



Universidad Católica de Santa María

Facultad de Ciencias e Ingenierías Físicas y Formales

Escuela Profesional de Ingeniería Mecánica-Electrónica

**Estimación de vida útil restante en motores eléctricos mediante aprendizaje
automático aplicado a mantenimiento predictivo en una empresa minera
del sur del país**

Tesis presentada por:

Flores Alvaro, Renato Adrian

ORCID: 0009-0002-5332-4159

para optar el Título Profesional de Ingeniero Mecánico Electricista

Asesor (a):

Dr. Arévalo Daza, Jorge Luis

ORCID: 0000-0001-5516-8642

Arequipa - Perú

2026

UCSM-ERP

UNIVERSIDAD CATÓLICA DE SANTA MARÍA

INGENIERIA MECANICA-ELECTRICA

TITULACIÓN CON TESIS

DICTAMEN APROBACIÓN DE BORRADOR

Arequipa, 06 de Diciembre del 2025

Dictamen: 015343-C-EPIMMEM-2025

Visto el borrador del expediente 015343, presentado por:

2021150101 - FLORES ALVARO RENATO ADRIAN

Titulado:

**ESTIMACIÓN DE VIDA ÚTIL RESTANTE EN MOTORES ELÉCTRICOS MEDIANTE APRENDIZAJE
AUTOMÁTICO APLICADO A MANTENIMIENTO PREDICTIVO EN UNA EMPRESA MINERA DEL
SUR DEL PAÍS**

Nuestro dictamen es:

APROBADO

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

INGENIERO MECANICO ELECTRICISTA

**29569057 - CASTILLO CACERES CESAR PIO
DICTAMINADOR**



**29479140 - VALENCIA SALAS MARIO JOSE
DICTAMINADOR**



**29592341 - MESTAS RAMOS SERGIO ORLANDO
DICTAMINADOR**



ESTIMACIÓN DE VIDA ÚTIL RESTANTE EN MOTORES ELÉCTRICOS MEDIANTE APRENDIZAJE AUTOMÁTICO APLICADO A MANTENIMIENTO PREDICTIVO EN UNA EMPRESA MINERA DEL SUR DEL PAÍS

INFORME DE ORIGINALIDAD

10%

INDICE DE SIMILITUD

8%

FUENTES DE INTERNET

3%

PUBLICACIONES

4%

TRABAJOS DEL ESTUDIANTE

FUENTES PRIMARIAS

1

revista.gnerando.org

Fuente de Internet

<1 %

2

titula.universidadeuropea.com

Fuente de Internet

<1 %

3

Submitted to Universidad Andina Nestor
Caceres Velasquez

Trabajo del estudiante

<1 %

4

dspace.ups.edu.ec

Fuente de Internet

<1 %

5

dspace.unitru.edu.pe

Fuente de Internet

<1 %

6

apps.ucsm.edu.pe

Fuente de Internet

<1 %

7

repositorio.esan.edu.pe

Fuente de Internet

<1 %

Dedicatoria

Esta tesis va dedicada a mi madre, Heidy Alvaro Ramos, y a mis hermanas, Rosita y Marie Jose, por ser el pilar fundamental de mi vida, por brindarme su amor incondicional, comprensión y apoyo en cada etapa. Gracias por enseñarme con su ejemplo la importancia del esfuerzo, la perseverancia y los valores que hoy me guían. Este logro no es solo mío, sino también suyo, porque cada sacrificio y palabra de aliento ha sido la fuerza que me impulsó a seguir adelante. Con todo mi cariño y gratitud, les dedico este trabajo como muestra de cuánto significan para mí.



Agradecimientos


Agradezco a Dios, por ser mi guía y fortaleza, por concederme vida, salud y sabiduría para superar cada desafío.

A mi madre, Heidy Alvaro Ramos y mis hermanas, Rosita y Marie Jose, por su apoyo constante y motivación en este camino, por su amor incondicional y por enseñarme el valor del esfuerzo y la perseverancia.

A mis docentes, por compartir sus conocimientos y contribuir a mi formación profesional.

Este logro es reflejo del amor, la fe y el esfuerzo de todos quienes me acompañaron.

¡Gracias de corazón!



RESUMEN

La investigación aborda la estimación de la vida útil restante (RUL) en motores eléctricos de una empresa minera del sur del país, utilizando técnicas de aprendizaje automático supervisado para mejorar la planificación del mantenimiento predictivo y reducir las paradas no programadas. El estudio inicia con la recopilación y preprocesamiento de datos históricos de operación, incluyendo variables como vibración, temperatura y corriente. Posteriormente, se implementan y comparan tres modelos en MATLAB: Bagging (TreeBagger), LSBoost y Red Neuronal (fitrnet). Las métricas empleadas para la validación fueron RMSE, MAE, MAPE y R^2 , permitiendo evaluar la precisión y capacidad de generalización de cada modelo. Los resultados indican que, aunque LSBoost obtuvo mejor desempeño en entrenamiento (RMSE = 17.383, MAE = 13.491, $R^2 = 0.71698$), el modelo Bagging (TreeBagger) presentó la mejor capacidad de generalización en datos de prueba (RMSE = 24.352, MAE = 19.208, MAPE = 128.41, $R^2 = 0.4363$), superando a LSBoost y a la Red Neuronal. Esto confirma su mayor estabilidad y confiabilidad para estimar el RUL y planificar mantenimientos según escenarios P20, P50 y P98, anticipando fallas entre 12 y 14 meses posteriores al último registro. La investigación demuestra que la integración de machine learning en mantenimiento predictivo es técnica y económicamente viable, ofreciendo una solución escalable para la industria minera mediante el uso de plataformas accesibles como MATLAB y datos operativos disponibles, sin requerir infraestructura costosa.

Palabras Clave: Motores Eléctricos, Redes Neuronales, Vida Útil Restante (RUL).

ABSTRACT

The research addresses the estimation of remaining useful life (RUL) in electric motors at a mining company, using supervised machine learning techniques to improve predictive maintenance planning and reduce unscheduled downtime. The study begins with the collection and preprocessing of historical operating data, including variables such as vibration, temperature, and current. Subsequently, three models are implemented and compared in MATLAB: Bagging (TreeBagger), LSBoost, and Neural Network (fitrnet). The metrics used for validation were RMSE, MAE, MAPE, and R^2 , allowing the accuracy and generalization capacity of each model to be evaluated. The results indicate that, although LSBoost performed better in training (RMSE = 17.383, MAE = 13.491, R^2 = 0.71698), the Bagging (TreeBagger) model showed the best generalization ability in test data (RMSE = 24.352, MAE = 19.208, MAPE = 128.41, R^2 = 0.4363), outperforming LSBoost and the Neural Network. This confirms its greater stability and reliability for estimating RUL and planning maintenance according to P20, P50, and P98 scenarios, anticipating failures between 12 and 14 months after the last record. The research shows that integrating machine learning into predictive maintenance is technically and economically viable, offering a scalable solution for the mining industry through the use of accessible platforms such as MATLAB and available operational data, without requiring costly infrastructure.

Keywords: Electric Motors, Neural Networks, Remaining Useful Life (RUL).

ÍNDICE

DEDICATORIA

AGRADECIMIENTOS

RESUMEN

ABSTRACT

INTRODUCCIÓN 1

CAPÍTULO I..... 2

PLANTEAMIENTO DE ESTUDIO..... 2

1.1. PROBLEMA DE INVESTIGACIÓN 3

1.1.1. Identificación del Problema 3

1.1.2. Descripción del Problema 4

1.1.3. Justificación de la investigación..... 5

1.2. Antecedentes investigativos..... 6

1.2.1. Antecedentes Internacionales..... 6

1.2.2. Antecedentes Nacionales 7

1.3. OBJETIVOS 9

1.3.1. Objetivo General..... 9

1.3.2. Objetivos Específicos..... 9

1.4. ALCANCES 9

1.5. MARCO TEÓRICO 10

1.5.1. Mantenimiento en la industria minera 10

1.5.2. Motores eléctricos industriales..... 14

1.5.3. Estimación de vida útil restante (Remaining Useful Life - RUL) 18

1.5.4. Machine Learning aplicado al mantenimiento predictivo..... 19

1.5.5. Proceso general 21

1.5.6. Marco conceptual..... 26

1.6. HIPÓTESIS 36

CAPÍTULO II 37

PLANTEAMIENTO OPERACIONAL 37

2.1. Técnicas e Instrumentos..... 38

2.1.1. Técnicas 38

2.1.2. Instrumentos..... 38

2.2. Variables de estudio.....	38
2.3. Campo de Verificación	39
2.3.1. Ubicación Temporal.....	39
2.3.2. Ubicación espacial	39
2.3.3. Unidades de Estudio	39
2.4. Estrategias de recolección de datos	39
2.5. Limitaciones.....	40
2.6. Esquema metodológico	41
CAPÍTULO III.....	42
DIAGNÓSTICO OPERATIVO DE LOS MOTORES ELÉCTRICOS.....	42
3.1. Datos operativos de motores eléctricos.....	43
3.2. Diagnóstico de motores eléctricos en falla	48
CAPÍTULO IV.....	53
MODELO DE APRENDIZAJE AUTOMÁTICO SUPERVISADO	53
4.1. Modelado por subsistemas del motor eléctrico.....	54
4.2. Modelo Bagging (TreeBagger).....	59
4.3. LSBoost (fitrensemble).....	62
4.4. Red Neuronal (fitrnet).....	65
4.5. Métricas de precisión	68
4.6. Validación cruzada (k-fold).....	85
CAPÍTULO V	91
RESULTADOS Y ANÁLISIS.....	91
5.1. Estimación de la vida útil.....	92
5.2. Pronóstico de falla de los motores	103
5.3. Análisis de sensibilidad de variables sobre el RUL.....	107
CONCLUSIONES	109
RECOMENDACIONES	110
REFERENCIAS BIBLIOGRÁFICAS	111
ANEXOS	117

ÍNDICE DE TABLAS

Tabla 1	Caracterización estadística de las variables operativas de los motores eléctricos.....	16
Tabla 2	Motor en falla - Resumen por medias	49
Tabla 3	Muestras en zona de falla de rodamientos.....	51
Tabla 4	Subsistemas modelados.....	54
Tabla 5	Procedimientos de preparación y limpieza de datos	54
Tabla 6	Modelado del subsistema de rodamientos.....	55
Tabla 7	Modelado del subsistema del estator.....	56
Tabla 8	Modelado del subsistema del rotor	57
Tabla 9	Integración de los subsistemas en el modelo global	58
Tabla 10	Desempeño entre entrenamiento y prueba del modelo (base para k-fold).....	89
Tabla 11	Proyección de Degradación y Fallas Estimadas (P20, P50, P98)	97
Tabla 12	Proyección Mensual de Casos de Falla - P20	100
Tabla 13	Proyección Mensual de Casos de Falla - P50	101
Tabla 14	Resultados del análisis de sensibilidad.....	107

ÍNDICE DE FIGURAS

Figura 1 Esquema en corte transversal de un motor de inducción trifásico industrial.....	17
Figura 2 Estructura de una red neuronal.....	30
Figura 3 Tipos de motores eléctricos	36
Figura 4 Diagrama metodológico del proceso	41
Figura 5 Datos Completos: RPM y carga	44
Figura 6 Eléctricos: Variables eléctricas como voltaje, corriente y factor de potencia	45
Figura 7 Mecánicos: RPM, carga y eficiencia	46
Figura 8 Ambientales: Temperaturas y humedad	47
Figura 9 Condición: Vibraciones y estado del motor	48
Figura 10 Motor de falla - rodamientos	52
Figura 11 Desempeño del modelo Bagging en Entrenamiento y Prueba.....	60
Figura 12 Distribución y Comportamiento de Errores - Bagging.....	61
Figura 13 Desempeño del modelo LSBoost en Entrenamiento y Prueba	63
Figura 14 Distribución y Comportamiento de Errores - LSBoost	64
Figura 15 Desempeño del modelo Red Neuronal en Entrenamiento y Prueba.....	66
Figura 16 Distribución y Comportamiento de Errores - Red Neuronal	67
Figura 17 Desempeño en entrenamiento	72
Figura 18 Desempeño en prueba.....	76
Figura 19 Brecha Prueba vs Entrenamiento	78
Figura 20 Desempeño en Prueba: RMSE y MAE por Modelo	79
Figura 21 Curva de Cobertura del Error Absoluto - Prueba	81
Figura 22 Bland-Itman en el Conjunto de Prueba - Comparación de Modelos	82
Figura 23 Calibración de Predicciones del RUL: Bagging, LSBoost y Red Neuronal.....	84
Figura 24 Distribución y Probabilidad Acumulada del RUL P50 – muestra de 110 días	94
Figura 25 Variabilidad Cuántica del RUL P50.....	95
Figura 26 Fan Chart del Tiempo de Vida Útil Restante (RUL).....	99
Figura 27 Timeline de Vida Útil Restante por Motor	102
Figura 28 Cronograma de fallas pronosticadas de los motores eléctricos	103
Figura 29 Desempeño del modelo de predicción de fallas (TreeBagger – Bagging.....	104
Figura 30 Tendencia de degradación y estimación del RUL para el motor 4.....	106

ÍNDICE DE ANEXOS

Anexo N° 1. Matriz de consistencia.....	117
Anexo N° 2. Datos operativos.....	118
Anexo N° 3. Simulación en Matlab	150
Anexo N° 4. Datasheet WEG W22 Motor Eléctrico Trifásico	155



ÍNDICE DE ABREVIATURAS

RUL	Vida Útil Restante (Remaining Useful Life)
ML	Aprendizaje Automático (Machine Learning)
IA	Inteligencia Artificial
IoT	Internet de las Cosas (Internet of Things)
IIoT	Internet Industrial de las Cosas (Industrial Internet of Things)
MATLAB	Matrix Laboratory
RMSE	Raíz del Error Cuadrático Medio (Root Mean Square Error)
MAE	Error Absoluto Medio (Mean Absolute Error)
MAPE	Error Porcentual Absoluto Medio (Mean Absolute Percentage Error)
R^2	Coefficiente de Determinación
MSE	Error Cuadrático Medio (Mean Squared Error)
LSBoost	Least Squares Boosting
TreeBagger	Modelo de ensamble basado en árboles de decisión mediante Bagging
Bagging	Agregación Bootstrap (Bootstrap Aggregating)
fitrnet	Función de MATLAB para entrenar redes neuronales de regresión
k-fold	Validación cruzada por k particiones
ANN	Red Neuronal Artificial (Artificial Neural Network)
LSTM	Memoria de Corto y Largo Plazo (Long Short-Term Memory)
SVM	Máquina de Vectores de Soporte (Support Vector Machine)
PCA	Análisis de Componentes Principales (Principal Component Analysis)
MTBF	Tiempo Medio Entre Fallas (Mean Time Between Failures)
MTTR	Tiempo Medio de Reparación (Mean Time To Repair)
PMP	Porcentaje de Mantenimiento Planificado
OEE	Eficacia General del Equipo (Overall Equipment Effectiveness)
RPM	Revoluciones por Minuto
HP	Caballos de Fuerza (Horsepower)
MQTT	Transporte de Telemetría de Cola de Mensajes (Message Queuing Telemetry Transport)
ESG	Criterios Ambientales, Sociales y de Gobernanza (Environmental, Social and Governance)

INTRODUCCIÓN

En la industria minera, los motores eléctricos desempeñan un papel importante al accionar equipos utilizados en procesos de extracción, transporte y procesamiento de minerales. Estas máquinas operan bajo condiciones exigentes, como altas cargas, ambientes agresivos y funcionamiento continuo, lo que acelera su desgaste y aumenta el riesgo de fallas inesperadas (Odar, 2023). Ante esta realidad, el mantenimiento de estos activos se vuelve una actividad clave para garantizar la disponibilidad operativa y reducir costos asociados a paradas no planificadas.

