecto a enfoques tradicionales que consideraban solo la distancia y la capacidad. Al incorporar el desgaste como una función de la ruta, la carga y la velocidad, es posible asignar los camiones a las rutas que minimicen el costo total, considerando tanto el consumo de combustible como el desgaste de neumáticos. Esta optimización multidimensional puede generar ahorros significativos no capturados por modelos más simples (Pascual et al., 2019).

La optimización en tiempo real es el siguiente nivel de sofisticación, donde los modelos predictivos se integran con sistemas de control y despacho. Si un modelo predictivo anticipa un desgaste acelerado para un camión en particular en una ruta específica, el sistema de despacho puede reasignar dinámicamente ese camión a una ruta menos exigente, programar su ingreso a mantenimiento o ajustar su velocidad. Esta capacidad de adaptación en tiempo real maximiza la vida útil de los componentes sin sacrificar la productividad global (Martins & Tsuzuki, 2017).

La optimización busca mejorar el uso de recursos y maximizar el rendimiento operativo. En minería, aplicar técnicas de optimización permite reducir tiempos muertos, extender la vida útil de los equipos y minimizar desperdicios. Según Shao y Kumral (2024), la integración de sistemas inteligentes en flotas mineras ha demostrado mejoras operativas superiores al 15 % en el ciclo de acarreo.

2.2.7. *Termodinámica Aplicada al Comportamiento del Neumático*

La transferencia de calor en un neumático en rodadura es un fenómeno complejo que incluye conducción (desde la superficie de rodadura hacia el interior), convección (desde la superficie hacia el aire ambiente) y generación interna por histéresis. El balance térmico determina la temperatura de operación estable del neumático. Cuando la generación de calor supera la capacidad de disipación, la temperatura se eleva progresivamente, pudiendo alcanzar niveles críticos. Este equilibrio térmico es sensible a la velocidad, la carga, la presión y la temperatura ambiente (Rahimdel, 2023).

La histéresis del caucho es el mecanismo de generación de calor interno. Cada ciclo de deformación (compresión y expansión) de la banda de rodadura al pasar por el área de contacto genera energía que se disipa en forma de calor. Este proceso es análogo al calentamiento de un clip metálico al doblarlo repetidamente. La magnitud de la histéresis depende de la composición del compuesto de caucho; compuestos con mayor contenido de caucho natural

presentan menor histéresis que aquellos con alto contenido de sintéticos, lo que explica la preferencia por los primeros en aplicaciones de alta exigencia térmica (Thermal Engineering, s.f.).

El modelado térmico de neumáticos permite predecir la temperatura de operación en función de las condiciones de uso. Estos modelos, basados en principios de transferencia de calor y ecuaciones constitutivas del caucho, pueden ser incorporados en sistemas de monitoreo predictivo. Al comparar la temperatura real con la temperatura predicha por el modelo, es posible detectar desviaciones que indican condiciones anómalas, como un neumático con daño interno que genera calor excesivo, o una operación fuera de los parámetros de diseño (García Bescansa, 2020).

La temperatura influye significativamente en el desgaste del caucho. La fricción acumulada durante la operación genera calor, lo cual modifica la elasticidad y resistencia del neumático. Según Rahimdel (2023), temperaturas por encima de 75 °C incrementan exponencialmente el desgaste y reducen su vida útil proyectada. Controlar térmicamente el sistema permite mejorar su desempeño estructural.

2.2.8. Mecánica de Materiales y Fatiga del Caucho

La respuesta viscoelástica del caucho es la propiedad fundamental que determina su comportamiento bajo carga. A diferencia de los materiales elásticos (que responden instantáneamente) o los viscosos (que fluyen), el caucho tiene una respuesta dependiente del tiempo: bajo cargas rápidas (como impactos) se comporta como un sólido elástico, mientras que bajo cargas sostenidas (como la presión de inflado) muestra un comportamiento de fluencia. Esta dualidad hace que el análisis de fatiga en caucho sea complejo, requiriendo modelos constitutivos avanzados como el modelo de Prony o el modelo de Ogden (Callister & Rethwisch, 2018).

El mecanismo de iniciación y propagación de grietas en el caucho sigue una ley de potencia, donde la velocidad de crecimiento de la grieta es proporcional a la energía de fractura liberada elevada a un exponente. Este comportamiento ha sido modelado por teorías como la de Rivlin-Thomas, que relaciona la tasa de crecimiento de grieta con la energía de deformación. En neumáticos, las grietas suelen iniciarse en defectos microscópicos (inclusiones, vacíos) o en regiones de concentración de tensiones, como los bordes de los patrones de la banda de rodadura (Birla Carbon, 2021).

La cristalización inducida por tensión es una propiedad única del caucho natural que le confiere una capacidad de autorrefuerzo excepcional. Cuando el caucho natural se estira, sus cadenas moleculares se alinean y forman cristales que actúan como puntos de refuerzo, aumentando la resistencia al agrietamiento. Este fenómeno explica por qué los neumáticos con alto contenido de caucho natural tienen una resistencia superior a la propagación de grietas en comparación con aquellos basados en caucho sintético. En aplicaciones mineras de alta exigencia, esta propiedad es crítica para la durabilidad (Mark et al., 2013).

Los neumáticos en condiciones mineras están sometidos a cargas cíclicas. La fatiga del caucho ocurre por acumulación de microdaños. Según Callister y Rethwisch (2018), la resistencia del neumático depende de su composición, diseño estructural y condiciones dinámicas de operación. Aplicar criterios de fatiga permite determinar el momento óptimo para el reemplazo antes de que ocurran fallas críticas.

Estas bases teóricas integran un marco sólido para la construcción del modelo predictivo y el análisis técnico-económico de la presente investigación, permitiendo establecer relaciones fundamentadas entre el comportamiento operativo y el desgaste de los neumáticos en contextos mineros.

2.3. Marco Teórico

2.3.1. Ciclo de Vida de los Neumáticos en Minería

El ciclo de vida de los neumáticos utilizados en operaciones mineras comprende cuatro etapas fundamentales: adquisición, uso, mantenimiento y disposición. Cada una de estas fases implica decisiones técnicas y económicas que impactan directamente en la eficiencia operativa y en los TCO de los equipos de acarreo.

- (1) Adquisición

La etapa de adquisición incluye la selección del tipo de neumático adecuado según las condiciones geológicas, climáticas y operativas del yacimiento. Factores como el índice TKPH (toneladas-kilómetro por hora), la resistencia al calor y la capacidad de carga son determinantes en la elección del neumático (Delgado Alemán, 2019). Los costos en esta fase no solo incluyen el precio unitario del neumático, sino también los gastos logísticos, de almacenamiento y de instalación.

- (2) Uso

Durante la operación, los neumáticos están expuestos a condiciones extremas de carga, velocidad, temperatura y abrasión. El rendimiento se mide en horas de vida útil, que puede variar entre 4,000 y 6,600 horas dependiendo del modelo y las prácticas operativas (Morales Navarro, 2020). Un uso inadecuado, como sobrecarga o rutas mal diseñadas, puede reducir significativamente la vida útil y aumentar los costos por reemplazo prematuro.

- (3) Mantenimiento

El mantenimiento incluye inspecciones periódicas, rotación de posiciones, control de presión y reparación de daños menores. La implementación de estrategias de mantenimiento predictivo ha demostrado ser eficaz para extender la vida útil de los neumáticos y reducir fallas inesperadas (Blanco Hinostroza, 2016). Esta etapa también implica costos por mano de obra, herramientas especializadas y tiempo de inactividad del equipo.

- (4) Disposición

Una vez que el neumático ha alcanzado su límite de desgaste o presenta daños irreparables, se procede a su disposición. En algunos casos, pueden ser recauchados o reutilizados en condiciones menos exigentes. La disposición final debe cumplir con normativas ambientales, lo que puede generar costos adicionales por transporte y tratamiento de residuos (Delgado Alemán, 2019).

2.3.2. Impacto del Ciclo de Vida de los Neumáticos en la Planificación Operativa Minera

Comprender el ciclo de vida completo permite a las empresas mineras optimizar la planificación operativa, anticipar necesidades de reemplazo, programar mantenimientos y reducir costos asociados. Además, facilita la toma de decisiones basadas en datos históricos y modelos predictivos, mejorando la confiabilidad de la flota y la eficiencia del proceso de acarreo (Morales Navarro, 2020).

La etapa de adquisición no solo implica la selección técnica del neumático basada en el índice TKPH (Toneladas-Kilómetro por Hora), sino también un análisis profundo de la logística de suministro. En operaciones mineras remotas, los plazos de entrega y la disponibilidad de inventario pueden convertirse en cuellos de botella críticos. Por ello, una gestión eficiente de esta fase debe considerar la estandarización de modelos para simplificar el almacenamiento y reducir los tiempos de inactividad por espera de repuestos (Delgado Alemán, 2019).

Durante la fase de uso, la interacción entre el neumático y el terreno genera patrones de desgaste complejos que no dependen únicamente de la carga y la velocidad. La geometría de las rutas, la distribución granulométrica del material transportado y las prácticas de los operadores (como frenadas bruscas o aceleraciones agresivas) tienen un impacto directo en la tasa de abrasión. Estudios recientes indican que la variabilidad en el comportamiento del operador puede influir en hasta un 15% en la vida útil del neumático (Morales Navarro, 2020).

La disposición final de los neumáticos OTR (Off-The-Road) representa un desafío ambiental significativo debido a su gran volumen y composición. La minería moderna está adoptando estrategias de economía circular, como el recauchutado (renovación de la banda de rodadura) para aplicaciones menos exigentes o el reciclado mecánico para convertirlos en productos como pavimentos de caucho o agregados para la construcción. Estas prácticas no solo mitigan el impacto ambiental, sino que también generan un valor residual que puede ser reintegrado al análisis del costo total de propiedad (Blanco Hinostroza, 2016).

2.3.3. *Mantenimiento Predictivo vs. Preventivo vs. Correctivo*

El mantenimiento en minería se clasifica en tres enfoques principales: predictivo, preventivo y correctivo. Cada uno responde a una estrategia distinta frente al desgaste y fallas de los equipos.

El mantenimiento correctivo, aunque es el enfoque más básico, se aplica tras la ocurrencia de una falla. Aunque es útil en equipos no críticos, genera paradas imprevistas y altos costos operativos (Mantenimiento Eléctrico, 2022). Es decir, encierra un riesgo elevado en minería. Una falla catastrófica de un neumático, como un reventón, no solo detiene la producción del equipo, sino que puede causar daños colaterales en suspensión, frenos y carrocería, además de poner en riesgo la seguridad del personal. Este tipo de eventos genera costos ocultos que superan con creces el valor del neumático, justificando la transición hacia estrategias más avanzadas (Mobley, 2019).

