

FACULTAD DE INGENIERÍA

Escuela Académico Profesional de Ingeniería Eléctrica

Tesis

**Desarrollo de un indicador de salud basado en algoritmos de
aprendizaje supervisado para predecir la vida útil de motores
eléctricos en equipos de gran minería**

**Edson Amidey Apaza Choquepata
Susan Mabel Taya Martinez**

Para optar el Título Profesional de
Ingeniero Electricista

Arequipa, 2025

Repositorio Institucional Continental
Tesis digital



Esta obra está bajo una Licencia "Creative Commons Atribución 4.0 Internacional" .

**INFORME DE CONFORMIDAD DE ORIGINALIDAD DE TRABAJO DE
INVESTIGACIÓN**

A : Decano de la Facultad de Ingeniería
DE : Ronald Alex Gaona Gallegos
Asesor de trabajo de investigación
ASUNTO : Remito resultado de evaluación de originalidad de trabajo de investigación
FECHA : 28 de Junio de 2025

Con sumo agrado me dirijo a vuestro despacho para informar que, en mi condición de asesor del trabajo de investigación:

Título:

Desarrollo de un indicador de salud basado en algoritmos de aprendizaje supervisado para predecir la vida útil de motores eléctricos en equipos de gran minería

Autores:

1. Edson Amidey Apaza Choquepata – EAP. Ingeniería Eléctrica
2. Susan Mabel Taya Martinez – EAP. Ingeniería Eléctrica

Se procedió con la carga del documento a la plataforma "Turnitin" y se realizó la verificación completa de las coincidencias resaltadas por el software dando por resultado 12 % de similitud sin encontrarse hallazgos relacionados a plagio. Se utilizaron los siguientes filtros:

- | | | |
|---|--|-----------------------------|
| • Filtro de exclusión de bibliografía | SI ☒ | NO ☐ |
| • Filtro de exclusión de grupos de palabras menores
Nº de palabras excluidas: 10 | SI ☒ | NO ☐ |
| • Exclusión de fuente por trabajo anterior del mismo estudiante | SI ☒ | NO ☐ |

En consecuencia, se determina que el trabajo de investigación constituye un documento original al presentar similitud de otros autores (citas) por debajo del porcentaje establecido por la Universidad Continental.

Recae toda responsabilidad del contenido del trabajo de investigación sobre el autor y asesor, en concordancia a los principios expresados en el Reglamento del Registro Nacional de Trabajos conducentes a Grados y Títulos – RENATI y en la normativa de la Universidad Continental.

Atentamente,

La firma del asesor obra en el archivo original (No se muestra en este documento por estar expuesto a publicación).

AGRADECIMIENTOS

De Edson:

Agradezco a Dios por darme vida, salud, sabiduría, fortaleza y la perseverancia para encaminar mi vida, gracias por guiarme en cada paso y enseñarme el camino de la fe.

Mi tesis la dedico con todo mi amor y cariño a mi amada compañera de vida Kenia Flores, por su apoyo incondicional, sacrificio y esfuerzo, por ser cómplice de haber logrado un objetivo más de mi vida, por creer en mi capacidad, aunque hemos pasado momentos difíciles siempre ha estado brindándome su apoyo, comprensión, cariño y amor. Te amo vida mía.

A mis adoradas princesas Ivanna y Antonnella, por ser mi fuente de inspiración, mi motor y motivo. Qué sería mi vida sin ustedes... que lo son todo para mí. Espero que este logro sea un ejemplo para ustedes y las inspire a alcanzar sus sueños.

A mis padres Felipe y Concepción, que me dieron y la vida y formaron una persona luchadora y resiliente, que da lucha día a día. Gracias por sus consejos sus palabras que a pesar de la distancia siempre estuvieron presente. A ti mamita, que nunca perdiste la fe por tu menor hijo.

A todos mis familiares, hermanos por sus consejos y compartir sus experiencias de vida y a todos mis sobrinas y sobrinos, hijos míos espero que este logro sea para ustedes una inspiración para construir sus sueños y sus metas.

A una persona muy especial, mi ángel Marjhory, que estas en el cielo. Aunque no estás aquí para ver este logro, espero que te sientas orgullosa de mí. Te recuerdo siempre y estarás por siempre dentro de mí. Te amo mi Mayito.

De Susan:

En primer lugar, agradezco profundamente a Dios, por haberme guiado en cada paso de este camino. Por darme fuerzas en los momentos difíciles, claridad en los momentos de duda y por no soltarme nunca, incluso cuando yo mismo estuve a punto de rendirme.

Con el corazón lleno de gratitud, quiero dedicar estas palabras a quienes han sido el verdadero sostén de mi vida y de este logro.

A mis padres, Ines e Ian, quienes con amor, sacrificio y ejemplo me enseñaron que los sueños sí se alcanzan con esfuerzo y constancia. Gracias por cada palabra de aliento, cada gesto de apoyo y por ser mi refugio en los momentos difíciles. Todo lo que soy y lo que he logrado, se los debo a ustedes.

A mis hermanos, Jorge, Cinthia, Gianfranco y Thiago, por ser mi fuerza en los días grises y mi alegría en los días de luz. Gracias por acompañarme con risas, consejos y por creer en mí.

A mi querida abuela Corina Mendoza, mi ángel en la tierra, gracias por tu amor inmenso, tus oraciones sinceras y por cada gesto lleno de ternura que me ha acompañado desde siempre. Tu fe en mí ha sido una luz constante en mi camino.

Y a mi pareja Diego Pineda, gracias por estar a mi lado con paciencia, amor y comprensión. Por cada palabra de ánimo, por cada abrazo que me devolvió la calma, por creer en mí y por impulsarme a seguir adelante cuando sentía que no podía más. Tu presencia ha sido un regalo invaluable en este proceso.

Este trabajo no solo es mío, es también de ustedes. Gracias por caminar a mi lado con tanto amor.

DEDICATORIA

De Edson:

- A mis amados padres, esposa e hijas.
- A mis cuñados Marco y Marizol.
- A la universidad, por ser una casa de estudios y dar oportunidad a las personas que decidimos trabajar y estudiar.
- A los docentes por su profesionalismo y vocación de enseñanza.
- A mis asesores por su apoyo incondicional y su experiencia compartida.
- A mis compañeros de la universidad.
- A mi amigo Carlos Chalco.

De Susan:

A mi madre Ines, por ser mi guía, mi fuerza y mi ejemplo de vida. Gracias por estar siempre, por darme tanto sin esperar nada a cambio, y por enseñarme con tu ejemplo lo que significa el verdadero amor y la entrega. Este logro lleva tu nombre, porque sin tu valentía, tu lucha diaria y tu apoyo incondicional, jamás habría llegado hasta aquí.

A mi abuela Corina, por ser mi segunda madre, por llenarme de cariño, sabiduría y fe desde que tengo memoria. Tu voz, tus consejos y tu forma de cuidarme han marcado mi vida de una manera profunda. Tu presencia ha sido una luz constante en mi vida, y sin ti, este camino habría sido mucho más difícil. Siempre estarás en mi corazón.

Este trabajo es un homenaje a ustedes, dos mujeres excepcionales que han dejado huella en mi alma. Todo lo que he alcanzado es fruto del amor que sembraron en mí.

ÍNDICE

AGRADECIMIENTOS	iv
DEDICATORIA	vi
ÍNDICE	vii
ÍNDICE DE TABLAS	xi
ÍNDICE DE FIGURAS.....	xii
RESUMEN	xv
ABSTRACT.....	xvi
INTRODUCCIÓN	xvii
CAPÍTULO I	1
PLANTEAMIENTO DEL ESTUDIO	1
1.1 Planteamiento del problema.....	1
1.1.1 Problema general	1
1.1.2 Problemas específicos	1
1.2 Objetivos	2
1.2.1 Objetivo general.....	2
1.2.2 Objetivos específicos	2
1.3 Justificación e importancia	2
1.3.1 Justificación social	2
1.3.2 Justificación económica	3
1.3.3 Justificación teórica	3
1.3.4 Importancia	4
1.4 Limitaciones de la investigación.....	4
1.5 Hipótesis y descripción de variables.....	5
1.5.1 Hipótesis general.....	5
1.5.2 Hipótesis específicas	5
1.6 Descripción de variables	5
1.6.1 Variable 1: independiente	5

1.6.2	Variable 2: dependiente	5
1.6.3	Operacionalización de variables	6
CAPÍTULO II		7
MARCO TEÓRICO.....		7
2.1	Antecedentes de la investigación	7
2.1.1	Antecedentes internacionales	7
2.1.2	Antecedentes nacionales	8
2.2	Bases teóricas.....	9
2.2.1	Motores eléctricos	9
2.2.2	Ventajas de los motores trifásicos de corriente alterna	12
2.2.3	Mantenimiento de los motores trifásicos de corriente alterna.....	13
2.2.4	Vida útil de los motores eléctricos.....	13
2.2.5	Indicador de salud	14
2.2.6	Mantenimiento predictivo	15
2.2.7	Algoritmos de aprendizaje supervisado	16
2.2.8	Predicción de fallas	28
2.2.9	Tiempo promedio hasta la falla (MTTF)	29
2.2.10	Vibraciones	30
2.2.11	Temperatura	30
2.2.12	Corriente	30
2.2.13	Aislamiento del bobinado	30
2.2.14	Frecuencia de fallas.....	30
2.2.15	Índices de desgaste.....	30
2.2.16	Matlab	31
CAPÍTULO III.....		32
METODOLOGÍA		32
3.1	Método de la investigación	32
3.1.1	Tipo de investigación	32
3.1.2	Nivel de investigación.....	32

3.1.3	Diseño de investigación	32
3.2	Población y muestra	32
3.2.1	Población.....	32
3.2.2	Muestra	33
3.3	Técnicas de instrumentos y recolección de datos	33
3.3.1	Técnicas de recolección de datos	33
3.3.2	Instrumentos de recolección de datos	33
3.4	Técnicas de análisis y procesamiento de datos	34
3.4.1	Técnicas de análisis de datos	34
3.4.2	Técnicas de procesamiento de datos	35
CAPÍTULO IV		36
DIAGNÓSTICO, ANÁLISIS Y RESULTADOS		36
4.1	Análisis de los factores que afectan la vida útil de motores eléctricos	36
4.1.1	Temperatura de los motores eléctricos.....	36
4.1.2	Contaminación de motor de tracción por pase de aceite.....	44
4.1.3	Generación potencia eléctrica	48
4.2	Análisis de fallas eléctricas	55
4.2.1	Análisis de eventos en conjunto.....	55
4.2.2	Análisis de eventos por camión	57
4.2.3	Análisis de potencias de Grid.....	60
4.2.4	Análisis de temperatura de aceite y potencia	63
4.2.5	Análisis de patrones de correlación con ventana móvil de un mes	65
4.2.6	Análisis de Drive Motor Power vs Electric Retarding Grid Power Consumption	67
4.2.7	Umbrales de Electric Retarding Grid Power Consumption	69
4.2.8	Electric Retarding Grid Power Consumption	72
4.2.9	Análisis de downhill	76
4.2.10	Análisis de Drive Motor Phases Current vs Phases Module Temp.....	78
4.2.11	Análisis de desbalance de potencia del motor.....	81

4.3	Desarrollo de modelos de aprendizaje supervisado	83
4.4	Discusión	96
CAPÍTULO V		99
CONCLUSIONES Y RECOMENDACIONES.....		99
5.1	Conclusiones.....	99
5.2	Recomendaciones	100
REFERENCIAS BIBLIOGRÁFICAS.....		101
ANEXOS		104

ÍNDICE DE TABLAS

Tabla 1.	Descripción y operacionalización de variables.	6
Tabla 2.	Ventajas y desventajas del algoritmo Random Forest.	23
Tabla 3.	Clasificación mediante Random Forest.	23
Tabla 4.	Tipos de redes neuronales (25).	25
Tabla 5.	Retroalimentación de diagnóstico.	51
Tabla 6.	Eventos reportados por los camiones 798 AC.	56

ÍNDICE DE FIGURAS

Figura 1.	Motor de Corriente Alterna Trifásico..	10
Figura 2.	Equipo eléctrico trifásico sincronizado de la marca Weg.	11
Figura 3.	Máquina eléctrica trifásica de inducción.	12
Figura 4.	Procedimiento de Selección en Random Forests..	17
Figura 5.	Modelo de clasificación basado en un árbol de decisiones.	21
Figura 6.	Clasificación mediante Random Forest..	24
Figura 7.	Modelo de SVM aplicado a tareas de categorización..	25
Figura 8.	Comparación de Redes Neuronales: Monocapa vs. Multicapa.	26
Figura 9.	Características en redes neuronales para reconocimiento facial.	27
Figura 10.	Red Neuronal Recurrente (RNN) con retroalimentación.	28
Figura 11.	Motor Eléctrico.	36
Figura 12.	Curvas características de par-velocidad en motores de inducción.	38
Figura 13.	Sistema de retardo.	39
Figura 14.	Flujo de potencia de un sistema de retardo.	40
Figura 15.	Parrilla de retardo.	41
Figura 16.	Monitoreo de parámetros relacionados con un motor eléctrico de tracción. ...	42
Figura 17.	Límites de temperatura para rodamientos DE.	43
Figura 18.	Límites de temperatura para rodamientos NDE.	43
Figura 19.	Daño en conexión neutra del estator del motor de tracción.	46
Figura 20.	Presencia de contaminación por aceite en el motor de tracción.	46
Figura 21.	Inspección de componentes internos del motor.	47
Figura 22.	Evidencia de contaminación por aceite en el motor de tracción.	47
Figura 23.	Identificación de partes.	49
Figura 24.	Corriente de excitación al generador.	49
Figura 25.	Ubicación de sensores RTD.	51
Figura 26.	Límites de Temperatura en cojinete.	53
Figura 27.	Límites de Temperatura en devanado.	54

Figura 28.	Acumulación de Eventos por mes.....	56
Figura 29.	Zoom al periodo a partir del 2024.....	57
Figura 30.	Cantidad de eventos por mes Camión.....	59
Figura 31.	Boxplot de la tendencia para los camiones usando tendencia máxima.....	60
Figura 32.	Boxplot de la tendencia para cada uno de los camiones para el año 2024.....	60
Figura 33.	Boxplot izquierdo con la data antes 2024, boxplot derecho desde el 2024.....	61
Figura 34.	Tendencia Electric Retarding Grid Power Consumption por camión.....	63
Figura 35.	Matriz de correlación para las tendencias en sus valores mínimos.....	63
Figura 36.	Matriz de correlación para las tendencias en sus valores máximos.	64
Figura 37.	Matriz de correlación para las tendencias en sus valores promedios.	64
Figura 38.	Correlación en el tiempo para las 2 tendencias por camión.....	66
Figura 39.	Correlación en el tiempo para las 2 tendencias y las señales por camión.	69
Figura 40.	Gráfico por mes contabilizando la cantidad que sobrepasan los límites.....	72
Figura 41.	Gráfico de la tendencia y su valor acumulado en rojo.	75
Figura 42.	Gráfica de la altitud, payload y potencia de grid por camión.	77
Figura 43.	Matriz de correlación de Corriente y temperatura de los módulos de fase.	78
Figura 44.	Correlación en el tiempo de la temperatura y corriente de los módulos.....	80
Figura 45.	Potencia de los motores y la diferencia en verde.	82
Figura 46.	Generación de datos.....	84
Figura 47.	Aplicación de Variación Anova para normalización de datos.	84
Figura 48.	Datos de entrenamiento.....	85
Figura 49.	Datos de validación.....	85
Figura 50.	Datos de entrenamiento a partir de la variación ANOVA.	86
Figura 51.	Visualización del entrenamiento para Random Forest y SVM.....	87
Figura 52.	Visualización del entrenamiento de la Red Neuronal Artificial (ANN).	87
Figura 53.	Entrenamiento de la red neuronal utilizando el algoritmo Levenberg- Marquardt	89
Figura 54.	Regresión del rendimiento de la red neuronal.....	90
Figura 55.	Evolución del gradiente en la red neuronal.....	92

Figura 56.	Histograma de errores y desempeño de validación durante el entrenamiento de la red neuronal.	92
Figura 57.	Comparación de modelos de predicción de RUL.	93
Figura 58.	Comparación del rendimiento de los modelos.	94
Figura 59.	Proyección del indicador de salud.	96

RESUMEN

Este trabajo tiene como propósito desarrollar un indicador de salud que permita predecir de forma confiable la vida útil de motores eléctricos utilizados en equipos de gran minería, haciendo uso de algoritmos de aprendizaje supervisado. Para lograrlo, se partió del análisis de datos históricos de operación y mantenimiento, identificando las variables que influyen directamente en el desgaste y funcionamiento de estos motores. A lo largo del estudio, se construyeron y entrenaron modelos predictivos empleando algoritmos como Random Forest, Support Vector Machines (SVM) y redes neuronales artificiales, todo dentro del entorno MATLAB. Una vez desarrollados, estos modelos fueron validados mediante simulaciones, con el objetivo de comprobar su capacidad para anticipar fallas y, así, mejorar las estrategias de mantenimiento predictivo. La metodología incluyó varias etapas clave: primero, se recopilaron datos históricos relevantes; luego, estos se prepararon mediante técnicas de filtrado y normalización. También se realizó un análisis de monotonidad para seleccionar las variables más representativas. Con esta información, se entrenaron los modelos de predicción aplicando reducción de dimensiones a través del Análisis de Componentes Principales (PCA). Finalmente, se evaluó el desempeño de los modelos usando métricas como el Error Cuadrático Medio (MSE), el Error Absoluto Medio (MAE), la Raíz del Error Cuadrático Medio (RMSE) y el Error Porcentual Absoluto Medio (MAPE). Los resultados obtenidos evidencian que el modelo basado en Red Neuronal Artificial (ANN) presentó el mejor desempeño general, al registrar el menor MSE (716.75), así como los valores más bajos de MAE (24.38), RMSE (26.77) y MAPE (77.65%), en comparación con Support Vector Machines (SVM) y Random Forest. La simulación del indicador de salud mostró una degradación progresiva del motor eléctrico a lo largo del tiempo, permitiendo predecir el tiempo restante hasta alcanzar un umbral crítico. En conclusión, la implementación del indicador de salud podría mejorar la gestión del mantenimiento predictivo, optimizando la disponibilidad de los equipos y reduciendo los costos asociados a fallas inesperadas.

Palabras claves: aprendizaje supervisado, mantenimiento predictivo, minería, motores eléctricos, vida útil.

ABSTRACT

The objective of this work is to design a health indicator based on supervised learning algorithms to predict the useful life of electric motors in large mining equipment. For this purpose, the variables that affect the health and useful life of electric motors were identified from the analysis of historical operation and maintenance data. In addition, supervised learning models were developed and trained using algorithms such as Random Forest, Support Vector Machines (SVM) and artificial neural networks in MATLAB environment. Finally, the simulation and validation of the health indicator was carried out in order to evaluate its accuracy in failure prediction and predictive maintenance optimization. The methodology employed included the collection of historical data, its preprocessing using filtering and normalization techniques, and the selection of relevant features using monotonicity analysis. Subsequently, the service life prediction models were trained by applying dimension reduction techniques such as principal component analysis (PCA) and evaluating their performance by means of different metrics: Mean Squared Error (MSE), Mean Absolute Error (MAE), Root Mean Squared Error (RMSE) and Mean Absolute Percentage Error (MAPE). The results obtained show that the model based on Artificial Neural Network (ANN) presented the best overall performance, registering the lowest MSE (716.75), as well as the lowest values of MAE (24.38), RMSE (26.77) and MAPE (77.65%), compared to Support Vector Machines (SVM) and Random Forest. The simulation of the health indicator showed a progressive degradation of the electric motor over time, allowing to predict the remaining time to reach a critical threshold. In conclusion, the implementation of the health indicator could improve predictive maintenance management, optimizing equipment availability and reducing costs associated with unexpected failures.

Keywords: supervised learning, predictive maintenance, mining, electric motors, service life.

INTRODUCCIÓN

El mantenimiento eficiente de los motores eléctricos en equipos de gran minería es un factor determinante para garantizar la operatividad continua y la optimización de los costos asociados a fallas inesperadas. En la minería, donde el entorno de trabajo es particularmente hostil y el suministro de equipos significa poder, el mantenimiento predictivo se ha convertido en una forma clave de lograr una mayor fiabilidad de los activos y reducir costos. Hasta hoy, el mantenimiento de espectro se ha basado en planes de mantenimiento preventivo o correctivo, con reparaciones e intervenciones erróneas que pudieron haber llevado a costosas reparaciones debido a causas no calculadas.

En este escenario, aplicar el aprendizaje supervisado utilizando modelos avanzados para predecir la vida útil del motor eléctrico se puede garantizar una mejor estimación del momento en que se debe realizar algún mantenimiento. El objetivo de este estudio es desarrollar un indicador de salud que permita estimar la vida restante de las máquinas eléctricas con la ayuda de modelos basados en aprendizaje supervisado, como Bosques Aleatorios, Máquinas de Soporte Vectorial (SVM) y Redes Neuronales Artificiales (ANN). El enfoque se basa en la recopilación y análisis de datos históricos de Operaciones y Mantenimiento (O&M) para aislar variables críticas que influyen en el rendimiento del motor.