Tradicionalmente, se han aplicado estrategias de mantenimiento correctivo y preventivo, las cuales no siempre consideran el estado real del equipo, generando intervenciones innecesarias o tardías. Aunque existen sistemas de monitoreo predictivo avanzados, su alto costo limita su implementación en muchas operaciones mineras. Actualmente, el desarrollo de modelos predictivos basados en aprendizaje automático ofrece una alternativa más accesible para estimar la vida útil restante (Remaining Useful Life - RUL) de los motores eléctricos (Hanifi et al., 2024). Estas técnicas permiten analizar datos históricos y operativos recopilados por sensores, y detectar patrones que anticipen fallas. Herramientas como MATLAB facilitan la implementación de algoritmos eficientes sin requerir infraestructura costosa, lo que representa una solución técnica y económicamente viable.

El contenido de este trabajo se estructura en cinco capítulos. En el Capítulo I, se describe el planteamiento del problema, la justificación, los objetivos y los antecedentes que fundamentan la investigación. El Capítulo II presenta el diseño metodológico, las variables, técnicas e instrumentos de recolección de datos, así como el alcance del estudio. En el Capítulo III, se desarrolla el diagnóstico operativo de los motores eléctricos, abordando sus condiciones de funcionamiento y la información recopilada para el análisis. El Capítulo IV expone el proceso de implementación de los modelos de aprendizaje automático, su entrenamiento, validación y las métricas utilizadas para evaluar su desempeño. Finalmente, el Capítulo V muestra los resultados obtenidos, el análisis comparativo de los modelos, las conclusiones y las recomendaciones para la aplicación del mantenimiento predictivo en la operación minera.

CAPÍTULO I
PLANTEAMIENTO DE ESTUDIO

1.1. PROBLEMA DE INVESTIGACIÓN

1.1.1. *Identificación del Problema*

En la industria minera, los motores eléctricos forman parte del equipamiento utilizado para mantener en funcionamiento diversas operaciones. Con el paso del tiempo y ante condiciones de trabajo exigentes, estos equipos pueden presentar fallas debido al desgaste progresivo, lo que genera detenciones imprevistas, pérdida de tiempo operativo y mayores gastos por intervenciones no programadas. Los métodos tradicionales de mantenimiento correctivo o preventivo, si bien han sido aplicados por muchos años, no siempre permiten anticiparse con suficiente precisión a posibles fallos, lo cual puede conllevar reemplazos innecesarios o interrupciones operativas prolongadas.

Una de las dificultades más comunes en este contexto es la estimación adecuada de la vida útil restante (Remaining Useful Life - RUL) de los motores eléctricos. El mantenimiento predictivo, en combinación con tecnologías actuales como el Internet de las Cosas (IoT) y el aprendizaje automático (Machine Learning), ofrece nuevas posibilidades para anticipar condiciones que podrían derivar en una falla. No obstante, la implementación de estas herramientas requiere afrontar varios retos, como la calidad de los datos recogidos por sensores, la presencia de ruido en las mediciones y la selección de modelos adecuados para distintos escenarios (Taşcı et al., 2023).

Diversos estudios han mostrado que los algoritmos de aprendizaje automático pueden mejorar las estimaciones relacionadas con el estado operativo de los equipos. Por ejemplo, el uso de redes neuronales, Random Forest y Support Vector Machines ha mostrado resultados favorables en la detección de comportamientos anómalos y patrones que pueden asociarse a fallas en motores eléctricos (Nikfar et al., 2022). Estos enfoques no solo permiten identificar posibles fallos con antelación, sino que también ayudan a caracterizar el tipo de falla probable, contribuyendo a una respuesta técnica más oportuna. En el caso particular de empresas mineras, donde los costos por interrupciones inesperadas son significativos, contar con un sistema de mantenimiento predictivo que utilice modelos de aprendizaje automático podría representar una mejora en la gestión de los motores eléctricos. La estimación del RUL, basada en datos reales de operación, puede facilitar una programación más eficiente del mantenimiento, reduciendo tiempos de inactividad y gastos asociados (Kang et al., 2021).

Por ello, se identifica como problemática principal la falta de un modelo específico que permita estimar de forma confiable la vida útil restante de motores eléctricos en un entorno minero, aprovechando los beneficios del aprendizaje automático dentro de un enfoque de mantenimiento predictivo. En muchas operaciones industriales, los modelos existentes se han desarrollado con base en datos de sectores distintos, como manufactura o transporte, cuyas condiciones de trabajo no siempre se alinean con las particularidades del sector minero. Factores como la humedad, el polvo, las cargas variables y la exposición continua a ambientes adversos pueden influir en el comportamiento de los motores y en la forma en que estos se deterioran con el tiempo. En consecuencia, la adaptación o creación de un modelo ajustado al contexto real de una operación minera resulta relevante para mejorar la toma de decisiones sobre intervenciones técnicas, minimizar paradas no programadas y optimizar el uso de recursos destinados al mantenimiento. La ausencia de un sistema de este tipo limita la capacidad de anticipación de fallos, afectando la eficiencia operativa y aumentando el riesgo de daños mayores en los equipos.

1.1.2. Descripción del Problema

En el ámbito de la actividad minera, los motores eléctricos son utilizados en diversas aplicaciones operativas y se ven sometidos a cargas variables, ambientes agresivos y funcionamiento prolongado. Estas condiciones provocan un desgaste gradual que puede culminar en fallas inesperadas si no se gestionan adecuadamente. Los métodos de mantenimiento tradicional, como el correctivo y el preventivo calendarizado, presentan limitaciones al no considerar el estado real del equipo, lo que puede derivar en intervenciones innecesarias o en paradas imprevistas que afectan la continuidad del proceso productivo.

Si bien existen sistemas avanzados de monitoreo en línea para estimar la vida útil restante (RUL), estos suelen requerir equipamiento especializado y licencias de software de alto costo, lo cual dificulta su adopción en muchas operaciones. Además, a pesar del acceso a datos generados por sensores, aún persiste una brecha en el aprovechamiento efectivo de esta información para anticipar fallas en condiciones reales de operación. En este contexto, el uso de modelos predictivos basados en técnicas de aprendizaje automático surge como una alternativa más accesible y adaptable. Estos modelos, implementados en entornos como MATLAB, permiten aprovechar datos históricos operativos para estimar el RUL con mayor precisión y menor inversión, facilitando la toma de decisiones en mantenimiento.

1.1.3. Justificación de la investigación

1.1.3.1. Justificación Técnica

La presente investigación posee una justificación técnica al abordar la problemática de fallas imprevistas en motores eléctricos empleados en entornos mineros exigentes. Técnicamente, se propone la aplicación de modelos de aprendizaje automático supervisado para estimar la vida útil restante (RUL) de estos equipos, mediante el análisis de parámetros como vibración, temperatura y corriente, registrados históricamente por sensores. A diferencia de métodos tradicionales como el mantenimiento preventivo o correctivo, este enfoque permite anticipar condiciones anómalas antes de que se produzcan fallas, reduciendo intervenciones innecesarias. La implementación de este modelo en MATLAB representa una alternativa viable, accesible y adaptable para operaciones mineras que no disponen de infraestructura avanzada, optimizando el uso de recursos técnicos y mejorando la confiabilidad operativa de los motores eléctricos.

1.1.3.2. Justificación Económica

Desde una perspectiva económica, la investigación busca reducir los costos asociados a fallas no planificadas, que representan pérdidas significativas por paradas de equipos críticos en procesos mineros. La aplicación de técnicas predictivas mediante aprendizaje automático permite optimizar la planificación de mantenimiento, evitar reemplazos prematuros y disminuir los tiempos de inactividad. Esto se traduce en una reducción del gasto en repuestos, mano de obra de emergencia y pérdidas por interrupciones en la producción. Al utilizar software como MATLAB y datos ya disponibles, la solución propuesta no requiere una inversión elevada, lo cual la hace económicamente viable incluso para operaciones de mediana escala. En síntesis, se trata de una inversión técnica con alto retorno económico por la mejora en la eficiencia del mantenimiento.

1.1.3.3. Justificación Académica

Académicamente, esta investigación contribuye al fortalecimiento del conocimiento en la aplicación de inteligencia artificial al mantenimiento industrial, en el rubro minero. El estudio integra herramientas teóricas y prácticas como redes neuronales, árboles de decisión y regresión múltiple, brindando evidencia empírica sobre su efectividad para estimar el RUL de motores eléctricos. Además, brinda información en el campo académico de la ingeniería mecánica eléctrica al proponer un enfoque que puede ser replicable en otras industrias.

1.2. Antecedentes investigativos

1.2.1. Antecedentes Internacionales

Hanifi et al. (2024) desarrollaron un modelo de mantenimiento predictivo orientado a motores eléctricos industriales, específicamente aplicable en prensas metálicas de la planta de producción Mitsubishi Electric Air Conditioning en el Reino Unido. El estudio tuvo como objetivo optimizar el mantenimiento mediante el análisis de datos de vibración y temperatura recolectados por sensores Bluetooth, los cuales fueron instalados en motores de 22 kW que no contaban previamente con monitoreo alguno. Para garantizar la calidad de los datos, se aplicó un proceso de preprocesamiento que incluyó la detección de anomalías mediante el algoritmo Isolation Forest, eliminando así lecturas atípicas generadas por el entorno operacional y no por fallas del motor. Posteriormente, se entrenaron tres modelos de aprendizaje automático: ARIMA, Random Forest y LSTM, empleando una optimización de hiperparámetros a través del método Tree Parzen Estimator (TPE). Los resultados evidenciaron que el modelo ARIMA, con parámetros optimizados ($p = 2, d = 2, q = 3$), ofreció un rendimiento superior al predecir niveles futuros de vibración. La evaluación se basó en el análisis de residuos entre los valores reales y predichos, permitiendo establecer umbrales para detectar desviaciones anómalas que anticiparan fallas. Se concluyó que este enfoque no solo incrementó la capacidad de detección temprana de problemas, sino que también ofreció una solución adaptable a distintos tipos de motores, mejorando así la eficiencia operativa y reduciendo tiempos de inactividad no planificados.

Abdulkareem et al. (2025) llevaron a cabo una investigación con el propósito de desarrollar un modelo predictivo para la detección de fallas en motores de inducción trifásicos mediante técnicas de machine learning, con el fin de reducir tiempos de inactividad no planificados en entornos industriales. Para ello, se recopiló un extenso conjunto de datos provenientes de cuatro motores distintos, operando bajo condiciones normales y con fallas simuladas como desequilibrio de carga y fallas en rodamientos. Los datos incluyeron lecturas de vibración y temperatura, y se procesaron mediante técnicas de limpieza, normalización y extracción de características relevantes. Se entrenaron y evaluaron cuatro algoritmos: Random Forest, Redes Neuronales Artificiales, k-Nearest Neighbors y Árboles de Decisión. Los resultados mostraron que el modelo Random Forest obtuvo la mayor precisión (91 %), seguido por ANN y k-NN (90 %), mientras que el Árbol de Decisión logró un 89 %. A través del análisis de matrices de confusión y métricas como precisión, recall y F1-score, se evidenció que los

modelos eran eficaces en clasificar las distintas condiciones de los motores. El estudio concluyó que los algoritmos de machine learning son herramientas prometedoras para el mantenimiento predictivo, destacando la capacidad del modelo propuesto para generalizar en motores con diferentes especificaciones. Además, se identificó la necesidad de ampliar los tipos de fallas considerados y optimizar los hiperparámetros para mejorar la robustez del sistema en aplicaciones reales.

Chacón (2024) en su investigación tuvo como objetivo diseñar un banco de pruebas que permita determinar experimentalmente la vida útil restante en sistemas de transmisión de engranajes rectos. Para ello, se aplicó la metodología TRIZ, una herramienta sistemática de resolución de problemas inventivos que facilitó el desarrollo de un diseño conceptual innovador. El banco propuesto integra una caja de engranajes modular y un sistema de carga neumático, lo cual ofrece flexibilidad experimental, facilidad de mantenimiento y adaptabilidad para distintas condiciones operativas. La metodología empleada se estructuró en cuatro fases: establecimiento de condiciones iniciales mediante revisión bibliográfica y herramientas de diseño (QFD y TRIZ); desarrollo del diseño conceptual con modelado CAD y cálculos técnicos; validación a través de simulaciones computacionales estáticas y dinámicas utilizando software como Ansys y Adams; y finalmente, un análisis de costos unitarios para evaluar la viabilidad económica del proyecto. Como resultado, se obtuvo un banco de pruebas funcionalmente viable, capaz de simular condiciones reales de operación.