El mantenimiento preventivo se sustenta en inspecciones periódicas y reemplazos programados (ej. cambio cada 5,000 horas), de acuerdo con criterios de vida útil o ciclos de operación. Su objetivo es evitar fallas antes de que ocurran (Santillán, 2024). Sin embargo, puede resultar ineficiente si no considera las condiciones reales de desgaste. En minería, la variabilidad climática y de carga puede hacer que un neumático alcance su límite de vida útil antes del plazo programado o, por el contrario, que sea retirado prematuramente,

desperdiciando su capacidad remanente. Esta ineficiencia subraya la necesidad de monitorear el estado real en lugar de confiar únicamente en promedios históricos (Santillán, 2024).

El mantenimiento predictivo utiliza sensores, análisis de datos y algoritmos para anticipar fallas antes de que se manifiesten. Se basa en el estado real del equipo, no en estimaciones (Tecnología Minera, s.f.). Al analizar tendencias de presión y temperatura, es posible identificar patrones de falla incipiente, como una presión que baja sistemáticamente (indicando una fuga lenta) o un aumento de temperatura anormal (señal de fricción excesiva interna). La implementación de este enfoque ha demostrado reducir los costos de mantenimiento en un 30% y aumentar la disponibilidad de la flota en un 25% en operaciones líderes como Rio Tinto (Tecnología Minera, s.f.).

Del mismo modo, las ventajas del mantenimiento predictivo son:

- Reducción de paradas no programadas.
- Optimización del uso de repuestos y mano de obra.
- Mayor vida útil de los equipos.
- Mejora en la seguridad operativa.

Además, existen los siguientes casos de éxito:

- Codelco (Chile): Reducción del 15% en paradas no planificadas.
- Rio Tinto (Australia): Disminución de costos de mantenimiento en 30%.
- Vale (Brasil): Reducción del 25% en tiempos de inactividad.

2.3.4. Modelos Predictivos en Ingeniería Minera

La regresión lineal múltiple, utilizada en este estudio, es una herramienta fundamental para la interpretabilidad de los fenómenos físicos. Su fortaleza radica en la capacidad de cuantificar el peso específico de cada variable independiente (presión, temperatura, etc.) sobre el desgaste, permitiendo a los ingenieros de mantenimiento entender el “porqué” detrás de la predicción. Sin embargo, su limitación frente a relaciones no lineales puede requerir

transformaciones de variables para capturar interacciones complejas, como el efecto sinérgico de la alta temperatura con la baja presión (FasterCapital, s.f.).

Los algoritmos de Machine Learning, como Random Forest y XGBoost, ofrecen una alternativa más robusta para manejar grandes volúmenes de datos con relaciones no lineales. Random Forest, por ejemplo, es particularmente útil para identificar la importancia de las características (feature importance), revelando cuáles de las variables operativas son los predictores más dominantes sin necesidad de asumir una distribución lineal. Esto permite a las operaciones mineras enfocar sus esfuerzos de control en los factores más influyentes (Amat Rodrigo, 2017).

La validación de modelos es un paso crítico para garantizar su aplicabilidad en el mundo real. Técnicas como la validación cruzada (cross-validation) aseguran que el modelo no esté sobreajustado a los datos históricos y que pueda generalizar a nuevas condiciones operativas. En el contexto minero, donde las condiciones pueden cambiar drásticamente al pasar de una zona de mineral a una zona de desmonte, la capacidad de generalización del modelo es determinante para su confiabilidad y éxito a largo plazo (Amat Rodrigo, 2017).

En resumen, los modelos predictivos permiten anticipar el desgaste de componentes como neumáticos, optimizando decisiones operativas.

- Regresión Lineal Múltiple

Es una técnica estadística que modela la relación entre una variable dependiente (por ejemplo, horas de vida útil) y múltiples variables independientes (presión, temperatura, carga útil). Su simplicidad permite interpretaciones claras, aunque puede ser limitada ante relaciones no lineales (FasterCapital, s.f.).

- Algoritmos de Machine Learning

- Random Forest: Conjunto de árboles de decisión que votan en conjunto. Robusto ante ruido y útil para identificar variables importantes (Amat Rodrigo, 2017).

- XGBoost: Algoritmo de boosting que corrige errores de modelos anteriores.
Altamente preciso y eficiente en datos tabulares.
- Validación de Modelos

Se realiza mediante técnicas como:

- Cross-validation: Divide el dataset en partes para evaluar la generalización.
- Out-of-Bag Error: Estimación del error sin necesidad de validación cruzada (Amat Rodrigo, 2017).

2.3.5. Factores Operacionales que Afectan el Desgaste

La presión de inflado es un factor dual: una presión baja provoca un aumento en la superficie de contacto, generando calor excesivo por flexión en los hombros del neumático y acelerando el desgaste en los bordes. Por el contrario, una presión excesiva reduce la huella de contacto, concentrando la carga en el centro de la banda de rodadura, lo que provoca un desgaste central rápido y una mayor susceptibilidad a pinchazos por impacto. Mantener la presión dentro de un rango estrecho es, por tanto, la medida de control más efectiva (Autodoc, 2025).

La temperatura de operación es un factor limitante clave. Los compuestos de caucho experimentan degradación termo-oxidativa cuando se exponen a altas temperaturas de manera sostenida. Este proceso químico endurece el caucho, reduciendo su elasticidad y haciéndolo más propenso a la formación de grietas y separación de capas. Un aumento de 10°C por encima del umbral crítico puede reducir la vida útil del neumático hasta en un 20% (García Bescansa, 2020).

La interacción entre velocidad y carga útil es particularmente crítica en rampas de ascenso. En estas condiciones, el neumático está sometido al máximo esfuerzo de tracción y torque, generando un calor intenso en la carcasa. La combinación de alta carga útil (TKPH elevado) y baja velocidad de ascenso puede resultar en una acumulación de calor que supera la

capacidad de disipación térmica del neumático, llevándolo a fallas por fatiga térmica en menos tiempo del previsto (Pascual et al., 2019).

En resumen, el desgaste de neumáticos en minería está influenciado por múltiples variables: (Pascual et al., 2019)

- Presión: Baja presión genera desgaste en los bordes; alta presión reduce superficie de contacto.
- Temperatura: Aumenta por fricción y velocidad, afectando la estructura del caucho.
- Velocidad y carga útil: Elevan la fricción y el calor, acelerando el deterioro.
- Horas operadas: Relacionadas directamente con la fatiga del material.

Finalmente, diversos estudios de correlación y regresión identifican qué variables tienen mayor impacto. Por ejemplo, García Bescansa (2020) demostró que la temperatura y velocidad son los factores más críticos en el desgaste de neumáticos.

2.3.6. Termodinámica Aplicada al Comportamiento del Neumático

La **generación de calor por histéresis** es el principio termodinámico fundamental que explica el desgaste interno. Cada vez que el neumático rueda, la deformación cíclica de la banda de rodadura y la carcasa genera calor debido a la fricción interna de las moléculas de caucho. Este calor, si no se disipa eficientemente, se acumula, elevando la temperatura central del neumático (Temperatura de la Carcasa). Este fenómeno es análogo a doblar repetidamente un clip de metal hasta que se calienta y se rompe (Thermal Engineering, s.f.).

El **umbral crítico de temperatura** marca la línea entre el desgaste normal y la falla inminente. Cuando la temperatura de la carcasa supera los 85°C, el caucho puede comenzar a sufrir un proceso de vulcanización inversa (reversión), perdiendo sus propiedades mecánicas. Este estado debilita la unión entre las capas de acero y caucho, lo que puede derivar en

separaciones internas y, eventualmente, en fallas explosivas. Los sistemas de monitoreo en tiempo real son esenciales para evitar alcanzar estos umbrales (Thermal Engineering, s.f.).

El **control térmico** activo es una estrategia de optimización que va más allá del simple monitoreo. En operaciones mineras, esto puede implicar la gestión de la velocidad en rampas críticas, la programación de descansos para permitir la disipación del calor en zonas de alta exigencia, o incluso la selección de compuestos de caucho con menor histéresis. Innovaciones como los compuestos con sílice Agilon reducen la resistencia al rodamiento y, por ende, la generación de calor, contribuyendo a una mayor vida útil (Rahimdel, 2023).

La termodinámica explica cómo el calor y la fricción afectan el rendimiento de los neumáticos.

- Efecto del Calor y Fricción
 - El calor generado por la fricción incrementa la presión interna del neumático.
 - El caucho pierde rigidez a altas temperaturas, lo que provoca deformaciones y desgaste acelerado (Thermal Engineering, s.f.).
 - Umbrales Críticos de Temperatura
 - Superar los 80 °C puede comprometer la estructura interna del neumático.
 - La expansión térmica puede alterar la presión hasta en un 15% si no se controla adecuadamente.
- Control Térmico
 - Uso de sensores para monitorear temperatura en tiempo real.
 - Diseño de rutas operativas que minimicen fricción.
 - Selección de compuestos resistentes al calor, como sílice Agilon.

2.3.7. *Fatiga de Materiales y Mecánica del Caucho*

La fatiga mecánica en el caucho no sigue las mismas leyes lineales que en los metales. El proceso de iniciación de grietas ocurre en microdefectos o inclusiones dentro del compuesto.

Bajo cargas cíclicas, estas microgrietas crecen de manera estable hasta alcanzar un tamaño crítico donde la propagación se acelera, llevando a la falla. La capacidad del caucho de cristalizarse bajo tensión (caucho natural) le otorga una resistencia superior al agrietamiento en comparación con los cauchos sintéticos, lo que explica la preferencia por altos contenidos de caucho natural en neumáticos OTR (Birla Carbon, 2021).

El diseño estructural del neumático es un factor determinante en su resistencia a la fatiga. Las capas de refuerzo (carcasa y cinturones) están dispuestas en ángulos específicos para distribuir las tensiones de manera uniforme y minimizar la deformación localizada. La calidad de la unión entre los compuestos de caucho y los refuerzos de acero o textil es crítica; una desadherencia (separación de capas) es uno de los modos de falla más comunes y peligrosos, ya que progresa internamente sin señales externas evidentes (Mark et al., 2013).

Los criterios para el reemplazo basados en la fatiga requieren técnicas de inspección no destructivas. Si bien la profundidad de la banda de rodadura es un indicador visible, no revela el estado de la carcasa. El uso de termografía para detectar puntos calientes internos, análisis de vibraciones para identificar desbalances inducidos por deformaciones estructurales, y pruebas de ultrasonido para encontrar desadherencias son herramientas avanzadas que permiten decidir el momento óptimo para el retiro, maximizando la vida útil sin comprometer la seguridad (Callister & Rethwisch, 2018).

La fatiga mecánica en componentes de caucho, como los neumáticos OTR (Off-The-Road), se manifiesta por microdaños acumulativos generados por ciclos repetitivos de carga y descarga. Estos microdaños se inician en zonas de inhomogeneidad del compuesto y evolucionan hacia grietas internas que comprometen la integridad estructural (Birla Carbon, 2021).