A través del pre-procesamiento de datos, la normalización de datos y la selección de las características más informativas basadas en métodos como ANOVA, se busca mejorar la calidad de la información que se proporcionará al modelo predictivo. Esta supresión se implementa en MATLAB, se desarrolla un algoritmo de diseño y entrenamiento para implementar el indicador de salud propuesto. Los modelos se evalúan en base a criterios de error como el error cuadrático medio (MSE) para identificar la técnica más precisa en la predicción de la vida útil restante. El resultado obtenido permite evaluar los modelos en su capacidad para predecir fallas y, eventualmente, gestionar el mantenimiento para reducir los costos operativos, mejorando la disponibilidad del equipo. Así, la implementación de un indicador de salud utilizando aprendizaje supervisado como solución ofrece a la minería la posibilidad de contar con herramientas de monitoreo que contribuyen al proceso de toma de decisiones de una manera efectiva y operativa.

CAPÍTULO I

PLANTEAMIENTO DEL ESTUDIO

1.1 Planteamiento del problema

En la industria moderna, los motores eléctricos son indispensables en muchas operaciones de fabricación. Una avería inesperada puede llevar a un tiempo de inactividad, pérdida de productividad y reparaciones costosas. Las industrias de hoy en día generalmente dependen de programas de mantenimiento preventivo (PM) basados en el tiempo o en condiciones que desencadenan inspecciones periódicas, cuyos parámetros podrían no ser siempre efectivos. En tales casos, es un conocimiento previo que las técnicas antes descritas no proporcionan una descripción suficiente del estado de salud real de los motores y, por lo tanto, resultan en un mantenimiento excesivo o inadecuado (1).

El problema central radica en encontrar un método que pueda ayudar a determinar de manera precisa y eficiente la salud de los motores eléctricos de tracción, y en particular de los motores de jaula de ardilla utilizados para equipos de minería de gran tamaño. Mediante algoritmos de aprendizaje supervisado, se espera construir un indicador de salud que incorpore una amplia gama de datos operativos como temperatura, vibraciones, corriente y condiciones de funcionamiento del motor, para predecir fallos con antelación antes de que ocurran. El propósito de esta estrategia es optimizar los planes de mantenimiento, minimizar paradas imprevistas y reducir gastos operativos. En el curso de este estudio, se va a identificar los datos operativos más adecuados, establecer los medios apropiados para procesarlos y elegir algoritmos predictivos cuya prognosis sea confiable. Este diseño de indicador de salud, basado en tecnología de aprendizaje automático, está dirigido a proporcionar un método eficaz para predecir la vida útil de los motores de jaula de ardilla en equipos de minería de gran tamaño

1.1.1 Problema general

¿Cómo diseñar un indicador de salud basado en algoritmos de aprendizaje supervisado que permita predecir con precisión la vida útil de motores eléctricos en equipos de gran minería?

1.1.2 Problemas específicos

- a) ¿Cuáles son las variables que más influyen en la salud y la vida útil de los motores eléctricos, según el análisis de datos históricos de operación y mantenimiento?

- b) ¿Cómo desarrollar y entrenar modelos de aprendizaje supervisado en MATLAB, utilizando algoritmos como Random Forest, SVM, y redes neuronales, para predecir la vida útil de los motores eléctricos?
- c) ¿Qué tan preciso es el indicador de salud diseñado en MATLAB para predecir fallas y optimizar el mantenimiento predictivo de los motores eléctricos?

1.2 Objetivos

1.2.1 Objetivo general

Diseñar un indicador de salud basado en algoritmos de aprendizaje supervisado para predecir la vida útil de motores eléctricos en equipos de gran minería.

1.2.2 Objetivos específicos

- a) Identificar las variables que afectan la salud y la vida útil de los motores eléctricos mediante el análisis de datos históricos de operación y mantenimiento.
- b) Desarrollar y entrenar modelos de aprendizaje supervisado en MATLAB utilizando algoritmos como Random Forest, Support Vector Machines (SVM), y redes neuronales artificiales para predecir la vida útil de los motores.
- c) Simular y validar el indicador de salud en MATLAB para evaluar su precisión en la predicción de fallas y optimización del mantenimiento predictivo.

1.3 Justificación e importancia

La investigación sobre el diseño de un indicador de salud para la predicción de la vida útil de los motores eléctricos es de gran importancia en la industria, ya que es un factor clave para la estabilidad y sostenibilidad del negocio, especialmente cuando los esfuerzos coordinados en eficiencia y prevención de fallas son esenciales. Prevenir problemas antes de que ocurran no solo reduce el mantenimiento, las reparaciones y los gastos asociados, sino que maximiza la seguridad y la eficiencia en las operaciones industriales. Este enfoque proactivo, basado en datos y tecnologías avanzadas, es esencial para la transición hacia la Industria 4.0 y la modernización de procesos industriales.

1.3.1 Justificación social

Desde una perspectiva social, esta investigación representa un aporte importante para mejorar la seguridad en el trabajo y disminuir los riesgos en ambientes industriales. Los motores eléctricos, al ser piezas clave en muchas operaciones, pueden representar un peligro si fallan de

manera repentina, especialmente en lugares donde se manipulan materiales peligrosos o donde los procesos están fuertemente automatizados. Contar con un sistema que permita prever posibles fallas ayuda a prevenir accidentes, lo que se traduce en condiciones laborales más seguras y protegidas para los trabajadores. A su vez, un mantenimiento más eficiente reduce la presión y la incertidumbre que generan los paros imprevistos, fomentando un clima laboral más tranquilo y confiable. Este tipo de mejoras no solo impactan positivamente en quienes laboran directamente con estos equipos, sino también en las comunidades cercanas, ya que se disminuye la posibilidad de que ocurran incidentes industriales de mayor alcance.

1.3.2 Justificación económica

Desde el punto de vista económico, esta investigación juega un papel clave en la disminución de los gastos relacionados con el mantenimiento y funcionamiento de los motores eléctricos en entornos industriales. Poder anticipar con mayor exactitud cuánto tiempo funcionará un motor permite a las empresas organizar mejor sus labores de mantenimiento, evitando intervenciones de urgencia costosas y detenciones inesperadas en la producción, las cuales pueden afectar seriamente los ingresos y el rendimiento general. Además, contar con un modelo predictivo bien afinado ayuda a prolongar la vida útil de los motores, ya que permite intervenir en el momento justo, con acciones específicas que evitan reemplazos innecesarios. Esto no solo significa un ahorro económico directo, sino también una mejor gestión de los recursos y una mayor rentabilidad a largo plazo. En un mercado cada vez más competitivo, donde la eficiencia y la optimización de costos son prioridades constantes, aplicar este tipo de tecnología representa una ventaja estratégica para las empresas que deciden apostar por la innovación.

1.3.3 Justificación teórica

Desde el enfoque teórico, esta investigación representa un aporte importante al crecimiento y mejora de las estrategias de mantenimiento predictivo impulsadas por inteligencia artificial, en particular mediante el uso de algoritmos de aprendizaje supervisado. No solo se exploran nuevos modelos que buscan hacer las predicciones más precisas y eficaces, sino que también se plantea una guía metodológica que puede servir como referencia o adaptarse a distintos entornos industriales o a otros tipos de maquinaria. Además, este trabajo sienta las bases para futuras investigaciones que busquen integrar diversas fuentes de información como sensores IoT, datos operativos en tiempo real y registros históricos de mantenimiento dentro de un sistema integral para monitorear la salud de los equipos. Con ello, se fortalece el conocimiento en áreas como la ingeniería de confiabilidad, el aprendizaje automático en aplicaciones

industriales y la gestión inteligente de activos, abriendo paso a la innovación y al desarrollo de nuevas tecnologías dentro del sector.

1.3.4 Importancia

El valor de esta investigación radica en su capacidad para optimizar la gestión del ciclo de vida de los motores eléctricos dentro de ambientes industriales exigentes. Al diseñar un indicador de salud basado en algoritmos de aprendizaje supervisado, se propone una forma más proactiva y orientada por datos para realizar el mantenimiento de equipos clave. Gracias a este enfoque, no solo se logra reducir las interrupciones inesperadas y los costos asociados a reparaciones, sino que también se favorece una mayor durabilidad de los activos, contribuyendo así a una operación más eficiente y sostenible.

Mirando el panorama general, este trabajo respalda el camino hacia la Industria 4.0, al impulsar la digitalización y el uso de herramientas tecnológicas avanzadas que potencian la productividad y la competitividad de las empresas. Además, al disminuir las probabilidades de fallas y reforzar la seguridad en el entorno laboral, los beneficios de esta investigación se extienden más allá del aspecto técnico, generando un impacto positivo tanto en los resultados económicos como en la responsabilidad social empresarial y el cuidado del medio ambiente.

1.4 Limitaciones de la investigación

Aunque MATLAB es una herramienta muy útil para realizar simulaciones, no siempre logra reflejar con exactitud todas las complejidades que se presentan en un entorno industrial real, lo que podría influir en la precisión de las predicciones cuando se aplican en condiciones de operación concretas.

Por otro lado, los modelos más avanzados pueden requerir una gran capacidad de procesamiento y tiempos de entrenamiento prolongados, lo cual podría representar una barrera para aquellas empresas que no cuentan con infraestructura tecnológica de alto nivel.

Además, este estudio está centrado específicamente en motores eléctricos utilizados en la gran minería, por lo que los resultados y el indicador de salud propuesto podrían no aplicarse directamente a otros sectores o a motores con características distintas como aquellos de menor potencia, usados en contextos urbanos o en la mediana minería. Por ello, será necesario realizar investigaciones adicionales que permitan validar la flexibilidad y solidez del modelo en distintos entornos productivos.

Finalmente, si bien se confirma que el enfoque es técnicamente viable, no se ha llevado a cabo una implementación piloto en un entorno industrial real. Esto limita la posibilidad de evaluar factores clave como la integración con sistemas existentes, el comportamiento del sistema en condiciones extremas, la frecuencia con que requeriría mantenimiento y la aceptación que tendría entre los operarios.

1.5 Hipótesis y descripción de variables

1.5.1 Hipótesis general

El diseño de un indicador de salud utilizando algoritmos de aprendizaje supervisado permitirá predecir con alta precisión la vida útil de motores eléctricos en equipos de gran minería, mejorando así la eficiencia del mantenimiento predictivo y reduciendo la ocurrencia de fallas inesperadas en entornos industriales.

1.5.2 Hipótesis específicas

- a) La identificación de las variables clave que afectan la salud y la vida útil de los motores eléctricos, a través del análisis de datos históricos de operación y mantenimiento, permitirá mejorar la precisión en la predicción de fallas.
- b) El desarrollo y entrenamiento de modelos de aprendizaje supervisado en MATLAB, utilizando algoritmos como Random Forest, SVM y redes neuronales artificiales, proporcionará predicciones más precisas de la vida útil de los motores eléctricos.
- c) La simulación y validación del indicador de salud en MATLAB demostrará su efectividad en la predicción de fallas y en la optimización del mantenimiento predictivo de motores eléctricos, reduciendo tiempos de inactividad y costos operativos.

1.6 Descripción de variables

1.6.1 Variable 1: independiente

- Indicador de salud
- Algoritmos de aprendizaje supervisado

1.6.2 Variable 2: dependiente

- Vida útil de los motores eléctricos

1.6.3 Operacionalización de variables

Tabla 1. Descripción y operacionalización de variables.

VARIABLES	DEFINICION CONCEPTUAL	DIMENSIÓN	INDICADORES	UNIDAD DE MEDIDA
Vida útil de los motores eléctricos	Se refiere al periodo durante el cual un motor eléctrico puede funcionar de manera efectiva y segura antes de requerir reparaciones significativas o reemplazo, influenciada por factores como desgaste, condiciones de operación y mantenimiento.	Durabilidad	Tiempo promedio hasta la falla (MTTF)	(h)
		Rendimiento Operacional	Frecuencia de mantenimiento	(mant/h)
Indicador de salud	Es una herramienta analítica que evalúa el estado operativo de un motor eléctrico para predecir posibles fallas y optimizar el mantenimiento preventivo y predictivo en entornos industriales.	Monitoreo de Condición	Vibraciones	(m/s ²)
			Temperatura	(°C)
		Evaluación Predictiva	Corriente	(A)
			Aislamiento del bobinado	(Ω)
Algoritmos de aprendizaje supervisado	Son métodos de inteligencia artificial que utilizan datos etiquetados para entrenar modelos predictivos. Estos algoritmos aprenden patrones y relaciones dentro de los datos para realizar predicciones precisas o clasificaciones sobre nuevas entradas en diferentes aplicaciones.	Precisión del Modelo	Frecuencia de fallas	(%)
			Índices de desgaste	(%)
			Tasa de aciertos	(%)
		Eficiencia del Algoritmo	Error cuadrático medio (MSE)	(A ²)
			Área bajo la curva (AUC)	(%)
			Tiempo de entrenamiento	(min)
			Velocidad de convergencia	(min)

CAPÍTULO II

MARCO TEÓRICO

2.1 Antecedentes de la investigación

2.1.1 Antecedentes internacionales

Según Chicaiza et al. (2021) (1) en su tesis “Sistema de monitoreo en nube para el diagnóstico predictivo de fallos de motores eléctricos”, tuvieron como objetivo evaluar el estado de los motores eléctricos en una planta cementera ubicada en Guayaquil, utilizando datos históricos como base para anticipar posibles fallas. Para ello, se aplicaron técnicas de aprendizaje automático supervisado, entrenando un modelo predictivo con registros previos de pruebas de mantenimiento. Como parte del desarrollo, se implementó un sistema de monitoreo en la nube, el cual permitió clasificar el estado de los motores y generar reportes de mantenimiento de manera automatizada. Los resultados obtenidos mostraron una precisión del 94.5 % al predecir el estado de los equipos, lo que se tradujo en una mejora significativa en la eficiencia operativa y una reducción considerable en los costos asociados al mantenimiento.

De acuerdo con Huertas (2020) (2) en su tesis “Algoritmos de aprendizaje supervisado utilizando datos de monitoreo de condiciones: un estudio para el pronóstico de fallas en máquinas”, tuvo como propósito evaluar el estado de los motores eléctricos en una planta de cemento ubicada en Guayaquil, a través de la predicción de posibles fallas utilizando registros históricos. Para ello, se recopilaban datos de funcionamiento de más de 900 motores, los cuales fueron procesados mediante un software especializado en mantenimiento predictivo. Como parte del trabajo, se diseñó un sistema de monitoreo en la nube que permite clasificar el estado de los motores, analizar tendencias de comportamiento y generar reportes de mantenimiento de manera automatizada. Los resultados evidenciaron que el sistema desarrollado logró cumplir con los objetivos establecidos, resaltando especialmente por su facilidad de uso y la posibilidad de acceder a la información de forma remota.

Según Vargas (2021) (3) en su trabajo fin de grado “Detección de anomalías en un motor eléctrico mediante inteligencia computacional”, tuvo como objetivo desarrollar una metodología para diagnosticar fallos en motores eléctricos trifásicos de corriente alterna, utilizando herramientas de Inteligencia Computacional y aprendizaje automático. La propuesta metodológica se apoyó en el uso de Redes Neuronales Artificiales (RNA), sistemas neurodifusos y un esquema de toma de decisiones basado en OWA-RIM. Para alimentar el sistema, se recopilaban datos como la tensión, la corriente y el par del motor, obtenidos

mediante distintos dispositivos de medición. Los resultados demostraron que el sistema fue capaz de reconocer con precisión tanto los modos normales de operación como las fallas, lo que permitió detectar anomalías de manera temprana y mejorar la planificación del mantenimiento preventivo en entornos industriales.

2.1.2 Antecedentes nacionales

Según Alborno (2021) (4), en el estudio titulado “Aplicación del aprendizaje automático supervisado en el mantenimiento predictivo de motores eléctricos de inducción en las empresas mineras del Perú”, tuvo como propósito aplicar técnicas de aprendizaje automático supervisado para fortalecer el mantenimiento predictivo de motores de inducción dentro del sector minero en el Perú. Para ello, se diseñó una metodología que comparó dos enfoques distintos: uno basado en métodos tradicionales y otro apoyado en algoritmos de aprendizaje supervisado. Durante el proceso, se realizaron mediciones del estado del aislamiento del bobinado, así como análisis de las vibraciones mecánicas y del comportamiento de la corriente en el estator. Los hallazgos revelaron que el enfoque basado en inteligencia artificial logró mejorar significativamente la precisión y confiabilidad del mantenimiento predictivo, facilitando la detección anticipada de fallas y contribuyendo a una mejor gestión de los tiempos operativos de los motores.

Según Adauto (2021) (5), en su tesis titulada “Aplicación de la inteligencia artificial en la detección de fallas en motores eléctricos de corriente continua de imán permanente”, tuvo como finalidad aplicar técnicas de inteligencia artificial para detectar fallas en motores eléctricos de este tipo. Para ello, se llevaron a cabo pruebas bajo condiciones controladas, donde se recopiló información clave relacionada con el aislamiento de los devanados, las vibraciones mecánicas y el comportamiento de las corrientes. Los resultados evidenciaron que el uso de inteligencia artificial contribuyó de forma notable a mejorar la confiabilidad y eficiencia del mantenimiento predictivo, disminuyendo la probabilidad de fallas imprevistas y favoreciendo un mejor rendimiento de los motores eléctricos en entornos industriales.

Finalmente, de acuerdo con Contreras (2020) (6), en su tesis titulada “Diseño de un modelo para mantenimiento predictivo en motores de inducción utilizando técnicas de la Industria 4.0”, tuvo como propósito desarrollar un modelo de mantenimiento predictivo para motores de inducción, aprovechando las tecnologías avanzadas propias de la Industria 4.0. Para ello, se aplicó una metodología basada en la recolección y análisis de datos experimentales vinculados a fallas en rodamientos. Con esa información, se entrenó un modelo utilizando algoritmos de aprendizaje supervisado, como KNN, SVM y Random Forest. Además, se evaluaron distintos algoritmos de clasificación con el fin de identificar cuál ofrecía mejores resultados en la

detección de fallas. Los hallazgos mostraron que el modelo fue capaz de predecir con precisión el estado de los rodamientos, lo que permitió anticiparse a posibles fallos, mejorar las acciones de mantenimiento y reducir tanto las paradas inesperadas como los costos operativos dentro del entorno industrial.

2.2 Bases teóricas

2.2.1 Motores eléctricos

Los motores trifásicos de corriente alterna, son muy utilizados en el sector industrial debido a su alta eficiencia y su capacidad para trabajar con cargas pesadas. Su principio de funcionamiento se basa en la generación de un campo magnético rotativo a partir de tres fases de corriente alterna, lo que pone en movimiento el rotor y genera energía mecánica. Este tipo de motor suele emplearse en equipos como bombas, ventiladores, compresores y diversas máquinas industriales. Gracias a su estructura simple, su fiabilidad y su capacidad para operar de forma continua, se han convertido en una opción preferida en entornos industriales donde se requiere un alto rendimiento con un mantenimiento mínimo (8).

Su funcionamiento consiste en convertir la energía eléctrica en movimiento mecánico a través de tres fases de corriente alterna, las cuales generan un campo magnético giratorio en el estator. Este campo, a su vez, induce una corriente en el rotor, lo que produce el movimiento. Debido a su capacidad para trabajar con cargas exigentes de forma eficiente, son ampliamente utilizados en diversos entornos industriales. Además, su diseño simple y con pocas partes móviles facilita el mantenimiento y prolonga su vida útil, lo que los convierte en una opción confiable para operaciones continuas (9). Una característica importante de estos motores es que su dirección de giro puede invertirse fácilmente cambiando la conexión de dos de las fases del estator. Al hacer este ajuste, el campo magnético cambia de sentido, lo que hace que el motor gire en la dirección contraria. Esta capacidad resulta especialmente útil en entornos industriales donde es necesario adaptar el sentido de rotación del motor según las necesidades específicas de operación (10).



Figura 1. *Motor de Corriente Alterna Trifásico. (10).*

La figura 1 presenta un motor trifásico de corriente alterna, un tipo de máquina eléctrica muy común en el sector industrial por su capacidad para manejar cargas pesadas y su notable eficiencia. Su funcionamiento se basa en el uso de tres fases de corriente alterna que generan un campo magnético giratorio en el estator, el cual interactúa con el rotor para generar el movimiento mecánico que requieren distintos equipos. Este tipo de motor está diseñado para operar en condiciones exigentes, y se reconoce por su tamaño considerable, un sistema de ventilación que ayuda a disipar el calor, ganchos que facilitan su traslado y una estructura sólida que asegura una larga vida útil. Además, destaca por su eficiencia energética, su bajo requerimiento de mantenimiento y su capacidad para regular velocidad y torque mediante el uso de variadores de frecuencia, lo que lo convierte en una opción confiable y adaptable para una amplia gama de aplicaciones industriales.

Los motores trifásicos de corriente alterna juegan un papel fundamental en la industria, ya que permiten transformar la energía eléctrica en movimiento mecánico. Su principio de funcionamiento se basa en tres fases de corriente alterna que generan un campo magnético rotatorio, el cual hace girar el rotor y produce el movimiento necesario para operar distintos equipos. Este tipo de motor es ideal para tareas que demandan alta eficiencia y funcionamiento continuo durante largas jornadas. Su estructura simple formada por un estator, un rotor y componentes adicionales como sistemas de enfriamiento les brinda resistencia, una larga vida útil y un mantenimiento más sencillo. Son ampliamente utilizados gracias a su capacidad para trabajar con cargas industriales exigentes de forma eficaz y confiable. (11). Una de sus

principales fortalezas es su eficiencia energética, ya que pueden funcionar a plena capacidad consumiendo menos energía que otros tipos de motores eléctricos. Además, gracias a su compatibilidad con variadores de frecuencia, es posible ajustar tanto la velocidad como el torque según las necesidades del proceso, lo que los convierte en una alternativa versátil y fácil de adaptar a distintas aplicaciones dentro del entorno industrial (12).