1.2.2. Antecedentes Nacionales

Albornoz (2021) realizó un estudio orientado a demostrar cómo el uso del aprendizaje automático supervisado puede mejorar la fiabilidad y eficiencia del mantenimiento predictivo de motores eléctricos de inducción en empresas mineras peruanas. El objetivo principal fue comparar dos métodos de diagnóstico: uno tradicional, basado en sistemas computarizados sin algoritmos inteligentes, y otro que incorporaba modelos de machine learning entrenados con datos reales del motor, como el nivel de aislamiento del bobinado del estator, vibraciones mecánicas y comportamiento de la corriente. La investigación, de tipo aplicada y diseño preexperimental, utilizó herramientas estadísticas como SPSS para el análisis de datos recolectados mediante observación directa y entrevistas. Los resultados evidenciaron que la implementación del aprendizaje automático permitió predecir con mayor exactitud posibles fallas, optimizando los tiempos de mantenimiento y prolongando la vida útil de los equipos. Se

concluyó que el uso de algoritmos supervisados no solo incrementó la fiabilidad del diagnóstico, sino que también mejoró la eficiencia operativa del mantenimiento, sentando una base tecnológica sólida para su aplicación futura en entornos industriales exigentes como el minero.

Alvarez (2024) llevó a cabo una investigación enfocada en diseñar un sistema de mantenimiento predictivo basado en algoritmos de Machine Learning, con el propósito de reducir la inactividad productiva causada por fallas en un compresor industrial. El estudio, de tipo aplicada, con enfoque cuantitativo, diseño no experimental y nivel correlacional, tomó como muestra un compresor de aire de 7.5 HP, al que se le instalaron sensores para monitorear variables como temperatura, presión, vibración y humedad. Mediante el uso de Python, se entrenaron y evaluaron tres modelos de clasificación: regresión logística, árbol de decisión y random forest. Los resultados mostraron que el modelo de regresión logística logró un recall del 92,5% en la detección de fallas, el árbol de decisión alcanzó una precisión del 85,1%, y el modelo random forest destacó con un F1-score del 90,3%. Sin embargo, se observó que este último modelo requería ajustes en el punto de corte para mejorar la sensibilidad, a pesar del incremento en los falsos positivos. Se concluyó que la aplicación de algoritmos de Machine Learning permite anticipar fallas con alta precisión, optimizando así las estrategias de mantenimiento y contribuyendo a una gestión más eficiente y sostenible de los recursos industriales.

Torres (2023) en su investigación tuvo como objetivo determinar el impacto de la aplicación del mantenimiento predictivo en la disminución de los costos de mantenimiento de una flota de equipos Scooptram en una mina subterránea. La metodología empleada fue de tipo cuantitativa, con diseño cuasiexperimental y enfoque explicativo de corte transversal. La población estuvo conformada por 30 equipos Scooptram, y la muestra no probabilística incluyó 4 equipos representativos (Toro 151, LH203, Wagner ST3.5 y LH410). Se utilizó el análisis documental del historial de mantenimiento y se aplicaron instrumentos como fichas de observación y formatos de control. El análisis estadístico incluyó la prueba de Shapiro-Wilk para normalidad y, al no cumplirse esta, se usó la prueba no paramétrica de Wilcoxon. Los resultados demostraron que la implementación del mantenimiento predictivo tuvo un impacto positivo. Los costos de mantenimiento se redujeron de S/ 55,133.00 en el año 2021 a S/ 23,707.19 en el 2022, lo que representa una disminución de S/ 31,425.81. Además, se mejoró la disponibilidad de los equipos y la eficiencia global de las operaciones. Por tanto, se concluyó que esta metodología optimiza los costos y mejora el desempeño en el sector minero.

1.3. OBJETIVOS

1.3.1. Objetivo General

Estimar la vida útil restante en motores eléctricos mediante técnicas de aprendizaje automático aplicadas al mantenimiento predictivo en una empresa minera del sur.

1.3.2. Objetivos Específicos

- a) Recopilar y preprocesar datos operativos de motores eléctricos para el entrenamiento de modelos de aprendizaje automático.
- b) Implementar modelos de aprendizaje automático supervisado en MATLAB para estimar la vida útil restante de los motores eléctricos.
- c) Evaluar el desempeño de los modelos mediante métricas de validación para su aplicación en mantenimiento predictivo.

1.4. ALCANCES

La presente investigación se enfoca en el desarrollo de un modelo para la estimación de la vida útil restante en motores eléctricos, utilizando técnicas de aprendizaje automático supervisado aplicadas en el entorno de MATLAB. El estudio se limita al análisis de datos operativos previamente registrados, tales como temperatura, vibración y corriente.

El alcance comprende el proceso completo desde la recopilación y preprocesamiento de datos hasta la implementación, entrenamiento, validación y evaluación de modelos predictivos. Asimismo, se incluye la comparación de resultados mediante métricas cuantitativas como el error cuadrático medio (RMSE) y el coeficiente de determinación (R^2), a fin de seleccionar el modelo más adecuado. Este trabajo se orienta hacia entornos mineros, pero no contempla la instalación de sensores, el mantenimiento físico de los motores ni la intervención directa en operaciones industriales. La investigación se desarrolla en un entorno computacional y se centra en la parte analítica y predictiva del mantenimiento.

1.5. MARCO TEÓRICO

1.5.1. Mantenimiento en la industria minera

El mantenimiento predictivo en la industria minera ha evolucionado significativamente con la integración del machine learning, especialmente en el cuidado de motores eléctricos, equipos críticos para operaciones de extracción y procesamiento de minerales. Este enfoque combina análisis de datos en tiempo real, modelado predictivo y tecnologías IoT para optimizar la vida útil de los activos y reducir costos operativos (Albornoz, 2021).

Los motores eléctricos de inducción, fundamentales en transporte y maquinaria minera, son monitoreados mediante parámetros como nivel de aislamiento del bobinado del estator, vibraciones mecánicas y comportamiento de la corriente. Tradicionalmente, las empresas utilizaban sistemas computarizados para programar mantenimientos, pero ahora emplean algoritmos de aprendizaje automático supervisado que analizan patrones históricos y predicen fallas con mayor precisión (Trujillo, 2023). Por ejemplo, en camiones Komatsu 830E y 930E de Antapaccay (Perú), modelos de machine learning en MATLAB mejoraron la disponibilidad de estos equipos al predecir fallas en ruedas motrices, logrando una optimización del 82.2% en precisión de diagnóstico (Yarin y Moscoso, 2019).

1.5.1.1. Tipos de mantenimiento

En la industria minera, los tipos de mantenimiento se clasifican en preventivo, predictivo y correctivo, cada uno con enfoques y tecnologías específicas que se adaptan a las demandas de entornos operativos críticos como los motores eléctricos y maquinaria pesada.

El mantenimiento preventivo se programa con base en intervalos de tiempo, experiencia histórica y recomendaciones de fabricantes. Incluye lubricación de componentes, inspección de sistemas hidráulicos y reemplazo de filtros para evitar fallos inesperados. Su implementación reduce hasta un 40% los tiempos de inactividad no planificados, según estudios en operaciones mineras peruanas. En motores eléctricos, este enfoque se aplica mediante revisiones periódicas del aislamiento del estator y alineación de ejes, esenciales para prevenir desgastes acelerados por polvo y vibraciones (Contreras, 2020).

El mantenimiento predictivo, impulsado por machine learning y tecnologías IoT, utiliza sensores para monitorear variables como vibraciones, temperatura y corriente en tiempo real. Por ejemplo, algoritmos de aprendizaje automático analizan patrones en datos históricos de motores eléctricos para predecir fallas en rodamientos o desbalances mecánicos, logrando una

precisión del 85% en diagnósticos según casos documentados en mineras como BHP. Técnicas como la termografía infrarroja y el análisis espectral de vibraciones permiten identificar anomalías antes de que escalen, optimizando la vida útil de equipos en hasta un 25% (Alarcón et al., 2021).

El mantenimiento correctivo actúa ante fallas ya ocurridas, siendo el menos deseado por su impacto en la productividad. Sin embargo, en escenarios de alta criticidad como la reparación de motores de tracción en camiones de acarreo, se combina con estrategias predictivas para reducir su frecuencia (Neciosup y Rivera, 2021). Empresas como Atlas Copco destacan la importancia de kits de reparación especializados y protocolos estandarizados para minimizar tiempos de respuesta en estos casos. La integración de machine learning ha transformado estos enfoques: modelos de Gradient Boosting y redes neuronales procesan datos de sensores en motores eléctricos, identificando correlaciones entre variables operativas y riesgos de falla. En la minería peruana, esto ha permitido reducir en un 30% los costos asociados a paradas no planificadas, según aplicaciones en minas de cobre. Además, plataformas IoT centralizan datos para generar recomendaciones en tiempo real, como ajustar cargas operativas o priorizar órdenes de trabajo, optimizando la gestión de recursos (Alarcón et al., 2021).

1.5.1.2. Rol del mantenimiento predictivo en minería

El mantenimiento predictivo se ha consolidado como un componente estratégico en la industria minera, especialmente en la gestión de motores eléctricos —activos críticos para operaciones de transporte, bombeo y procesamiento de minerales—. Este enfoque, potenciado por machine learning y tecnologías IoT, permite anticipar fallas mediante el análisis de datos en tiempo real, transformando la gestión de activos de reactiva a proactiva.

Al integrar sensores en motores eléctricos, se monitorean variables como vibraciones axiales, temperatura de rodamientos y patrones de corriente, generando flujos de datos que algoritmos de aprendizaje automático procesan para detectar anomalías. Por ejemplo, modelos de Random Forest y redes neuronales recurrentes identifican desgastes en estatores o desalineaciones en ejes con precisión superior al 80%, según aplicaciones documentadas en mineras como Antapaccay (Revista Tecnología Minera, 2023). Estas técnicas superan los métodos tradicionales basados en intervalos fijos, reduciendo hasta un 30% las intervenciones innecesarias.

La implementación abarca tres pilares:

- Recolección de datos mediante sensores inalámbricos que miden parámetros operativos cada 0.5 segundos.
- Procesamiento predictivo con algoritmos entrenados en historiales de fallas, capaces de predecir eventos como cortocircuitos en bobinados con 72 horas de anticipación.
- Acciones prescriptivas, donde sistemas IoT generan órdenes de trabajo automatizadas priorizando críticos según impacto económico.

Los beneficios son multidimensionales. En costos, se registran reducciones del 15-20% en reparaciones no planificadas de motores de 1000 HP usados en molinos SAG, según casos en Chile. En seguridad, la detección temprana de sobrecalentamientos en transformadores asociados a motores disminuye riesgos de incendios en zonas de alta tensión. Adicionalmente, se extiende la vida útil de componentes como rodamientos en un 25%, optimizando inversiones en equipos que superan los \$2 millones de dólares por unidad (Revista Tecnología Minera, 2023a).

Un estudio de Deloitte aplicado en minas peruanas demostró que estas tecnologías reducen hasta un 50% el tiempo de planificación de mantenimiento, al automatizar la asignación de recursos y repuestos. Plataformas como MATLAB y Python integran modelos predictivos con sistemas CMMS (Computerized Maintenance Management Systems), permitiendo ajustar cargas operativas de motores en función de pronósticos de estrés térmico.

La minería 4.0 exige soluciones escalables: empresas como BHP utilizan gemelos digitales de motores eléctricos para simular escenarios de falla y validar estrategias de intervención, logrando un 92% de efectividad en diagnósticos. Esta transición tecnológica no solo mejora la confiabilidad operativa, sino que también alinea la industria con estándares ESG, al reducir el consumo energético mediante la optimización de ciclos de trabajo de motores.

1.5.1.3. Indicadores clave de mantenimiento

Los indicadores clave de mantenimiento en la industria minera, particularmente aplicados a motores eléctricos y estrategias predictivas, permiten evaluar la eficacia de las intervenciones y optimizar la gestión de activos críticos. Entre los más relevantes destacan:

- a) **Tiempo medio entre fallos (MTBF)**, que mide la confiabilidad de los equipos al calcular el intervalo promedio entre fallas (Canahua, 2021). En motores eléctricos, un MTBF elevado refleja la eficacia de programas predictivos basados en análisis de vibraciones y termografía, donde sensores IoT monitorean parámetros como desbalance mecánico o sobrecalentamiento de rodamientos. Su cálculo se realiza mediante la fórmula:

$$MTBF = \frac{\text{Tiempo Total Disponible} - \text{Tiempo Total Perdido}}{\text{Número de Paradas}} \quad \text{Ecuación (1)}$$

- b) **Tiempo medio de reparación (MTTR)** evalúa la eficiencia operativa al medir el tiempo promedio para restaurar un equipo tras una falla. En minería, su reducción se logra mediante kits de reparación estandarizados y protocolos automatizados, como órdenes de trabajo generadas por algoritmos de machine learning que priorizan intervenciones según impacto económico.
- c) **El porcentaje de mantenimiento planificado (PMP)** cuantifica la proporción de actividades programadas frente a las correctivas, siendo un indicador clave para validar la transición hacia estrategias predictivas. En motores eléctricos, modelos de Gradient Boosting procesan datos históricos de corriente y vibraciones para anticipar fallas, aumentando el PMP hasta un 85% en casos documentados (Canahua, 2021).
- d) **La disponibilidad de equipos y la eficacia general del equipo (OEE)** integran métricas de productividad y calidad. En motores de tracción de camiones mineros, la OEE mejora al optimizar ciclos de trabajo mediante pronósticos de estrés térmico, mientras la disponibilidad se incrementa al reducir paradas no planificadas mediante monitoreo continuo de parámetros eléctricos (Canahua, 2021)
- e) **Backlog de mantenimiento y tasa de cumplimiento de mantenimiento preventivo** completan el panorama, permitiendo identificar acumulación de órdenes pendientes y ajustar frecuencias de inspecciones basadas en MTBF. Por ejemplo, en motores de bombeo, el análisis predictivo ajusta intervalos de lubricación según patrones de desgaste detectados por sensores, reduciendo hasta un 30% las intervenciones innecesarias (Canahua, 2021).