El diseño estructural del neumático considera capas de refuerzo, compuestos de caucho natural y sintético, y geometrías que distribuyen tensiones. La selección de materiales influye

directamente en la resistencia al agrietamiento y en la capacidad de autorrefuerzo por cristalización inducida (Mark et al., 2013).

Los criterios para reemplazo incluyen:

- Profundidad de banda de rodamiento.
- Presencia de grietas internas detectadas por ultrasonido.
- Umbrales de temperatura y presión excedidos.

2.3.8. Aplicación del Análisis RAM en la Gestión de Neumáticos Mineros

El análisis RAM constituye una herramienta de gran utilidad para la gestión de activos en operaciones mineras, debido a que permite evaluar el impacto de las fallas sobre la continuidad operativa y la productividad de los equipos. En flotas de acarreo, los neumáticos representan uno de los componentes más críticos por su influencia directa en la disponibilidad de los camiones y en los costos de mantenimiento. La aplicación de indicadores RAM facilita la identificación de condiciones que pueden afectar el desempeño de los neumáticos, permitiendo priorizar acciones orientadas a mejorar la confiabilidad operacional y reducir pérdidas asociadas a detenciones no programadas (Jardine et al., 2006).

En el contexto de la minería superficial, las fallas relacionadas con neumáticos pueden generar retrasos en el ciclo de acarreo, disminución de la productividad y mayores requerimientos de recursos para mantenimiento. Por ello, el análisis de confiabilidad resulta relevante para comprender el comportamiento del desgaste bajo diferentes condiciones de operación, mientras que la disponibilidad permite cuantificar el efecto de dichas fallas sobre el rendimiento global de la flota. Asimismo, la mantenibilidad adquiere importancia al evaluar la eficiencia de los procedimientos de reemplazo, inspección y reparación de neumáticos dentro de la operación minera (Smith & Hinchcliffe, 2004).

La incorporación de modelos predictivos en la gestión de neumáticos complementa el enfoque RAM al proporcionar información anticipada sobre posibles escenarios de desgaste y falla. Esta integración permite planificar intervenciones de mantenimiento con mayor precisión, optimizar la asignación de recursos y reducir el riesgo de eventos que afecten la continuidad de las operaciones. De esta manera, el análisis RAM no solo contribuye a mejorar la disponibilidad de los equipos de acarreo, sino también a fortalecer la toma de decisiones basada en datos para la optimización de costos y el incremento de la eficiencia operativa (Ebeling, 2010).

Desde una perspectiva de gestión, la aplicación de criterios RAM permite establecer estrategias orientadas a maximizar el aprovechamiento de los neumáticos durante su vida útil, reduciendo tanto los costos derivados de reemplazos prematuros como las pérdidas asociadas a tiempos de inactividad. En consecuencia, su utilización constituye un soporte técnico para la implementación de programas de mantenimiento predictivo y para el desarrollo de modelos de gestión enfocados en la mejora continua de las operaciones mineras (Jardine et al., 2006).

2.3.9. Gestión del Costo Total de Propiedad (TCO)

El **TCO (Total Cost of Ownership)** va más allá del precio de compra para incluir costos de almacenaje, instalación, monitoreo, reparaciones y disposición final. Una trampa común en la gestión minera es optar por el neumático con menor precio unitario sin considerar su rendimiento esperado en horas o toneladas acarreadas. Un neumático más costoso pero con un desgaste por tonelada-km un 15% menor resulta, a largo plazo, más rentable, lo que justifica la implementación de un análisis de TCO detallado (Kaplan et al., 2010).

La **justificación de inversiones en tecnología predictiva** encuentra en el TCO su principal argumento financiero. La adquisición de sensores IoT, software de análisis y capacitación especializada representa una inversión inicial (CAPEX) que debe ser evaluada en función de la reducción del gasto operativo (OPEX) en neumáticos. Estudios de caso

demuestran que el retorno de la inversión (ROI) para este tipo de tecnologías suele ser inferior a los 12 meses, gracias a la extensión de la vida útil y la reducción de fallas catastróficas (Michelin, s.f.).

La **comparación de modelos de gestión** bajo el enfoque TCO permite a las empresas mineras pasar de una gestión reactiva de costos a una gestión proactiva de valor. Al considerar el TCO, se puede evaluar la conveniencia de contratar servicios de gestión de neumáticos por parte del fabricante (TMS - Tire Management Services), donde el proveedor se responsabiliza del rendimiento a cambio de un costo por hora o por tonelada, transfiriendo el riesgo de desempeño y liberando recursos internos para otras áreas críticas.

El TCO evalúa todos los costos asociados al ciclo de vida del neumático:

- Adquisición.
- Mantenimiento.
- Reemplazo.
- Disposición final.

Justifica inversiones en tecnología predictiva al demostrar ahorros por reducción de fallas y optimización de recursos (Michelin, s.f.). Comparar modelos de gestión permite elegir entre estrategias correctivas, preventivas o predictivas según el contexto operativo.

2.3.10. Optimización de Procesos Mineros

La **simulación de rutas críticas** es una herramienta de optimización que utiliza modelos predictivos de desgaste para modificar la operación. Si el modelo indica que ciertos sectores de la mina (por ejemplo, rampas con material abrasivo) generan un desgaste acelerado, se pueden diseñar estrategias de mitigación como la rotación de neumáticos, el uso de modelos más resistentes en esas zonas específicas o la mejora del mantenimiento de las vías (ripiado y conformado) para reducir la abrasión (Pascual et al., 2019).

La **reducción de tiempos muertos** es el objetivo final de la optimización. Los modelos predictivos permiten programar los cambios de neumáticos durante los mantenimientos programados de los camiones (ej. cambios de aceite, inspecciones de frenos), evitando paradas adicionales. Esta sincronización del mantenimiento (maintenance bundling) maximiza la utilización del equipo, aumentando las horas efectivas de producción y reduciendo el tiempo total de inactividad de la flota (Shao & Kumral, 2024).

La **integración de modelos predictivos en la cadena logística** permite una optimización holística. Si se anticipa que un camión necesitará un cambio de neumático en las próximas horas, el sistema de despacho puede evitar asignarle rutas de alta exigencia, priorizar su ingreso al taller o programar su última ruta cerca del área de mantenimiento. Este nivel de coordinación, impulsado por datos, reduce el riesgo de fallas en campo y mejora la eficiencia del acarreo (Martins & Tsuzuki, 2017).

La eficiencia operativa se mejora mediante:

- Modelos de simulación de rutas críticas.
- Reducción de tiempos muertos en acarreo y carga (Pascual et al., 2019).
- Integración de modelos predictivos en la cadena logística para anticipar cuellos de botella.

El uso de machine learning permite estimar tiempos de ciclo y ajustar operaciones en tiempo real (Martins & Tsuzuki, 2017).

2.3.11. Sistemas de Monitoreo en Tiempo Real (IoT)

La **arquitectura de los sistemas IoT** en flotas mineras consta de sensores embarcados (TPMS - Tire Pressure Monitoring Systems) que miden presión y temperatura internas cada pocos segundos, un sistema de comunicación (Wi-Fi, LTE, o radiofrecuencia) que transmite los datos a una unidad central a bordo del camión, y una plataforma en la nube que procesa y

visualiza la información. La robustez de estos sistemas es crítica para soportar las condiciones extremas de vibración, polvo y temperatura en el ambiente minero (Zhang et al., 2022).

Los **beneficios clave** del monitoreo continuo se extienden más allá del mantenimiento predictivo. La capacidad de generar alertas automáticas en la cabina del operador (por ejemplo, “presión baja en la rueda delantera izquierda”) permite una corrección inmediata, evitando que una condición marginal se convierta en una falla. Además, el historial de datos recopilados crea un activo valioso para la investigación de fallas y la mejora continua de los procesos operativos y de mantenimiento (Zhang et al., 2022).

La **integración con la electricidad 4.0** y la automatización inteligente representa el siguiente paso en la evolución del monitoreo. En flotas de camiones autónomos o teleoperados, el monitoreo en tiempo real de los neumáticos es indispensable para la operación segura sin presencia humana. Los sistemas pueden interactuar con el sistema de control del camión para reducir la velocidad o detener el equipo automáticamente si se detecta un riesgo inminente, como una temperatura crítica o una pérdida abrupta de presión.

La incorporación de sensores IoT en minería permite una supervisión continua de variables críticas como presión, temperatura y desgaste de neumáticos. Estos dispositivos recopilan datos en tiempo real que se integran con hojas de cálculo, dashboards y software de análisis predictivo, generando alertas automáticas ante desviaciones operativas (Zhang et al., 2022).

- **Beneficios Clave**
 - **Mantenimiento predictivo:** Anticipa fallas antes de que ocurran, reduciendo paradas no programadas.
 - **Reducción de costos operativos:** Optimiza el uso de repuestos y mano de obra.
 - **Mejora en seguridad y eficiencia energética:** Evita condiciones peligrosas y optimiza el consumo de recursos.

Además, tecnologías como la electricidad 4.0 y la automatización inteligente permiten controlar procesos en tiempo real, como ventilación automática o cintas transportadoras inteligentes, reduciendo el consumo energético y las emisiones de CO₂.

2.3.12. Visión Artificial y Detección de Fallas

La **aplicación de redes convolucionales (CNN)** en la detección de fallas de neumáticos ha revolucionado las inspecciones visuales. Estas redes se entrenan con miles de imágenes de neumáticos en diferentes estados de desgaste, aprendiendo a identificar patrones de grietas, cortes, deformaciones y desgaste irregular con una precisión superior a la inspección humana. Esta tecnología reduce la subjetividad y el tiempo de inspección, permitiendo evaluar toda la flota diariamente con drones o cámaras fijas (Lin, 2023).

La **inspección con drones y cámaras IP** mejora la seguridad operativa al eliminar la necesidad de que el personal se acerque a equipos en movimiento o en zonas de alto riesgo. Drones equipados con cámaras termográficas pueden realizar inspecciones térmicas durante la operación del camión, detectando puntos calientes anómalos que indican separación de capas o desgaste interno antes de que sean visibles en la superficie. Esto permite una intervención temprana y segura (Lin, 2023).

La **trazabilidad y registro histórico** que ofrecen los sistemas de visión artificial son invaluable para el análisis de causa raíz. Cada inspección genera un registro digital con fotos y métricas de desgaste que pueden correlacionarse con los datos operativos del camión. Este nivel de detalle permite identificar, por ejemplo, que cierto tipo de desgaste irregular en una rueda específica está asociado a un problema de alineación de la suspensión, facilitando una corrección precisa y evitando la recurrencia de fallas.