Un motor trifásico de corriente alterna está formado, en esencia, por tres componentes principales: el estator, el rotor y un sistema de enfriamiento. El estator, que permanece fijo, contiene los bobinados encargados de recibir la corriente trifásica. En cambio, el rotor que es la parte que se mueve gira dentro del estator gracias al efecto de los campos magnéticos que se generan. Este tipo de motor se caracteriza por su capacidad para operar de manera continua durante largos periodos, lo que lo convierte en una alternativa ideal para entornos industriales donde se valoran la durabilidad y la confiabilidad (9).




Figura 2. *Equipo eléctrico trifásico sincronizado de la marca Weg. (10).*

La figura 2 muestra un componente que forma parte de un sistema mecánico o de un motor, donde se destacan unas barras diseñadas especialmente para absorber impactos. Estas estructuras tienen como función principal reducir vibraciones o aumentos repentinos de energía, ayudando a mantener la estabilidad del sistema y disminuyendo el esfuerzo mecánico sobre sus partes. Tanto el tipo de material utilizado como la forma en que estas barras están ubicadas resultan clave para suavizar los cambios de carga, protegiendo así el equipo y mejorando su rendimiento en general. Al estar ubicadas en la parte externa, se entiende que están pensadas para trabajar junto con otros elementos mecánicos que requieren una gestión eficaz de vibraciones o fuerzas dinámicas (10).




Figura 3. *Máquina eléctrica trifásica de inducción. (10).*

El buen funcionamiento de los motores trifásicos de corriente alterna se debe a su diseño robusto y versátil. El estator, que es la parte fija del motor, contiene los bobinados por donde circula la corriente eléctrica, generando un campo magnético que hace girar al rotor. Esta interacción entre ambos componentes permite un rendimiento constante y confiable. Por ello, este tipo de motores es muy utilizado en sectores como la industria manufacturera, la minería y la generación de energía. Además, su diseño facilita su integración con sistemas de control de frecuencia, lo que permite regular la velocidad y el torque según las necesidades del proceso, ampliando así su campo de aplicación (12).

El funcionamiento de los motores eléctricos trifásicos se basa en la interacción entre su parte fija donde se encuentran los bobinados correspondientes a las tres fases y el rotor, que gira gracias al campo magnético generado. Este tipo de diseño permite un arranque suave y una distribución equilibrada de la carga entre las fases, lo que mejora su desempeño general. Además, estos motores de corriente alterna pueden configurarse en conexiones tipo estrella o triángulo, lo que permite adaptarlos a diferentes niveles de voltaje y corriente, haciéndolos una opción flexible y adecuada para múltiples usos industriales (13).

2.2.2 Ventajas de los motores trifásicos de corriente alterna

Una característica destacada de estos motores es la posibilidad de ajustar su velocidad utilizando controladores de frecuencia, lo que facilita una regulación exacta del torque y la velocidad para adaptarse a necesidades particulares. Esto resulta especialmente beneficioso en sectores industriales que demandan mayor adaptabilidad en el desempeño de sus máquinas. Además, los motores trifásicos se distinguen por su durabilidad y por requerir un

mantenimiento simple, lo que contribuye a disminuir los gastos operativos a lo largo del tiempo y a reducir los períodos de inactividad (13).

Estos equipos ofrecen múltiples beneficios destacados: son altamente eficientes en el consumo de energía, adecuados para manejar grandes cargas y presentan una notable confiabilidad. La simplicidad de su diseño contribuye a que necesiten poco mantenimiento, lo que los hace una opción económica para diversos usos en el ámbito industrial. Su habilidad para ajustar velocidad y torque mediante controladores de frecuencia les otorga una gran versatilidad operativa, adaptándose a distintos escenarios y necesidades. Por su estructura robusta y bajo coste de operación, son fundamentales en actividades industriales que demandan un rendimiento continuo y constante (13).

2.2.3 Mantenimiento de los motores trifásicos de corriente alterna

Para asegurar un rendimiento óptimo y evitar fallas importantes que puedan afectar las operaciones, es fundamental realizar inspecciones regulares en partes esenciales de los motores trifásicos, como los cojinetes, las bobinas y el sistema de enfriamiento. En el ámbito industrial, aplicar estrategias de cuidado preventivo y predictivo resulta crucial para maximizar la eficiencia del equipo y extender su durabilidad, garantizando un funcionamiento continuo y confiable (8).

Para asegurar un desempeño sostenido a lo largo del tiempo, es fundamental realizar el cuidado adecuado de estos motores. Existen dos enfoques principales: mantenimiento proactivo y correctivo. El mantenimiento proactivo se enfoca en inspecciones regulares con el objetivo de identificar y prevenir posibles problemas antes de que se manifiesten, como verificar la alineación del eje, evaluar el estado de los cojinetes y limpiar el sistema de enfriamiento. Por otro lado, el mantenimiento correctivo se aplica cuando el motor experimenta una avería, requiriendo reparaciones específicas para devolverlo a su condición ideal de operación (9).

2.2.4 Vida útil de los motores eléctricos

El arranque de un motor eléctrico puede influir directamente en su longevidad. Métodos como el arranque directo o el uso de arrancadores estrella-triángulo generan picos elevados de corriente y par, lo que ocasiona esfuerzos mecánicos y térmicos significativos. Esto puede acelerar el desgaste de los componentes, reduciendo la vida útil del motor. En cambio, el uso de variadores de velocidad permite un arranque más controlado, disminuyendo el estrés mecánico y mejorando la durabilidad del motor (14).

La vida útil de un motor eléctrico está vinculada al manejo adecuado de variables como la corriente, el torque y la velocidad. El monitoreo y control constante de estas magnitudes, especialmente durante el arranque, permite minimizar las perturbaciones en la red eléctrica y los esfuerzos excesivos en los componentes del motor, prolongando así su funcionalidad (14).

Los variadores de velocidad son dispositivos electrónicos que ajustan la frecuencia y tensión del motor, permitiendo un arranque y parada controlados. Este método no solo mejora la eficiencia operativa, sino que también reduce el calentamiento y los golpes mecánicos, factores que contribuyen significativamente al desgaste y, por ende, a la vida útil del equipo (14).

2.2.5 Indicador de salud

Un indicador de salud basado en algoritmos de aprendizaje supervisado permite evaluar el estado operativo de motores eléctricos en equipos críticos. Este enfoque utiliza datos históricos y en tiempo real, como vibraciones, temperatura, corriente y ciclos de operación, para predecir la vida útil restante del motor. Algoritmos como Random Forest, SVM o redes neuronales procesan estas variables, identificando patrones que anticipan fallas. Este indicador no solo optimiza la planificación del mantenimiento, reduciendo costos y tiempos de inactividad, sino que también mejora la confiabilidad del sistema, asegurando operaciones continuas en entornos exigentes como la minería o la industria pesada (15).

Un indicador de salud basado en algoritmos de aprendizaje supervisado evalúa continuamente el estado de motores eléctricos, proporcionando una estimación precisa de su vida útil restante. Este enfoque integra técnicas de machine learning, como Random Forest, redes neuronales profundas o Support Vector Machines (SVM), para analizar datos operativos como: vibraciones, temperatura, corriente, frecuencia de fallas y desgaste. Al entrenar modelos predictivos con datos históricos y en tiempo real, es posible identificar patrones que anticipen fallas y optimizar el mantenimiento predictivo. Este indicador mejora la confiabilidad de los equipos al reducir interrupciones no planificadas, optimizar costos y maximizar la eficiencia operativa. En sectores como la minería, donde la maquinaria está sometida a condiciones extremas, este tipo de herramienta es esencial para asegurar la continuidad de las operaciones y prolongar la vida útil de los activos. Además, el uso de software como Matlab facilita el desarrollo de estos modelos, integrando simulación, análisis de datos y algoritmos avanzados en una sola plataforma (14).

2.2.6 Mantenimiento predictivo

Se centra en la supervisión constante y el análisis exhaustivo del estado del transformador, con el objetivo de identificar posibles fallos antes de que se manifiesten. Utilizando herramientas como el monitoreo de gases disueltos y sensores especializados, este método facilita la detección temprana de anomalías, permitiendo planificar intervenciones cuando sean necesarias. A diferencia del mantenimiento preventivo, este enfoque no sigue un cronograma fijo, sino que se basa en las condiciones reales del equipo. Aunque implica invertir en sistemas de monitoreo y capacitación del personal, resulta beneficioso al optimizar el desempeño del transformador, minimizar paradas inesperadas y maximizar su disponibilidad operativa (14).

Este enfoque de mantenimiento se centra en monitorear el estado operativo del equipo mientras se encuentra en funcionamiento normal. Para ello, se utilizan herramientas de medición en tiempo real o se analizan datos estadísticos obtenidos de pruebas regulares. Con los datos recopilados, se diseña un plan que permite sustituir o mejorar las piezas que muestren signos de desgaste. Esta metodología ayuda a prevenir fallos potenciales, mejora el rendimiento del equipo y extiende su vida útil mediante intervenciones focalizadas en los componentes que requieren atención (15).

El mantenimiento planificado, también conocido como preventivo, consiste en realizar actividades programadas con el propósito de prevenir fallos futuros. Este enfoque utiliza diversos recursos, como manuales técnicos, catálogos de repuestos, análisis estadísticos de fallas e incluso la experiencia del personal encargado. Con base en esta información, se determina la periodicidad de las inspecciones, el reemplazo de componentes clave y el análisis de factores como la probabilidad de averías y la durabilidad de los elementos. Esta estrategia garantiza un funcionamiento constante y eficiente de los equipos, prolongando su vida útil (16)

El mantenimiento predictivo utiliza herramientas tecnológicas avanzadas para el monitoreo constante y el análisis en tiempo real del estado del transformador. A través de sensores y dispositivos de diagnóstico, este enfoque identifica posibles fallos antes de que se manifiesten, permitiendo optimizar el uso de recursos y minimizar los gastos relacionados con reparaciones imprevistas. Este tipo de mantenimiento proporciona un análisis detallado del desempeño del transformador y facilita la adaptación del plan de mantenimiento según las condiciones operativas actuales, incrementando la eficiencia y extendiendo la durabilidad del equipo (5).

El mantenimiento preventivo puede clasificarse en diferentes tipos según el criterio utilizado para su planificación:

Mantenimiento programado por tiempo: también conocido como TMB (Time-Based Maintenance), este enfoque organiza las actividades de mantenimiento en intervalos regulares, definidos previamente por el responsable. Estas frecuencias pueden variar desde semanales hasta anuales, entre otros periodos. Si los intervalos son demasiado cortos, podrían ocasionar interrupciones innecesarias, mientras que plazos excesivamente largos podrían permitir el desgaste crítico de componentes antes de intervenir. Por ello, ajustar los tiempos de manera precisa es esencial para minimizar tanto las pérdidas operativas como los costos asociados.

Mantenimiento basado en condiciones: denominado CBM (Condition-Based Maintenance), este método se centra en monitorear continuamente parámetros clave del equipo para programar intervenciones únicamente cuando sea necesario. Utiliza sistemas de supervisión constante para identificar variaciones que superen los límites aceptables, indicando posibles riesgos de fallas futuras. Este enfoque permite abordar problemas potenciales antes de que se conviertan en averías mayores, ajustando las acciones de mantenimiento según el estado real del equipo, en lugar de intervalos fijos.

Mantenimiento orientado a la confiabilidad: conocido como RCM (Reliability-Centered Maintenance), esta estrategia combina diversos enfoques para optimizar las actividades de mantenimiento. Busca reducir costos y garantizar la confiabilidad operativa de los equipos, evaluando cómo cada posible falla impacta en el sistema. Esto permite priorizar los riesgos más importantes y diseñar un plan de intervención más eficiente, enfocado en maximizar la efectividad de los recursos disponibles (12).

2.2.7 Algoritmos de aprendizaje supervisado

2.2.7.1. Random Forest

Los Random Forests, también llamados bosques aleatorios, representan una evolución del enfoque Bagging, en el cual se construyen diversos árboles empleando el algoritmo CART. Posteriormente, las salidas o clasificaciones producidas por cada árbol se integran para obtener un resultado final. Este método tiene como objetivo principal disminuir la alta variabilidad que puede surgir al usar un único árbol para analizar nuevos conjuntos de datos, logrando así una notable mejora en la precisión y eficacia del modelo (14).

Los métodos conocidos como Random Forests se fundamentan en el uso de estructuras de árbol para tomar decisiones, empleando principios de la teoría de la información. Los algoritmos de árboles de decisión, denominados CART (Classification and Regression Trees), fueron presentados por Breiman y su equipo en 1984 como parte de los avances en estadística y

aprendizaje automático. Esta metodología se diseñó para crear árboles orientados a realizar predicciones, resultandos útiles tanto en tareas de clasificación como de regresión, lo que los convierte en una herramienta versátil y efectiva en diversos contextos predictivos (15).

El enfoque conocido como Random Forest es una estrategia de aprendizaje automático que emplea un conjunto de árboles de decisión independientes para resolver problemas tanto de clasificación como de regresión. La estimación definitiva se alcanza al combinar, generalmente mediante un promedio, las predicciones realizadas por cada árbol del grupo (16).

Los Random Forests sobresalen como uno de los métodos más rápidos y efectivos en el ámbito del machine learning, debido a la robustez y eficiencia inherente al modelo base de árboles de decisión en el que se apoyan. Su arquitectura confiable y de fácil implementación permite manejar grandes conjuntos de datos con alta exactitud, posicionándolos como una opción ampliamente utilizada para problemas de predicción y clasificación (16).

Los Random Forests consisten en un conjunto de árboles completos, cuya finalidad es generar una estimación o categoría general para la variable objetivo. En problemas de regresión, el resultado final se obtiene promediando las salidas de todos los árboles, mientras que, en tareas de clasificación, se elige la categoría con mayor cantidad de votos (la más recurrente entre los árboles). Similar a los modelos de árboles de decisión, los bosques aleatorios suelen superar a los métodos paramétricos convencionales, especialmente en escenarios donde las interacciones entre variables son complejas o las relaciones no presentan linealidad evidente (17).




Figura 4. Procedimiento de Selección en Random Forests. (15).

La figura 4, muestra una representación simplificada del funcionamiento de un modelo Random Forest en el contexto del machine learning. A continuación, se detallan los elementos principales del proceso:

- Datos de entrada: se refiere a las variables o características iniciales que el modelo analizará. Estas proporcionan la base para generar las estimaciones.
- Árboles de decisión: un Random Forest está formado por múltiples árboles independientes. Aunque en la ilustración se ven tres, en aplicaciones reales pueden ser muchos más (decenas o cientos). Cada árbol utiliza una muestra diferente de los datos y produce su propia predicción basándose en la información de entrada.
- Resultados individuales: cada árbol genera un resultado único (por ejemplo, Predicción 1, Predicción 2, etc.), a partir de los datos analizados.
- Combinación de resultados: una vez obtenidas las predicciones, el modelo las combina. En tareas de clasificación, se aplica una votación, seleccionando la clase más frecuente como el resultado final. En problemas de regresión, las predicciones individuales se promedian para llegar a un valor definitivo.
- Resultado final: tras procesar las predicciones mediante votación o promedio, el sistema genera la salida final, que representa la estimación del modelo (16).

Similar al enfoque de Bootstrap Aggregation (Bagging), los Random Forests pertenecen a una categoría de estrategias conocidas como métodos de ensamblaje. Estas técnicas destacan por su habilidad para transformar modelos básicos y menos confiables en sistemas significativamente más robustos, logrando así una alta precisión en las predicciones. Este enfoque busca precisamente potenciar el rendimiento de los árboles de decisión (17).

Los Random Forests resultan especialmente útiles cuando se necesita identificar las variables más influyentes en un modelo predictivo, ya que proporcionan métricas que indican su importancia relativa. Este enfoque es práctico porque, al igual que los árboles de decisión, puede manejar datos faltantes y procesar tanto variables categóricas como numéricas sin requerir la creación de variables dummy. Además, desde una perspectiva computacional, este método destaca por su capacidad de ejecutarse en paralelo, ya que cada árbol dentro del bosque se genera de manera independiente, lo que optimiza el tiempo de procesamiento y mejora la escalabilidad del algoritmo (17).

Los Random Forests se desarrollan creando un conjunto definido de muestras aleatorias (ntree) extraídas del conjunto de datos de entrenamiento, utilizando un método de selección con

reemplazo similar al Bootstrap. Aunque estas muestras incluyen ligeras variaciones aleatorias, conservan las características principales del proceso original que originó los datos (17).

El Random Forest es un método de aprendizaje automático que extiende el uso de los árboles de decisión. Su estrategia consiste en construir múltiples árboles utilizando distintos subconjuntos de datos y seleccionando variables al azar. Cada árbol genera su propia estimación, y la predicción final del modelo se obtiene combinando los resultados, generalmente mediante votación mayoritaria. Este enfoque mejora la precisión del modelo, reduce la posibilidad de sobreajuste y es especialmente eficiente para procesar grandes volúmenes de datos con muchas variables. Además, su capacidad para gestionar datos complejos y relaciones no lineales lo convierte en una herramienta valiosa en diversas aplicaciones (18).

El algoritmo Random Forest es una técnica de aprendizaje supervisado que se basa en la creación aleatoria de múltiples árboles de decisión. Este conjunto, conocido como “bosque”, está formado por numerosos árboles que, en la mayoría de los casos, se entrenan utilizando el método de bagging. La lógica central de este enfoque radica en que, al combinar varios modelos de aprendizaje, se logra optimizar el desempeño general del sistema. Es decir, al trabajar de manera conjunta con múltiples modelos, se obtiene un resultado más confiable y preciso en comparación con el uso de un único modelo por separado (19).

Los Random Forests destacan por su capacidad para procesar grandes volúmenes de datos, ya sean numéricos o categóricos, con un mínimo nivel de preprocesamiento. Este método es especialmente resistente al sobreajuste y puede gestionar interacciones complejas entre diversas variables. En el ámbito del mantenimiento de motores trifásicos, este enfoque analiza factores como la vibración, la temperatura, el consumo eléctrico y el historial de servicios previos. Esto permite que el modelo predictivo determine con precisión el tiempo restante antes de requerir mantenimiento, maximizando la vida útil del motor y previniendo fallos operativos imprevistos (20).

Como se mencionó anteriormente, el Random Forest es un algoritmo de clasificación que se construye a partir de varios clasificadores individuales, todos ellos basados en estructuras de árboles de decisión (21). Este sistema se estructura de la siguiente forma:

$$\{h(x, \theta_k), k = 1, 2, 3 \dots n\} \quad (1)$$

Dónde:

- θ_k son vectores aleatorios independientes e idénticamente distribuidos.
- x representa al vector de entrada. (21).

Cuando se introduce un vector de datos, cada árbol de decisión emite un voto para determinar la clasificación más adecuada. La construcción de un Random Forest sigue tres etapas principales:

- Primero, mediante la técnica de Bootstrap, se generan k subconjuntos de datos de entrenamiento a partir del conjunto original S , asegurando que cada subconjunto tenga el mismo tamaño que S .
- Luego, con estos k subconjuntos, se crean k modelos basados en árboles de decisión. En este proceso, se trabaja con un total de M variables de entrada, seleccionando aleatoriamente N de ellas. Cada nodo interno del árbol se divide utilizando un criterio de partición óptimo aplicado a las N variables seleccionadas, manteniendo N constante durante la construcción del modelo.
- Por último, las predicciones de los k árboles se combinan para obtener el resultado final. En tareas de clasificación, esta combinación se realiza a través de un sistema de votación por mayoría (21).

Conocidos por su habilidad para trabajar con datos complejos y su estructura fácil de entender, los árboles de decisión son modelos utilizados en análisis y aprendizaje automático para tomar decisiones basadas en criterios específicos. Estos modelos dividen los datos en subconjuntos más pequeños, formando una estructura jerárquica similar a un árbol. En esta estructura, los nodos internos representan atributos o características de los datos, las ramas indican decisiones derivadas de esos atributos, y los nodos terminales o hojas corresponden a las categorías finales o resultados obtenidos (21).

A continuación, se presentan aspectos esenciales sobre los árboles de decisión:

a) Organización jerárquica:

- Raíz: el nodo principal que inicia el proceso de decisión.
- Nodos intermedios: representan preguntas o evaluaciones basadas en atributos específicos de los datos.
- Hojas: los nodos finales que reflejan las conclusiones o predicciones del modelo.

- b) Segmentación de datos: al construir el árbol, los datos se dividen en subconjuntos utilizando métricas como entropía, índice Gini o ganancia de información. Este proceso se aplica de forma iterativa para cada subconjunto generado.
- c) Fácil de comprender: los árboles de decisión destacan por su claridad. Cada recorrido desde la raíz hasta una hoja se interpreta como una secuencia de decisiones que lleva a un resultado.
- d) Compatibilidad con distintos tipos de datos: estos modelos pueden procesar tanto variables categóricas (como respuestas sí o no) como continuas (por ejemplo, edad o ingresos).
- e) Problemas de sobreajuste: los árboles de decisión, si son demasiado complejos, pueden ajustarse excesivamente a los datos de entrenamiento, capturando ruido en lugar de patrones reales. Para mitigar esto, se emplean técnicas como la poda, que elimina ramas irrelevantes o redundantes.
- f) Áreas de aplicación: son ampliamente utilizados en tareas como clasificación, regresión, diagnóstico médico, análisis de riesgos y más.
- g) Base para métodos avanzados: los árboles de decisión constituyen la base de modelos más avanzados, como Random Forest y Gradient Boosting, los cuales combinan múltiples árboles para incrementar la precisión, reducir el sobreajuste y mejorar la robustez del sistema de predicción (Ver Figura 5).