1.5.2. Motores eléctricos industriales

Los motores eléctricos industriales son dispositivos esenciales que transforman la energía eléctrica en energía mecánica, permitiendo el funcionamiento de una amplia gama de equipos y maquinarias en entornos industriales. Su diseño robusto y eficiente los convierte en componentes fundamentales en sectores como la manufactura, la construcción y la minería. Existen diversos tipos de motores eléctricos, incluyendo los de corriente alterna y corriente continua, cada uno adaptado a aplicaciones específicas según las necesidades de potencia, velocidad y control. La correcta selección y mantenimiento de estos motores es crucial para garantizar la eficiencia energética y la productividad en las operaciones industriales (Odar, 2023).

1.5.2.1. Principio de funcionamiento

El principio de funcionamiento de los motores eléctricos industriales se basa en la interacción entre el estator, que permanece fijo, y el rotor, que gira. En el estator se encuentran polos magnéticos compuestos por imanes y bobinas de cobre, por donde circula corriente eléctrica. Esta corriente genera un campo magnético que provoca una reacción en el rotor debido a la ley de los imanes: polos iguales se repelen y polos opuestos se atraen. Así, el rotor es impulsado por fuerzas de atracción y repulsión constantes, produciendo un movimiento giratorio conocido como torque. A este torque se le acopla un eje o flecha, que transfiere el movimiento a la maquinaria conectada. La velocidad de rotación del rotor, que se mide en revoluciones por minuto, depende de la cantidad de polos del estator. El espacio entre ambas partes, llamado entrehierro, se mantiene constante para asegurar el correcto funcionamiento del sistema. Además, los motores eléctricos operan conforme a dos leyes fundamentales: la ley de la inducción, que describe cómo los campos magnéticos inducen corriente, y la ley de Ampere, que establece la relación entre la corriente eléctrica y el campo magnético que esta genera. Gracias a esta combinación de principios físicos, los motores eléctricos son capaces de transformar eficientemente la energía eléctrica en energía mecánica, desempeñando un papel crucial en múltiples aplicaciones industriales (Carrillo et al., 2022).

1.5.2.2. Tipos de fallas comunes

En el ámbito industrial, los motores eléctricos de inducción, a pesar de ser altamente robustos y confiables, están expuestos a diferentes esfuerzos mecánicos, térmicos, eléctricos y ambientales que pueden originar fallos durante su vida útil. Entre las fallas más comunes destacan los defectos en el rotor, que incluyen la rotura de barras, una condición que puede generar desequilibrios en el campo magnético y afectar gravemente el desempeño del motor. Otro tipo de falla frecuente se presenta en los rodamientos, donde el desgaste progresivo o el daño en las pistas exteriores puede producir vibraciones, ruido y aumento de temperatura, comprometiendo el funcionamiento del motor. También son relevantes los fallos por desalineamientos, que ocurren cuando el eje del motor y el de la máquina acoplada no están correctamente alineados, generando tensiones adicionales y acelerando el desgaste de los componentes. Además, pueden presentarse fallos en los engranajes, especialmente por desgaste uniforme de sus dientes, lo que afecta la transmisión de potencia y la eficiencia del sistema. Por último, los problemas en el aislamiento del estator, como cortocircuitos entre espiras, pueden derivar en fallas eléctricas severas, sobrecalentamientos y deterioro de los materiales aislantes. Todos estos fallos, si no se detectan a tiempo, no solo reducen la eficiencia energética, sino que también pueden derivar en daños irreversibles que detienen procesos productivos y aumentan significativamente los costos de reparación y mantenimiento. Por ello, es fundamental implementar sistemas de monitoreo y diagnóstico predictivo que permitan identificar estos problemas en etapas tempranas y asegurar la continuidad operativa de los motores eléctricos industriales (Zamudio, 2023).

1.5.2.3. Parámetros críticos para su monitoreo

El monitoreo de motores eléctricos industriales requiere la evaluación constante de ciertos parámetros críticos que permiten conocer su estado operativo y prevenir posibles fallas. Entre los más relevantes se encuentran la tensión, la corriente y la potencia, los cuales ofrecen una visión detallada del comportamiento del motor en tiempo real. Estos parámetros, al ser analizados correctamente, permiten detectar variaciones anómalas que podrían indicar sobrecargas, desequilibrios o pérdidas de eficiencia. Para su adquisición y supervisión remota, se ha implementado un sistema IIoT basado en una pasarela inteligente, como la IoT2000, que recopila la información generada por los dispositivos conectados y la transmite a una plataforma en la nube. Este entorno digital facilita el almacenamiento, procesamiento y visualización de los datos desde ubicaciones remotas, permitiendo al operador realizar ajustes

y tomar decisiones oportunas. Gracias al uso del protocolo de comunicación MQTT, se garantiza una transmisión estable y segura, con baja latencia. Esta estructura no solo permite una supervisión más precisa y un tiempo de respuesta menor ante condiciones anómalas, sino que también promueve la eficiencia energética y operativa. Así, el monitoreo de parámetros eléctricos críticos en motores trifásicos, mediante tecnologías IIoT, se convierte en una herramienta esencial para optimizar el mantenimiento, mejorar el rendimiento y asegurar la continuidad de los procesos industriales (Villón, 2025).

1.5.2.4. Caracterización técnica de los motores eléctricos analizados

Los motores eléctricos considerados en la presente investigación corresponden a motores de inducción trifásicos industriales, con características operativas compatibles con equipos de baja tensión empleados en procesos mineros. Para fines de caracterización técnica en el estudio se toma como referencia motores industriales de la línea WEG W22, los parámetros de las variables operativas se observan a más detalle en el Anexo N.º 2

Tabla 1

Caracterización estadística de las variables operativas de los motores eléctricos


Grupo de variables	Variable medida	Rango registrado	Valor medio
Eléctrica	Voltaje	326 - 473 V	400 V
Eléctrica	Corriente	9 - 82 A	50 A
Eléctrica	Factor de potencia	0.63 - 0.96	0.80
Mecánica	Velocidad de rotación	1336 - 1695 rpm	1501 rpm
Mecánica	Carga	0 - 120 %	70 %
Mecánica	Eficiencia	85.9 - 100 %	94.9 %
Térmica	Temperatura del estator	22.2 - 95.2 °C	59.9 °C
Térmica	Temperatura de rodamientos	26.6 - 83.6 °C	55.1 °C
Ambiental	Temperatura ambiente	7.9 - 41.8 °C	25 °C
Ambiental	Humedad relativa	20 - 100 %	49.9 %
Condición	Vibración	0.33 - 3.77 mm/s	2.0 mm/s
Condición	Estado del motor	0 = normal; 1 = falla	---

Nota. Elaboración propia a partir del anexo N.º 2

La caracterización de los motores WEG W22 se realizó a partir de los registros operativos consignados en el Anexo N.º 2, los cuales incluyen variables eléctricas, mecánicas, térmicas, ambientales y de condición. Entre las variables medidas se encuentran el voltaje, corriente, factor de potencia, velocidad de rotación, carga, eficiencia, temperatura del estator, temperatura de rodamientos, vibración, temperatura ambiente, humedad relativa y estado del motor.

Figura 1

Esquema en corte transversal de un motor de inducción trifásico industrial



Nota. Elaboración propia a partir del datasheet WEG W22 Motor Eléctrico Trifásico

La Figura 1 muestra los principales componentes de un motor de inducción trifásico industrial:

- **Estator:** Es la parte fija del motor. Contiene los devanados eléctricos que generan el campo magnético necesario para producir el movimiento del rotor.
- **Rotor:** Es la parte móvil ubicada dentro del estator. Gira por acción del campo magnético y permite transformar la energía eléctrica en energía mecánica.
- **Eje:** Es el elemento encargado de transmitir el movimiento del rotor hacia la máquina o equipo acoplado.
- **Rodamientos:** Sostienen el eje y permiten su giro con menor fricción. Su desgaste puede generar vibraciones, ruido y aumento de temperatura.
- **Carcasa:** Protege los componentes internos del motor frente al polvo, humedad, golpes y agentes externos. También ayuda a disipar el calor.
- **Ventilador:** Permite enfriar el motor durante su funcionamiento, evitando el sobrecalentamiento del estator, rotor y rodamientos.
- **Caja de conexiones:** Permite el ingreso de los cables de alimentación eléctrica y distribuye la energía hacia los devanados del motor.
- **Juntas, anillos y elementos de fijación:** Cumplen funciones de sellado, ajuste y sujeción, evitando el ingreso de contaminantes y asegurando el correcto ensamblaje del motor.

1.5.3. Estimación de vida útil restante (*Remaining Useful Life - RUL*)

La estimación de la vida útil restante (RUL, por sus siglas en inglés) es un proceso clave dentro del mantenimiento basado en la condición, ya que permite predecir el tiempo restante en el que un componente, sistema o equipo podrá seguir operando adecuadamente antes de que se requiera su reemplazo. Esta estimación se fundamenta en múltiples factores, como las condiciones operativas, el entorno de trabajo, el historial de mantenimiento y los datos recogidos por sensores, tales como vibraciones, temperatura y señales acústicas. El conocimiento del RUL ayuda a planificar estrategias de mantenimiento más eficientes, reducir costos por fallos inesperados y evitar paradas no programadas. Para obtener resultados más precisos, se han desarrollado diversas metodologías de predicción, entre las que se incluyen enfoques basados en modelos matemáticos, en el análisis físico del desgaste, en la experiencia de expertos, en inteligencia artificial, y modelos híbridos que combinan múltiples técnicas. Las técnicas estadísticas, por ejemplo, utilizan análisis de series temporales y probabilidades, mientras que las técnicas de inteligencia computacional, como las redes neuronales, procesan grandes volúmenes de datos para detectar patrones de degradación. Además, la metodología basada en la física del fallo analiza el comportamiento del material ante esfuerzos para estimar su deterioro, y los métodos de fusión de datos integran diferentes fuentes de información para obtener una predicción más confiable. El desarrollo e implementación de bancos de pruebas específicos, como los que simulan condiciones reales de funcionamiento, han permitido validar experimentalmente estos modelos y optimizar la precisión en la estimación del RUL, convirtiéndolos en herramientas fundamentales para mejorar la confiabilidad y disponibilidad de los sistemas industriales (Chacón, 2024).

1.5.3.1. Variables que afectan la vida útil de motores

La vida útil de los motores eléctricos industriales puede verse influenciada por una serie de variables que afectan directamente su desempeño, eficiencia y durabilidad. Entre las más determinantes se encuentra la temperatura de operación, ya que un motor que funciona a temperaturas elevadas durante periodos prolongados puede sufrir un envejecimiento acelerado del aislamiento del bobinado, lo cual reduce drásticamente su tiempo de servicio. El sobreesfuerzo eléctrico, como sobrecargas o variaciones bruscas de voltaje, también es una causa común de degradación, pues somete al motor a tensiones que exceden su capacidad de diseño, afectando sus componentes internos (Perez et al., 2022). Asimismo, las condiciones mecánicas tienen un papel fundamental. La desalineación del eje, el desequilibrio en los

elementos rotativos, o el montaje incorrecto generan vibraciones y esfuerzos que deterioran gradualmente los rodamientos y otras partes móviles. El ambiente operativo en el que se instala el motor también es crucial: la presencia de polvo, humedad, sustancias corrosivas o incluso temperaturas ambientales extremas, contribuye al desgaste prematuro del aislamiento, la corrosión de partes metálicas y el ingreso de contaminantes al interior del motor (Barrios, 2022).

Otro factor determinante es la calidad del mantenimiento. Un motor que no recibe inspecciones periódicas, lubricación adecuada o reemplazo oportuno de partes desgastadas, presentará fallas más rápidamente que uno que es atendido bajo un plan de mantenimiento preventivo o predictivo. También influye la calidad de la energía eléctrica: problemas como armónicos, desbalances de fases o picos de tensión afectan el desempeño del motor y pueden dañar los devanados (Perez et al., 2022).

La frecuencia de arranques y paradas es otra variable crítica. Cada vez que un motor arranca, se generan esfuerzos térmicos y eléctricos elevados; si estos eventos son muy frecuentes, el deterioro del aislamiento se acelera. Además, la sobrecarga mecánica constante, es decir, operar con cargas superiores a la nominal, genera un aumento en la corriente consumida y un calentamiento excesivo, factores que dañan el aislamiento y reducen la vida útil del equipo (Barrios, 2022).

Por último, el tipo de aplicación y el diseño del motor también determinan su longevidad. Los motores mal seleccionados para una determinada tarea, por ejemplo, aquellos operando en régimen de arranque-paro continuo o en ambientes agresivos sin la protección adecuada, están más propensos a fallar. En conjunto, todos estos factores deben ser gestionados de forma integral para garantizar un funcionamiento prolongado, eficiente y seguro de los motores eléctricos industriales.

1.5.4. Machine Learning aplicado al mantenimiento predictivo

El machine learning aplicado al mantenimiento predictivo en la industria minera representa una revolución tecnológica que transforma la gestión de activos críticos, como motores eléctricos y maquinaria pesada, mediante el análisis de datos en tiempo real y la anticipación de fallas. Esta integración combina sensores IoT, algoritmos avanzados y plataformas de procesamiento para optimizar la disponibilidad de equipos y reducir costos operativos (Barroso, 2018).