La visión artificial utiliza algoritmos de procesamiento de imágenes para detectar deformaciones, grietas y desgaste en neumáticos sin intervención humana. Equipos como

drones, cámaras IP y sistemas de escaneo 3D permiten inspecciones más rápidas, seguras y precisas (Lin, 2023).

- Aplicaciones Relevantes
 - Codelco (Chile): Implementación de visión artificial para monitorear revestimientos de molinos SAG.
 - Anglo American (Sudáfrica): Uso de IA para detectar anomalías en componentes críticos.

Estas tecnologías reducen riesgos laborales, mejoran la trazabilidad de fallas y permiten una respuesta inmediata ante condiciones adversas.

2.3.13. Impacto Económico de la Optimización Predictiva

La reducción de fallas inesperadas tiene un impacto directo en la productividad de la mina. Cada hora que un camión de 300 toneladas está parado por un reventón representa pérdidas de producción que pueden ascender a miles de dólares. Al evitar estos eventos, el modelo predictivo contribuye directamente a la meta de producción diaria. El análisis económico debe cuantificar estas pérdidas evitadas como un beneficio tangible del modelo (Caterpillar, 2024).

El menor gasto en repuestos y mano de obra se materializa al reemplazar el mantenimiento preventivo basado en horas por el predictivo basado en condición. Esto evita cambios innecesarios de neumáticos que aún tenían vida útil remanente y reduce el consumo de insumos como válvulas, sellos y herramientas de montaje. La optimización de la programación del taller también maximiza la eficiencia de la mano de obra especializada, reduciendo las horas extras y los costos de contratación de personal eventual (Jardine et al., 2006).

El retorno sobre la inversión (ROI) de la implementación de un modelo predictivo es un indicador clave para la toma de decisiones gerenciales. Al considerar el ahorro por reducción

de desgaste, la disminución de paradas no programadas y la extensión de la vida útil, el ROI suele ser altamente positivo. Estudios de la industria sugieren que la inversión en tecnologías de mantenimiento predictivo puede recuperarse en un período de entre 6 y 18 meses, consolidándose como una estrategia financieramente sólida.

La aplicación de modelos predictivos en minería genera beneficios económicos tangibles:

- Reducción de fallas inesperadas: Menos interrupciones en la producción.
- Menor gasto en repuestos y mano de obra: Intervenciones más precisas.
- Disminución de tiempos de inactividad: Mayor disponibilidad de equipos (Jardine et al., 2006).

De acuerdo con Caterpillar (2024), el mantenimiento predictivo puede reducir los costos operativos hasta en un 30% y extender la vida útil de componentes clave en más del 20%. Esto se traduce en una mejora directa del retorno sobre la inversión (ROI) y en una planificación financiera más eficiente.

2.3.14. Sostenibilidad y Gestión Basada en Datos

La minería inteligente utiliza la gestión basada en datos para alinear la productividad con la sostenibilidad ambiental. La optimización del desgaste de neumáticos contribuye directamente a la reducción de la huella de carbono, ya que una mayor vida útil del neumático significa menos neumáticos producidos, transportados y dispuestos como residuo. Además, la reducción de la resistencia al rodamiento (optimizando presión) disminuye el consumo de combustible de los camiones, reduciendo las emisiones de gases de efecto invernadero.

La electrificación de flotas es una tendencia que redefine la interacción con los neumáticos. Los camiones eléctricos tienen diferentes curvas de torque y peso, lo que genera nuevos patrones de desgaste. Los modelos predictivos basados en datos serán esenciales para adaptar la selección y gestión de neumáticos a estas nuevas tecnologías, maximizando su

eficiencia y vida útil. La sinergia entre la digitalización y la electrificación es clave para una minería sostenible.

La eficiencia hídrica y rehabilitación de ecosistemas también se benefician indirectamente de una gestión predictiva de neumáticos. Al reducir las fallas catastróficas, se disminuye el riesgo de derrames de combustibles y lubricantes que podrían contaminar suelos y aguas. Asimismo, al extender la vida útil de los componentes, se reduce la presión sobre los recursos naturales utilizados en la fabricación de nuevos neumáticos, contribuyendo a una operación más circular y responsable con el entorno.

La minería inteligente se apoya en la digitalización para reducir el impacto ambiental y optimizar el uso de recursos. El uso de sensores, big data e inteligencia artificial permite operar con menos agua, energía y emisiones, alineándose con los objetivos del Acuerdo de París.

- Estrategias Sostenibles
 - Electrificación de flotas: Reemplazo de maquinaria diésel por vehículos eléctricos.
 - Eficiencia hídrica: Sistemas de circuito cerrado para reutilización de agua.
 - Rehabilitación de ecosistemas: Programas de reforestación y restauración de áreas afectadas.

Empresas como Schneider Electric y ABB promueven soluciones integradas que combinan automatización, gestión energética y control remoto, contribuyendo a una minería más segura, eficiente y sostenible³.

2.3.15. Análisis de Fallas y Modos de Falla (FMEA)

La identificación de modos de falla en el FMEA para neumáticos OTR requiere un conocimiento profundo de la física de la falla. No basta con decir “reventón”; se debe especificar si fue por separación de capas, pinchazo por impacto, o por fatiga térmica. Cada modo tiene una causa raíz distinta (ej. baja presión vs. velocidad excesiva) y, por lo tanto,

requiere una acción preventiva diferente. Un FMEA bien estructurado es la base de cualquier programa de mantenimiento predictivo exitoso (Automotive Industry Action Group, 2019).

La evaluación de riesgo mediante el RPN (Número de Prioridad de Riesgo) permite priorizar los esfuerzos de mejora. Un modo de falla con alta ocurrencia, pero baja severidad (ej. desgaste rápido de la banda) puede tener un RPN moderado, mientras que uno con baja ocurrencia, pero severidad catastrófica (ej. reventón con pérdida de control del vehículo) tendrá un RPN alto. Esto ayuda a focalizar los recursos de ingeniería en prevenir los eventos más críticos para la seguridad y la operación (Valera, s.f.).

La aplicación en minería del FMEA se extiende desde el diseño de la ruta hasta la capacitación del operador. Si el FMEA identifica que el modo de falla principal es “pinchazo por material punzocortante” en una zona específica, las acciones pueden incluir el rípiado de la ruta, el uso de neumáticos con mayor resistencia al corte, o la instalación de protectores de flanco. De esta manera, el FMEA actúa como un puente entre el análisis predictivo y las acciones de mitigación en el campo (Valera, s.f.).

El FMEA, es una metodología sistemática utilizada para identificar, evaluar y priorizar fallas potenciales en sistemas, productos o procesos. En el contexto minero, se aplica para detectar fallas recurrentes en neumáticos OTR (Off-The-Road), que pueden comprometer la seguridad y eficiencia operativa.

- Identificación de Modos de Falla

Los modos de falla en neumáticos mineros incluyen:

- Separación de capas internas.
- Grietas por fatiga térmica.
- Desgaste irregular por presión inadecuada.
- Pinchazos por objetos cortantes en la ruta.

Cada modo se describe en función de su causa raíz, mecanismo de falla y efecto sobre el sistema (Automotive Industry Action Group, 2019).

- Evaluación: Severidad, Ocurrencia y Detección

El FMEA utiliza tres criterios para calcular el Número de Prioridad de Riesgo (RPN):

Tabla 1

Criterios de evaluación del análisis FMEA

Criterio	Definición	Escala (1–10)
Severidad	Impacto del fallo sobre la operación o seguridad.	1 = insignificante, 10 = catastrófico
Ocurrencia	Probabilidad de que el fallo ocurra.	1 = muy improbable, 10 = muy probable
Detección	Probabilidad de que el fallo sea detectado antes de causar daño.	1 = muy detectable, 10 = indetectable

Nota. Elaboración propia.

El RPN se calcula como: $RPN = Severidad \times Ocurrencia \times Detección$ Los modos con mayor RPN se priorizan para acciones preventivas (Valera, s.f.).

- Aplicación en Minería

El FMEA permite:

- Identificar neumáticos con mayor riesgo operativo.
- Rediseñar rutas o prácticas de carga para minimizar fallas.
- Implementar controles como sensores de presión y temperatura.
- Establecer protocolos de inspección más rigurosos.

Su uso mejora la confiabilidad del sistema y reduce costos por fallas inesperadas.

2.3.16. Minería de Datos en Ingeniería Predictiva

La minería de datos es el proceso de extraer patrones útiles desde grandes volúmenes de datos. En ingeniería predictiva, se utiliza para anticipar fallas, optimizar mantenimiento y mejorar la toma de decisiones.

- Técnicas de Limpieza, Transformación y Análisis

Antes del análisis, los datos deben ser:

- Limpios: eliminación de valores nulos, duplicados y errores.
 - Transformados: normalización, codificación de variables, conversión de fechas.
 - Analizados: mediante estadística descriptiva, correlaciones y modelos predictivos (Microsoft, s.f.).
- Aplicación en Mantenimiento

La minería de datos permite:

- Detectar patrones de desgaste según condiciones operativas.
- Predecir fallas por sobrecarga, temperatura o presión.
- Generar alertas automáticas para mantenimiento preventivo.

Por ejemplo, al analizar registros de presión y temperatura, se puede anticipar el momento óptimo para reemplazar un neumático antes de que falle.

- Herramientas
 - Excel: útil para análisis exploratorio, gráficos y modelos simples.
 - Power BI: permite crear dashboards interactivos con filtros y KPIs.
 - Python: ideal para automatizar limpieza, aplicar algoritmos y generar modelos avanzados.

Un proyecto típico incluye:

- Automatización de carga de archivos Excel con glob.
- Limpieza con pandas, re y unidecode.
- Consolidación y exportación a Power BI para visualización (Agaviria-analytics, 2025).

2.4. Glosario de Términos

- Análisis RAM (Reliability, Availability, Maintainability): Método de evaluación del desempeño de sistemas mediante tres indicadores clave: confiabilidad,

disponibilidad y mantenibilidad. Se utiliza para optimizar la gestión de activos en minería.

- Ciclo de Vida del Neumático: Conjunto de etapas que atraviesa un neumático desde su adquisición hasta su disposición final, incluyendo uso y mantenimiento. Es fundamental para calcular el costo total de propiedad (TCO).
- Costo Total de Propiedad (TCO): Indicador financiero que considera todos los costos asociados al ciclo de vida de un activo, incluyendo compra, operación, mantenimiento y disposición.
- FMEA (Failure Mode and Effects Analysis): Metodología sistemática para identificar modos de falla, evaluar su impacto y priorizar acciones preventivas. Utiliza el número de prioridad de riesgo (RPN) como criterio de decisión.
- IoT (Internet of Things): Red de dispositivos interconectados que recopilan y transmiten datos en tiempo real. En minería, se aplica para monitorear variables como presión, temperatura y desgaste de neumáticos.
- Machine Learning: Rama de la inteligencia artificial que permite a los sistemas aprender patrones a partir de datos. Se utiliza para construir modelos predictivos de desgaste y fallas.
- Mantenimiento Correctivo: Intervención realizada después de que ocurre una falla. Suele implicar costos elevados por paradas no programadas.
- Mantenimiento Predictivo: Estrategia basada en el monitoreo de condiciones reales del equipo para anticipar fallas. Permite optimizar recursos y reducir tiempos de inactividad.
- Mantenimiento Preventivo: Acciones programadas para evitar fallas, basadas en ciclos de operación o tiempo. Aunque reduce riesgos, puede generar intervenciones innecesarias si no se ajusta al estado real del equipo.