Figura 5. *Modelo de clasificación basado en un árbol de decisiones. (15).*

El algoritmo de Random Forest es una técnica de aprendizaje automático que pertenece a los “métodos de ensamble” (ensemble methods). Este enfoque se aplica principalmente en tareas

de clasificación y regresión, combinando múltiples árboles de decisión para mejorar la precisión y mitigar el riesgo de sobreajuste, una limitación común de los árboles de decisión individuales (15).

Funcionamiento y características principales de Random Forest:

a) Construcción del conjunto de árboles:

El algoritmo genera una colección de árboles de decisión utilizando subconjuntos aleatorios del conjunto de datos de entrenamiento. Estos subconjuntos se crean mediante la técnica de “bootstrapping”, que consiste en seleccionar muestras aleatorias con reemplazo del conjunto original.

Durante el entrenamiento de cada árbol, se utiliza un subconjunto aleatorio de características en cada nodo para decidir la división, introduciendo mayor diversidad y aleatoriedad en los árboles generados.

b) Proceso de predicción:

En clasificación, cada árbol emite un "voto" para una clase cuando se introduce un nuevo dato. La clase que recibe la mayor cantidad de votos se convierte en la predicción final del modelo.

Para tareas de regresión, el modelo combina los resultados de los árboles calculando el promedio de sus predicciones.

c) Ventaja en la reducción de varianza:

Al integrar las predicciones de varios árboles, Random Forest disminuye la varianza del modelo en comparación con un único árbol de decisión (ver figura 6). Esto mejora el rendimiento general y proporciona mayor estabilidad en los resultados (15).

Random Forest se destaca por su capacidad para manejar grandes conjuntos de datos con características diversas y por su efectividad en problemas donde los modelos individuales pueden ser menos precisos o más propensos al sobreajuste (15).

Tabla 2. Ventajas y desventajas del algoritmo Random Forest.

Aspecto	Ventajas	Desventajas
Robustez	Su diseño basado en múltiples árboles y la aleatoriedad lo hacen menos propenso al sobreajuste, a diferencia de un solo árbol.	Al ser un modelo más complejo, su interpretación es menos intuitiva que la de un árbol de decisión individual.
Manejo de datos ausentes	Puede procesar conjuntos de datos con valores faltantes, proporcionando predicciones confiables incluso en estas condiciones.	El procesamiento de grandes volúmenes de datos y la creación de muchos árboles demandan más recursos computacionales.
Selección de características	Ofrece herramientas para analizar la relevancia de cada variable en el modelo, facilitando la identificación de atributos clave.	
Flexibilidad	Funciona tanto para problemas de clasificación como de regresión, y es adecuado para variables continuas y categóricas.	

Nota: tomada de (15).

Random Forest es un algoritmo flexible y poderoso que combina la facilidad de los árboles de decisión con la fortaleza de los métodos de ensamblaje, logrando una mayor precisión y capacidad de generalización en tareas de clasificación y predicción.

Tabla 3. Clasificación mediante Random Forest.

Aplicaciones Comunes	Descripción
Clasificación de imágenes	Ayuda a identificar y categorizar objetos o patrones dentro de conjuntos de imágenes digitales.
Detección de fraudes	Se utiliza para identificar transacciones inusuales o comportamientos sospechosos en sistemas financieros.
Diagnóstico médico	Soporta la identificación de enfermedades o condiciones médicas a partir de datos clínicos o imágenes.
Predicción de riesgo crediticio	Evalúa la probabilidad de incumplimiento crediticio basándose en el análisis de datos financieros y de clientes.
Análisis de sentimientos	Interpreta opiniones o emociones expresadas en textos, como reseñas o comentarios en redes sociales.

Nota: tomada de (15).




Figura 6. Clasificación mediante Random Forest. (15).

2.2.7.2. Máquinas de soporte Vectorial o Support Vector Machine (SVM)

Altamente efectivas para trabajar con datos en espacios de alta dimensión, las Máquinas de Soporte Vectorial (SVM, por sus siglas en inglés) son algoritmos de aprendizaje supervisado diseñados principalmente para tareas de clasificación y, ocasionalmente, regresión. Su propósito es identificar el hiperplano que mejor separa las clases en el espacio de características (Ver Figura 7). A continuación, se resumen sus aspectos más importantes:

- Hiperplano: en espacios de múltiples dimensiones, un hiperplano actúa como la extensión de una línea en un plano bidimensional o una superficie en tres dimensiones. La SVM busca el hiperplano que maximiza la separación entre las clases.
- Margen: representa la distancia mínima entre el hiperplano y los puntos más cercanos de cada clase. El modelo SVM óptimo encuentra el hiperplano que maximiza este margen, mejorando así su capacidad para generalizar.
- Vectores de soporte: son los puntos de datos más próximos al hiperplano y definen tanto su posición como el margen. Estos puntos son esenciales para entrenar el modelo, ya que determinan su configuración.
- Kernels: para abordar problemas no lineales, SVM utiliza funciones núcleo, que permiten transformar los datos a espacios de mayor dimensión sin necesidad de calcular sus coordenadas explícitas, facilitando la separación de las clases.
- Regularización: un parámetro de regularización ayuda a equilibrar la maximización del margen y la minimización de los errores de clasificación, permitiendo cierta tolerancia a errores para prevenir el sobreajuste.

Las Máquinas de Soporte Vectorial son un método altamente eficaz dentro del aprendizaje automático, diseñado para abordar tareas complejas de clasificación y regresión (25).




Figura 7. Modelo de SVM aplicado a tareas de categorización. (25).

2.2.7.3. Redes neuronales

La selección del tipo de red depende del problema a resolver. Las redes CNN, RNN y los modelos profundos son ampliamente utilizados, y en tareas complejas es común combinar varios tipos para obtener mejores resultados.

Tabla 4. Tipos de redes neuronales (25).

TIPO DE RED	DESCRIPCIÓN Y APLICACIONES
Perceptrón Multicapa	Arquitectura básica con al menos tres capas (entrada, ocultas y salida). Útil para tareas generales de clasificación.
Redes Convolucionales (CNN)	Diseñadas para procesar imágenes mediante filtros que extraen características clave. Ejemplo: detección de objetos.
Redes Recurrentes (RNN)	Estructura con conexiones cíclicas, adecuada para procesar secuencias. Ejemplo: análisis de voz o generación de texto.
Redes LSTM	Una variante de las RNN que incorpora memoria a largo plazo, ideal para datos secuenciales. Ejemplo: predicciones financieras.
Redes Generativas	Crean datos nuevos como imágenes o textos. Ejemplo: GANs para generar imágenes realistas.
Autoencoders	Reducen la dimensionalidad de los datos mediante compresión y posterior reconstrucción.
Redes Profundas (Deep Learning)	Modelos con múltiples capas ocultas, utilizadas para problemas complejos en áreas como visión por computadora y lenguaje natural.
Redes de Creencias Profundas	Combinan conceptos de probabilidad bayesiana con aprendizaje profundo.
Redes Híbridas	Integran diferentes tipos de redes, como CNNs y RNNs, para resolver problemas complejos.
Redes Sparses	Estructuras con conexiones limitadas entre neuronas para mejorar la eficiencia y el rendimiento computacional.

La figura 8 muestra dos tipos de arquitecturas de redes neuronales artificiales: la red monocapa y la red multicapa, diferenciadas principalmente por la cantidad de capas presentes entre la entrada y la salida.

En el lado izquierdo, la red monocapa tiene una estructura sencilla que consiste únicamente en una capa de entrada y una capa de salida. Las neuronas de la capa de entrada están conectadas directamente a las de la capa de salida, sin capas intermedias. Este tipo de red es más simple y adecuado para problemas lineales, ya que no incluye capas ocultas que puedan capturar relaciones complejas en los datos.

Por otro lado, el lado derecho ilustra la red multicapa, que incluye al menos una capa oculta entre la capa de entrada y la capa de salida. Las capas ocultas permiten que la red procese datos de forma jerárquica y extraiga características más complejas, haciéndola más adecuada para problemas no lineales. En esta red, las conexiones entre las neuronas se realizan en diferentes niveles, lo que mejora la capacidad de modelar patrones y relaciones complejas en los datos de entrada.

Ambas arquitecturas tienen aplicaciones específicas, siendo las redes multicapa más potentes y versátiles, aunque a costa de una mayor complejidad computacional (25).




Figura 8. Comparación de Redes Neuronales: Monocapa vs. Multicapa. (25).

La figura 9 ilustra el funcionamiento de una red neuronal profunda para tareas de reconocimiento facial, destacando cómo las capas de la red procesan de manera jerárquica las características de las imágenes.

- Capa de entrada (Input Layer): a la izquierda, se observa un conjunto de imágenes de rostros que son introducidas como datos de entrada en la red. Cada imagen es

representada como un conjunto de patrones básicos (por ejemplo, contrastes locales), que constituyen los datos iniciales procesados por la red.

- Primera capa oculta (Hidden Layer 1): en esta etapa, la red identifica patrones simples en las imágenes, como bordes o contrastes locales. Estas características básicas se extraen a partir de las conexiones entre las neuronas de la capa de entrada y las de la primera capa oculta.
- Segunda capa oculta (Hidden Layer 2): las características simples detectadas en la primera capa se combinan para formar patrones más complejos, como rasgos faciales específicos (ojos, nariz, boca, etc.). Este procesamiento jerárquico permite que la red comience a construir una representación más detallada de los rostros.
- Capa de salida (Output Layer): finalmente, las características combinadas en las capas ocultas se utilizan para clasificar o identificar las imágenes como rostros específicos. En este punto, la red produce una salida que corresponde a las categorías o etiquetas deseadas, como identificar la identidad de la persona en la imagen (25).

La figura 8, muestra cómo las redes neuronales profundas trabajan de manera jerárquica, comenzando con patrones simples en las capas iniciales y avanzando hacia representaciones complejas que permiten resolver problemas como el reconocimiento facial. Este enfoque es fundamental en tareas de visión por computadora.




Figura 9. Características en redes neuronales para reconocimiento facial. (25).

La figura 10, representa la estructura básica de una red neuronal recurrente (RNN, por sus siglas en inglés), que es un tipo especial de red neuronal diseñado para procesar datos secuenciales y modelar dependencias temporales.

- a) Capas de entrada: a la izquierda se encuentran las neuronas de la capa de entrada (en azul), que representan los datos iniciales que se introducen al sistema. Estos datos

podrían ser, por ejemplo, palabras de una frase, puntos en una serie temporal o características de una señal.

- b) Capas ocultas: en el centro están las capas ocultas (en naranja), que realizan el procesamiento principal de los datos. En una red recurrente, estas capas tienen una característica única: incluyen conexiones hacia atrás o de retroalimentación. Esto significa que el estado actual de las neuronas depende no solo de los datos de entrada, sino también de su propio estado anterior.
- c) Red recurrida (retroalimentación): la conexión marcada en rojo muestra cómo las salidas de las capas ocultas se retroalimentan hacia sí mismas. Este mecanismo permite que la red "recuerde" información de pasos previos, lo cual es fundamental para analizar secuencias temporales o contextos. Por ejemplo, en el caso de texto, permite entender la relación entre palabras consecutivas.
- d) Capa de salida: a la derecha está la capa de salida (en verde), que genera la predicción o el resultado final basado en el procesamiento interno de las capas ocultas. Dependiendo del problema, podría ser una categoría (en clasificación) o un valor numérico (en regresión).




Figura 10. Red Neuronal Recurrenta (RNN) con retroalimentación. (25).

2.2.8 Predicción de fallas

La predicción de fallas es un proceso que utiliza técnicas analíticas, modelos estadísticos y algoritmos de aprendizaje automático para identificar de manera anticipada posibles averías en sistemas o componentes. En motores eléctricos, esto implica analizar parámetros como vibraciones, temperatura, corriente y otros indicadores de salud para prever fallos antes de que ocurran, lo que permite optimizar el mantenimiento y evitar interrupciones inesperadas en la operación (26).

La predicción de fallas se vincula con el uso de herramientas y estrategias de mantenimiento predictivo y basado en confiabilidad. Esta técnica permite anticipar averías potenciales mediante el análisis de indicadores clave como vibraciones, temperatura, y corriente eléctrica, entre otros. La predicción se basa en el monitoreo continuo de los equipos, ayudando a reducir costos, minimizar tiempos de inactividad y optimizar la disponibilidad operativa (26).

Por tanto, la predicción de fallas se describe como un proceso proactivo que, mediante el análisis de datos históricos y en tiempo real, identifica patrones que sugieren un riesgo elevado de falla. En esta línea, el empleo de algoritmos de aprendizaje supervisado mejora la precisión de los modelos predictivos, proporcionando una evaluación confiable del estado de los motores eléctricos en la gran minería. Esto se traduce en una mejor planificación del mantenimiento y mayor efectividad en la operación de los equipos (26).

2.2.9 Tiempo promedio hasta la falla (MTTF)

El MTTF (Mean Time to Failure) es una métrica que indica el tiempo promedio de funcionamiento de un equipo o componente antes de que presente una falla. Es un indicador clave de la confiabilidad de los sistemas eléctricos, especialmente en motores, y se calcula mediante el análisis estadístico del historial de fallas. Este valor permite planificar estrategias de mantenimiento preventivo y predictivo (27).

El MTTF (Mean Time to Failure), o tiempo promedio hasta la falla, es una métrica en la confiabilidad y mantenimiento de sistemas eléctricos y mecánicos. Este indicador refleja el tiempo promedio que un equipo puede operar sin fallas, considerando su desempeño bajo condiciones normales (27).

El MTTF se calcula a partir de datos históricos de fallas y permite evaluar la durabilidad del equipo. Este indicador permite planificar estrategias de mantenimiento preventivo y predictivo, asegurando que las intervenciones se realicen antes de que ocurran fallas críticas. Además, el MTTF es especialmente útil para la comparación de diferentes sistemas o componentes, identificando cuáles tienen mayor confiabilidad operativa (27).

El cálculo del MTTF puede ser optimizado mediante metodologías como RAM (Reliability, Availability, Maintainability), las cuales integran tasas de falla y de reparación para diseñar programas de mantenimiento basados en datos específicos del sistema. Este enfoque permite reducir tiempos muertos y maximizar la disponibilidad de los equipos (27).

2.2.10 Vibraciones

Las vibraciones son indicadores clave del estado mecánico de un motor eléctrico. Cambios inusuales en los niveles de vibración pueden señalar problemas como desalineaciones o daños en los rodamientos, por lo que su monitoreo continuo es vital para detectar fallas incipientes (27).

2.2.11 Temperatura

La temperatura refleja las condiciones térmicas internas del motor y su comportamiento bajo carga. Niveles elevados pueden indicar sobrecarga, fallos en el sistema de enfriamiento o deterioro del aislamiento, siendo un parámetro crucial para prevenir daños mayores (5).

2.2.12 Corriente

El análisis de la corriente eléctrica permite detectar anomalías en el funcionamiento del motor, como desequilibrios, sobrecargas o cortocircuitos. Su monitoreo contribuye al diagnóstico temprano de fallas eléctricas y mecánicas (6).

2.2.13 Aislamiento del bobinado

El aislamiento del bobinado protege los conductores de cortocircuitos y fallos eléctricos. Su degradación es una causa común de fallas en motores eléctricos, por lo que es fundamental evaluar su estado mediante pruebas de resistencia y análisis térmico (6).

2.2.14 Frecuencia de fallas

La frecuencia de fallas mide la recurrencia de averías en un periodo específico. Este indicador permite evaluar la estabilidad operativa del motor, identificar patrones de fallas repetitivas y diseñar estrategias de mejora en el mantenimiento (6).

2.2.15 Índices de desgaste

Los índices de desgaste representan el nivel de deterioro de los componentes del motor a lo largo del tiempo. Estos índices se calculan con base en variables como vibraciones, temperatura y corriente, ayudando a prever fallas futuras y planificar reemplazos oportunos (6).

2.2.16 Matlab

Matlab es un software ampliamente utilizado en la simulación y análisis de datos para la predicción de fallas y monitoreo de motores eléctricos. Su capacidad para implementar modelos de aprendizaje supervisado lo convierte en una herramienta esencial para el desarrollo de algoritmos predictivos en la industria minera (6).

Matlab es un entorno de programación especializado en cálculos técnicos y análisis matemático, basado en operaciones matriciales. Sus principales componentes incluyen:

- Lenguaje Matlab: facilita el manejo de datos en formas como escalares, vectores y matrices, siendo utilizado tanto en el espacio de trabajo como para el desarrollo de programas mediante archivos M (M-files).
- Espacio de trabajo: área destinada para realizar cálculos, almacenar y manipular datos que pueden intercambiarse durante las operaciones.
- Entorno gráfico: permite la representación visual de datos en 2D y 3D, incluyendo animaciones, integrándose con cálculos realizados en el espacio de trabajo o mediante toolboxes.
- Funciones de librería: proporciona un amplio conjunto de operaciones predefinidas que facilitan tareas complejas; su utilidad puede consultarse con el comando "help".
- API de Matlab: extiende las funcionalidades de Matlab a otros entornos de programación, permitiendo comunicación con aplicaciones externas.
- Toolboxes: herramientas especializadas que incrementan la potencia de Matlab, ofreciendo interfaces amigables y capacidades avanzadas para tareas específicas (28).

En conjunto, estos componentes hacen de Matlab una plataforma versátil y poderosa para tareas de análisis, simulación y visualización de datos (28).

CAPÍTULO III

METODOLOGÍA

3.1 Método de la investigación

3.1.1 Tipo de investigación

El tipo de investigación es cuantitativa experimental. Esta investigación emplea datos numéricos recopilados de los motores eléctricos y utiliza simulaciones en MATLAB para experimentar con diferentes algoritmos de aprendizaje supervisado. El enfoque cuantitativo permite medir, analizar y modelar las relaciones entre las variables para predecir con precisión la vida útil de los motores.

3.1.2 Nivel de investigación

El nivel de investigación es explicativo, dado que se busca no solo describir las características de los motores eléctricos y sus fallas, sino también explicar las causas de estas fallas a través del análisis de datos y la predicción de la vida útil mediante algoritmos avanzados.

3.1.3 Diseño de investigación

El diseño de la investigación es cuasi - experimental y correlacional:

- Cuasi - experimental, porque implica el desarrollo y pruebas de algoritmos de aprendizaje supervisado para predecir la vida útil de los motores eléctricos en un entorno controlado.
- Correlacional, porque se examina la relación entre variables independientes (datos operativos como vibraciones, temperatura, corriente, etc.) y la variable dependiente (vida útil de los motores eléctricos) para identificar patrones y desarrollar el indicador de salud más preciso.

3.2 Población y muestra

3.2.1 Población

La población de esta investigación está compuesta por todos los motores eléctricos de inducción de jaula de ardilla utilizados en equipos de gran minería, que requieren mantenimiento predictivo para optimizar su operación. Estos motores se encuentran principalmente en camiones de tracción eléctrica y maquinaria pesada en sectores como minería, petróleo y gas,

y otras industrias de alta demanda energética, donde se utilizan para aplicaciones críticas que varían en tamaño, potencia y condiciones operativas.

3.2.2 Muestra

La muestra seleccionada para esta investigación consistirá en un subconjunto de motores eléctricos de inducción de corriente alterna (CA) de jaula de ardilla utilizados en equipos de gran minería, específicamente en camiones de tracción y maquinaria pesada. Estos motores han sido seleccionados debido a su operación crítica en entornos mineros desafiantes, donde están expuestos a condiciones severas de carga, temperatura y vibraciones. Los motores incluidos en la muestra contarán con un historial detallado de monitoreo de parámetros operativos como vibraciones, temperatura del bobinado, corriente y aislamiento eléctrico. La selección de la muestra se basará en la disponibilidad de datos históricos de monitoreo confiables y completos, permitiendo analizar patrones y tendencias relevantes para el mantenimiento predictivo. Para la simulación y validación en MATLAB, se utilizarán datos de al menos 3 motores eléctricos representativos, lo que garantizará la robustez de los resultados y su aplicabilidad en entornos industriales de gran minería.

3.3 Técnicas de instrumentos y recolección de datos

3.3.1 Técnicas de recolección de datos

Las técnicas de recolección de datos utilizadas en esta investigación incluyen:

- Monitoreo continuo: recolección de datos en tiempo real desde sensores instalados en los motores eléctricos de jaula de ardilla. Los sensores recopilan información sobre vibraciones, temperatura, corriente, y aislamiento del bobinado.
- Revisión de registros históricos: análisis de datos históricos de operación y mantenimiento disponibles en las bases de datos de las empresas. Estos datos incluyen registros de mantenimiento, fallas ocurridas, horas de operación, y parámetros de funcionamiento del motor.
- Simulación computacional: uso de MATLAB para simular condiciones de operación de los motores eléctricos de jaula de ardilla y generar datos adicionales que permitan validar y ajustar los modelos de predicción desarrollados.

3.3.2 Instrumentos de recolección de datos

Los instrumentos de recolección de datos empleados en esta investigación son:

Sensores de vibración y temperatura: dispositivos que se instalan en los motores para medir continuamente las vibraciones y la temperatura. Estos sensores proporcionan datos críticos sobre el estado de salud del motor y posibles fallas.

Medidores de corriente y aislamiento: equipos que registran la corriente eléctrica que pasa por el motor y el estado del aislamiento del bobinado, ambos parámetros clave para evaluar la condición del motor.

Software de monitoreo predictivo: herramientas de software que integran los datos obtenidos de los sensores y permiten la visualización en tiempo real, almacenamiento y análisis de datos históricos.

MATLAB: software utilizado para el desarrollo, entrenamiento, y validación de los modelos de aprendizaje supervisado. MATLAB se emplea para procesar los datos, simular diferentes escenarios de operación y evaluar el desempeño del indicador de salud propuesto.