Los sistemas predictivos se sustentan en sensores IoT que monitorean variables como vibraciones, temperatura, presión y corriente en motores eléctricos, generando flujos de datos continuos. Estos datos se procesan mediante algoritmos de machine learning como Gradient Boosting Trees, Random Forest y redes neuronales que identifican patrones históricos y correlaciones entre parámetros operativos y riesgos de falla. Por ejemplo, en BHP Minerals Americas, modelos de Gradient Boosting analizan variables como horizonte de planificación, impacto económico de materiales y patrones de inventario para predecir órdenes de trabajo riesgosas, logrando un accuracy del 82.2% y un AUC de 0.731 en pruebas con datos reales (Barroso, 2018).

La integración de machine learning no solo optimiza la eficiencia, sino que también alinea la industria con estándares ESG. Al predecir fallas en motores eléctricos, se ajustan ciclos de trabajo para reducir el consumo energético, contribuyendo a la sostenibilidad ambiental. Además, la reducción de paradas no planificadas mejora la seguridad laboral al minimizar exposiciones humanas a reparaciones urgentes en zonas de riesgo. Su adopción masiva refleja la transición hacia la minería 4.0, donde la inteligencia artificial no es solo una herramienta, sino un eje estratégico para la competitividad global (Yarin y Moscoso, 2019).

1.5.4.1. Tipos de algoritmos utilizados

Los algoritmos de machine learning se clasifican según su enfoque y aplicación, siendo los más relevantes aquellos vinculados a regresión, clasificación, redes neuronales y técnicas de aprendizaje no supervisado. Estos métodos se diferencian por su objetivo, complejidad y uso en problemas específicos, desde predicciones numéricas hasta análisis de patrones en datos no estructurados.

a) Algoritmos supervisados

Regresión se emplea para predecir valores numéricos continuos, como el precio de una vivienda o la expectativa de vida. La regresión lineal, uno de los algoritmos más simples modela relaciones lineales entre variables, siendo rápido de entrenar y fácil de interpretar. Por ejemplo, en minería de datos, se utiliza para estimar el ciclo de vida del cliente o el precio de acciones, aunque su eficacia depende de la linealidad de los datos. Para problemas no lineales, técnicas como regresión logística (clasificación binaria) o regresión polinómica amplían su aplicabilidad (Valero et al., 2022).

La clasificación resuelve problemas donde la variable objetivo es categórica (ejemplo: spam vs. no spam). Algoritmos como árbol de decisión y SVM (Máquinas de Vectores Soporte) destacan por su precisión. Los árboles de decisión estructuran reglas jerárquicas para predecir

resultados, siendo útiles en diagnósticos médicos o detección de fraudes. Las SVM, por su parte, identifican hiperplanos que separan clases maximizando el margen de seguridad, aplicándose en reconocimiento de escritura o clasificación de noticias.

Redes neuronales fundamento del deep learning imitan la estructura del cerebro humano para resolver problemas complejos. Su arquitectura en capas (entrada, ocultas y salida) permite aprender patrones no lineales en datos como imágenes o texto. En aplicaciones como el procesamiento del lenguaje natural o la detección de anomalías en sensores industriales, estas redes superan a métodos tradicionales en precisión (Valero et al., 2022).

- b) Algoritmos no supervisados:** El aprendizaje no supervisado explora datos sin etiquetas para identificar patrones ocultos. K-means el algoritmo de agrupación más popular segmenta clientes o usuarios en clusters basados en similitudes, como en marketing o recomendación de productos. Análisis de componentes principales (PCA) reduce la dimensionalidad de datos proyectándolos en subespacios, conservando información clave para visualización o preprocesamiento.
- c) Métodos ensemble:** Los métodos ensemble combinan múltiples algoritmos débiles para crear modelos robustos. Bosque aleatorio y Gradient Boosting son ejemplos destacados: el primero evita el sobreajuste mediante árboles entrenados en muestras aleatorias, mientras que el segundo mejora iterativamente predicciones mediante aprendices débiles. Estos métodos son esenciales en problemas de alta complejidad, como la detección de fraudes financieros o la optimización de motores eléctricos en minería.

1.5.5. Proceso general

El proceso general de machine learning integra tres fases fundamentales: adquisición de datos, procesamiento y entrenamiento, cada una con etapas especializadas que garantizan la calidad y eficacia de los modelos. Este flujo, respaldado por metodologías académicas y aplicaciones industriales, se estructura así:

A) Adquisición de datos

La primera fase implica recolección sistemática de información relevante desde fuentes diversas. Los datos pueden ser internos (transacciones, registros operativos) o externos (APIs, bases públicas, sensores IoT), siempre que sean pertinentes al problema a resolver. Por ejemplo, en minería, se capturan lecturas de sensores en motores eléctricos o datos de producción, mientras que, en finanzas, se integran transacciones bancarias y datos macroeconómicos. El etiquetado es crítico en aprendizaje supervisado: cada dato debe asociarse a una salida esperada (ejemplo: “falla” o “funcionamiento óptimo”) para que los algoritmos aprendan patrones (Pedrero et al., 2021).

a. Procesamiento de datos

Esta etapa transforma los datos brutos en un formato utilizable para los algoritmos. Incluye:

- **Limpeza:** eliminación de valores faltantes, corrección de errores y filtrado de ruido. En minería, se ajustan lecturas de sensores para eliminar variaciones aleatorias.
- **Transformación:** ingeniería de características para destacar relaciones ocultas. Por ejemplo, en análisis de vibraciones de motores, se derivan métricas como desbalance mecánico o desgaste de rodamientos.
- **Normalización/escalado:** ajuste de escalas numéricas para evitar sesgos en algoritmos sensibles a magnitudes (ejemplo: escalado de temperaturas y presiones en motores).
- **Gestión:** almacenamiento estructurado y versionado para garantizar reproducibilidad, usando herramientas como ETL (Extract, Transform, Load) y almacenes de metadatos (Pedrero et al., 2021).

b. Entrenamiento

Aquí los algoritmos aprenden patrones mediante optimización matemática. El proceso sigue estos pasos:

- **División de datos:** separación en conjuntos de entrenamiento, validación y prueba para evitar sobreajuste.
- **Selección del algoritmo:** dependiendo del problema (regresión, clasificación, clustering), se elige desde modelos simples como regresión lineal hasta redes neuronales profundas.

- **Ajuste de parámetros:** los algoritmos iteran sobre los datos, miden errores mediante funciones como MSE (Mean Squared Error) y actualizan sus parámetros para minimizarlos (Pedrero et al., 2021).
- **Validación:** evaluación del modelo con datos no vistos para medir métricas como precisión, recall o AUC, asegurando su capacidad de generalización.

c. Optimización y despliegue

Tras el entrenamiento, se fine-tunean los modelos ajustando hiperparámetros (ejemplo: profundidad de árboles en Gradient Boosting) y se implementan en sistemas operativos. En minería, esto implica integrar modelos predictivos con sensores IoT para monitoreo en tiempo real, mientras que, en finanzas, se automatizan decisiones basadas en predicciones de riesgo.

Este flujo, respaldado por buenas prácticas como automatización de pipelines y gestión ética de datos, garantiza que los modelos sean robustos, escalables y alineados con objetivos estratégicos. Su éxito depende de la calidad inicial de los datos y la iteración continua entre las fases, adaptándose a nuevos patrones y mejorando su precisión con el tiempo (Pedrero et al., 2021).

1.5.5.1. Sensores y monitoreo en tiempo real

Los sensores y sistemas de monitoreo en tiempo real son pilares de la transformación digital en la industria minera, permitiendo la gestión proactiva de equipos, seguridad y procesos mediante la captura y análisis instantáneo de datos. Estas tecnologías, respaldadas por IoT y plataformas de procesamiento avanzado, optimizan la eficiencia operativa y reducen riesgos críticos (Revista Tecnología Minera, 2024).

a) Tipos de sensores y parámetros monitoreados

Los sensores se especializan en medir variables clave: vibraciones mecánicas, temperatura, presión, humedad y concentración de gases. En equipos críticos como motores eléctricos, detectan desbalances, sobrecalentamientos o desgaste de rodamientos, anticipando fallas mediante análisis predictivo. En minas subterráneas, sensores nanotecnológicos monitorean densidad del terreno, vibraciones sísmicas y estabilidad de galerías, enviando alertas ante riesgos de derrumbes. Además, dispositivos portátiles como casco IoT de Guardhat vigilan la salud de los trabajadores (pulso, temperatura corporal) y su entorno, bloqueando operaciones si no usan equipos de seguridad (Revista Tecnología Minera, 2024a).

b) Tecnologías de transmisión y conectividad

La infraestructura de comunicación es vital: redes LoRa (bajo consumo y largo alcance) y sistemas inalámbricos de Worldsensing permiten transmitir datos desde sensores instalados en zonas remotas, incluso con autonomía de hasta 10 años. En minas a cielo abierto, plataformas como Newtrax integran telemetría de equipos móviles (MET), mejorando la productividad en operaciones como la de Glencore en Canadá, donde aumentó la extracción de mineral de 55 a 60 toneladas por salida (Revista Tecnología Minera, 2024a).

c) Aplicaciones estratégicas

- **Mantenimiento predictivo:** Sensores en maquinaria pesada (cargadores, camiones) detectan anomalías en tiempo real, reduciendo paradas no planificadas. Por ejemplo, algoritmos analizan patrones de vibración para predecir fallos en rodamientos, evitando costos de reparación y optimizando inventarios de repuestos.
- **Seguridad laboral:** Sistemas como los de Guardhat combinan cámaras, micrófonos y sensores para alertar sobre exposición a gases tóxicos, caídas o proximidad a equipos en movimiento, activando protocolos de emergencia.
- **Exploración geológica:** Drones equipados con sensores inteligentes sobrevuelan áreas inaccesibles, recopilando datos de composición del suelo y humedad para identificar depósitos minerales con mayor precisión.
- **Sostenibilidad ambiental:** Monitorean impactos como contaminación acústica o emisiones, permitiendo ajustes inmediatos para minimizar la huella ecológica.

d) Desafíos y soluciones

La infraestructura de conectividad sigue siendo un obstáculo en zonas con cobertura limitada, aunque tecnologías como LoRa y redes locales mitigaron este problema. La gestión de datos requiere plataformas robustas que integren información de múltiples fuentes (sensores, drones, sistemas CMMS) para generar insights accionables. Por ejemplo, en minas a cielo abierto, Worldsensing combina datos de sensores con modelos predictivos para optimizar la estabilidad de taludes y cumplir normativas de seguridad (Revista Tecnología Minera, 2024a).

1.5.5.2. Plataformas y herramientas usada

Las plataformas y herramientas tecnológicas en la industria minera moderna se centran en optimizar procesos mediante el análisis de datos y el aprendizaje automático, destacando Python como eje central y TensorFlow como motor de modelos avanzados. Estas tecnologías, respaldadas por investigaciones y aplicaciones prácticas, transforman operaciones críticas como mantenimiento predictivo, simulación de procesos y gestión de activos (Revista Tecnología Minera, 2023a).

a) Python: el lenguaje base para la minería digital

Python se ha consolidado como el lenguaje de programación preferido en la industria minera por su versatilidad y ecosistema de librerías especializadas. Pandas y NumPy son fundamentales para la manipulación de datos, permitiendo integrar información de sensores, equipos y sistemas operativos en estructuras como DataFrames, facilitando filtrado, agrupación y análisis estadístico. Por ejemplo, en la optimización de rutas de transporte, Pandas procesa datos de GPS y consumo de combustible para reducir costos operativos. Matplotlib y Seaborn visualizan datos geológicos y operativos, como distribución de minerales o patrones de producción, generando gráficos que simplifican la toma de decisiones estratégicas. Scikit-learn implementa algoritmos de machine learning como Random Forest y SVM para clasificar muestras minerales o predecir fallos en equipos mediante datos históricos (Taboada, 2024).

En el ámbito de la simulación, SimPy modela procesos complejos como la extracción de minerales, permitiendo comparar métodos de operación (ejemplo: “Corte y Relleno” vs. “Hundimiento de Bloques”) y evaluar su eficiencia antes de implementarlos físicamente. Estudios demuestran que estas simulaciones reducen riesgos y optimizan la planificación, ajustando variables como tiempo de extracción y cantidad de mineral obtenido.

b) TensorFlow: aprendizaje profundo para problemas complejos

TensorFlow, desarrollado por Google, es una plataforma de código abierto para el desarrollo de modelos de deep learning. En minería, se emplea para tareas que requieren análisis de datos no estructurados o secuencias temporales, como la predicción de fallos en equipos mediante redes neuronales LSTM (Long Short-Term Memory). Estas redes procesan datos de sensores en tiempo real (vibraciones, temperatura) para identificar patrones que anticipen desgastes o sobrecalentamientos, mejorando la disponibilidad de activos críticos.

Su arquitectura modular permite implementar modelos en dispositivos móviles, servidores o la nube, facilitando la escalabilidad y la integración con sistemas IoT. Además, herramientas como TensorBoard analizan la eficacia de los modelos durante el entrenamiento,

mientras que Keras simplifica la construcción de redes neuronales mediante interfaces de alto nivel (Quiroz, 2021).

c) Integración y aplicaciones prácticas

La combinación de Python y TensorFlow potencia soluciones innovadoras. Por ejemplo, en mantenimiento predictivo, Scikit-learn clasifica fallos mediante datos históricos, mientras que TensorFlow refina estos modelos con redes neuronales para mejorar la precisión en escenarios de alta variabilidad. En exploración geológica, librerías como GeoPandas (para datos espaciales) se integran con TensorFlow para analizar imágenes satelitales y detectar depósitos minerales mediante técnicas de computer vision.

Estas herramientas también optimizan la gestión de inventarios y la planificación de producción, usando datos de sensores y algoritmos de optimización para ajustar horarios y recursos. En minas a cielo abierto, plataformas como Newtrax integran telemetría de equipos móviles con Python, mejorando la productividad en operaciones como la de Glencore en Canadá.

d) Desafíos y tendencias futuras

Aunque estas tecnologías son disruptivas, persisten retos como la gestión de datos desbalanceados (ejemplo: escasez de registros de fallas en equipos) y la interoperabilidad entre sistemas heredados y plataformas modernas. Sin embargo, la adopción de IoT y gemelos digitales que simularan comportamientos de equipos en entornos virtuales está acelerando la transición hacia la minería 4.0 (Revista Tecnología Minera, 2023a).