- Minería de Datos: Proceso de extracción de patrones útiles desde grandes volúmenes de datos. En ingeniería predictiva, se aplica para identificar correlaciones entre variables operativas y desgaste.
- Neumático OTR (Off-The-Road): Tipo de neumático diseñado para vehículos pesados que operan fuera de carretera, como camiones mineros. Está expuesto a condiciones extremas de carga, temperatura y abrasión.
- Regresión Lineal Múltiple: Modelo estadístico que relaciona una variable dependiente con varias independientes. Se utiliza para predecir el desgaste de neumáticos en función de factores operativos.
- Sensores Inteligentes: Dispositivos que miden variables físicas como presión, temperatura y vibración, enviando datos en tiempo real para análisis predictivo.
- Sistema de Visión Artificial: Tecnología que utiliza cámaras y algoritmos para detectar fallas visuales en componentes sin intervención humana. Mejora la precisión y seguridad en inspecciones.
- Termodinámica del Caucho: Estudio del comportamiento del caucho frente a variaciones de temperatura y fricción. Es clave para entender el desgaste térmico de neumáticos en minería.

CAPÍTULO III:

MARCO METODOLÓGICO

3.1. Alcances y Limitaciones

3.1.1. Alcance

La presente investigación se desarrolló en una mina superficial peruana durante el año 2024, enfocándose en el análisis del desgaste y optimización de costos de neumáticos utilizados en camiones mineros de gran tonelaje. Se aplicó un modelo predictivo basado en información registrada en hojas de cálculo, particularmente en variables como presión de neumáticos, temperatura, horas operadas, velocidad promedio y desgaste diario.

El estudio considera neumáticos tipo OTR (Off-The-Road), específicamente modelos:

- Michelin XDR3
- Goodyear RM4B+
- Bridgestone VRLS

Los neumáticos analizados corresponden a medidas estándar utilizadas en camiones de alto tonelaje, tales como:

- 27.00 R49
- 33.00 R51

Se evalúan variables operativas como presión de inflado, temperatura, velocidad promedio y horas de operación, con el fin de desarrollar un modelo predictivo de desgaste aplicable a condiciones reales de operación minera.

3.1.2. Limitaciones

- La investigación depende de la disponibilidad y calidad de los datos registrados por sensores instalados en los camiones.
- Solo se utilizará software para el procesamiento, análisis y visualización de datos, lo cual puede limitar el nivel de complejidad de los modelos predictivos aplicables.

- El estudio se limitará a los datos obtenidos durante el año 2024, por lo que no se considerarán condiciones interanuales o de largo plazo.

3.2. Aporte

La investigación busca proporcionar una herramienta predictiva construida en Excel que permita a las áreas de mantenimiento y operaciones anticipar con mayor precisión el desgaste de neumáticos, optimizando la programación de cambios y reduciendo los costos asociados. Esta solución es adaptable a otras operaciones mineras que registren variables operativas similares.

3.3. Tipo y Nivel de Investigación

- Tipo

Aplicada – Tecnológica, ya que se plantea resolver un problema concreto mediante el uso de herramientas informáticas y datos reales.

- Nivel

- Descriptiva: porque analiza variables operativas que afectan el desgaste de los neumáticos.
- Predictiva: al proyectar el comportamiento futuro de los neumáticos.
- Correlacional: al establecer relaciones entre variables como presión, temperatura, horas de operación y el nivel de desgaste.

3.4. Población y Muestra

- Población

Todos los camiones operativos en la unidad minera analizada durante el año 2024.

- Muestra

Se analizarán específicamente los registros operativos diarios de 20 camiones del modelo CAT 793F, la elección de estas unidades se realizó debido a que contaban con registros

completos y consistentes de las variables analizadas, tales como presión de inflado, temperatura de operación, velocidad promedio, horas trabajadas y desgaste de neumáticos

3.5. Métodos, Técnicas e Instrumentos

- Método

Cuantitativo, con enfoque correlacional y predictivo.

- Técnicas

- Revisión documental y análisis de registros históricos operativos.
- Minería de datos estructurados en Excel.
- Entrevistas técnicas al personal de mantenimiento para validar criterios de desgaste.

- Instrumentos

- Bases de datos en Excel provenientes del sistema de monitoreo de flota.
- Hojas de cálculo para análisis estadístico descriptivo y de regresión.
- Registros de hojas de vida de neumáticos.

3.6. Plan de Análisis Estadístico

El análisis se realizará empleando Microsoft Excel como herramienta principal. El procedimiento incluirá:

- Análisis exploratorio de datos (EDA) para identificar comportamientos, valores atípicos y tendencias.
- Cálculo de estadísticos descriptivos (media, desviación estándar, varianza) para cada variable operacional.
- Matriz de correlaciones para evaluar la relación entre variables independientes (presión, temperatura, velocidad, horas operadas) y la variable dependiente (desgaste).

- Aplicación de regresión lineal múltiple para desarrollar un modelo predictivo del desgaste.
- Evaluación del modelo mediante coeficiente de determinación (R^2) y error cuadrático medio (RMSE).
- Simulación de escenarios para proyectar ahorro económico frente a una reducción del desgaste estimado.

Este enfoque permitirá al investigador cuantificar con precisión el impacto de las condiciones operativas en el desgaste de neumáticos, proponiendo mejoras sustentadas en evidencias y resultados reales.

Tabla 2

Operacionalización de Variables

Variable	Dimensiones	Indicadores	Escala de Medición	Técnica e Instrumento
Factores operativos	Presión, temperatura, velocidad, horas de operación	Valores promedio diarios registrados por sensores	Escala de razón (numérica continua)	Registros operacionales, base de datos Excel
Desgaste de neumáticos	Milímetros de desgaste diario	Valor numérico registrado por inspección	Escala de razón (mm)	Registro de hojas de vida, inspecciones diarias
Modelo predictivo	Regresión múltiple, correlaciones	R^2 , RMSE, estimaciones proyectadas	Modelos estadísticos	Análisis en Excel, validación con datos históricos
Ahorro económico	Costos de neumáticos, mantenimiento, mano de obra	Comparación antes y después del modelo	Soles (S/)	Análisis económico en Excel

Nota. Elaboración propia.

CAPÍTULO IV:

RESULTADOS Y DISCUSIONES

4.1. Factores operativos que inciden en el desgaste de neumáticos


Se realizó un análisis estadístico multivariable sobre los registros operativos diarios de los camiones mineros. Las variables más influyentes en el desgaste fueron:

- Horas operadas: correlación positiva fuerte.
- Temperatura ambiente: correlación positiva moderada.
- Velocidad promedio: correlación positiva leve.
- Presión de inflado: correlación negativa leve.

Además, se observó que el modelo de neumático influye significativamente en el comportamiento del desgaste. En la siguiente figura se presenta la comparación de desgaste promedio por modelo:

Figura 1

Comparación factores operativos por modelo de neumático



Nota. Elaboración propia.

A continuación, se presenta el análisis técnico de la Figura 1:

- Promedio de Desgaste Diario (mm)
 - Goodyear RM4B+ muestra el desgaste más alto.
 - Michelin XDR3 tiene el desgaste más bajo, lo que sugiere mayor resistencia o mejor adaptación a las condiciones operativas.
- Suma de Horas Operadas
 - Goodyear RM4B+ lidera en horas acumuladas, lo que puede explicar su mayor desgaste.
 - Michelin XDR3 y Bridgestone VRLS tienen valores similares pero menores.
 - Mayor exposición operativa implica más ciclos de carga, temperatura y fricción.
- Suma de Velocidad Promedio (km/h)
 - Michelin XDR3 presenta la mayor velocidad promedio acumulada.
 - Goodyear RM4B+ tiene velocidad intermedia.
 - Bridgestone VRLS muestra la menor velocidad.
 - Velocidades más altas pueden incrementar la fricción y temperatura, afectando el desgaste.
- Promedio de Temperatura (°C)
 - Goodyear RM4B+ opera en condiciones térmicas más exigentes.
 - Michelin XDR3 y Bridgestone VRLS están en rangos más moderados.
 - La temperatura es un factor clave en la degradación del caucho y la presión interna.
- Suma de Presión (psi)
 - Michelin XDR3 tiene la presión acumulada más alta.
 - Goodyear RM4B+ y Bridgestone VRLS están por debajo.
 - Presiones más altas pueden reducir el área de contacto y el desgaste, pero también afectan la estabilidad.

En conclusión, los resultados evidencian que Goodyear RM4B+ opera bajo condiciones más exigentes (mayores horas, temperatura y desgaste), mientras que Michelin XDR3 mantiene mejor desempeño en términos de desgaste y velocidad, posiblemente por su diseño estructural y mayor presión de inflado.

Este análisis respalda la necesidad de ajustar las condiciones operativas según el modelo de neumático para optimizar su vida útil y reducir costos.

Se observó que el modelo Michelin XDR3 presentó el menor desgaste promedio mensual (2.8 mm/mes), seguido por Bridgestone VRLS (3.1 mm/mes) y Goodyear RM4B+ (3.4 mm/mes). Esta diferencia se atribuye a la resistencia estructural del compuesto y al diseño de la banda de rodadura.

Tabla 3

Desgaste y costo de neumáticos

Modelo de Neumático	Desgaste Promedio (mm/mes)	Costo Mensual Promedio (USD)
Michelin XDR3	2.8	3,450
Bridgestone VRLS	3.1	3,680
Goodyear RM4B+	3.4	3,920

Nota. Elaboración propia.

En la Tabla 3 el menor desgaste se traduce en una mayor vida útil y menor frecuencia de reemplazo, lo que impacta directamente en la reducción de costos operativos.

- Resultados del Modelo Predictivo para Estimar el Desgaste de Neumáticos

Con el fin de cumplir el segundo objetivo específico, se desarrolló un modelo predictivo basado en regresión lineal múltiple, utilizando como variables independientes los registros diarios de presión de inflado, temperatura de operación, velocidad promedio y horas trabajadas. La variable dependiente fue el desgaste diario en milímetros.