3.4 Técnicas de análisis y procesamiento de datos

3.4.1 Técnicas de análisis de datos

- a) Análisis descriptivo: se utilizó para resumir las características principales de los datos recolectados de los motores eléctricos de jaula de ardilla, incluyendo variables como vibraciones, temperatura, corriente y aislamiento del bobinado. Este análisis permitió identificar tendencias generales y establecer una base para el análisis predictivo.
- b) Análisis correlacional: se aplicaron matrices de correlación para evaluar la relación entre las variables independientes y la variable dependiente. Esto permitió identificar aquellas variables con mayor influencia en la vida útil de los motores, sirviendo como insumo para la selección de características.
- c) Análisis predictivo con algoritmos de aprendizaje supervisado: los datos fueron empleados para entrenar modelos en MATLAB, utilizando algoritmos como Random Forest, SVM y redes neuronales artificiales. Se dividieron los datos en conjuntos de entrenamiento y prueba. Además, se integraron las variables seleccionadas a partir del análisis de monotonía y del análisis de varianza (ANOVA), previamente descritos en el desarrollo metodológico.
- d) Validación cruzada: para evaluar la robustez de los modelos predictivos, se utilizó validación cruzada, lo cual permitió verificar la capacidad de generalización de los modelos al aplicarlos en subconjuntos distintos de datos, evitando sobreajuste.

3.4.2 Técnicas de procesamiento de datos

- Preprocesamiento de datos: se realizó una limpieza inicial para eliminar registros inconsistentes y valores extremos. Posteriormente, se aplicaron técnicas de normalización para escalar las variables a una misma magnitud, garantizando un desempeño equilibrado en los algoritmos. Este paso se complementó con la organización y filtrado de las señales medidas, lo cual se detalla en el capítulo IV.
- Reducción de dimensionalidad: se emplearon técnicas como el Análisis de Componentes Principales (PCA) para reducir la cantidad de variables independientes, priorizando aquellas que explicaban mayor varianza en los datos, lo cual permitió disminuir la complejidad del modelo y mejorar su rendimiento.
- Análisis de sensibilidad: se implementó para observar el impacto de las variables más influyentes sobre la predicción de la vida útil. Esta técnica permitió validar que el modelo responde adecuadamente ante cambios en los parámetros de entrada.

CAPÍTULO IV

DIAGNÓSTICO, ANÁLISIS Y RESULTADOS

4.1 Análisis de los factores que afectan la vida útil de motores eléctricos

4.1.1 Temperatura de los motores eléctricos

El sistema de control de motores eléctricos de frecuencia variable (VFD) es una tecnología que se utiliza en la gestión eficiente de la energía en aplicaciones industriales. En la figura 11, se representa el flujo de energía desde un generador de corriente alterna trifásico hasta el motor de tracción, destacando las etapas de rectificación, control de potencia y modulación de la señal para su correcto funcionamiento.

El diagrama muestra cómo la energía generada es rectificada a corriente continua mediante un conjunto de rectificadores de tracción, permitiendo su almacenamiento en un bus de potencia de corriente continua. Posteriormente, los transistores de potencia, controlados por el módulo electrónico del motor (ECM), conmutan la energía mediante pulsos de modulación por ancho de pulso (PWM), generando una señal de corriente alterna de frecuencia variable que alimenta el motor eléctrico.




Figura 11. Motor Eléctrico.

Se observa que el control de la conmutación de los transistores permite regular la velocidad y el torque del motor, asegurando su rendimiento óptimo. Sin embargo, la figura también destaca que un incremento en la frecuencia de operación puede derivar en un aumento de la corriente, lo que, a su vez, influye en el calentamiento del sistema. Esto resalta la importancia del monitoreo continuo de la temperatura, ya que el sobrecalentamiento puede afectar negativamente la vida útil de los devanados y rodamientos del motor.

En la primera gráfica de la figura 12, se observa la relación entre el par electromagnético (M) y el deslizado (s), indicando las tres principales regiones de operación del motor de inducción:

a) Región de freno ($s > 1$):

- Cuando el deslizamiento es mayor que 1, el motor actúa como un freno, absorbiendo energía del sistema para reducir la velocidad de la carga.
- En esta zona, el par es positivo pero decreciente a medida que el tamaño aumenta.

b) Región de motor ($0 < s < 1$):

- Es la zona de funcionamiento normal del motor de inducción, donde el par alcanza su valor máximo, proporcionando la potencia necesaria para accionar la carga.
- El par decrece a medida que la velocidad del motor se acerca a la velocidad síncrona.

c) Región de generador ($s < 0$):

- Cuando el desplazamiento es negativo, el motor actúa como un generador, devolviendo energía al sistema.
- El par se invierte y la velocidad del motor excede la velocidad síncrona.

Por otro lado, la segunda gráfica de la figura 12 muestra el comportamiento del par inducido en función de la velocidad mecánica, donde se pueden identificar diversas curvas que representan diferentes condiciones de carga. Se evidencia que el par máximo se alcanza a velocidades bajas, disminuyendo progresivamente a medida que la velocidad aumenta. Este comportamiento es característico de los motores de inducción y refleja la relación entre la velocidad y la capacidad de generación de par.




Figura 12. Curvas características de par-velocidad en motores de inducción

A partir del análisis visto anteriormente se infiere lo siguiente:

- Temperatura: un funcionamiento prolongado en la zona de alto deslizamiento puede generar sobrecalentamiento, afectando la vida útil de los devanados y rodamientos.
- Sobrecarga: operar el motor cerca de su par máximo durante períodos largos puede generar un esfuerzo térmico y mecánico excesivo.
- Condiciones de operación: velocidades demasiado bajas o muy altas pueden provocar vibraciones y esfuerzos adicionales en los componentes mecánicos del motor.

El sistema de retardo es un mecanismo utilizado en motores eléctricos de tracción para disipar la energía generada durante la desaceleración o frenado del equipo. Esta energía, si no se gestiona adecuadamente, puede generar un aumento de temperatura en los componentes internos del motor, lo que podría afectar su rendimiento y reducir su vida útil. La figura 13 presenta los elementos principales que permiten regular la potencia generada en estos procesos, garantizando un funcionamiento seguro y eficiente.

El sistema está compuesto por diversos módulos encargados de transformar la energía cinética en energía eléctrica y, posteriormente, disiparla en forma de calor mediante resistencias diseñadas para soportar altas cargas térmicas. Entre sus componentes se encuentran el módulo de tren de potencia, el módulo chopper, los contactores de retardo, y el sistema de disipación de energía, los cuales trabajan de manera coordinada para controlar la desaceleración sin comprometer la integridad del motor.




Figura 13. Sistema de retardo.

A continuación, se describe el funcionamiento de los componentes del sistema de retardo:

a) Módulo de tren de potencia (ECM Tren Potencia):

- Regule el flujo de energía y coordine la operación de los motores eléctricos durante el retardo.
- Controle la activación de los motores de tracción izquierdo (LH) y derecho (RH), ajustando la salida de potencia según las necesidades del sistema.

b) Módulo Chopper:

- Se encarga de la reducción del voltaje de la barra de alimentación, pasando de 1500 VDC a 850 VDC.
- Regule la disipación de energía durante el frenado, protegiendo los componentes eléctricos.

c) Contactores de retardo:

- Controlan la conexión y desconexión de los circuitos de retardo.
- Cuando el retardo supera el 50%, los contactores se activan al 100%, permitiendo disipar hasta 4750 kW de potencia.

d) Sistema de disipación de energía (Retarding Grid):

- Convierte la energía eléctrica generada durante el retardo en calor, disipándola a través de resistencias y ventiladores.
- Ayude a mantener el sistema dentro de los rangos de temperatura adecuados

En un sistema de retardo, el flujo de potencia es un aspecto utilizado para el control de la energía generada durante la desaceleración de motores eléctricos, asegurando su disipación de manera controlada y eficiente. Durante el frenado, los motores de tracción actúan como generadores, convirtiendo la energía cinética del vehículo en energía eléctrica, la cual debe ser gestionada para evitar sobrecargas en los componentes eléctricos y mecánicos. La figura 14 representa el camino que sigue la energía desde su generación hasta su disipación, pasando por diferentes módulos de control y elementos disipadores.

• FLUJO DE POTENCIA




Figura 14. *Flujo de potencia de un sistema de retardo.*

El sistema debe de estar diseñado para garantizar que la energía generada no afecte negativamente el rendimiento del motor ni de los sistemas eléctricos asociados. Para ello, se emplean módulos de control que regulan la transferencia de energía hacia elementos de disipación, como resistencias y sistemas de ventilación, que transforman la energía eléctrica en calor. Este proceso es necesario para mantener dentro de límites seguros la temperatura de los devanados del motor y otros componentes sensibles. Un correcto funcionamiento de este sistema contribuye a mantener el motor en condiciones óptimas de operación, evitando daños derivados de la acumulación de energía durante el frenado.

La parrilla de retardo es un elemento diseñado para disipar la energía eléctrica generada durante el proceso de frenado de motores eléctricos de tracción, contribuyendo a la protección del sistema y a la mejora de su rendimiento. Durante la desaceleración, los motores de tracción convierten la energía cinética en energía eléctrica, la cual, si no se gestiona adecuadamente, puede generar sobrecargas térmicas que afectan la eficiencia operativa y la vida útil de los componentes internos. La figura 15 representa la configuración de este sistema, que permite

transformar la energía eléctrica excedente en calor a través de elementos resistivos, asegurando una disipación controlada.




Figura 15. *Parrilla de retardo.*

Este sistema se compone de resistencias de alta potencia, módulos de control electrónico y ventiladores de refrigeración que trabajan de manera conjunta para disipar el calor generado. Además, la parrilla de retardo permite mantener el rendimiento del motor bajo condiciones de operación exigentes, protegiendo sus devanados y rodamientos de temperaturas extremas que podrían deteriorar su funcionalidad. Una correcta operación de la parrilla de retardo garantiza que el motor funcione dentro de los límites de temperatura establecidos.

Durante la operación de un motor de tracción, factores como el calentamiento excesivo, variaciones en la velocidad de rotación y condiciones de carga pueden influir directamente en su eficiencia y vida útil. Para abordar esto, se emplean sensores y módulos de control que recopilan información en tiempo real y la envían a sistemas de gestión electrónica (ver figura 16). Esto permite realizar ajustes automáticos o alertar a los operadores en caso de que los valores monitoreados se salgan de los límites establecidos, pero no siempre respeta a las alertas tempranas, como lo haría un modelo de indicador de salud, que es lo que se propone en esta investigación.




Figura 16. Monitoreo de parámetros relacionados con un motor eléctrico de tracción.

El control de la temperatura en los rodamientos de los motores eléctricos es importante para garantizar su funcionamiento seguro y prolongar su vida útil. La figura 17 presenta los rangos de temperatura establecidos para el rodamiento en el extremo de transmisión del motor eléctrico (Drive End - DE), clasificando su estado operativo en diferentes niveles de condición.

Durante la operación, los rodamientos están sometidos a esfuerzos mecánicos y térmicos que pueden generar un aumento de temperatura. Un monitoreo preciso permite identificar posibles anomalías y tomar medidas preventivas para evitar daños mayores en el motor. En la figura se distinguen tres zonas de temperatura:

a) Temperatura normal ($< 95^{\circ}\text{C}$):

- Indica que el rodamiento opera dentro de los límites recomendados, asegurando un funcionamiento eficiente y sin riesgo de daños térmicos.
- En este rango, el motor puede continuar operando sin restricciones.

b) Evento de nivel 2 ($95^{\circ}\text{C} \leq T^{\circ} < 100^{\circ}\text{C}$):

- Indica una condición de advertencia donde la temperatura ha superado el límite normal pero aún se encuentra dentro de un rango tolerable.
- Se recomienda la supervisión del sistema y la posible reducción de carga para evitar un mayor aumento de temperatura.

c) Evento de nivel 3 ($T^{\circ} = 100^{\circ}\text{C}$):

- Señala una condición crítica en la que la temperatura ha alcanzado el límite máximo de operación segura.
- En este punto, es necesario detener la operación del motor para evitar daños irreversibles en el rodamiento y otros componentes relacionados.




Figura 17. Límites de temperatura para rodamientos DE.

La figura 18 presenta los rangos de temperatura operativa establecidos para el rodamiento en el extremo no de transmisión del motor eléctrico (Non-Drive End - NDE), clasificando las condiciones en diferentes niveles de operación.




Figura 18. Límites de temperatura para rodamientos NDE.

Durante el funcionamiento del motor, los rodamientos del lado NDE están sujetos a cargas mecánicas y térmicas que pueden generar un incremento gradual de la temperatura. Un monitoreo adecuado permite identificar condiciones anómalas y tomar medidas correctivas para prevenir daños en los componentes. En la figura se distinguen tres zonas de temperatura:

a) Temperatura normal ($< 110^{\circ}\text{C}$):

- Indica que el motor opera dentro de los límites seguros, sin riesgo de sobrecalentamiento.
- En este rango, no se requiere intervención, ya que las condiciones son óptimas para la operación continua.

b) Evento de nivel 2 ($110^{\circ}\text{C} \leq T^{\circ} < 120^{\circ}\text{C}$):

- Sugiere una condición de advertencia donde la temperatura ha superado el rango normal de operación.
- En esta fase, es recomendable monitorear la situación de cerca y reducir la carga para evitar que la temperatura siga aumentando.

c) Evento de nivel 3 ($T^{\circ} = 120^{\circ}\text{C}$):

- Indica que la temperatura ha alcanzado un nivel crítico que puede comprometer la integridad del rodamiento.
- Se recomienda la detención inmediata del motor para evitar daños mayores y programar una inspección para determinar la causa del sobrecalentamiento.

Un control eficiente de la temperatura en los rodamientos es esencial para evitar fallos prematuros debido a la expansión térmica, la degradación del lubricante y el desgaste excesivo. Operar el motor de manera continua en niveles elevados de temperatura puede acelerar el deterioro de los componentes, aumentando la necesidad de mantenimiento correctivo y reduciendo la confiabilidad del sistema.

4.1.2 Contaminación de motor de tracción por pase de aceite

La contaminación del motor de tracción por paso de aceite es una de las principales variables que pueden afectar negativamente la salud y la vida útil de estos equipos. Este problema se presenta cuando el aceite proveniente del sistema de mando final migra hacia el interior del motor, afectando componentes críticos como los devanados, los rodamientos y el estator.

La presencia de aceite en el interior del motor genera múltiples riesgos operacionales, entre ellos:

- Deterioro del aislamiento eléctrico: el aceite y sus residuos pueden infiltrarse en los devanados del estator, reduciendo la capacidad de aislamiento del sistema eléctrico y aumentando el riesgo de cortocircuitos.
- Aumento de la temperatura de operación: la acumulación de aceite puede actuar como una barrera térmica, dificultando la disipación del calor generado en el motor, lo que puede provocar un sobrecalentamiento de los componentes internos.
- Desgaste acelerado de componentes mecánicos: la presencia de aceite en lugares no diseñados para su presencia puede degradar materiales de sellado y elementos estructurales, provocando fallas prematuras en los rodamientos y otras partes críticas.

Entre las causas identificadas que pueden contribuir al paso de aceite hacia el motor de tracción, se encuentran:

- Desgaste de sellos labio y manguitos: la exposición prolongada a condiciones de operación exigentes provoca el deterioro de los elementos de sellado, permitiendo la fuga de lubricante hacia el motor.
- Obstrucción de respiraderos: la acumulación de suciedad y partículas puede bloquear los respiraderos, generando presiones internas que facilitan el desplazamiento del aceite hacia áreas no deseadas.
- Condiciones operativas extremas: factores como temperaturas elevadas, sobrecargas o vibraciones excesivas pueden agravar la pérdida de estanqueidad del sistema.



Figura 19. *Daño en conexión neutra del estator del motor de tracción.*

La contaminación por aceite representa un riesgo para la confiabilidad del motor eléctrico. Si no se controla un tiempo, puede generar fallas que resultan en costosos tiempos de inactividad y reparaciones. Además, la combinación de contaminación y altas temperaturas puede acelerar la degradación de los materiales aislantes, reduciendo la vida útil del equipo.



Figura 20. *Presencia de contaminación por aceite en el motor de tracción.*

La contaminación del motor de tracción por pase de aceite puede generar daños significativos en los componentes internos, afecta el rendimiento y reduce su vida útil. La figura 21 muestra el estado de diversas partes del motor luego de un periodo de funcionamiento extendido, permitiendo evaluar el impacto de la contaminación y el desgaste en los elementos clave.

El aceite ingresado al motor puede impregnar los devanados del estator, afectando la capacidad de aislamiento eléctrico y favoreciendo el sobrecalentamiento. Además, la acumulación de residuos en el sistema puede comprometer la integridad de los rodamientos y otros componentes mecánicos, lo que podría derivar en fallas operativas graves.



Figura 21. Inspección de componentes internos del motor de tracción tras operación prolongada.

La figura 22 muestra claros indicios de la presencia de aceite en diferentes partes del motor, lo que representa un factor crítico que puede afectar su rendimiento y confiabilidad a largo plazo. La presencia de aceite en áreas no diseñadas para su exposición, como los devanados del estator y las conexiones mecánicas, puede generar una serie de problemas operativos que comprometen la integridad del sistema.



Figura 22. Evidencia de contaminación por aceite en el motor de tracción y sus componentes internos.

El análisis de las figuras 21 y 22 sugiere que la contaminación por aceite ha impregnado los devanados del estator, lo que puede comprometer la resistencia dieléctrica del aislamiento, aumentando el riesgo de fallos eléctricos como cortocircuitos o descargas parciales. Además, la acumulación de suciedad y residuos en los componentes mecánicos puede generar un incremento en la fricción, provocando un desgaste acelerado en rodamientos y superficies de contacto críticas. La presencia de aceite en estas zonas no solo afecta la eficiencia operativa del motor, sino que también contribuye al aumento de temperatura, lo que agrava aún más el deterioro de los materiales aislantes y mecánicos.

El origen de la contaminación puede atribuirse a factores como el desgaste en los sellos del eje, fallas en el sistema de respiración del motor o condiciones operativas severas, como vibraciones excesivas y altas temperaturas, que comprometen la estanqueidad del sistema. La pérdida de aislamiento eléctrico derivada de esta contaminación puede conducir a fallas inesperadas, afectando la disponibilidad y confiabilidad del motor de tracción. El impacto de la contaminación por aceite en la vida útil del motor es significativo, ya que reduce su eficiencia, incrementa la necesidad de mantenimiento y, en algunos casos, puede llevar a la necesidad de una reparación mayor o incluso el reemplazo total de ciertos componentes.

4.1.3 Generación potencia eléctrica

La generación de potencia eléctrica es un proceso que permite el funcionamiento adecuado de los motores eléctricos de tracción, ya que proporciona la energía necesaria para su operación. Un generador eléctrico transforma la energía mecánica en energía eléctrica a través de la interacción de sus diferentes componentes, los cuales deben operar dentro de parámetros específicos para evitar fluctuaciones de voltaje, desequilibrios de fase o pérdidas de eficiencia que puedan afectar el rendimiento del motor. Aspectos como el desgaste mecánico, el sobrecalentamiento y la acumulación de contaminantes pueden comprometer el funcionamiento del generador, lo que podría generar fallos en el sistema eléctrico y reducir la vida útil del motor.

La figura 23 muestra los principales elementos de un generador eléctrico, los cuales desempeñan funciones específicas en la generación de potencia. El estator, encargado de inducir corriente en sus devanados, requiere un mantenimiento adecuado para evitar pérdidas de eficiencia y sobrecalentamientos. El rotor, que genera el campo magnético necesario para la inducción de corriente, puede presentar problemas de vibración y desgaste si no se mantiene en condiciones óptimas. El regulador de campo excitador (EFR) permite controlar la cantidad de corriente suministrada al rotor, asegurando que la salida de voltaje se mantenga dentro de los

límites establecidos. Por último, la excitatriz, que proporciona la corriente de excitación inicial, tiene un papel importante en la generación de potencia eléctrica de manera estable.



Figura 23. Identificación de partes.

La corriente de excitación es un parámetro que influye en el desempeño del generador eléctrico, ya que permite el control del campo magnético necesario para la generación de potencia eléctrica. La figura 24 muestra el regulador de campo excitador (EFR), el cual se encarga de ajustar la corriente suministrada al rotor del generador, asegurando que la potencia eléctrica entregada se mantiene dentro de los límites requeridos para el funcionamiento del motor de tracción.

El regulador de campo excitador es un componente que controla la intensidad del campo magnético generado por el rotor del generador, lo que impacta directamente en la tensión de salida. Un funcionamiento fuera del rango de operación puede provocar fluctuaciones de voltaje, afectando la estabilidad del suministro eléctrico y, por consiguiente, el rendimiento del motor. Un nivel de excitación inadecuado puede generar sobrecalentamiento en los devanados, desequilibrios eléctricos y pérdida de eficiencia en el motor.




Figura 24. Corriente de excitación al generador.

La figura anterior ilustra el rango de funcionamiento de la corriente de excitación, indicando los límites dentro de los cuales el generador opera de manera adecuada. Un incremento en la corriente de excitación más allá del rango especificado puede resultar en un esfuerzo excesivo en los devanados y componentes eléctricos del generador, mientras que una corriente insuficiente podría llevar a una reducción en la capacidad de generación, afectando el rendimiento del motor eléctrico de tracción. El análisis de la corriente de excitación es necesario para evitar efectos adversos sobre la vida útil del motor, ya que una gestión inadecuada puede generar pérdidas de aislamiento, fatiga térmica y una disminución en la capacidad operativa del equipo.