1.5.6. Marco conceptual

1.5.6.1. Mantenimiento predictivo

En el contexto del mantenimiento predictivo de motores eléctricos, el uso de *Machine Learning* supervisado se presenta como una solución efectiva y avanzada para anticipar fallos y optimizar la operación de estos equipos. Este enfoque consiste en desarrollar un modelo de aprendizaje capaz de identificar patrones de funcionamiento normal y anómalo a partir de datos históricos etiquetados. El proceso incluye la creación del modelo, su ajuste mediante técnicas de entrenamiento y validación, y finalmente su implementación en un entorno productivo. Una vez en operación, el modelo puede recibir datos en tiempo real y generar alertas o recomendaciones, lo cual mejora significativamente la eficiencia del mantenimiento (Albornoz, 2021).

Sin embargo, uno de los desafíos más relevantes en este tipo de aplicaciones es la gran cantidad de datos que se generan y necesitan ser procesados. En entornos industriales, los sensores instalados en los motores eléctricos pueden generar volúmenes masivos de información relacionados con temperatura, vibración, corriente, ruido, entre otros. Este fenómeno, conocido como *Big Data*, excede la capacidad de procesamiento de una sola máquina, lo que hace necesaria la utilización de arquitecturas distribuidas y plataformas especializadas en almacenamiento, análisis y visualización de datos (Taboada, 2024).

Una solución destacada es el uso de plataformas en la nube, como IBM Cloud (anteriormente conocida como Bluemix), que ofrece herramientas poderosas para el desarrollo e integración de aplicaciones basadas en inteligencia artificial. Esta plataforma permite recolectar datos desde múltiples fuentes, almacenarlos en bases de datos escalables, procesarlos mediante modelos de *Machine Learning* y analizarlos con herramientas gráficas o informes automáticos. Además, cuenta con módulos de reconocimiento de voz que permiten a los usuarios interactuar mediante comandos hablados, así como sistemas de visión artificial capaces de identificar objetos, ambientes y características visuales como color, textura o forma, generando así una base de conocimiento visual para mejorar la precisión del sistema predictivo (Taboada, 2024).

Estos sistemas se basan en el principio de que una máquina puede aprender de experiencias previas para tomar decisiones de manera más acertada en el futuro. Este concepto forma parte del campo más amplio de la *Inteligencia Artificial* (IA), que se define como la ciencia y tecnología encargada de diseñar agentes o sistemas capaces de emular capacidades cognitivas humanas, tales como la percepción, el razonamiento, el aprendizaje y la resolución de problemas. El término fue acuñado por John McCarthy en 1956, y desde entonces, ha evolucionado para convertirse en una de las disciplinas más influyentes del siglo XXI (Albornoz, 2021).

Un agente inteligente, dentro de este contexto, está compuesto por cuatro elementos esenciales: la percepción, que permite captar información del entorno; la acción, que es la capacidad de responder o ejecutar tareas; el entorno, que representa el medio en el que opera el agente; y las metas, que definen los objetivos que debe alcanzar. Estos componentes permiten a los sistemas de IA adaptarse, mejorar su rendimiento y tomar decisiones complejas, siendo especialmente útiles en aplicaciones industriales como el mantenimiento predictivo, donde la anticipación de fallos y la reducción de tiempos de inactividad son cruciales para la productividad y seguridad operativa.

1.5.6.2. Vida útil restante (RUL)

La vida útil restante (RUL, por sus siglas en inglés) representa el tiempo estimado que le queda a un componente, como un rodamiento en motores eléctricos, antes de que falle o requiera reemplazo. Este concepto es especialmente importante en la industria, donde los rodamientos son piezas críticas y frecuentes en equipos rotativos, siendo responsables del 50 al 60% de los fallos en motores de inducción. Predecir con precisión la RUL permite implementar estrategias de mantenimiento predictivo más efectivas, lo que ayuda a reducir costos, evitar interrupciones inesperadas en la producción y mejorar la seguridad operativa (Villacrés et al., 2024).

La estimación de la RUL ha evolucionado considerablemente con la llegada del Machine Learning (ML), particularmente en el contexto de la cuarta revolución industrial. Gracias a sensores avanzados, especialmente los de vibración, es posible obtener grandes volúmenes de datos en tiempo real que, analizados con algoritmos de ML, permiten identificar patrones de degradación y predecir el tiempo restante de vida útil. Esta tarea puede abordarse desde dos enfoques: uno basado en modelos físicos, y otro en datos. El enfoque basado en datos ha cobrado mayor relevancia recientemente por su flexibilidad y capacidad de adaptación a diversos escenarios industriales (Villacrés et al., 2024).

Sin embargo, esta tarea conlleva múltiples desafíos. Uno de ellos es la extracción adecuada de características a partir de señales de vibración. Estas señales pueden analizarse en tres dominios: tiempo, frecuencia y tiempo-frecuencia, siendo los dos primeros los más comunes. La calidad de los datos y la manera en que se procesan influyen directamente en el rendimiento de los modelos predictivos. Las características pueden extraerse manualmente, lo cual requiere conocimientos técnicos específicos, o de forma automática usando algoritmos de Deep Learning (DL), que, aunque más eficientes, exigen grandes volúmenes de datos y altos recursos computacionales.

Otro reto significativo es la identificación del inicio del proceso de degradación, lo cual permite diferenciar entre la etapa de operación normal del componente y su fase de deterioro progresivo. Además, existe la dificultad de desarrollar modelos que sean generalizables a distintas condiciones operativas, ya que muchos estudios se basan en datos recogidos bajo condiciones de laboratorio, como en la plataforma PRONOSTIA, la cual realiza pruebas de vida útil acelerada en rodamientos. Aunque esta base de datos es ampliamente utilizada y permite la comparación entre metodologías, su aplicabilidad a contextos reales aún representa una limitación.

Los modelos de ML utilizados para predecir la RUL abarcan desde redes neuronales profundas (deep neural networks) y modelos convolucionales (CNN), hasta enfoques híbridos y algoritmos como LSTM, Support Vector Machine o regresiones lineales. Estas técnicas son evaluadas utilizando métricas como el error cuadrático medio (RMSE), el error absoluto medio (MAE) y el error porcentual absoluto medio (MAPE), las cuales permiten medir la precisión del modelo (Abdulkareem et al., 2025).

1.5.6.3. Machine Learning

El aprendizaje automático, también conocido como machine learning o aprendizaje de máquinas, es una de las ramas más importantes y dinámicas de la inteligencia artificial (IA). Su objetivo principal es dotar a las computadoras de la capacidad de aprender a partir de datos, sin necesidad de ser programadas explícitamente para cada tarea. Esto se logra mediante el desarrollo e implementación de algoritmos y técnicas heurísticas que permiten transformar conjuntos de datos en modelos computacionales capaces de realizar predicciones, clasificaciones y análisis autónomos. En lugar de escribir instrucciones paso a paso, los sistemas aprenden de la experiencia, es decir, de los datos que se les suministra, mejorando su rendimiento a medida que reciben más información.


El machine learning se clasifica principalmente en dos grandes categorías: aprendizaje supervisado y no supervisado. En el aprendizaje supervisado, el modelo requiere la intervención humana, ya que se entrena con un conjunto de datos etiquetados, es decir, con ejemplos que incluyen tanto las entradas como las salidas esperadas. Los algoritmos “aprenden” a establecer relaciones entre ambos, lo que les permite generalizar comportamientos a partir de nuevos datos. Este tipo de aprendizaje se aplica en problemas de clasificación, donde los elementos se asignan a distintas categorías (por ejemplo, clasificar correos como spam o no spam), y en problemas de regresión, donde se predicen valores numéricos continuos (como el precio de una casa o la demanda energética) (Albornoz, 2021).

Por otro lado, el aprendizaje no supervisado no requiere que los datos estén etiquetados. Aquí, los algoritmos analizan los datos en busca de patrones, agrupaciones o estructuras ocultas sin ayuda externa. Dos técnicas comunes en este enfoque son el clustering, que agrupa datos similares sin conocer previamente sus categorías, y la asociación, que busca encontrar relaciones significativas o reglas dentro de un conjunto de datos, como las que se usan en sistemas de recomendación (por ejemplo, cuando se sugiere un producto en función de compras anteriores).

Además, dentro del machine learning existe una subcategoría avanzada llamada deep learning o aprendizaje profundo. Esta técnica se inspira en el funcionamiento del cerebro humano, utilizando redes neuronales artificiales compuestas por múltiples capas que permiten aprender representaciones complejas de los datos. El deep learning es especialmente potente en tareas como el reconocimiento de voz, visión por computadora, procesamiento de lenguaje natural y análisis predictivo, gracias a su capacidad de procesar grandes volúmenes de datos y extraer características de manera jerárquica y automatizada (Albornoz, 2021).

Figura 2

Estructura de una red neuronal



Nota. Tomado de (Albornoz, 2021).

1.5.6.4. Algoritmos de predicción

Los algoritmos de predicción utilizados permiten estimar parámetros críticos de estabilidad en corredores de transmisión eléctrica a partir de datos obtenidos mediante simulaciones de Montecarlo. Estos datos incluyen variables como voltajes, corrientes, potencias de carga máxima, márgenes de estabilidad y puntos de colapso. Para manejar la alta dimensionalidad del conjunto de datos, se aplica la técnica de extracción de características conocida como Análisis de Componentes Principales (PCA), que conserva la mayor parte de la variabilidad reduciendo el número de variables y eliminando correlaciones redundantes (Chiza y Cepeda, 2021).

Con la información procesada, se entrenan tres tipos de modelos de regresión: Bagging (TreeBagger), LSBoost y Red Neuronal (fitrnet), cada uno con enfoques distintos para la predicción (Chiza y Cepeda, 2021).

- a) **Bagging (TreeBagger):** Este método se basa en la combinación de múltiples árboles de decisión entrenados sobre subconjuntos aleatorios de los datos. Cada árbol contribuye con un modelo independiente y la predicción final resulta del promedio de todos ellos, lo que reduce la varianza y evita el sobreajuste. El algoritmo aprovecha la diversidad de los árboles para mejorar la estabilidad y precisión del modelo en escenarios complejos, como los márgenes de estabilidad eléctrica (Chiza y Cepeda, 2021).
- b) **LSBoost (Least Squares Boosting):** A diferencia del Bagging, el LSBoost construye árboles de decisión de manera secuencial. Cada nuevo árbol intenta corregir los errores cometidos por el conjunto anterior minimizando la función de pérdida cuadrática. Con cada iteración, el modelo se vuelve más preciso, ya que las predicciones se ajustan progresivamente a las particularidades de los datos. Este método es especialmente útil cuando existen relaciones no lineales y se requiere una alta capacidad predictiva (Chiza y Cepeda, 2021).
- c) **Red Neuronal (fitrnet):** El modelo *fitrnet* implementa redes neuronales artificiales para tareas de regresión. Emplea capas conectadas entre sí donde cada neurona realiza una combinación ponderada de las entradas seguida de una función de activación, lo que permite capturar relaciones complejas entre variables. Este enfoque es flexible, ya que se pueden definir el número de capas ocultas, tipo de activación y método de optimización, logrando adaptarse a patrones no lineales presentes en los datos eléctricos (Chiza y Cepeda, 2021).

Para todos los modelos, la optimización de hiperparámetros se realiza mediante GridSearchCV, que evalúa sistemáticamente distintas combinaciones para encontrar la que ofrece el mejor desempeño. El rendimiento final se mide con el Error Cuadrático Medio (MSE), observándose que el ajuste adecuado de hiperparámetros mejora notablemente la precisión en la predicción de márgenes de estabilidad, contribuyendo a la toma de decisiones preventivas en la operación del sistema eléctrico (Chiza y Cepeda, 2021).

1.5.6.5. Modelos de clasificación en Machine Learning

Los modelos de clasificación en Machine Learning son algoritmos diseñados para asignar etiquetas o categorías a entradas de datos, basándose en patrones aprendidos a partir de ejemplos previamente etiquetados. Son esenciales en situaciones donde se necesita determinar la clase a la que pertenece un elemento, como sucede en la detección de correos no deseados, el reconocimiento de voz o la categorización de imágenes.

Este proceso se divide en dos etapas. Primero, en la fase de entrenamiento, el modelo analiza un conjunto de datos con etiquetas conocidas, detectando relaciones entre las características y sus respectivas clases. Luego, en la fase de prueba, el modelo aplica lo aprendido para clasificar nuevos datos, evaluando su rendimiento mediante métricas de precisión.

Entre los algoritmos más relevantes de clasificación se encuentran los árboles de decisión, que utilizan una estructura jerárquica compuesta por nodos que representan decisiones basadas en atributos. Cada nodo guía el camino hacia una predicción final representada en las hojas. Estos árboles se construyen dividiendo los datos en subconjuntos homogéneos respecto a la variable objetivo. Se destacan por su claridad visual y facilidad de interpretación, lo cual es útil en disciplinas como la medicina o la economía. Existen variantes como ID3, que usa ganancia de información para elegir atributos; C4.5, que mejora a ID3 incorporando normalización y manejo de datos continuos; y CART, que aplica el índice Gini y sirve tanto para clasificación como para regresión. Para evitar que el modelo se ajuste excesivamente a los datos de entrenamiento, se aplican técnicas como la poda, que elimina ramas poco útiles (Bansal et al., 2022).

Otro algoritmo destacado es Random Forest, una técnica que combina múltiples árboles de decisión entrenados con subconjuntos aleatorios del conjunto original mediante bootstrap. En cada división del árbol se consideran solo algunas características seleccionadas al azar, reduciendo la correlación entre árboles. En clasificación, la predicción final se obtiene por mayoría de votos, y en regresión, se promedian los resultados. Esta técnica es efectiva para manejar datos de gran volumen y múltiples variables sin sobreajuste significativo. Además, permite evaluar la importancia de cada característica. Sin embargo, su complejidad hace que pierda interpretabilidad y puede requerir mayor poder computacional (Arana, 2021).