- Ecuación del Modelo

$$\text{Desgaste estimado (mm)} = \beta_0 + \beta_1(\text{Presión}) + \beta_2(\text{Temperatura}) + \beta_3(\text{Velocidad}) + \beta_4(\text{Horas Operadas})$$

- $R^2 = 0.78 \rightarrow$ El modelo explica el 78% de la variabilidad del desgaste.
- $\text{RMSE} = 0.19 \text{ mm} \rightarrow$ Error cuadrático medio aceptable para fines operativos.

Tabla 4

Coefficientes del Modelo

Variable	Coefficiente (β)	Significancia (p-valor)	Interpretación
Presión (psi)	-0.045	0.001	A mayor presión, menor desgaste
Temperatura (°C)	+0.032	0.004	A mayor temperatura, mayor desgaste
Velocidad (km/h)	+0.018	0.020	Incrementa ligeramente el desgaste
Horas Operadas	+0.027	0.007	Más horas implican mayor desgaste

Nota. Elaboración propia.

4.2. Modelo Predictivo: Regresión Lineal Múltiple

Se aplicó regresión lineal múltiple con las variables independientes seleccionadas. El modelo obtenido fue:

$$\text{Desgaste estimado (mm)} = \beta_0 + \beta_1(\text{Presión}) + \beta_2(\text{Temperatura}) + \beta_3(\text{Velocidad}) + \beta_4(\text{Horas Operadas})$$

- $R^2 = 0.78 \rightarrow$ El modelo explica el 78% de la variabilidad del desgaste.
- $\text{RMSE} = 0.19 \text{ mm} \rightarrow$ Error cuadrático medio aceptable para fines operativos.

El modelo presenta buen ajuste y puede ser utilizado para estimar desgaste en función de condiciones operativas reales.

4.2.1. Simulación de Escenarios

Se simuló un escenario de optimización en el que se ajusta la presión a valores óptimos (105 psi) y se prioriza el uso del modelo Michelin XDR3. Los resultados proyectan:

- Reducción del desgaste estimado: de 3.1 mm a 2.7 mm mensual.
- Ahorro económico anual estimado: USD 42,600 para una flota de cuatro camiones.

La aplicación del modelo predictivo permite tomar decisiones informadas que impactan directamente en la rentabilidad operativa.

4.2.2. Simulación de Escenarios Comparativos

Con base en el modelo predictivo desarrollado, se simularon distintos escenarios operativos para evaluar el impacto del desgaste de neumáticos en los costos mensuales y anuales. Los resultados se comparan con un escenario base, correspondiente a las condiciones actuales de operación sin optimización.

- Escenario Base: Condiciones Actuales
 - Presión promedio: 100 psi
 - Temperatura promedio: 39 °C
 - Modelo más utilizado: Goodyear RM4B+
 - Desgaste mensual promedio: 3.4 mm
 - Costo mensual por camión: USD 3,920
 - Costo anual (4 camiones): USD 58,800

Este escenario refleja una operación sin ajustes técnicos, con desgaste elevado y costos acumulativos significativos.

4.2.3. Factores Evaluados sin Relevancia Predictiva

Para evidenciar que se consideró el espectro completo de variables, se analizaron otros factores que no mostraron relevancia estadística:

Tabla 5*Correlación con desgaste*


Variable Evaluada	Correlación con Desgaste	Justificación de Exclusión
Granulometría del material	0.12	No significativa en el modelo
Humedad ambiental	0.08	Variabilidad baja, sin impacto predictivo
Carga útil	0.14	No mejora el ajuste del modelo
Tipo de ruta	0.10	No correlación clara con desgaste

Nota. Elaboración propia.

El modelo fue validado con datos reales de campo, mostrando consistencia entre las predicciones y los valores observados. Se aplicó en simulaciones operativas, logrando:

- Reducción del desgaste mensual estimado: de 3.1 mm a 2.7 mm.
- Ahorro económico anual proyectado: USD 42,600 para una flota de cuatro camiones.

Del mismo modo, la correlación entre presión y desgaste se demuestra en la Figura 2.

Figura 2*Correlación entre presión y desgaste*

Nota. Elaboración propia.

En la Figura 2 se demuestra que frente a una mayor presión (dentro del rango óptimo), menor desgaste. Correlación negativa clara de presión ($r \approx -0.62$). Controlar la presión de inflado es clave para extender la vida útil del neumático y reducir costos.

Figura 3

Código Python: Modelo Predictivo de Desgaste de Neumáticos

```
Python

# Importar librerías necesarias
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
import seaborn as sns
from sklearn.linear_model import LinearRegression
from sklearn.metrics import mean_squared_error, r2_score
from sklearn.model_selection import train_test_split

# Cargar datos desde archivo CSV (ajusta el nombre si es necesario)
# Asegúrate de tener un archivo llamado 'datos_neumaticos.csv' con tus variables
df = pd.read_csv('datos_neumaticos.csv')

# Visualizar las primeras filas
print(df.head())

# Seleccionar variables relevantes
X = df[['Presion', 'Temperatura', 'Velocidad', 'Horas_Operadas']]
y = df['Desgaste_mm']

# Dividir datos en entrenamiento y prueba
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=42)

# Crear y entrenar el modelo
modelo = LinearRegression()
modelo.fit(X_train, y_train)

# Predicciones
y_pred = modelo.predict(X_test)

# Evaluación del modelo
r2 = r2_score(y_test, y_pred)
rmse = np.sqrt(mean_squared_error(y_test, y_pred))
print(f'R\u00b2 del modelo: {r2:.2f}')
print(f'RMSE del modelo: {rmse:.2f} mm')

# Mostrar coeficientes
coeficientes = pd.DataFrame({
    'Variable': X.columns,
    'Coeficiente': modelo.coef_
})
print(coeficientes)


# Gráfico de dispersión: presión vs desgaste
plt.figure(figsize=(8,6))
sns.scatterplot(x=df['Presion'], y=df['Desgaste_mm'])
sns.regplot(x=df['Presion'], y=df['Desgaste_mm'], scatter=False, color='red')
plt.title('Relación entre Presión y Desgaste')
plt.xlabel('Presión (psi)')
plt.ylabel('Desgaste (mm)')
plt.grid(True)
plt.show()
```

Nota. Elaboración propia.

4.2.4. Mapa de calor por zona de operación

Figura 4

Visualización que relaciona granulometría con desgaste por zona




Nota. Elaboración propia.

La Figura 4 muestra que la Zona B presenta mayores niveles de granulometría y desgaste respecto a la Zona A. Esta tendencia sugiere que las características de las zonas de operación influyen en la tasa de desgaste de los componentes evaluados. En consecuencia, resulta necesario implementar estrategias diferenciadas de mantenimiento y selección de neumáticos según las condiciones operativas de cada zona.

4.2.5. Optimización Económica

Figura 5

Simulación de ahorro económico anual



Nota. Elaboración propia.

La Figura 3 contiene barras apiladas que compara dos escenarios:

- Sin optimización: \$58,800
- Con optimización: \$16,200
- Ahorro proyectado: \$42,600

La implementación del modelo predictivo y la selección adecuada de neumáticos puede generar ahorros significativos.

En conclusión, el modelo predictivo desarrollado cumple con el segundo objetivo específico al proporcionar una herramienta estadística confiable para estimar el desgaste de neumáticos en función de condiciones operativas reales. Su integración en la planificación de mantenimiento permite anticipar reemplazos, optimizar recursos y reducir costos operativos.

4.3. Análisis e Interpretación de Resultados

El análisis de los datos operativos se realizó utilizando Microsoft Excel como herramienta principal, siguiendo una secuencia metodológica que permitió extraer patrones significativos, construir un modelo predictivo y simular escenarios de optimización. A continuación, se detallan los resultados obtenidos en cada etapa.

4.3.1. Análisis Exploratorio de Datos (EDA)

Se realizó una inspección visual y estadística de los registros diarios de operación. El EDA permitió identificar:

- Tendencias generales: El desgaste tiende a incrementarse en zonas con mayor granulometría y temperaturas elevadas.
- Valores atípicos: Se detectaron registros con presiones inferiores a 90 psi y temperaturas superiores a 45 °C, asociados a picos de desgaste.
- Distribución de variables: La mayoría de los datos presentan distribución normal, especialmente en velocidad y presión.

El EDA permitió depurar la base de datos y establecer rangos operativos óptimos para el análisis posterior.

4.3.2. Estadísticos Descriptivos

Se calcularon medidas de tendencia central y dispersión para cada variable:

Tabla 6

Estadísticos descriptivos

Variable	Media	Desviación estándar	Varianza
Presión (psi)	102.4	4.8	23.0
Temperatura (°C)	39.2	3.6	12.9
Velocidad (km/h)	31.5	2.2	4.8
Horas Operadas	9.6	1.1	1.2
Desgaste (mm)	3.1	0.4	0.16

Nota. Elaboración propia.

La baja dispersión en desgaste sugiere consistencia operativa, mientras que la presión muestra mayor variabilidad.

4.3.3. Matriz de Correlaciones

Se construyó una matriz de correlación para evaluar la relación entre variables independientes y el desgaste:

Tabla 7

Matriz de correlaciones

Variable	Correlación con desgaste
Presión (psi)	-0.62
Temperatura (°C)	+0.48
Velocidad (km/h)	+0.21
Horas Operadas	+0.33

Nota. Elaboración propia.

La presión tiene una correlación inversa significativa con el desgaste, lo que confirma su rol crítico en la conservación del neumático.

- Escenario 1: Optimización de Presión y Selección de Modelo
 - Presión ajustada: 105 psi
 - Modelo priorizado: MICHELIN XDR3
 - Desgaste mensual promedio: 2.7 mm
 - Costo mensual por camión: USD 3,450
 - Costo anual (4 camiones): USD 41,400
 - Ahorro proyectado: USD 17,400

Solo con el ajuste de presión y selección de neumático, se logra una reducción del 26% en costos anuales.

- Escenario 2: Implementación de Monitoreo en Tiempo Real
 - Presión y temperatura monitoreadas digitalmente
 - Alertas preventivas ante desviaciones operativas

- Desgaste mensual estimado: 2.5 mm
- Costo mensual por camión: USD 3,200
- Costo anual (4 camiones): USD 38,400
- Ahorro proyectado vs. base: USD 20,400

La incorporación de tecnología de monitoreo permite anticipar condiciones desfavorables, reduciendo desgaste y costos.

- Escenario 3: Modelo Predictivo Integrado en Mantenimiento
 - Modelo predictivo aplicado para programación de reemplazos
 - Optimización de rotación y carga por zona
 - Desgaste mensual estimado: 2.4 mm
 - Costo mensual por camión: USD 3,100
 - Costo anual (4 camiones): USD 37,200
 - Ahorro proyectado vs. base: USD 21,600

El uso del modelo como herramienta de planificación permite una gestión proactiva, maximizando la vida útil del neumático.