La tabla 5 muestra la interpretación de las señales de retroalimentación del regulador de campo excitador (EFR) a través del ciclo de trabajo de la modulación por ancho de pulso (PWM Duty Cycle). Estas señales permiten que al módulo de control de la transmisión (Drivetrain ECM) evalúe el estado del sistema de excitación del generador y realice ajustes en función de las condiciones operativas del motor de tracción.

El ciclo de trabajo de la señal PWM es un parámetro crítico en el control del campo del generador, ya que determina la cantidad de corriente suministrada al rotor. Un ciclo de trabajo adecuado garantiza que el generador produzca la potencia eléctrica requerida para la operación del motor eléctrico sin generar esfuerzos adicionales en sus componentes. Por otro lado, valores fuera de los rangos establecidos pueden indicar problemas en el sistema de excitación, como sobrecarga, fallas en los devanados o variaciones en la tensión de salida.

Por otro lado, el módulo de control de la transmisión (ECM) interpreta estas señales de retroalimentación para ajustar la corriente de excitación de acuerdo con la demanda de carga del motor de tracción. Un monitoreo constante de estas señales permite detectar posibles anomalías antes de que se conviertan en fallas críticas, lo que contribuye a mantener la eficiencia operativa y prolongar la vida útil del motor.

Tabla 5. Retroalimentación de diagnóstico.

EFR: EFR Diagnostic Feedback PWM Signals	
PWM Duty Cycle	Interpretación del Drivetrain ECM
<5%	Corto a tierra en la línea de retroalimentación
10%	EFR inabilitado, esperando por la señal de habilitación del Drivetrain ECM
20%	EFR en espera, voltaje de salida en alto a la espera de comandos.
30%	Voltaje de entra fuera del rango
40%	Salida del EFR en cortocircuito
50%	Operación normal
60%	Salida del EFR en estado abierto
70%	Corriente de salido alta
80%	Señal PWM del Drivetrain ECM fuera de rango
90%	Falla interna del EFR

Los sensores de temperatura por resistencia (RTD) son dispositivos utilizados para monitorear la temperatura en componentes críticos de los motores eléctricos de tracción. La figura 25 muestra la disposición de estos sensores en diferentes zonas del motor, lo que permite detectar variaciones térmicas y prevenir posibles fallos derivados del sobrecalentamiento.




Figura 25. Ubicación de sensores RTD.

En la figura se identifican tres puntos de monitoreo de temperatura:

a) Temperatura del devanado:

- Este sensor se encuentra ubicado dentro del estator y mide la temperatura de los devanados del motor.
- Su función es detectar incrementos térmicos que pueden comprometer el aislamiento eléctrico, lo que podría generar fallas por cortocircuito o degradación del material aislante.
- Los sensores en los devanados no son reemplazables, por lo que un daño en ellos requiere una intervención mayor en el motor.

b) Temperatura del cojinete del lado de transmisión (Drive End - DE):

- Situado en el extremo de salida del motor, este sensor monitorea la temperatura del cojinete, ayudando a identificar posibles problemas de lubricación o desgaste mecánico.
- Un aumento de temperatura en este punto podría indicar fricción excesiva o desalineaciones, factores que pueden reducir la vida útil del motor.
- Estos sensores son reemplazables, permitiendo su sustitución en caso de fallos.

c) Temperatura del cojinete del lado opuesto a la transmisión (No Drive End - NDE):

- Ubicado en el extremo opuesto del motor, este sensor también mide la temperatura del cojinete para asegurar una operación estable.
- Al igual que el sensor en el lado de transmisión, un incremento de temperatura podría sugerir problemas en la lubricación o fallas estructurales en el cojinete.
- Estos sensores también son reemplazables, con número de parte específica para su reposición.

El monitoreo de la temperatura en los cojinetes es un aspecto importante para garantizar el funcionamiento adecuado del motor eléctrico y prevenir fallos mecánicos. La figura 26 muestra los niveles de temperatura establecidos para los cojinetes del motor, los cuales permiten evaluar el estado térmico de estos componentes y tomar acciones correctivas en caso de condiciones anormales.

COJINETE # 2:
CID 3016 FMI 03
CID 3016 FMI 04

NIVEL 3
E724
E725
 $T^{\circ} = 105^{\circ}\text{C} \dots 10 \text{ seg}$




Figura 26. Límites de Temperatura en cojinete.

La figura anterior establece tres zonas de temperatura:

a) Temperatura normal ($< 100^{\circ}\text{C}$):

- Indica condiciones de operación dentro de los parámetros recomendados.
- En este rango, el cojinete opera de manera eficiente, sin riesgos de sobrecalentamiento ni afectaciones en su desempeño.

b) Evento de nivel 2 ($100^{\circ}\text{C} \leq T^{\circ} \leq 105^{\circ}\text{C}$):

- Señala una condición de advertencia en la que la temperatura ha superado los límites normales, pero aún se encuentra en un rango tolerable.
- En esta fase, se recomienda el monitoreo continuo del sistema y la implementación de acciones preventivas, como la revisión de lubricación o ajustes operativos para evitar un incremento adicional de temperatura.

c) Evento de nivel 3 ($T^{\circ} \geq 105^{\circ}\text{C}$):

- Indica que la temperatura ha alcanzado niveles críticos, con un tiempo de exposición de 10 segundos.
- Esta condición requiere una intervención inmediata para evitar daños graves en el cojinete, como el desgaste prematuro, la pérdida de lubricación efectiva o incluso la falla mecánica.

El monitoreo de la temperatura del cojinete se lleva a cabo mediante sensores RTD, que proporcionan datos en tiempo real sobre la condición térmica del componente. La detección temprana de temperaturas elevadas permite prevenir fallos, optimizar los programas de mantenimiento y prolongar la vida útil del motor eléctrico.

Límites de temperatura en devanado muestra los rangos de temperatura establecidos para los devanados, proporcionando una guía para la detección temprana de condiciones anómalas que podrían comprometer la integridad del aislamiento eléctrico y la eficiencia operativa del motor (ver figura 27).

La figura 27 define tres zonas de temperatura:

a) Temperatura normal ($< 155^{\circ}\text{C}$):

- Indica que el motor opera dentro de los parámetros adecuados sin riesgo de deterioro térmico.
- En esta zona, los devanados mantienen sus propiedades dieléctricas y mecánicas, lo que permite un desempeño confiable del motor.

b) Evento de nivel 2 ($105^{\circ}\text{C} \leq T^{\circ} \leq 155^{\circ}\text{C}$):

- Sugiere una condición de advertencia en la que la temperatura ha superado los límites recomendados para la operación normal.
- En este rango, el material aislante del devanado comienza a experimentar un mayor estrés térmico, por lo que es recomendable implementar medidas preventivas como la reducción de carga o la revisión del sistema de refrigeración.

c) Evento de nivel 3 ($T^{\circ} \geq 105^{\circ}\text{C}$):

- Señala condición crítica donde la temperatura alcanzó niveles que pueden comprometer gravemente el aislamiento eléctrico y provocar fallas prematuras en el motor.
- Un tiempo de exposición de 10 segundos a esta temperatura puede generar un deterioro acelerado del aislamiento, elevando el riesgo de cortocircuito y fallas en los devanados.




Figura 27. Límites de Temperatura en devanado.

El monitoreo continuo de la temperatura de los devanados a través de sensores RTD permite detectar aumentos de temperatura y tomar decisiones oportunas para evitar sobrecargas térmicas. La acumulación de calor en los devanados es uno de los factores más influyentes en la reducción de la vida útil del motor, ya que puede provocar fallos eléctricos y mecánicos si no se controla adecuadamente.

4.2 Análisis de fallas eléctricas

Se realizó un análisis inicial de las señales eléctricas en los camiones modelo 794 AC, tras la detección de fallas en la operación de Quellaveco. A partir de los resultados obtenidos, se ha decidido extender el análisis a los camiones 798 AC en la operación de Toromocho con un enfoque preventivo. Este proceso busca identificar posibles tendencias y patrones que puedan anticipar fallas similares, permitiendo la implementación de estrategias de mantenimiento oportunas.

El análisis se centra en la evaluación de diversas señales eléctricas claves recomendadas por los especialistas, tales como el consumo de potencia de la parrilla de frenado eléctrico (Electric Retarding Grid Power Consumption), la temperatura del aceite de freno (Brake Oil Temperature), la potencia del motor de tracción (Drive Motor Power), la corriente de las fases del motor Drive Motor Phases Current) y la temperatura de los módulos de fase (Phases Module Temp). Estas variables permiten comprender mejor el comportamiento de los sistemas eléctricos de los camiones y detectar posibles anomalías que puedan derivar en fallas operativas.

4.2.1 Análisis de eventos en conjunto

El análisis de eventos en conjunto permite evaluar el comportamiento de las fallas eléctricas reportadas en los camiones 798 AC a lo largo del tiempo, identificando patrones y tendencias que pueden ayudar a la implementación de acciones preventivas. La tabla 6 presenta una lista de códigos de eventos relacionados con el sistema de frenado eléctrico, incluyendo situaciones como la excesiva capacidad de frenado primario (evento 915), energía térmica acumulada en la parrilla de retardo (eventos 1082 y 1083), y discrepancias en la señal de los contactores de retardo (evento 897), entre otros. Estos eventos están asociados principalmente a la disipación de energía térmica durante la operación de los camiones y pueden afectar la eficiencia del sistema de retardo si no se controlan adecuadamente.

Tabla 6. Eventos reportados por los camiones 798 AC.

Código Evento	Nombre
915	Primary Retarding Capacity Exceeded
1082	High Chopper Retarding Grid Accumulated Thermal Energy
1083	High Contactor Retarding Grid Accumulated Thermal Energy
911	Unexpected Chopper Module Output Current Detected
908	Low Retarding Grid Contactor Output Current
897	Retarding Grid Contactor Signal Mismatch

La figura 28 muestra la evolución del número de eventos registrados desde agosto de 2022 hasta mayo de 2024. Se observan picos significativos de eventos en ciertos periodos, como septiembre de 2022 y octubre de 2023, lo que sugiere la existencia de factores operativos o condiciones de carga que pueden haber contribuido al aumento de las fallas. También se aprecia una tendencia fluctuante en la cantidad de eventos, con periodos de relativa estabilidad seguidos de incrementos pronunciados, lo que resalta la necesidad de un monitoreo continuo del sistema de retardo eléctrico.




Figura 28. Acumulación de Eventos por mes

Por otro lado, la figura 29 proporciona una visión más detallada de los eventos ocurridos durante los primeros meses del año, permitiendo identificar patrones más recientes. Se observa un aumento considerable de eventos en marzo de 2024, seguido de una reducción en abril, para luego registrar un nuevo incremento en mayo. Este comportamiento sugiere que ciertos factores operacionales o condiciones ambientales podrían estar contribuyendo a la recurrencia de eventos en determinados meses.




Figura 29. Zoom al periodo a partir del 2024.


El análisis de estos eventos es relevante para comprender cómo influyen en la salud y la vida útil del motor eléctrico, ya que la acumulación de energía térmica excesiva en la parrilla de retardo puede generar sobrecalentamiento y reducir la eficiencia del sistema. Además, las discrepancias en las señales de los contactores de retardo pueden indicar fallos en el control del sistema, afectando la capacidad de frenado del camión y comprometiendo la seguridad operativa.

4.2.2 Análisis de eventos por camión

El análisis de eventos por camión permite evaluar la frecuencia y distribución de los principales eventos eléctricos reportados en cada unidad de la operación, proporcionando información detallada sobre el comportamiento individual de los camiones a lo largo del tiempo. Este análisis facilita la identificación de patrones específicos de fallas en cada equipo, lo que contribuye a la detección temprana de anomalías ya la toma de decisiones enfocadas en el mantenimiento preventivo y correctivo.

En las siguientes gráficas se presenta la cantidad de ocurrencias de los seis eventos previamente mencionados, contabilizados mensualmente para cada camión. Estos datos permiten visualizar tendencias operativas, comparar el desempeño entre diferentes unidades y detectar posibles factores que influyen en la recurrencia de las fallas, tales como condiciones de operación, cargas de trabajo y mantenimiento realizado.


CM501 - Events per machine and month



CM502 - Events per machine and month



CM503 - Events per machine and month



CM504 - Events per machine and month





Figura 30. Cantidad de eventos por mes Camión.

4.2.3 Análisis de potencias de Grid

Para esta etapa se analiza la tendencia de “Electric Retarding Grid Power Consumption” en la data de tendencias para los valores máximos.




Figura 31. *Boxplot de la tendencia para cada uno de los camiones usando tendencia máxima.*

En la figura 31 se muestran los boxplots de la tendencia “Electric Retarding Grid Power Consumption” para cada uno de los camiones entre las fechas 2022-07-15 al 2024-05-08. Sin embargo, hay que considerar que los equipos del CM504 al CM508 recién han empezado a operar desde enero del 2024.




Figura 32. *Boxplot de la tendencia para cada uno de los camiones para el año 2024.*

En la figura 32 se muestra la gráfica para las tendencias máximas en el periodo de 2024-01-01 al 2024-05-08. Es en este rango de fechas que los 8 camiones están operando y se puede hacer una comparación más relevante.





Figura 33. *Boxplot izquierdo con la data antes 2024, boxplot derecho con la data a partir del 2024.*

En la figura 33 se hace la comparación del periodo antes y después del 2024 usando la data de todos los camiones. Se puede observar que en el boxplot de la derecha su mediana es menor en comparación, pero hay que considerar que en este periodo se encuentran los camiones más nuevos que pueden contribuir a cambiar la distribución de los datos.


Adicionalmente se añade el detalle de cada uno de los camiones para la tendencia de “Electric Retarding Grid Power Consumption”.




CM503 - Electric Retarding Grid Power Consumption [kW]




CM504 - Electric Retarding Grid Power Consumption [kW]



CM505 - Electric Retarding Grid Power Consumption [kW]



CM506 - Electric Retarding Grid Power Consumption [kW]



CM507 - Electric Retarding Grid Power Consumption [kW]






Figura 34. *Tendencia Electric Retarding Grid Power Consumption por camión.*

4.2.4 Análisis de temperatura de aceite y potencia

En este parte se busca ver si existe correlación entre las tendencias de “Brake Oil Temperature” y “Electric Retarding Grid Power Consumption” para esto se realiza la matriz de correlación para la data entre las fechas de 2022-07-15 al 2024-05-08.

En la matriz de correlación se puede ver que hay campos en blanco para el gráfico de los valores mínimos, eso es porque no se ha podido calcular el valor debido a que los valores mínimos son iguales y no hay cambio. Sin embargo, para las tendencias máximas y promedios sí se pueden visualizar el valor de correlación.




Figura 35. *Matriz de correlación para las tendencias en sus valores mínimos.*



Figura 36. *Matriz de correlación para las tendencias en sus valores máximos.*




Figura 37. *Matriz de correlación para las tendencias en sus valores promedios.*

En las figuras 35, 36 y 37 se muestran la correlación entre las señales para sus valores mínimos, máximos y promedios respectivamente. Se observa que los valores mínimos son los que menos


tienen correlación entre la temperatura del aceite y la potencia. Sin embargo, para los valores máximos la correlación aumenta hasta 0.59 y para los valores promedios hasta 0.38.

En general la correlación entre las tendencias de “Brake Oil Temperature” y “Electric Retarding Grid Power Consumption” es baja, esto puede ser debido a que la temperatura varía más lentamente que la potencia del grid.


4.2.5 Análisis de patrones de correlación con ventana móvil de un mes

Utilizando las señales de “Brake Oil Temperature” y “Electric Retarding Grid Power Consumption” se obtuvo un valor de correlación usando la información de los 30 días anteriores, de esta forma se obtuvo una señal de cómo cambia la correlación en el tiempo. Para esto se usó la señal de valores promedios ya que reduce el ruido para la comparación con la temperatura.

CM501 - Electric Retarding Grid Power Consumption vs Left Front Brake Oil Temperature




CM502 - Electric Retarding Grid Power Consumption vs Left Front Brake Oil Temperature




CM503 - Electric Retarding Grid Power Consumption vs Left Front Brake Oil Temperature




CM504 - Electric Retarding Grid Power Consumption vs Left Front Brake Oil Temperature




CM505 - Electric Retarding Grid Power Consumption vs Left Front Brake Oil Temperature



CM506 - Electric Retarding Grid Power Consumption vs Left Front Brake Oil Temperature



CM507 - Electric Retarding Grid Power Consumption vs Left Front Brake Oil Temperature



CM508 - Electric Retarding Grid Power Consumption vs Left Front Brake Oil Temperature




Figura 38. Correlación en el tiempo para las 2 tendencias por camión

En las imágenes de la figura 38 se muestran cómo la correlación de las señales de “Brake Oil Temperature” y “Electric Retarding Grid Power Consumption” va variando en el tiempo. Para calcular cada uno de los valores se utilizan los datos de los 30 días anteriores. El indicador de la correlación como máximo llega a los 0.55, lo cual indica que no hay mucha relación entre las variables.

4.2.6 Análisis de Drive Motor Power vs Electric Retarding Grid Power Consumption

En esta etapa se realizó el análisis de las tendencias de “Drive Motor Power” y “Electric Retarding Grid Power Consumption”, utilizando a la correlación como indicador y los valores de promedios de las dos tendencias. Para calcular cada uno de los puntos de la correlación se utilizan los datos de las 2 señales con un periodo de 30 días anteriores.


En las imágenes de la figura 39 se muestran a continuación que en el eje izquierdo está la escala de las 2 tendencias y en el eje derecho está la escala de la correlación, que puede ir de -1 a 1. Cuando la correlación tiene valores negativos indica una relación inversa en las 2 señales y un valor positivo indica una relación directa. Entre más cercano a 1 o -1, la correlación es más fuerte y valores cercanos a 0 indican muy poca relación entre las variables.



CM503 - Drive Motor Power - #1 vs Electric Retarding Grid Power Consumption - #1




CM504 - Drive Motor Power - #1 vs Electric Retarding Grid Power Consumption - #1



CM505 - Drive Motor Power - #1 vs Electric Retarding Grid Power Consumption - #1



CM506 - Drive Motor Power - #1 vs Electric Retarding Grid Power Consumption - #1



CM507 - Drive Motor Power - #1 vs Electric Retarding Grid Power Consumption - #1






Figura 39. *Correlación en el tiempo para las 2 tendencias y las señales originales por camión.*


En las gráficas de la figura 39 se puede observar que la correlación tiene un valor cambiante en el tiempo, para estos camiones se ve que los valores pueden ser positivos o negativos en ciertos periodos de tiempo. Sin embargo, el indicador de correlación se comporta de manera similar para cada uno de los camiones en los mismos periodos de tiempo y resalta el rango de fechas de octubre 2023 a diciembre 2023, en donde para los 3 primeros camiones la correlación alcanza los valores mínimos. Esto puede indicar un factor externo que ha influido en los 3 equipos por igual.

4.2.7 Umbrales de Electric Retarding Grid Power Consumption


En esta etapa se eligieron umbrales para la tendencia de Electric Retarding Grid Power Consumption, y agruparlos por meses para contabilizar cuántas veces llegan o sobrepasan ese valor. Los valores seleccionados con el equipo eléctrico fueron 3594, 4086 y 5000. En las siguientes gráficas de la figura 40 se muestran la cantidad de veces que sobrepasan los valores agrupados por cada mes.



CM501 - Electric Retarding Grid Power Consumption - #1




CM502 - Electric Retarding Grid Power Consumption - #1




CM502 - Electric Retarding Grid Power Consumption - #1




CM503 - Electric Retarding Grid Power Consumption - #1




CM503 - Electric Retarding Grid Power Consumption - #1




CM504 - Electric Retarding Grid Power Consumption - #1



CM504 - Electric Retarding Grid Power Consumption - #1



CM505 - Electric Retarding Grid Power Consumption - #1



CM505 - Electric Retarding Grid Power Consumption - #1



CM506 - Electric Retarding Grid Power Consumption - #1







Figura 40. Gráfico de barras por mes contabilizando la cantidad que sobrepasan los límites.

En cada una de las imágenes de la figura 40 se muestra la cantidad de veces que se sobrepasó los límites establecidos, además se añade una segunda imagen en la que se muestra cuando pasa el límite de 5000, excepto para los equipos CM506 y CM508 que no se muestra ese detalle porque no pasaron el límite en lo que se tiene de data.


4.2.8 Electric Retarding Grid Power Consumption

Para este caso se busca ver la acumulación de la tendencia de “Electric Retarding Grid Power Consumption” en el tiempo. Para esto se realizan 2 gráficas, la primera consta de la tendencia de “Electric Retarding Grid Power Consumption” en su valor máximo para cada hora, acompañada de un indicador que va sumando los valores pasados. La segunda gráfica es la suma de los valores de la tendencia dividida por la cantidad de registros que se tienen en cada mes.


CM501 - Electric Retarding Grid Power Consumption - #1




CM501 - Electric Retarding Grid Power Consumption - #1




CM502 - Electric Retarding Grid Power Consumption - #1




CM502 - Electric Retarding Grid Power Consumption - #1



CM503 - Electric Retarding Grid Power Consumption - #1




CM503 - Electric Retarding Grid Power Consumption - #1




CM504 - Electric Retarding Grid Power Consumption - #1



CM504 - Electric Retarding Grid Power Consumption - #1



CM505 - Electric Retarding Grid Power Consumption - #1



CM505 - Electric Retarding Grid Power Consumption - #1







Figura 41. Gráfico de la tendencia y su valor acumulado en rojo.

En la primera gráfica de las tendencias máximas de “Electric Retarding Grid Power Consumption” también se añadió el indicador que va acumulando cada valor. Esto puede dar una idea de cuanto uso se le ha dado a la máquina. En la segunda gráfica se muestra el valor promedio de la misma tendencia por cada mes, en este caso se puede ver en cuales meses se ha tenido mayores valores de potencia del grid.