En la misma línea, el Bagging (TreeBagger) adopta un enfoque similar al Random Forest en cuanto a la creación de múltiples árboles, pero cada árbol es entrenado de forma independiente y con igual ponderación en la predicción final. El objetivo es disminuir la

varianza del modelo y mejorar su estabilidad al promediar los resultados de todos los árboles entrenados. Esto lo hace adecuado para situaciones con alta variabilidad en los datos, logrando un desempeño sólido incluso en escenarios con ruido significativo (Chiza y Cepeda, 2021).

Por otro lado, LSBoost (Least Squares Boosting) sigue un procedimiento secuencial en el que cada árbol posterior intenta corregir los errores del anterior. A través de múltiples iteraciones, los árboles van ajustando progresivamente sus predicciones mediante la minimización de la función de pérdida cuadrática. Este método logra modelos con alta precisión, especialmente cuando se requiere capturar patrones no lineales y relaciones complejas entre variables (Chiza y Cepeda, 2021).

Las máquinas de soporte vectorial (Support Vector Machines, SVM) también son ampliamente utilizadas. Su objetivo es hallar un hiperplano que separe con el mayor margen posible las distintas clases en un espacio multidimensional. Si los datos no pueden separarse linealmente, se emplean funciones kernel que los transforman a espacios de mayor dimensión donde sí es posible trazar divisiones lineales. Este método se basa en problemas de optimización convexa, asegurando soluciones globalmente óptimas. Son especialmente útiles en contextos con alta dimensionalidad y datos complejos, ya que logran un equilibrio entre precisión y capacidad de generalización (Bansal et al., 2022).

Respecto a las Redes Neuronales Artificiales (RNA), el modelo fitrnet permite su aplicación en tareas de regresión, donde la información se procesa a través de capas conectadas con funciones de activación que capturan relaciones no lineales entre las variables. Al entrenarse mediante algoritmos de optimización y ajustar los pesos de sus conexiones, estas redes logran aproximar funciones complejas con alta precisión. Su flexibilidad para adaptarse a diferentes arquitecturas las convierte en herramientas muy versátiles para predicción y modelado de datos (Chiza y Cepeda, 2021).

El algoritmo K-Nearest Neighbors (KNN) también es una técnica de aprendizaje supervisado, donde la predicción de una nueva instancia se basa en la comparación con sus k vecinos más cercanos. Si se trata de clasificación, se asigna la clase más común entre ellos; si es regresión, se calcula la media. La elección del valor de k afecta directamente el rendimiento: valores bajos hacen al modelo más sensible al ruido, mientras que valores altos pueden reducir la precisión. Aunque es fácil de implementar y entender, KNN puede volverse ineficiente con grandes volúmenes de datos debido a la necesidad de calcular múltiples distancias, lo cual se mitiga mediante algoritmos de búsqueda optimizada (Arana, 2021). En conjunto, estos algoritmos representan herramientas fundamentales dentro del aprendizaje supervisado, cada

uno con fortalezas y limitaciones, y su elección depende del problema específico, la naturaleza de los datos y los recursos disponibles.

1.5.6.6. Modelos supervisados y no supervisados

En el desarrollo de modelos de predicción aplicados al trading algorítmico en mercados de commodities, se emplean tanto enfoques de aprendizaje supervisado como no supervisado. El aprendizaje supervisado se basa en el uso de datos etiquetados, lo que significa que se entrena un modelo con ejemplos de entrada y sus respectivas salidas esperadas. Este tipo de modelos permite realizar tareas de clasificación y regresión, donde se evalúa el rendimiento mediante métricas como precisión, recall y F1-score. Dentro de las técnicas supervisadas más utilizadas en este contexto se encuentran las redes neuronales, los árboles de decisión, los modelos de Random Forest y las máquinas de soporte vectorial, los cuales permiten detectar patrones complejos en series temporales relacionadas con precios de commodities (Bermejo, 2025).

Por otro lado, el aprendizaje no supervisado se enfoca en descubrir estructuras ocultas dentro de los datos sin necesidad de etiquetas predefinidas. Este enfoque es útil para identificar agrupamientos naturales y relaciones no evidentes entre variables, lo que puede aportar información valiosa para desarrollar estrategias de trading basadas en similitudes de comportamiento. Entre las técnicas más representativas se incluyen el algoritmo K-means y el clustering jerárquico, los cuales permiten agrupar periodos o activos con patrones similares de comportamiento, facilitando así la segmentación de escenarios de mercado (Bermejo, 2025).

Ambos enfoques se integran dentro del proceso de diseño del modelo de detección de patrones, que comienza con la recopilación y análisis de datos históricos de precios de commodities y variables macroeconómicas relacionadas. Tras el procesamiento y selección de variables relevantes, se construyen y optimizan los modelos de aprendizaje automático. La validación se realiza utilizando técnicas como la validación cruzada y el backtesting, permitiendo verificar la capacidad del modelo para generalizar en nuevos contextos y evaluar su rentabilidad potencial (Bermejo, 2025).

1.5.6.7. Motores eléctricos


Los motores eléctricos son dispositivos electromecánicos esenciales en la transformación de energía eléctrica en energía mecánica rotativa, lo que ha permitido su integración en una gran variedad de aplicaciones tanto industriales como domésticas. Estas máquinas funcionan gracias a la interacción entre campos magnéticos generados por bobinas ubicadas en el estator (parte fija) y el rotor (parte móvil), generando un par o torque que impulsa el eje y produce movimiento. Desde su invención en el siglo XIX, han evolucionado significativamente en términos de eficiencia, versatilidad y diseño, convirtiéndose en pilares del avance tecnológico, particularmente con el auge de la automatización, la movilidad eléctrica y la transición energética hacia tecnologías más limpias (Tirira et al., 2024).

Existen múltiples tipos de motores eléctricos, clasificados principalmente según el tipo de corriente con la que operan: corriente continua (CC), corriente alterna (CA), y los motores universales que pueden funcionar con ambas. Cada categoría tiene subdivisiones basadas en su construcción y características de funcionamiento. Los motores de corriente continua incluyen variantes como los de imanes permanentes, excitación serie, excitación en paralelo (shunt), compound y excitación independiente, cada uno adaptado a distintas necesidades como control de velocidad, alto torque de arranque o estabilidad bajo diferentes cargas (Tirira et al., 2024).

Por otro lado, los motores de corriente alterna se dividen en monofásicos y trifásicos. Los motores monofásicos, ideales para usos domésticos o comerciales de baja potencia, incluyen tipos como los de polos sombreados, de fase partida, con capacitor de arranque, con capacitor permanente y con doble capacitor (arranque y marcha). Estos motores se caracterizan por su simplicidad y bajo costo. En entornos industriales, predominan los motores trifásicos debido a su alta eficiencia y capacidad de manejar cargas pesadas. Dentro de estos destacan los motores asíncronos o de inducción, subdivididos en aquellos con rotor de jaula de ardilla y rotor bobinado, así como los motores síncronos, que operan a velocidad constante sincronizada con la frecuencia de la red, siendo ideales para aplicaciones de precisión.

Figura 3

Tipos de motores eléctricos



Nota. Tomado de (Tirira et al., 2024).

1.6. HIPÓTESIS

Si se aplican técnicas de aprendizaje automático supervisado a partir de datos operativos históricos de motores eléctricos, entonces se podrá estimar con mayor precisión la vida útil restante (RUL) de dichos motores en una empresa minera del sur, contribuyendo a mejorar la planificación del mantenimiento y reducir fallas imprevistas.



CAPÍTULO II

PLANTEAMIENTO OPERACIONAL

2.1. Técnicas e Instrumentos

2.1.1. Técnicas

Para el análisis de datos se emplearán técnicas de aprendizaje automático supervisado, enfocadas en modelos de regresión que permitan estimar la vida útil restante (RUL) de motores eléctricos. Entre las técnicas consideradas se encuentran Bagging (TreeBagger), LSBoost y Redes Neuronales (fitrnet), las cuales serán comparadas según su desempeño.

El análisis incluye:

- **Preprocesamiento de datos:** normalización, limpieza de datos, manejo de valores atípicos y segmentación de datos históricos.
- **Entrenamiento y validación cruzada:** para evaluar la capacidad predictiva y evitar sobreajuste.
- **Evaluación del desempeño:** mediante métricas como el error cuadrático medio (RMSE), error absoluto medio (MAE) y coeficiente de determinación (R^2).

2.1.2. Instrumentos

Los instrumentos utilizados en la investigación son de tipo digital y computacional:

- **Registros históricos de operación de motores eléctricos:** Contienen datos como temperatura, corriente y vibración.
- **Software MATLAB:** que servirá como entorno principal para el desarrollo del modelo, procesamiento de datos, implementación de algoritmos de aprendizaje automático y análisis estadístico.
- **Módulos de aprendizaje automático de MATLAB:** Bagging (TreeBagger), LSBoost y Red Neuronal (fitrnet) para el diseño, entrenamiento y validación de los modelos.

2.2. Variables de estudio

Variable Independiente: Aprendizaje automático

Indicadores:

- Tipo de algoritmo aplicado
- Precisión del modelo
- Métricas de validación cruzada

Variable Dependiente: Vida útil restante estimada de motores eléctricos

Indicadores:

- Tiempo estimado de funcionamiento restante
- Error de predicción
- Coeficiente de determinación (R^2)

2.3. Campo de Verificación

2.3.1. Ubicación Temporal

La investigación se desarrollará durante el año 2025.

2.3.2. Ubicación espacial

El estudio se realizará de manera computacional utilizando MATLAB como plataforma principal. Los datos analizados provendrán de registros históricos de motores eléctricos utilizados en entornos mineros del sur del país. No se realizará intervención directa en campo, ya que el enfoque es analítico y basado en datos previamente recolectados.

2.3.3. Unidades de Estudio

Las unidades de estudio estarán conformadas por los motores eléctricos utilizados en procesos mineros de la línea WEG W22, específicamente aquellos que cuenten con registros operativos históricos provenientes de sensores instalados en condiciones reales de operación.

2.4. Estrategias de recolección de datos

La estrategia de recolección de datos se basa en el aprovechamiento de registros históricos operativos provenientes de motores eléctricos instalados en una empresa minera del sur del país. Para garantizar la calidad de los datos, se empleará una fase inicial de depuración que incluye la detección y eliminación de valores atípicos, el tratamiento de datos faltantes y la normalización de los registros. Posteriormente, estos datos serán organizados en conjuntos de entrenamiento, validación y prueba para alimentar los modelos de aprendizaje automático desarrollados en MATLAB.

Para garantizar la integridad y confiabilidad de la base de datos, se contempla una fase inicial de limpieza y depuración. Esta etapa incluye la detección y eliminación de valores atípicos, el tratamiento de datos ausentes o inconsistentes, y la normalización de los registros,

asegurando que todos los datos estén escalados a un rango común y sean comparables entre sí. Estas acciones son esenciales para minimizar errores de modelado y evitar sesgos en los resultados. Posteriormente, los datos serán organizados en conjuntos de entrenamiento, validación y prueba, siguiendo buenas prácticas en el desarrollo de modelos de aprendizaje automático. Esta división permite evaluar el rendimiento del modelo en diferentes etapas y evita el sobreajuste (overfitting), garantizando así su capacidad de generalización.

Adicionalmente, se emplearán técnicas estadísticas y de ingeniería de características para extraer indicadores relevantes derivados de las señales registradas. Estas características como la media, desviación estándar, curtosis, frecuencia dominante, entre otras son utilizadas como entradas para los modelos predictivos, ya que contienen información representativa del estado del motor. Este procesamiento permite capturar de manera más robusta los patrones de degradación y las señales tempranas de falla.

2.5. Limitaciones

La presente investigación, si bien propone una alternativa para la estimación de la vida útil restante (RUL) en motores eléctricos mediante el uso de aprendizaje automático, presenta ciertas limitaciones que deben ser consideradas al momento de interpretar los resultados y su aplicabilidad en contextos reales.


- Una primera limitación está relacionada con la naturaleza de los datos utilizados, los cuales provienen de registros históricos previamente recopilados. Al no realizarse una recolección de datos en tiempo real ni en condiciones controladas, se está sujeto a la calidad, consistencia y frecuencia de los datos disponibles, lo que puede restringir la precisión de los modelos entrenados.
- En segundo lugar, el modelo propuesto se desarrolla e implementa en un entorno computacional, sin validación directa en campo. Esto implica que, aunque los resultados puedan ser prometedores en simulaciones, su desempeño real en entornos operativos podría variar debido a factores no modelados o dinámicas de operación no representadas completamente en los datos históricos.
- Otra limitación importante es la generalización del modelo a otros tipos de motores o ambientes industriales. Dado que el estudio se enfoca en motores eléctricos utilizados específicamente en una empresa minera del sur del país, los modelos entrenados pueden no ser directamente aplicables a otros contextos sin una recalibración o reentrenamiento con datos nuevos.

2.6. Esquema metodológico

El proceso metodológico seguido en esta investigación se basa en un enfoque secuencial que integra la adquisición de datos, el modelado mediante técnicas de aprendizaje automático.

Figura 4

Diagrama metodológico del proceso



Nota. Elaboración Propia

CAPÍTULO III
DIAGNÓSTICO OPERATIVO DE LOS
MOTORES ELÉCTRICOS

3.1. Datos operativos de motores eléctricos

En el desarrollo de la presente investigación, la recopilación y análisis de datos operativos de motores eléctricos constituyen el punto de partida para la construcción del modelo predictivo orientado a estimar la vida útil restante (RUL) de dichos equipos. Los datos utilizados provienen de registros históricos en los que se han considerado variables eléctricas, mecánicas, ambientales y de condición, con el objetivo de caracterizar de manera integral el comportamiento operativo de los motores a lo largo del tiempo.