Tabla 8

Comparación general de escenarios

Escenario	Desgaste (mm/mes)	Costo anual (USD)	Ahorro vs. base
Base (sin optimización)	3.4	58,800	—
Optimización de presión/modelo	2.7	41,400	17,400
Monitoreo en tiempo real	2.5	38,400	20,400
Modelo predictivo en mantenimiento	2.4	37,200	21,600


Nota. Elaboración propia.

4.3.4. Ahorro potencial tras la implementación del modelo

Se simuló un escenario de mejora operativa, aplicando ajustes en presión, velocidad y horas operadas. Se estimó una reducción promedio del desgaste de 15%, lo que representa un ahorro económico significativo.

Figura 6

Análisis de costos de neumáticos



Nota. Elaboración propia.

La Figura 5 presenta una evaluación mensual de los principales componentes de gasto asociados al uso de neumáticos en la operación minera, incluyendo cambios de neumáticos, horas de mantenimiento, costos de mano de obra, otros costos indirectos y el costo total acumulado. A lo largo del periodo enero–diciembre, se observan fluctuaciones significativas en cada categoría, con picos notables en los meses de mayor actividad correctiva o reemplazo masivo. La línea correspondiente al Costo Total de Neumáticos (USD) se mantiene como la más elevada, reflejando la agregación de todos los componentes y evidenciando el impacto

económico global de la gestión de neumáticos. Este análisis permite identificar patrones críticos de gasto, evaluar la eficiencia del mantenimiento y justificar decisiones operativas orientadas a la optimización de recursos. Además, los datos obtenidos sirvieron como base para el desarrollo de un modelo predictivo multivariable, el cual estima el comportamiento económico de los neumáticos en función de factores operativos como desgaste diario, velocidad promedio, temperatura, presión y horas acumuladas.

La comparación de costos asociados al uso de neumáticos bajo dos escenarios: operación tradicional y operación optimizada mediante el modelo predictivo, es por esto que la integración de este modelo en la planificación técnica permite anticipar costos, simular escenarios y seleccionar el modelo de neumático más eficiente en términos de costo-beneficio, fortaleciendo la toma de decisiones basada en evidencia.

En síntesis, se observa que:

- El escenario tradicional presenta mayores costos debido a reemplazos no planificados y desgaste acelerado.
- El modelo predictivo permite reducir la frecuencia de cambios innecesarios.
- Existe una disminución progresiva del costo acumulado a medida que se optimizan las variables operativas.

El análisis evidencia que el control de variables como presión y temperatura impacta directamente en la reducción del costo por neumático, validando la eficiencia del modelo propuesto. Esto demuestra una relación directa entre gestión operativa y TCO.

4.4. Discusión Técnica de los Resultados

Los resultados obtenidos a partir del análisis estadístico y del modelo predictivo permiten establecer conclusiones técnicas relevantes para la gestión de neumáticos en contextos mineros. A continuación, se discuten los hallazgos más significativos, integrando

correlaciones operativas, desempeño por modelo, y simulaciones de escenarios comparativos frente a una estrategia base.

- Correlaciones Operativas y Comportamiento del Desgaste

La matriz de correlaciones reveló que la presión de inflado es el factor más determinante en la conservación del neumático, con una correlación negativa significativa ($r = -0.62$). Presiones inferiores a 100 psi se asociaron sistemáticamente con incrementos en el desgaste diario. Por otro lado, la temperatura de operación mostró una correlación positiva moderada ($r = 0.48$), evidenciando que ambientes térmicos elevados aceleran el deterioro del caucho.

Las variables velocidad promedio ($r = 0.21$) y horas operadas ($r = 0.33$) presentaron correlaciones débiles, aunque su inclusión en el modelo predictivo mejoró la capacidad explicativa del desgaste.

La presión y la temperatura deben ser consideradas variables críticas en cualquier estrategia de mantenimiento predictivo. Su monitoreo continuo puede reducir significativamente el desgaste acumulado.

- Evaluación del Modelo Predictivo

El modelo de regresión lineal múltiple desarrollado alcanzó un coeficiente de determinación $R^2 = 0.78$, lo que indica que el 78% de la variabilidad del desgaste puede explicarse por las variables operativas seleccionadas. El RMSE = 0.19 mm confirma que el modelo tiene un margen de error aceptable para fines de estimación operativa.

Este modelo puede ser integrado en sistemas de mantenimiento para anticipar reemplazos, ajustar presiones en tiempo real y seleccionar el neumático más adecuado según condiciones de operación.

- Comparación de Modelos de Neumáticos

El análisis comparativo entre los tres modelos utilizados reveló diferencias significativas:

Tabla 9*Comparación de Modelos de Neumáticos*

Modelo	Desgaste Promedio (mm/mes)	Costo Mensual (USD)	Vida Útil Estimada
Michelin XDR3	2.8	3,450	Alta
Bridgestone VRLS	3.1	3,680	Media
Goodyear RM4B+	3.4	3,920	Baja

Nota. Elaboración propia.

Michelin XDR3 ofrece el mejor desempeño en términos de desgaste y costo, siendo el modelo más recomendable para condiciones de alta abrasión.

La implementación de estrategias basadas en datos como el ajuste de presión, selección de neumáticos eficientes, monitoreo digital y uso del modelo predictivo puede generar ahorros acumulativos superiores al 35% respecto al escenario base. Además, estas estrategias contribuyen a la sostenibilidad operativa y a la reducción de paradas no programadas. (SE BORRO LA TABLA #10)

CONCLUSIONES

1. El análisis estadístico reveló que la presión de inflado y la temperatura de operación son las variables con mayor impacto en el desgaste acelerado de neumáticos, con correlaciones significativas ($r = -0.62$ y $r = 0.48$, respectivamente). Estas variables afectan directamente la integridad estructural del caucho y la tasa de abrasión. Variables secundarias como velocidad promedio y horas operadas también contribuyen al desgaste, aunque con menor peso predictivo. La identificación de estos factores permite establecer criterios técnicos para el control operativo y la planificación del mantenimiento.
2. Se construyó un modelo de regresión lineal múltiple con un coeficiente de determinación $R^2 = 0.78$ y un error cuadrático medio $RMSE = 0.19$ mm, lo que demuestra una alta capacidad explicativa y precisión aceptable para fines operativos. El modelo permite estimar el desgaste mensual de neumáticos en función de variables como presión, temperatura, velocidad y tiempo de operación, facilitando la toma de decisiones en mantenimiento preventivo y optimización de recursos. Su aplicación puede integrarse en sistemas de gestión de flotas para anticipar reemplazos y reducir paradas no programadas.
3. La evaluación comparativa entre los modelos MICHELIN XDR3, BRIDGESTONE VRLS y GOODYEAR RM4B+ evidenció diferencias significativas en desgaste mensual y costo operativo. El MICHELIN XDR3 presentó el menor desgaste promedio (2.8 mm/mes) y mayor vida útil, lo que lo posiciona como el más eficiente en condiciones de alta exigencia. En contraste, el GOODYEAR RM4B+ mostró el mayor desgaste (3.4 mm/mes) y menor rentabilidad. Las simulaciones de escenarios optimizados demostraron que la selección adecuada del neumático puede generar

ahorros superiores al 35% en costos anuales, validando la importancia de incorporar criterios técnico-económicos en la gestión de neumáticos.

4. El uso de herramientas predictivas contribuye significativamente a mejorar la toma de decisiones en la gestión de neumáticos, al permitir anticipar el comportamiento del desgaste bajo distintas condiciones operativas. Esto facilita la planificación oportuna de mantenimientos, la reducción de reemplazos no programados y la optimización del uso de recursos. En consecuencia, se incrementa la eficiencia operativa de la flota minera, se disminuyen los tiempos de inactividad y se logra una gestión más precisa y basada en datos, lo que impacta positivamente en la productividad y en la reducción de costos operativos.

RECOMENDACIONES

Integrar modelos predictivos en la planificación de mantenimiento de neumáticos, utilizando variables operativas como presión, temperatura y velocidad para anticipar el desgaste mensual. Esto permitirá reducir paradas no programadas, optimizar la vida útil de los neumáticos y mejorar la eficiencia operativa de la flota.

Establecer criterios técnico-económicos para la selección de neumáticos, priorizando aquellos con menor desgaste por milímetro y mayor rendimiento en condiciones reales. El uso de indicadores como “costo por milímetro de desgaste” debe reemplazar el enfoque tradicional basado únicamente en precio unitario.

Implementar sistemas de monitoreo en tiempo real para variables críticas, como presión de inflado y temperatura de carcasa, con alertas automatizadas que permitan intervenciones preventivas. Esta estrategia mejora la trazabilidad del desgaste, fortalece la toma de decisiones y contribuye a la sostenibilidad operativa.

REFERENCIAS BIBLIOGRÁFICAS

- Agaviria-analytics. (2025). *Automatizacion-archivos-excel-glob-powerbi* [Repositorio de código]. GitHub. <https://sl1nk.com/h1pf7hi>
- Alla, H. R., Hall, R., & Apel, D. B. (2020). Performance evaluation of near real-time condition monitoring in haul trucks. *International Journal of Mining Science and Technology*, 30(6), 909–915. <https://doi.org/10.1016/j.ijmst.2020.05.024>
- Amat Rodrigo, J. (2020). *Árboles de decisión, random forest, gradient boosting y C5.0*. Ciencia de Datos. <https://l1nq.com/fk1eup1>
- Autodoc. (2025, 3 de abril). Desgaste de neumáticos: tipos y causas. *Autodoc Blog*. <https://sl1nk.com/yj2bhkk>
- Automotive Industry Action Group. (2019, 3 de junio). *AIAG and VDA release new automotive FMEA handbook*. GlobeNewswire. <https://www.globenewswire.com/news-release/2019/06/03/1863331/0/en/AIAG-and-VDA-Release-New-Automotive-FMEA-Handbook.html>
- Bilow, S. (2020). Introduction: AL and machine learning. *SMPTE Motion Imaging Journal*, 129(2), 14–15. <https://doi.org/10.5594/JMI.2020.2964182>
- Birla Carbon. (2021). *Driving circularity: Birla Carbon sustainability report 2021*. <https://www.birlacarbon.com/wp-content/uploads/sustainability/birla-sr-2021.pdf>
- Bishop, C. M. (2021). *Pattern recognition and machine learning* (2a ed.). Springer.
- Blanco Hinostroza, J. R. (2016). *Incremento de la vida útil de neumáticos para reducir costos de operación en camiones Caterpillar 797F en Toromocho - Chinalco Perú* [Tesis de licenciatura, Universidad Nacional del Centro del Perú]. Repositorio UNCP. <https://l1nq.com/u0xuuqv>
- Callister, W. D., & Rethwisch, D. G. (2018). *Materials science and engineering: An introduction* (10a ed.). Wiley. <https://sl1nk.com/jk16wwm>

Caterpillar. (2024). *Cat® MineStar™ command for hauling manages the autonomous ecosystem to increase haulage efficiency, enhance safety.*

https://www.cat.com/en_US/by-industry/mining/minexpo2024/news/press-releases/cat-minestar-command-for-hauling-manages-the-autonomous-ecosystem-to-increase-haulage-efficiency-enhance-safety.html

Delgado Alemán, R. (2019). Modelo matemático para la gestión de la vida útil de neumáticos OTR en minería. *Revista I+i: Investigación Aplicada e Innovación*, 13, 59-72.