4.2.9 Análisis de downhill

En este análisis se desea identificar la sobrecarga del Grid, cuando el camión está bajando cargado una pendiente. Para esto se utilizó la data segundo a segundo; por ello, se tomó muestras en periodos de tiempos para algunos equipos. Las señales que se visualizan son la altitud en verde, la carga en rojo y la potencia del grid en azul.






Figura 42. Gráfica de la altitud, payload y potencia de grid por camión.

En las gráficas de la figura 42 se puede observar que en la muestra tomada para diferentes días el camión no está bajando cargado constantemente, pero sí se puede observar que sube cargado ya que el incremento de la altitud coincide con los periodos de carga. Solo es posible ver cortos

periodos de tiempo en donde el camión realiza un pequeño descenso cuando está cargado, pero no es continuo. Para los periodos de tiempo seleccionados los que más muestran el comportamiento de bajar pequeñas pendientes son el CM508 y el CM503.

4.2.10 Análisis de Drive Motor Phases Current vs Phases Module Temp

En esta parte se busca ver la relación que existe entre las variables “Drive Motor Phases Current” y “Phases Module Temp” que representa la corriente de cada una de las fases de los motores y la temperatura de los módulos de fase.

Primero graficamos la matriz de correlación de estas señales.




Figura 43. Matriz de correlación de Corriente y temperatura de los módulos de fase.

De la matriz se puede ver que la corriente y la temperatura de los módulos de fase tienen poca correlación, esto podría ser ocasionado porque la temperatura varía más lentamente y además estos módulos tienen refrigeración.

En las siguientes gráficas de la figura 44 se ve a detalle cómo varía la correlación entre variables durante el tiempo.






Figura 44. *Correlación en el tiempo de la temperatura y corriente de los módulos de fase por camión.*

En las gráficas de la correlación en el tiempo de la figura 44 se ve que los valores siguen siendo bajos, siendo el mayor valor 0.35, esto junto con la información de la matriz de confusión indica que la temperatura y la corriente no están relacionadas y tampoco en el tiempo se ve que la relación aumente significativamente.

4.2.11 Análisis de desbalance de potencia del motor

Para este análisis se busca ver el comportamiento de la señal “Drive Motor Power” para los 2 motores e identificar si existe algún desbalance en la data de tendencia. El desbalance se mide restando la potencia de ambos motores, las potencias no deberían tener mucha diferencia porque eso indicaría un desbalance.





Figura 45. *Potencia de los motores y la diferencia en verde.*

De las gráficas del desbalance de la figura 45 se observa que, para los 3 primeros camiones, el desbalance como mínimo ha llegado a -500, pero en los camiones más nuevos han llegado hasta -1000. Esto indica que los equipos nuevos se comportan de manera diferente a los más antiguos. Sin embargo, como los nuevos camiones tienen poca data, no se puede generalizar porque podría tener casuísticas especiales.

Del análisis de las fallas eléctricas se infiere lo siguiente:

- Del análisis de eventos concluimos que el comportamiento de los camiones a nivel de cantidades es similar; sin embargo, en marzo del 2024 se detecta un incremento en las alertas que puede ser ocasionado por factores externos o algún cambio en las condiciones de la mina.
- Del análisis de la señal “Electric Retarding Grid Power Consumption” concluimos que los camiones más antiguos suelen pasar los 4000 kW de consumo mientras que los nuevos suelen encontrarse por debajo de ese valor.
- Los camiones nuevos presentan un mayor desbalance de potencia de los motores (de hasta 1000 kW) mientras que los camiones antiguos presentan un desbalance menor (de hasta 500 kW)

4.3 Desarrollo de modelos de aprendizaje supervisado

El desarrollo de modelos de aprendizaje supervisado se presenta como una solución eficaz para la predicción de la vida útil de los motores eléctricos utilizados en equipos de gran minería. La implementación de estos modelos permite identificar patrones y tendencias en los datos operativos, contribuyendo a una gestión más eficiente del mantenimiento y la reducción de fallas inesperadas. En esta sección, se describen las técnicas utilizadas para la creación de modelos predictivos mediante algoritmos como Random Forest, Support Vector Machines (SVM) y Redes Neuronales Artificiales (ANN), que han demostrado ser herramientas valiosas en la evaluación del estado de salud de los motores.

El proceso de desarrollo involucra diversas etapas, que incluyen la selección y procesamiento de datos relevantes, la normalización de las variables, y validación de los modelos. La finalidad es construir un indicador de salud robusto que permita estimar con precisión el tiempo de vida restante del motor y optimizar las estrategias de mantenimiento predictivo.

Se han considerado variables clave como la temperatura, la corriente, la vibración y el aislamiento del bobinado (ver figura 46), ya que estos parámetros influyen significativamente en el rendimiento y la durabilidad de los motores eléctricos en equipos de gran minería. La combinación de algoritmos de aprendizaje supervisado permite aprovechar la diversidad de técnicas para mejorar la precisión del modelo, ofreciendo una visión integral del estado de los equipos.




Figura 46. Generación de datos.

La figura 47 representa la estructura de la tabla de características extraídas de los datos del sistema de monitoreo, almacenadas en la variable FeatureTable11 dentro del entorno de MATLAB. La normalización de datos mediante el análisis de varianza (ANOVA) es una técnica que se está utilizando para garantizar que las características extraídas tengan una escala uniforme y que las diferencias en magnitudes no afecten el rendimiento de los modelos de aprendizaje supervisados.

En el entorno de trabajo de MATLAB, se observa la carga de los datos desde el archivo FeatureTable1.mat, donde se han registrado múltiples métricas como valor pico (PeakValue), valor RMS, relación señal-ruido (SNR), y desviación estándar normalizada (ShapeFactor). Estas métricas son utilizadas para la evaluación del estado de salud del motor, ya que permiten cuantificar las condiciones de operación y detectar patrones asociados a posibles fallas.




Figura 47. Aplicación de Variación Anova para normalización de datos.

La figura 48 muestra la evolución del indicador de salud (Health Indicator - HI) en función del tiempo para el conjunto de datos de entrenamiento. Se observa una alta variabilidad en los

datos, lo que sugiere la presencia de ruido interno a las mediciones de los sensores. Este conjunto de datos se utiliza para el ajuste del modelo de predicción de la vida útil restante de los motores eléctricos. La diversidad en los patrones de comportamiento refleja la necesidad de aplicar técnicas de preprocesamiento como la suavización y la normalización para mejorar la precisión del modelo.




Figura 48. *Datos de entrenamiento.*

La figura 49 representa la serie temporal de los datos de validación, donde se evalúa el rendimiento del modelo entrenado. Similar a los datos de entrenamiento, los valores presentan fluctuaciones significativas, lo que indica la necesidad de verificar la estabilidad del modelo ante diferentes condiciones operativas. Un buen ajuste en esta etapa asegura que el modelo pueda generalizar su desempeño a nuevos datos con características similares a las del entrenamiento.




Figura 49. *Datos de validación.*

La figura 50 ilustra la selección de características basada en la monotonidad, obtenida mediante el análisis de varianza (ANOVA). En esta gráfica, se presentan las características más relevantes para la predicción de la vida útil del motor eléctrico, clasificadas en orden de importancia. Se observa que las métricas SINAD (Signal-to-Noise and Distortion Ratio) y SNR (Signal-to-Noise Ratio) son las más significativas, indicando que la relación señal-ruido juega un papel crucial en la predicción del estado de salud del motor. Características como la media, RMS y factor de cresta, aunque relevantes, presentan menor contribución en comparación con las principales.




Figura 50. Datos de entrenamiento a partir de la variación ANOVA.

A partir de los datos de entrenamiento realizamos la elaboración de los algoritmos de aprendizaje supervisado. La figura 51 muestra el desempeño de los modelos de aprendizaje supervisado Random Forest y Support Vector Machines (SVM) en la predicción de la vida útil restante (RUL) de los motores eléctricos. La evaluación del entrenamiento es esencial dado que permite verificar la capacidad del modelo de ajustarse a los datos históricos y proporcionar predicciones precisas que permitan planificar el mantenimiento predictivo de manera eficiente, y a partir de esto realizar el logro de los objetivos planteados en esta investigación.




Figura 51. Visualización del entrenamiento para Random Forest y SVM.

La figura 52 muestra la comparación entre la vida útil restante real (RUL) y la vida útil predicha por el modelo de red neuronal artificial durante la fase de entrenamiento. Las redes neuronales artificiales son utilizadas para modelar relaciones no lineales complejas en los datos, lo que permite una predicción más precisa del estado de salud del motor eléctrico en función de Múltiples características operativas.




Figura 52. Visualización del entrenamiento de la Red Neuronal Artificial (ANN).

- La gráfica muestra una correspondencia bastante estrecha entre la RUL real y la predicción de la ANN en las primeras etapas del ciclo de vida del motor.
- Sin embargo, hacia el final del ciclo (alrededor de la marca de tiempo 9), la predicción presenta una ligera desviación con respecto a los valores reales, lo que sugiere una

posible necesidad de ajuste en la configuración de la red, como el número de neuronas ocultas o la función de activación utilizada.

- Durante la primera mitad del tiempo analizado, la red neuronal muestra un excelente seguimiento de la tendencia real, lo que indica que el modelo ha captado correctamente los patrones subyacentes en los datos de entrenamiento.
- La ANN sigue una tendencia casi lineal, mostrando su capacidad para modelar la evolución de la RUL en términos generales. Sin embargo, la ligera diferencia en los últimos puntos resalta la necesidad de validación cruzada para evitar problemas de generalización en nuevos datos.

La red neuronal artificial presenta un rendimiento adecuado en la predicción de la vida útil restante, especialmente en las etapas iniciales del ciclo de vida. La ligera discrepancia observada en la fase final sugiere que se podría mejorar la robustez del modelo mediante estrategias como el ajuste de hiperparámetros, el aumento de datos de entrenamiento o la aplicación de regularización para evitar el sobreajuste.

La figura 53 muestra los resultados del proceso de entrenamiento de una red neuronal artificial (ANN) aplicado a la predicción de la vida útil restante (RUL) de motores eléctricos. El entrenamiento se realizó utilizando el algoritmo Levenberg-Marquardt, una técnica de optimización ampliamente utilizada para ajustar redes neuronales debido a su alta eficiencia en problemas de ajuste no lineal y su rapidez en la convergencia.

- Se observa que el proceso de entrenamiento ha finalizado con éxito, alcanzando el criterio de mínimo gradiente, lo que indica que la red ha encontrado un punto óptimo para minimizar el error.
- El número de épocas utilizado es 4, significativamente menor al valor objetivo de 1000, lo que sugiere que la red ha aprendido rápidamente a partir de los datos proporcionados.
- La métrica de Performance, basada en el error cuadrático medio (MSE), ha disminuido de un valor inicial de 54.9 a un valor extremadamente bajo de $1.26e-19$, lo que indica un excelente ajuste a los datos de entrenamiento.
- El gradiente, que mide la tasa de cambio del error con respecto a los pesos, se ha reducido de 153 a $3.85e-09$, indicando que la red ha alcanzado una condición de convergencia satisfactoria.




Figura 53. Entrenamiento de la red neuronal utilizando el algoritmo Levenberg-Marquardt.

La figura 54 muestra la evaluación del ajuste del modelo de red neuronal artificial (ANN) utilizando gráficos de regresión para los conjuntos de datos de entrenamiento, validación, prueba y el conjunto completo. El coeficiente de evaluación (R) es una medida clave utilizada para evaluar la calidad del ajuste del modelo, indicando qué tan bien las predicciones del modelo coinciden con los valores reales.




Figura 54. *Regresión del rendimiento de la red neuronal.*

En el conjunto de entrenamiento, se observa un valor de compensación de $R = 0.99999$, lo que indica que el modelo ha logrado capturar con precisión la relación entre las variables de entrada y salida. La línea de regresión casi coincide con la línea ideal de referencia, lo que sugiere un excelente ajuste a los datos de entrenamiento, reflejando que la red neuronal ha aprendido eficazmente los patrones presentes en estos datos.

Para el conjunto de validación, se registra un coeficiente de compensación de $R = 1$, lo que implica una correspondencia perfecta entre los valores reales y los predichos. La alineación de la línea de regresión con la diagonal de referencia demuestra que el modelo ha generalizado adecuadamente los datos nunca antes vistos, mostrando un buen equilibrio entre ajuste y capacidad de generalización.

En el caso del conjunto de prueba, el coeficiente de compensación también es de $R = 1$, lo que sugiere una alta capacidad de predicción en datos no utilizados durante el entrenamiento. Sin

embargo, la pendiente de la ecuación de ajuste muestra una ligera discrepancia, indicando que, en ciertas condiciones, el modelo podría estar subestimando algunos valores de la vida útil restante.

Finalmente, al analizar el rendimiento global de la red neuronal, se obtiene un coeficiente de precisión de $R = 0.93467$, lo que indica una relación fuerte entre las predicciones y los valores reales en general. No obstante, la pendiente de la regresión sugiere una ligera subestimación de la vida útil restante, lo que puede indicar la necesidad de ajustes adicionales en el modelo, como la optimización de hiperparámetros o la selección de características más relevantes.

La figura 55 presenta el comportamiento de varios parámetros clave durante el proceso de entrenamiento del modelo basado en redes neuronales artificiales. Los gráficos muestran la evolución del gradiente, el parámetro de regularización μ y la cantidad de verificaciones de validación a lo largo de las épocas de entrenamiento.

- El primer gráfico representa la disminución del gradiente, este comportamiento indica que el modelo ha logrado minimizar la función de error de manera eficiente, acercándose a un punto de convergencia donde las actualizaciones de los pesos neuronales son cada vez menores. La reducción constante del gradiente sugiere que el algoritmo de optimización ha encontrado una solución estable.
- El segundo gráfico muestra la evolución de μ , un parámetro clave del algoritmo Levenberg-Marquardt utilizado para regularizar la optimización y controlar la transición entre el método de descenso de gradiente y la aproximación de Newton. Se observa que μ ha disminuido constantemente desde su valor inicial de 0.00, lo que sugiere que la red está convergiendo hacia una solución óptima sin necesidad de ajustes significativos.
- El tercer gráfico ilustra las verificaciones de validación, las cuales han alcanzado un total de dos durante el entrenamiento. Esto indica que el modelo ha mantenido un buen equilibrio entre el ajuste a los datos de entrenamiento y su capacidad de generalización en los datos de validación.




Figura 55. Evolución del gradiente en la red neuronal.

La figura 56 presenta un análisis del rendimiento del modelo en términos de error durante el proceso de entrenamiento. La imagen está compuesta por dos gráficos clave: a la izquierda, el histograma de errores y, a la derecha, la evolución del error cuadrático medio (MSE) en función de las épocas de entrenamiento.




Figura 56. Histograma de errores y desempeño de validación durante el entrenamiento de la red neuronal.

El histograma de errores muestra la distribución de las diferencias entre los valores de salida predichos y los valores reales para los conjuntos de entrenamiento, validación y prueba. Se observa que la mayoría de los errores se concentran alrededor de valores cercanos a cero, lo que sugiere un buen ajuste del modelo. La distribución de los errores indica que el modelo ha logrado una precisión aceptable en los diferentes conjuntos de datos, con un número reducido de instancias que presentan desviaciones mayores. La presencia de errores pequeños sugiere que la red neuronal ha aprendido de manera efectiva los patrones de los datos de entrada.

El gráfico de la derecha representa la evolución del error cuadrático medio (MSE) a lo largo de las épocas de entrenamiento. Se destaca que el mejor desempeño de validación se alcanzó en la segunda época con un valor de MSE de 0.022348, como se indica en la figura. A partir de este punto, el error en los conjuntos de entrenamiento y validación continúa disminuyendo de manera constante, lo que indica que la red está mejorando sus signos de precisión sin evidencias de sobreajuste. La curva de entrenamiento, muestra una reducción progresiva del error, mientras que la curva de validación, mantiene un comportamiento estable, confirmando la capacidad del modelo para generalizar a datos no vistos.

La figura 57 muestra el desempeño de tres enfoques de aprendizaje supervisado aplicados a la estimación de la vida útil restante (RUL) de un motor eléctrico. En el gráfico se presentan los resultados obtenidos mediante los modelos de Random Forest, Support Vector Machines (SVM) y Redes Neuronales Artificiales (ANN), comparados con la RUL real a lo largo del tiempo.




Figura 57. Comparación de modelos de predicción de RUL.

Se observa que, en las primeras etapas del tiempo, los tres modelos siguen de cerca la tendencia de la RUL real, mostrando una capacidad adecuada para capturar la dinámica del deterioro del motor. Sin embargo, a medida que avanza el tiempo, las predicciones a estabilizarse en valores diferentes a la RUL real, lo que sugiere posibles limitaciones en la capacidad de los modelos para extrapolar correctamente la degradación a largo plazo.

- El modelo basado en Redes Neuronales tiende a sobreestimar la vida útil restante, manteniéndose en valores más bajos en comparación con los otros modelos.
- Por otro lado, el modelo de SVM muestra una estimación más ajustada a la RUL real en las primeras etapas, pero presenta fluctuaciones que reflejan cierta inestabilidad en la predicción. Esto sugiere que la sensibilidad del modelo a variaciones en los datos de entrada podría estar afectando su desempeño.
- El modelo de Random Forest ofrece una predicción más estable, aunque subestima la vida útil restante en comparación con la RUL real. Su comportamiento indica que este modelo tiene una capacidad de generalización razonable.

La figura 58 presenta un análisis comparativo del error cuadrático medio (MSE) obtenido en los modelos de predicción de vida útil restante (RUL) aplicando Random Forest, Support Vector Machines (SVM) y Redes Neuronales Artificiales (ANN).

Evaluando el rendimiento de los modelos...

Modelo	MSE	MAE	RMSE	MAPE
Random Forest	751.69	25.02	27.42	79.18
SVM	753.67	24.96	27.45	79.15
Red Neuronal	716.75	24.38	26.77	77.65

--- Ejemplos Comparativos de Predicción de RUL (primeros 15) ---

Día 1:	RUL Real = 11	RF = 4.16	SVM = 1.37	ANN = 2.05
Día 2:	RUL Real = 12	RF = 4.15	SVM = 2.37	ANN = 2.73
Día 3:	RUL Real = 13	RF = 4.20	SVM = 3.37	ANN = 2.37
Día 4:	RUL Real = 14	RF = 4.20	SVM = 3.76	ANN = 2.54
Día 5:	RUL Real = 15	RF = 5.01	SVM = 4.69	ANN = 3.38
Día 6:	RUL Real = 16	RF = 5.73	SVM = 5.63	ANN = 4.98
Día 7:	RUL Real = 17	RF = 6.31	SVM = 7.02	ANN = 7.88
Día 8:	RUL Real = 18	RF = 6.81	SVM = 8.37	ANN = 9.53
Día 9:	RUL Real = 19	RF = 6.83	SVM = 8.63	ANN = 9.98
Día 10:	RUL Real = 20	RF = 6.41	SVM = 9.63	ANN = 7.12
Día 11:	RUL Real = 21	RF = 5.17	SVM = 5.56	ANN = 6.10
Día 12:	RUL Real = 22	RF = 5.17	SVM = 5.56	ANN = 6.10
Día 13:	RUL Real = 23	RF = 5.17	SVM = 5.56	ANN = 6.10
Día 14:	RUL Real = 24	RF = 4.74	SVM = 5.56	ANN = 6.10
Día 15:	RUL Real = 25	RF = 4.46	SVM = 5.56	ANN = 6.10

El mejor modelo es: Red Neuronal con un MSE de 716.75

Figura 58. Comparación del rendimiento de los modelos.


De la figura 58 se infiere lo siguiente:

- El modelo Red Neuronal Artificial (ANN) mostró el mejor desempeño global con el menor Error Cuadrático Medio ($MSE = 716.75$), además de obtener el menor MAE (24.38), RMSE (26.77) y MAPE (77.65%), lo que indica que sus predicciones fueron, en promedio, más cercanas al RUL real que las de los demás modelos. A diferencia de evaluaciones anteriores, en este caso ANN mantiene un rendimiento estable tanto al inicio como al final del conjunto de prueba, descartando la hipótesis previa de sobreajuste localizado.
- Support Vector Machines (SVM) también mostró un rendimiento competitivo, con valores de error similares a los de ANN. En varios de los primeros días (1 al 5), las predicciones de SVM fueron las más cercanas al valor real del RUL. Sin embargo, a partir del día 6, su error comienza a incrementarse progresivamente, lo que sugiere que el modelo pierde precisión conforme avanza el ciclo de vida del motor.
- El modelo Random Forest, si bien mostró una estabilidad relativa en términos de error promedio ($MSE = 751.69$), no destacó en precisión individual. En casi todos los ejemplos, sus predicciones se mantuvieron por encima de las reales, lo que evidencia una tendencia general a la sobreestimación del RUL. Esto puede ser crítico en entornos industriales, ya que una sobreestimación podría retrasar intervenciones necesarias y aumentar el riesgo de fallas.

La figura 59 ilustra la evolución esperada de la condición del motor eléctrico a lo largo del tiempo, expresada mediante el indicador de salud (Health Indicator, HI). La gráfica muestra una curva de degradación esperada en color azul, la cual representa la tendencia decreciente del HI conforme avanza el tiempo, indicando el desgaste progresivo del motor. Los puntos de evaluación resaltados en rojo señalan momentos clave en los cuales se han realizado estimaciones específicas para distintos escenarios temporales.