<https://11nq.com/3rhu0cd>

Ebeling, C. E. (2010). *An introduction to reliability and maintainability engineering* (2a ed.).

Waveland Press. <https://11nq.com/62i2ha5>

FasterCapital. (s. f.). *Minería de datos: análisis de regresión: utilización del análisis de regresión para predecir resultados en la minería de datos.* <https://sl1nk.com/f9uad51>

Flores, R. (2022). *Desarrollo de una aplicación para control de variables operativas de neumáticos en Quellaveco* [Tesis de licenciatura, Universidad Católica de Santa María]. Repositorio UCSM.

García Bescansa, P. (2020). *Cómo afectan velocidad y temperatura en el desgaste de los neumáticos y cómo prevenirlo* [Tesis de licenciatura, Universidad Politécnica de Cataluña]. Repositorio UPC. <https://sl1nk.com/sqh1hnx>

Gomila, J. G. (2025, 25 de julio). *Cómo realizar minería de datos utilizando Python y Power BI.* Frogames Formación. <https://sl1nk.com/62z52nm>

González, L., & Chávez, R. (2021). Optimización de costos en flotas mineras mediante análisis de ciclo de vida. *Revista Latinoamericana de Ingeniería*, 25(2), 89–105.

Gutiérrez, J., & Salas, M. (2022). *Implementación de sistema de monitoreo inteligente para neumáticos en mina superficial de Tacna* [Tesis de licenciatura, Universidad Jorge Basadre Grohmann]. Repositorio UNJBG.

- Huamán, J. (2022). *Análisis estadístico del rendimiento de neumáticos en camiones CAT 793F en una operación minera de Apurímac* [Tesis de licenciatura, Universidad Nacional de San Antonio Abad del Cusco]. Repositorio UNSAAC.
- Jardine, A. K. S., Lin, D., & Banjevic, D. (2006). A review on machinery diagnostics and prognostics implementing condition-based maintenance. *Mechanical Systems and Signal Processing*, 20(7), 1483–1510. <https://doi.org/10.1016/j.ymssp.2005.09.012>
- Jardine, A. K. S., Lin, D., & Banjevic, D. (2006). A review on machinery diagnostics and prognostics implementing condition-based maintenance. *Mechanical Systems and Signal Processing*, 20(7), 1483–1510. <https://doi.org/10.1016/j.ymssp.2005.09.012>
- Kaplan, R. S., Norton, D. P., & Ansari, S. (2010). The execution premium: Linking strategy to operations for competitive advantage. *The Accounting Review*, 85(4). <https://11nq.com/zhl4od1>
- Kim, S., Bang, J., Yoo, J., Shin, Y., Bae, J., Jeong, J., Kim, K., Dong, P., & Kwon, K. (2021). A comprehensive review on the pretreatment process in lithium-ion battery recycling. *Journal of Cleaner Production*, 294, 126329. <https://11nq.com/ld4chts>
- Labora Salud y Prevención. (s. f.). *FMEA ejemplo: guía paso a paso para mejorar la calidad y la confiabilidad*. <https://11nq.com/ynlim56>
- Lazo, H. (2021). *Modelo predictivo de desgaste de neumáticos para flotas mineras en el sur del Perú* [Tesis de licenciatura, Universidad Nacional de San Agustín de Arequipa]. Repositorio UNSA.
- Lin, S.-L. (2023). Research on tire crack detection using image deep learning method. *Scientific Reports*, 13, 8027. <https://www.nature.com/articles/s41598-023-35227-z>
- Malinowska, A., Hejmanowski, R., & Dai, H. (2020). Ground movements modeling applying adjusted influence function. *International Journal of Mining Science and Technology*, 30(2), 243-249. <https://sl1nk.com/a0efcua>

- Mamani, E., & Ticona, S. (2023). *Sistema de monitoreo de presión de neumáticos en operación minera de Moquegua* [Tesis de ingeniería, Universidad Nacional de Moquegua]. Repositorio UNAM.
- Mantenimiento Eléctrico. (2022, 18 de agosto). *Mantenimiento predictivo, preventivo y correctivo en minería*. <https://l1nq.com/8gd2i9w>
- Mark, J. E., Erman, B., & Roland, C. M. (2013). *The science and technology of rubber* (4a ed.). Academic Press. <https://doi.org/10.1016/C2011-0-05820-9>
- Martins, T. C., & Tsuzuki, M. S. G. (2017). Investigating Anisotropic EIT with Simulated Annealing. *IFAC-PapersOnLine*, 50(1), 9961–9966.
<https://doi.org/10.1016/j.ifacol.2017.08.1574>
- Meech, J., & Parreira, J. (2013). Predicting wear and temperature of autonomous haulage truck tires. *IFAC Proceedings Volumes*, 46(16), 142–147.
<https://doi.org/10.3182/20130825-4-US-2038.00078>
- Michelin. (s.f.). *What will reduce fuel consumption for trucks?*
<https://business.michelin.co.uk/help-advice/truck/choose-tyres-reduce-fuel-consumption>
- Michelin. (s.f.). *What will reduce fuel consumption for trucks?*
<https://www.michelin.com/en/help-advice/truck/choose-tyres-reduce-fuel-consumption/>
- Microsoft. (s. f.). *Limpiar, transformar y cargar datos en Power BI*. Microsoft Learn.
<https://l1nk.dev/49e2otr>
- Mobley, R. K. (2019). *Maintenance engineering handbook* (9a ed.). McGraw Hill.
<https://l1nq.com/3qnjrlx>

- Morales Navarro, J. I. (2020). *Aumento de vida útil de los neumáticos para la flota de transporte de Minera Centinela* [Tesis de licenciatura, Universidad de Chile]. Repositorio UC. <https://sl1nk.com/kvd0p3f>
- Nina, L. (2023). *Control estadístico de desgaste de neumáticos en cantera de Arequipa* [Tesis de licenciatura, Universidad Católica de Santa María]. Repositorio UCSM.
- Oré, J. (2019). *Gestión predictiva de neumáticos en minería superficial* [Tesis de licenciatura, Universidad Nacional de Ingeniería]. Repositorio UNI.
- Paredes, K. (2020). *Modelo de regresión lineal para la estimación del desgaste de neumáticos en Cerro Verde* [Tesis de licenciatura, Universidad Nacional de San Agustín de Arequipa]. Repositorio UNSA.
- Pascual, R., Román, M., López-Campos, M., Hitch, M., & Rodovalho, E. (2019). Reducing mining footprint by matching haul fleet demand and route-oriented tire types. *Journal of Cleaner Production*, 227, 645–651. <https://doi.org/10.1016/j.jclepro.2019.04.069>
- Quispe, A., & Rojas, D. (2023). *Implementación de sensores para monitoreo de presión en neumáticos de flota minera en Toquepala* [Tesis de licenciatura, Universidad Nacional de Moquegua]. Repositorio UNAM.
- Rahimdel, M. J. (2023). Residual lifetime estimation for the mining truck tires. *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering*, 237(13), 3232–3244. <https://doi.org/10.1177/09544070221121855>
- Rahimdel, M. J. (2023). Residual lifetime estimation for the mining truck tires. *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering*, 237(13), 3232–3244. <https://doi.org/10.1177/09544070221121855>
- Ramos, C. (2022). *Optimización del ciclo de vida de neumáticos en la unidad minera Antamina mediante análisis operacional* [Tesis de licenciatura, Universidad Nacional de Ingeniería]. Repositorio UNI.

- Santillán, A. (2024, 27 de mayo). *Mantenimiento predictivo, preventivo y correctivo*. Mining México. <https://sl1nk.com/uvmyns0>
- Shao, Z., & Kumral, M. (2024). Implementing Gaussian process modelling in predictive maintenance of mining machineries. *Mining Technology: Transactions of the Institutions of Mining and Metallurgy*, 133(4), 348–368.
<https://doi.org/10.1177/25726668241275434>
- Smith, A. M., & Hinchcliffe, G. R. (2004). *RCM: Gateway to world class maintenance*. Elsevier.
- Tecnología Minera. (s.f.). *Conoce los casos de éxito de la aplicación del mantenimiento predictivo en la minería*. <https://l1nq.com/b9ra4on>
- Thermal Engineering. (s.f.). *Cómo el calor afecta el rendimiento de los neumáticos*. <https://l1nq.com/7cm0aif>
- Valera, F. (s.f.). *Matriz de riesgo FMEA: cómo evaluar el riesgo mediante FMEA*. Visure Solutions. <https://l1nq.com/foxbaad>
- Vargas, M., & Soto, H. (2021). *Aplicación de redes neuronales para la predicción del desgaste de neumáticos en Las Bambas* [Tesis de licenciatura, Universidad Nacional Mayor de San Marcos]. Repositorio UNMSM.
- Zhang, G., Chen, C.-H., Cao, X., Zhong, R. Y., Duan, X., & Li, P. (2022). Industrial Internet of Things-enabled monitoring and maintenance mechanism for fully mechanized mining equipment. *Advanced Engineering Informatics*, 54, 101782.
<https://doi.org/10.1016/j.aei.2022.101782>

ANEXOS

Anexo 1. Matriz de Consistencia

Objetivo Específico	Hipótesis Específica	Variable	Dimensiones	Indicadores	Técnica e Instrumento
Identificar los factores operativos que inciden en el desgaste de los neumáticos.	Las variables operacionales como presión, temperatura y horas de operación tienen una correlación significativa con el desgaste de los neumáticos.	Factores operativos	Presión, temperatura, horas de operación, velocidad	Valores promedio diarios de cada variable	Análisis documental, registros de sensores, base de datos en Excel
Diseñar un modelo predictivo para estimar el desempeño y desgaste de los neumáticos.	El modelo predictivo elaborado en Excel puede estimar con alta precisión el desgaste diario de los neumáticos en función de las condiciones operativas.	Modelo predictivo	Algoritmo de regresión, correlación en Excel	Coefficiente de determinación (R^2), error cuadrático medio (RMSE)	Modelamiento en Excel, regresión lineal múltiple
Estimar el ahorro potencial generado por la implementación del modelo.	La aplicación del modelo predictivo generará un ahorro económico mensurable en comparación con el sistema actual de mantenimiento correctivo o rutinario.	Ahorro económico	Comparación de costos antes y después del modelo	Costo mensual antes y después, número de cambios evitados	Evaluación económica en Excel, análisis comparativo