Se presentan estimaciones del indicador de salud para diferentes períodos de tiempo:

- A los 15 días, el HI es de 0.9704, lo que sugiere que el motor mantiene un estado óptimo.
- A los 30 días, el valor disminuye a 0.9418, mostrando una ligera degradación.
- A los 90 días, el HI se reduce a 0.8353, reflejando un desgaste más pronunciado.
- A los 180 días, el indicador baja a 0.6977, evidenciando un deterioro significativo.
- A los 365 días, el valor alcanza 0.4819, lo que indica un nivel de salud que, si bien es aceptable, muestra un avance progresivo de la degradación.



Estimación de la salud del motor en diferentes escenarios:

Para 15 días: Indicador de Salud = 0.9704

Para 30 días: Indicador de Salud = 0.9418

Para 90 días: Indicador de Salud = 0.8353

Para 180 días: Indicador de Salud = 0.6977

Para 365 días: Indicador de Salud = 0.4819

El indicador de salud no cae por debajo del umbral de 0.30 en el período de simulación.

Figura 59. *Proyección del indicador de salud.*

Se observa que el indicador de salud no desciende por debajo del umbral crítico de 0.30, lo que sugiere que, bajo las condiciones actuales de operación y mantenimiento, el motor eléctrico no enfrentará una falla catastrófica en el período de simulación considerado.

4.4 Discusión

El presente estudio ha permitido desarrollar un indicador de salud basado en algoritmos de aprendizaje supervisado para predecir la vida útil restante (RUL) de motores eléctricos en equipos de minería. La metodología aplicada ha demostrado ser adecuada, evaluándose tres modelos: Random Forest, Support Vector Machines (SVM) y Redes Neuronales Artificiales (ANN). Los resultados mostraron que el modelo basado en Red Neuronal Artificial (ANN) obtuvo el mejor desempeño general, con un error cuadrático medio (MSE) de 716.75, seguido de Random Forest con 751.69 y Support Vector Machines (SVM) con 753.67. A diferencia de evaluaciones anteriores, la red neuronal no solo presentó alta precisión en los últimos días del

conjunto de prueba, sino que mantuvo una mayor consistencia en sus predicciones a lo largo de los 15 ejemplos, lo que sugiere un mejor ajuste global y mayor capacidad para adaptarse a la progresión del desgaste del motor. En contraste, SVM y Random Forest mostraron mayores fluctuaciones, especialmente en los días intermedios y finales, consolidando al modelo ANN como la alternativa más precisa y robusta para la predicción del RUL. Sin embargo, se debe considerar que los modelos pueden presentar limitaciones en la extrapolación de la degradación a largo plazo, ya que en algunas etapas los valores predichos mostraron desviaciones respecto a la vida útil restante real.

En cuanto a la validez externa, los resultados pueden ser aplicables a otros sectores industriales con condiciones operativas similares, como la minería (4), la manufactura (2) y el mantenimiento de motores industriales (3). Se observó que la degradación del indicador de salud (HI) a lo largo del tiempo sigue un patrón progresivo, con un valor de 0.9704 a los 15 días y 0.4819 tras 365 días, sin alcanzar el umbral crítico de 0.30, lo que sugiere que los motores monitoreados no presentarán fallas severas dentro del periodo de análisis. No obstante, la aplicabilidad de estos modelos en otros entornos industriales requiere pruebas adicionales, ya que distintos factores pueden influir en la degradación de los motores.

Los resultados obtenidos son consistentes con estudios previos sobre mantenimiento predictivo mediante inteligencia artificial. Investigaciones como las de (2), (3) y (5) han demostrado mejoras en la detección temprana de fallas y en la planificación del mantenimiento. La principal diferencia radica en el enfoque utilizado, ya que en este trabajo se implementaron Random Forest, SVM y redes neuronales, mientras que otros estudios han empleado sistemas neurodifusos o metodologías basadas en OWA-RIM. Esta comparación sugiere que el uso de redes neuronales puede proporcionar predicciones más precisas en el contexto analizado.

Respecto a la contrastación de hipótesis, se ha validado que la aplicación de algoritmos de aprendizaje supervisado contribuye significativamente a mejorar la predicción de la vida útil de los motores eléctricos. Entre los modelos evaluados, la Red Neuronal Artificial (ANN) se destacó por presentar el menor error cuadrático medio (MSE) de 716.75, junto con los valores más bajos de MAE, RMSE y MAPE, lo que evidencia una mayor precisión global. A diferencia de evaluaciones previas, la red neuronal no solo mostró buena precisión en los últimos días, sino que mantuvo un rendimiento estable a lo largo de todo el conjunto de prueba, confirmando su capacidad de generalización y descartando indicios de sobreajuste. En contraste, los modelos SVM y Random Forest presentaron mayores variaciones en sus errores, especialmente en la parte intermedia y final del ciclo de vida. Estos resultados respaldan la efectividad del enfoque basado en aprendizaje automático para el diagnóstico predictivo en sistemas industriales. Sin

embargo, persisten algunos desafíos, como la estabilidad del modelo a largo plazo y su desempeño en condiciones reales de operación. Para mejorar estos aspectos, futuras investigaciones podrían enfocarse en la combinación de diferentes algoritmos mediante técnicas de ensamble o en la incorporación de modelos adaptativos con aprendizaje en tiempo real.

Los resultados obtenidos muestran que los modelos de aprendizaje supervisado pueden ser una herramienta eficaz en la predicción de la vida útil de motores eléctricos en minería, destacándose la red neuronal por su mejor desempeño. La evaluación del indicador de salud confirma su utilidad en la optimización del mantenimiento predictivo. No obstante, es recomendable continuar con estudios que permitan evaluar su estabilidad en diferentes entornos operativos y sectores industriales para mejorar su aplicabilidad y fiabilidad.

CAPÍTULO V

CONCLUSIONES Y RECOMENDACIONES

5.1 Conclusiones

El diseño de un indicador de salud basado en algoritmos de aprendizaje supervisado ha demostrado ser una herramienta efectiva para predecir la vida útil de motores eléctricos en equipos de gran minería. Mediante la recopilación y análisis de datos operativos clave, el modelo desarrollado permite anticipar fallas potenciales, optimizando así las estrategias de mantenimiento y reduciendo los costos asociados con tiempos de inactividad no planificados.

A través del análisis de datos históricos de operación y mantenimiento, se han identificado las variables críticas que impactan directamente en la salud y la vida útil de los motores eléctricos. Parámetros como la temperatura y corriente han demostrado ser determinantes en la predicción de fallas, proporcionando una base sólida para el desarrollo del modelo de aprendizaje supervisado.

La implementación y entrenamiento de modelos de aprendizaje supervisado en MATLAB utilizando los algoritmos Random Forest, Support Vector Machines (SVM) y redes neuronales artificiales permitió evaluar el desempeño de cada enfoque en la predicción de la vida útil de los motores eléctricos. Los resultados indicaron que el modelo de Red Neuronal Artificial (ANN) ofreció una mayor precisión en la estimación de la vida útil restante, al obtener el menor error cuadrático medio (MSE) de 716.75, superando tanto a Random Forest (MSE: 751.69) como a Support Vector Machines (SVM) (MSE: 753.67). Además, el modelo ANN presentó los valores más bajos en MAE, RMSE y MAPE, lo que confirma su efectividad para realizar predicciones más precisas y consistentes con respecto a los valores reales del RUL en motores eléctricos.

La simulación y validación del indicador de salud en MATLAB confirmaron su capacidad para predecir con precisión el deterioro de los motores eléctricos, permitiendo optimizar los posibles programas de mantenimiento predictivo que hubiera. La proyección del indicador de salud mostró una tendencia decreciente alineada con el comportamiento esperado de los motores en condiciones operativas normales. Esto evidencia que el indicador desarrollado puede ser una herramienta clave para mejorar la eficiencia operativa y reducir los costos de mantenimiento.

5.2 Recomendaciones

Se recomienda integrar el indicador de salud desarrollado en los sistemas de monitoreo en tiempo real de los motores eléctricos, lo que permitirá una detección temprana de posibles fallas y una optimización del mantenimiento predictivo. Esto contribuirá a minimizar los tiempos de inactividad no planificados y mejorar la disponibilidad de los equipos de gran minería.

Es recomendable realizar una actualización periódica de los modelos de aprendizaje supervisado, incorporando nuevos datos de operación y mantenimiento para mejorar la precisión de las predicciones. Además, la evaluación de nuevas técnicas de preprocesamiento de datos y ajuste de hiperparámetros podría potenciar aún más el rendimiento de los modelos implementados.

Para garantizar un uso eficiente del indicador de salud, se sugiere capacitar al personal de mantenimiento y operación en la interpretación de los resultados generados por los modelos de predicción. Esto permitirá una toma de decisiones más informada y efectiva en la programación de actividades de mantenimiento preventivo y correctivo.

Se recomienda extender la metodología desarrollada a otros componentes críticos de los equipos de minería, como sistemas hidráulicos y de transmisión, para obtener una visión integral del estado de salud de toda la maquinaria. Esto permitirá una gestión más eficiente de los activos y una reducción global de los costos operativos.

REFERENCIAS BIBLIOGRÁFICAS

01. SALAS HERNÁNDEZ, J. *Propuesta de un Modelo de Gestión de Mantenimiento RCM para la máquina de producción inyectora Haitian 250 de la empresa Industrias Plásticas Gr.* [En línea]. 2024 [Fecha de consulta: 12 de marzo de 2025]. Disponible en: <https://repositorio.ecci.edu.co/handle/001/4065>
02. CHICAIZA OÑA, R. M. y GONZÁLEZ JIMÉNEZ, H. *Sistema de Monitoreo en Nube Para el Diagnóstico Predictivo de Fallos de Motores Eléctricos.* Guayaquil: Escuela Superior Politécnica del Litoral, 2021. [En línea]. [Fecha de consulta: 12 de marzo de 2025]. Disponible en: <http://www.dspace.espol.edu.ec/handle/123456789/54265>
03. HUERTAS MORA, A. *Algoritmos de aprendizaje supervisado utilizando datos de monitoreo de condiciones: un estudio para el pronóstico de fallas en máquinas.* [En línea]. 2020 [Fecha de consulta: 12 de marzo de 2025]. Disponible en: <http://hdl.handle.net/11634/29886>
04. VARGAS FERNÁNDEZ, Á. *Detección de anomalías en un motor eléctrico mediante inteligencia computacional.* [En línea]. 2021 [Fecha de consulta: 12 de marzo de 2025]. Disponible en: <https://uvadoc.uva.es/handle/10324/47247>
05. ALBORNOZ CABELLO, G. *Aplicación del aprendizaje automático supervisado en el mantenimiento predictivo de los motores eléctricos de inducción en las empresas mineras del Perú.* [En línea]. 2021 [Fecha de consulta: 12 de marzo de 2025]. Disponible en: <http://repositorio.uncp.edu.pe/handle/20.500.12894/7567>
06. ADAUTO ARANA, R. *Aplicación de la inteligencia artificial en la detección de fallas en los motores eléctricos de corriente continua de imán permanente.* [En línea]. 2021 [Fecha de consulta: 12 de marzo de 2025]. Disponible en: <http://repositorio.uncp.edu.pe/handle/20.500.12894/7313>
07. CONTRERAS ALVAREZ, J. *Diseño de un modelo para mantenimiento predictivo en motores de inducción utilizando técnicas de la Industria 4.0.* [En línea]. Lima: 2020 [Fecha de consulta: 12 de marzo de 2025]. Disponible en: <https://hdl.handle.net/20.500.12867/4275>
08. HIDALGO SALINAS, J. P. *Diseño y simulación de un inversor trifásico de 0.5 kW aplicando la técnica de modulación de ancho de pulso de vector espacial.* [En línea].

- Pontificia Universidad Católica del Perú, 2011 [Fecha de consulta: 12 de marzo de 2025]. Disponible en: <http://hdl.handle.net/20.500.12404/818>
09. MACÍAS SÁNCHEZ, M. S. y MENDOZA SANTAFÉ, J. *Generación de una práctica de mantenimiento preventivo y correctivo de motores de corriente alterna (AC) en un entorno de realidad virtual*. [En línea]. 2023 [Fecha de consulta: 12 de marzo de 2025]. Disponible en: <http://hdl.handle.net/20.500.12749/20795>
10. SEDANO MONTES, P. M. *Diseño de un sistema de arranque electrónico para la puesta en marcha de motores síncronos*. [En línea]. 2016 [Fecha de consulta: 12 de marzo de 2025]. Disponible en: <http://hdl.handle.net/20.500.12404/7577>
11. TORRES TRUJILLO, Y. S. y ESCOBAR NAVARRO, A. *Diseño e implementación de un sistema predictor de fallas con redes neuronales para motores trifásicos en el sector industrial*. [En línea]. 2024 [Fecha de consulta: 12 de marzo de 2025]. Disponible en: <https://hdl.handle.net/20.500.12867/9843>
12. GARCÍA CUADROS, R. *Competencias de rediseño de devanados y software de rediseño de devanados en motores de corriente alterna*. [En línea]. 2024 [Fecha de consulta: 12 de marzo de 2025]. Disponible en: <https://hdl.handle.net/20.500.12867/9168>
14. CARRILLO ROMER, J. A. *El variador de velocidad como método de arranque ideal para motores eléctricos de inducción*. *Ingeniería, Investigación y Desarrollo*. 2013, 13(1).
15. AYALA SILVA, M. E. *Análisis de algoritmos de control predictivo basado en el modelo aplicado al accionamiento hexafásico*. [En línea]. 2017 [Fecha de consulta: 12 de marzo de 2025]. Disponible en: <http://hdl.handle.net/20.500.14066/2927>
16. ARANDA RAMOS, J. *Influencia del método Duval en Python del análisis de aceite aislante en el diagnóstico preventivo del transformador de potencia 10/12 MVA - U.M. Raura*. [En línea]. 2024 [Fecha de consulta: 12 de marzo de 2025]. Disponible en: <http://hdl.handle.net/20.500.12894/10992>
17. LATA CAND, J. P. *Análisis del estado funcional de transformadores de potencia con voltaje de funcionamiento de hasta 500kV mediante el uso de lógica difusa*. [En línea]. 2022 [Fecha de consulta: 12 de marzo de 2025]. Disponible en: <http://dspace.ups.edu.ec/handle/123456789/22517>
18. BREIMAN, L. *Bagging predictors*. *Machine Learning*. 1996, 24, pp. 123-140.

19. NILSEN, V. et al. *Predicción del coeficiente de expansión térmica del hormigón y otras propiedades mediante aprendizaje automático*. 2019.
20. VIDYARTHI, S. K. *Prediction of size and mass of pistachio kernels using random Forest machine learning*. Journal of Food Process Engineering. 2020, 43(9). [En línea] [Fecha de consulta: 11 de marzo de 2025]. Disponible en: <https://doi.org/10.1111/jfpe.13473>
21. CARDONA ALZATE, N. *Predicción y selección de variables con bosques aleatorios en presencia de variables correlacionadas*. [En línea]. 2019 [Fecha de consulta: 12 de marzo de 2025]. Disponible en: <https://repositorio.unal.edu.co/handle/unal/75561>
22. MEDINA MERINO, R. F. y ÑIQUE CHACÓN, C. I. *Bosques aleatorios como extensión de los árboles de clasificación con los programas R y Python*. Interfases. 2017, 0(010), pp. 165–165. [En línea] [Fecha de consulta: 04 de marzo de 2025]. Disponible en: <https://doi.org/10.26439/interfases2017.n10.1775>
23. VEGA ALALUNA, J. A. *Modelo de random forest aplicado a ventas cruzadas en un e-commerce de telefonía móvil para la predicción de compra o no compra de productos*. 2019.
24. LI, X., LI, W. y HE, J. *Design and Implementation of Equipment Maintenance Predictive Model Based on Machine Learning*. IOP Conference Series: Materials Science and Engineering. 2018, 466, 012001. [En línea] [Fecha de consulta: 12 de marzo de 2025]. Disponible en: <https://doi.org/10.1088/1757-899x/466/1/012001>
25. BETANCOURT, G. *Las máquinas de soporte vectorial (SVMs)*. Scientia Et Technica. 2005, 1(27).
26. RODRIGUEZ DEL AGUILA, M. A. *Propuesta de mejora de la gestión de mantenimiento basado en la mantenibilidad de equipos de acarreo de una empresa minera de Cajamarca*. [En línea]. 2012 [Fecha de consulta: 12 de marzo de 2025]. Disponible en: <https://hdl.handle.net/11537/89>
27. BUITRAGO CUELLAR, F. J. *Modelo de confiabilidad con metodología (RAM) para un sistema de bombeo*. [En línea]. 2018 [Fecha de consulta: 12 de marzo de 2025]. Disponible en: <http://repositorio.uptc.edu.co/handle/001/3056>
28. CAMPOS OLGUÍN VÍCTOR, M. H. *MATLAB para ingenieros*. México D.F.: Pearson, 2007.

ANEXOS

Anexo 01. Carta de autorización de uso de información de empresa.



CARTA DE AUTORIZACIÓN DE USO DE INFORMACIÓN DE EMPRESA

Arequipa, 16 de Abril del 2022

Señor:

DIRECTOR DE LA ESCUELA DE POSGRADO DE LA UNIVERSIDAD CONTINENTAL

Presente. -

Yo, DANIEL ADRIAN FERNANDO LAJO CARPIO, identificado con DNI 45975883, en mi calidad de JEFE DE MANTENIMIENTO – OPERACIÓN CERRO VERDE – de la Empresa Ferreyros S.A, con RUC 20100028698, ubicada en la ciudad de Arequipa.

OTORGO LA AUTORIZACIÓN,

Al señor(a) Edson Amidey Apaza Choquepata, identificado(a) con DNI N°45971103, de la Universidad Continental de Arequipa, para que utilice la siguiente información de la empresa: Ferreyros S.A ya sea en forma oral, visual, escrita, grabada en medios magnéticos o en cualquier otra forma tangible y que se encuentre claramente marcada como tal al ser entregada al estudiante, con la finalidad de que pueda desarrollar su Trabajo de Investigación para optar el grado de Ingeniero Electricista.

En virtud de esta autorización, el estudiante se compromete a lo siguiente:

1. No divulgar ni usar para fines personales la "Información Confidencial" que, con objeto de la relación o actividad académica, le fue suministrada por parte de la Empresa
2. No proporcionar a terceras personas, verbalmente o por escrito, directa o indirectamente o a través de cualquier medio de comunicación, información alguna de las actividades y/o procesos de cualquier clase que fuesen observadas en la empresa durante la duración del proyecto y
3. No utilizar completa o parcialmente ninguno de los productos (documentos, metodología, procesos y demás) relacionados con el proyecto. El estudiante asume que toda información y el resultado del proyecto serán de uso exclusivamente académico.

El material suministrado por la empresa será la base para la construcción de un estudio de caso o el desarrollo de sus actividades o prácticas académicas. La información y el resultado que se obtenga del mismo podrían llegar a convertirse en una herramienta didáctica que apoye la formación de los estudiantes.

En caso de que el estudiante incumpla parcial o totalmente las obligaciones enumeradas en el presente acuerdo, queda sujeto a la responsabilidad civil por daños y perjuicios que cause a la Empresa, así como a las sanciones de carácter penal o legal a que se le hubiere acreedor.

Adjunto a esta carta, está la siguiente documentación:

☒ Ficha RUC o pantallazo de consulta RUC

Indicar si el Representante que autoriza la información de la empresa, solicita mantener el nombre o cualquier distintivo de la empresa en reserva, marcando con una "X" la opción seleccionada.

- ☒ Mantener en Reserva el nombre o cualquier distintivo de la empresa;
☐ Mencionar el nombre de la empresa.

Firma y sello
DNI: 45975883

Número de RUC:	20100028698 - FERREYROS SOCIEDAD ANÓNIMA		
Tipo Contribuyente:	SOCIEDAD ANONIMA		
Nombre Comercial:	-		
Fecha de Inscripción:	09/10/1992	Fecha de Inicio de Actividades:	29/04/1987
Estado del Contribuyente:	ACTIVO		
Condición del Contribuyente:	HABIDO		
Domicilio Fiscal:	JR. CRISTOBAL DE PERALTA NORT NRO. 820 URB. SAN IDELFONSO LIMA - LIMA - SANTIAGO DE SURCO		
Sistema Emisión de Comprobante:	COMPUTARIZADO	Actividad Comercio Exterior:	IMPORTADOR/EXPORTADOR
Sistema Contabilidad:	COMPUTARIZADO		
Actividad(es) Económica(s):	Principal - 4659 - VENTA AL POR MAYOR DE OTROS TIPOS DE MAQUINARIA Y EQUIPO Secundaria 1 - 3312 - REPARACIÓN DE MAQUINARIA Secundaria 2 - 7730 - ALQUILER Y ARRENDAMIENTO DE OTROS TIPOS DE MAQUINARIA, EQUIPO Y BIENES TANGIBLES		
Comprobantes de Pago c/aut. de impresión (F. 806 u 816):	FACTURA BOLETA DE VENTA NOTA DE CREDITO NOTA DE DEBITO GUIA DE REMISION - REMITENTE COMPROBANTE DE RETENCION COMPROBANTE DE PERCEPCION VENTA INTERNA		
Sistema de Emisión Electrónica:	DESDE LOS SISTEMAS DEL CONTRIBUYENTE. AUTORIZ DESDE 28/06/2014		
Emisor electrónico desde:	28/06/2014		
Comprobantes Electrónicos:	FACTURA (desde 28/06/2014),BOLETA (desde 28/06/2014)		
Afiliado al PLE desde:	01/03/2013		
Padrones:	Incorporado al Régimen de Agentes de Retención de IGV (R.S.096-2012) a partir del 01/06/2012 Incorporado al Régimen de Agentes de Percepción de IGV - Venta Interna (D.S.203-2013) a partir del 01/02/2014		