El conjunto de datos, detallado en el Anexo N°2, se ha organizado en categorías que facilitan su procesamiento y análisis posterior. En primer lugar, se encuentran los datos completos, que comprenden la totalidad de los registros sin segmentación inicial y permiten tener una visión global del desempeño de los equipos. A partir de esta información general, se han definido cuatro grupos principales:

- **Variables eléctricas:** Incluyen el voltaje, la corriente y el factor de potencia. Estos parámetros reflejan el consumo energético, la calidad de la energía suministrada y la eficiencia del motor desde el punto de vista eléctrico. Su análisis permite identificar posibles sobrecargas, desbalances o pérdidas en la conversión de energía eléctrica a mecánica.
- **Variables mecánicas:** Integran la velocidad de rotación (RPM), el porcentaje de carga y la eficiencia del equipo. Estos indicadores son esenciales para evaluar el desempeño dinámico del motor, ya que permiten relacionar el esfuerzo mecánico al que está sometido con su capacidad de mantener condiciones operativas estables.
- **Variables ambientales:** Comprenden la temperatura ambiente, la humedad relativa y la temperatura interna del estator y los rodamientos. Estas condiciones externas e internas influyen directamente en el envejecimiento de materiales, la degradación del aislamiento y la reducción de la vida útil de los componentes críticos del motor.
- **Variables de condición:** Consideran las vibraciones y el estado operativo del motor. Su monitoreo permite detectar comportamientos anómalos asociados a desalineaciones, desequilibrios o fallas incipientes que podrían evolucionar hacia paradas no planificadas si no se corrigen oportunamente.

La Figura 5 muestra la evolución de la velocidad de rotación (RPM) y el porcentaje de carga de los motores eléctricos durante el periodo analizado.

Figura 5

Datos Completos: RPM y carga




Nota. Elaboración Propia

Los resultados evidencian que la velocidad de rotación mantiene un promedio de 1501 rpm, con valores mínimos y máximos de 1335 rpm y 1695 rpm, respectivamente. Se observa que el 50 % de los registros se concentran entre 1468 rpm y 1535 rpm, lo que confirma una operación estable y cercana a las condiciones nominales del equipo, sin variaciones abruptas que indiquen eventos críticos o paradas imprevistas. Por su parte, el porcentaje de carga oscila entre 0 % y 120 %, con un valor medio de 70 %. El rango intercuartílico, comprendido entre 56 % y 84 %, revela que la mayor parte del tiempo los motores operan dentro de parámetros normales, aunque se identifican picos por encima del 100 % que corresponden a escenarios de sobrecarga y que, de repetirse con frecuencia, podrían afectar la eficiencia y la vida útil del sistema.

La Figura 6 muestra el comportamiento del voltaje, la corriente y el factor de potencia de los motores eléctricos a lo largo del tiempo.

Figura 6

Eléctricos: Variables eléctricas como voltaje, corriente y factor de potencia




Nota. Elaboración Propia

Los registros evidencian que el voltaje presenta un promedio de 400 V, con valores entre 326 V y 473 V. El 50 % de los datos se concentran en el rango de 387 V a 414 V, lo que indica que la alimentación eléctrica se mantuvo estable y cercana al valor nominal, sin fluctuaciones significativas que pudieran comprometer la operación del motor. En cuanto a la corriente, se observan valores comprendidos entre 9 A y 82 A, con un promedio de 50 A. El rango intercuartílico (43 A a 57 A) confirma que la mayor parte del tiempo la demanda de corriente se mantuvo dentro de parámetros normales, sin evidenciar sobrecargas frecuentes. Por último, el factor de potencia registra un promedio de 0.80, con un mínimo de 0.63 y un máximo de 0.96. Estos valores demuestran un desempeño energético adecuado, ya que la mayoría de los datos superan el valor de 0.75, considerado aceptable para sistemas eléctricos industriales.

La Figura 7 representa la evolución temporal de la velocidad de rotación (RPM), la carga (%) y la eficiencia (%) de los motores eléctricos.

Figura 7

Mecánicos: RPM, carga y eficiencia




Nota. Elaboración Propia

Los resultados muestran que la velocidad de rotación mantiene un promedio de 1501 rpm, con valores que oscilan entre 1336 rpm y 1695 rpm. El 50 % de los registros se sitúan en el rango de 1468 rpm a 1535 rpm, lo que confirma una operación estable y próxima a las condiciones nominales de diseño. Respecto al porcentaje de carga, se observa una media del 70%, con un rango de 0% a 120%. El rango intercuartílico, comprendido entre 56% y 84%, indica que la mayoría del tiempo los motores trabajaron en condiciones normales, aunque se identifican momentos puntuales de sobrecarga por encima del 100%, los cuales podrían, en escenarios repetitivos, afectar la eficiencia y la vida útil del sistema. Finalmente, la eficiencia promedio fue de 94.9%, con valores entre 85.9% y 100%, y con la mayor concentración de datos entre 93.1% y 96.8%. Estos resultados confirman un desempeño energético adecuado durante todo el periodo analizado, sin pérdidas significativas que pudieran reflejar fallas en el proceso o degradación del motor.

La Figura 8 presenta la evolución de la temperatura del estator, la temperatura de los rodamientos, la temperatura ambiente y la humedad relativa durante el periodo de monitoreo.

Figura 8

Ambientales: Temperaturas y humedad




Nota. Elaboración Propia

Los resultados muestran que la temperatura del estator registra un promedio de 59.9 °C, con valores entre 22.2 °C y 95.2 °C, mientras que la temperatura de los rodamientos mantiene un promedio de 55.1 °C, con un rango de 26.6 °C a 83.6 °C. En ambos casos, el 50 % de los registros se concentra entre 53 °C y 67 °C para el estator y entre 50 °C y 60 °C para los rodamientos, lo que indica condiciones térmicas operativas dentro de los parámetros normales del equipo. Por su parte, la temperatura ambiente presenta valores que oscilan entre 7.9 °C y 41.8 °C, con un promedio de 25 °C, lo cual evidencia variaciones atribuibles a factores climáticos externos, pero sin impactos significativos en la operación de los motores. Finalmente, la humedad relativa registra un promedio de 49.9%, con un rango entre 20% y 100 %, y con la mayor concentración de datos entre 40% y 60%, lo que representa condiciones aceptables para la operación de los equipos eléctricos, reduciendo el riesgo de condensación o degradación del aislamiento.

La Figura 9 muestra la evolución de la vibración (mm/s) y el estado operativo de los motores eléctricos durante el periodo analizado.

Figura 9

Condición: Vibraciones y estado del motor



Nota. Elaboración Propia

Los resultados indican que la vibración presenta un promedio de 2.0 mm/s, con valores que oscilan entre 0.33 mm/s y 3.77 mm/s. El 50 % de los registros se concentra entre 1.66 mm/s y 2.35 mm/s, lo que evidencia que la mayoría de los motores operaron en condiciones mecánicas aceptables y por debajo de los límites críticos recomendados para equipos rotativos en aplicaciones industriales. En cuanto al estado del motor, representado de forma binaria (0 = operación normal, 1 = evento de falla), se observa que el 84.8% de los datos corresponde a funcionamiento normal, mientras que solo el 15.2% muestra situaciones asociadas a paradas o fallas detectadas. Estos valores confirman que, durante el periodo de observación, la ocurrencia de eventos críticos fue reducida en comparación con el tiempo total de operación.

3.2. Diagnóstico de motores eléctricos en falla

En esta sección se realiza el diagnóstico de motores eléctricos bajo condiciones de falla utilizando los mismos registros operativos descritos en el apartado 3.1 y el Anexo N.º 2. A diferencia del análisis previo centrado en rangos operativos aceptables aquí se trabajan escenarios controlados en los que se identifican y examinan ventanas temporales alrededor de eventos etiquetados como falla, comparándolas con el comportamiento basal (operación normal) del mismo motor. Esta estrategia permite aislar el efecto de la falla de la variabilidad

propia del proceso. Metodológicamente, para cada motor y tipo de falla se selecciona el primer instante de detección y se extrae una ventana de análisis (por ejemplo, 90 min) alrededor de ese punto. Sobre esa ventana se calculan estadísticas de referencia (medias, dispersión y métricas móviles) y se contrastan con el baseline en estado normal. El diagnóstico se fundamenta en indicadores físicos medibles y trazables en la base de datos:

- **Condición mecánica:** vibration_rms_mm_s, vibration_kurtosis, y sus promedios/desviaciones móviles.
- **Térmicos:** temp_bearing_C, temp_stator_C (relación carga-temperatura).
- **Calidad eléctrica/energética:** imbalance_pct, misalignment_idx, insulation_MOhm, current_A, power_factor, thd_i_pct, thd_v_pct, y efficiency_pct.
- **Contexto operativo:** rpm, load_pct, y variables ambientales.

El análisis aborda las fallas desbalance, desalineación, falla en rodamientos, sobrecalentamiento y baja aislación. De forma esperada, se observan firmas diferenciales: (i) incrementos de vibración y kurtosis en rodamientos; (ii) alzas térmicas en estator/rodamientos ante sobrecalentamiento; (iii) reducción de insulation_MOhm en baja aislación; (iv) aumentos de imbalance_pct en desbalance y de misalignment_idx en desalineación.

La Tabla 2 compara el comportamiento del motor en su baseline de operación normal frente a una ventana temporal en falla. El contraste se realiza sobre variables de condición mecánica, térmicas, eléctricas y de desempeño, permitiendo aislar el efecto de la falla respecto del mismo equipo.

Tabla 2

Motor en falla - Resumen por medias

Variable	Media_Normal	Media_VentanaFalla
vibration_rms_mm_s	3.9935	4.1026
vibration_kurtosis	2.998	3.04
temp_bearing_C	33.648	36.299
temp_stator_C	41.171	44.126
imbalance_pct	1.6097	1.7967
misalignment_idx	0.50084	0.49934
insulation_MOhm	241.08	238.57
rpm	1795.1	1796.1
load_pct	0.76043	0.79565
efficiency_pct	90.894	90.651

Nota. Elaboración Propia

Principales variaciones respecto al baseline (Δ y %):

- Vibración RMS: +0.109 mm/s (+2.73 %).
- Curtosis de vibración: +0.042 (+1.40 %).
- Temperatura de rodamientos: +2.651 °C (+7.88 %).
- Temperatura del estator: +2.955 °C (+7.18 %).
- Desbalance de tensión (imbalance_pct): +0.187 p.p. (+11.62 %).
- Índice de desalineación: -0.0015 (-0.30 %; sin cambio relevante).
- Resistencia de aislamiento: -2.51 M Ω (-1.04 %; leve descenso).
- RPM: +1.0 rpm (+0.06 %; prácticamente estable).
- Carga (pu): +0.0352 (+4.63 %; leve aumento).
- Eficiencia: -0.243 p.p. (-0.27 %; ligera penalización).

El incremento simultáneo de vibración RMS, curtosis y temperaturas (especialmente en rodamientos) es consistente con una falla mecánica localizada en rodamientos. La carga sube moderadamente y la eficiencia cae levemente, lo que sugiere fricción adicional sin pérdida severa de desempeño global. El desbalance de tensión aumenta, pero el índice de desalineación no muestra un cambio significativo, por lo que no se infiere desalineación como causa principal. La resistencia de aislamiento desciende marginalmente, sin evidencia de degradación eléctrica dominante en esta ventana.

La Tabla 3 reúne tres instantes representativos del Motor 9 etiquetados como “*falla_rodamientos*”. En los dos primeros registros (03:00 y 07:08), la carga es alta (0.95 y 0.89 pu) y coincide con vibraciones RMS elevadas (7.34-7.51 mm/s) y kurtosis incrementada (4.88-4.54), firma típica de impulsos asociados a defectos en elementos rodantes. La respuesta térmica acompaña el cuadro de esfuerzo mecánico: rodamientos en 43.2-40.9 °C y estator hasta 53.75 °C. La eficiencia se mantiene en torno a 90-90.2 %, con ligera penalización frente a condiciones normales.

En el tercer registro (21:27), al disminuir la carga a 0.56 pu, la vibración desciende, pero permanece alta (5.21 mm/s) y la kurtosis sigue sobre 4.1, lo que sugiere que el defecto persiste aun con menor sollicitación. La temperatura cae (estator 27.86 °C, rodamientos 18.36 °C), coherente con el alivio térmico por menor carga; la eficiencia sube a 92.06 %, reflejando el alivio de pérdidas por fricción, aunque la magnitud de vibración sigue por encima del patrón observado en la sección 3.1.

Tabla 3

Muestras en zona de falla de rodamientos


timestamp	01-Jan-2025 03:00:00	01-Jan-2025 07:08:00	01-Jan-2025 21:27:00
motor_id	9	9	9
state	“falla_rodamientos”	“falla_rodamientos”	“falla_rodamientos”
rpm	1780.4	1783.1	1815.7
load_pct	0.94719	0.88754	0.55505
vibration_rms_mm_s	7.3392	7.5098	5.2139
vibration_kurtosis	4.8836	4.5392	4.117
temp_bearing_C	43.172	40.87	18.362
temp_stator_C	46.009	53.753	27.863
efficiency_pct	89.697	90.229	92.063

Nota. Elaboración Propia

La Figura 10 sintetiza la evolución de tres señales del mismo motor alrededor del instante marcado como “Falla” (línea punteada roja): vibración RMS, kurtosis de vibración y temperaturas de rodamientos y estator.

Figura 10

Motor de falla - rodamientos



Nota. Elaboración Propia

- **Vibración RMS.** Tras el punto de falla, la señal se mantiene por encima del baseline (línea de referencia) y aparecen picos repetitivos que alcanzan del orden de 5-8 mm/s, consistentes con un incremento de energía vibratoria típico de defectos en elementos rodantes.
- **Kurtosis.** Se observan impulsos (aumentos bruscos de kurtosis) distribuidos en el tiempo, lo que refuerza la presencia de choques periódicos propios de pitings/planicies en jaula.
- **Temperaturas.** Las trazas de rodamientos (naranja) y estator (azul) muestran ciclos térmicos diarios; sin embargo, en varias crestas el rodamiento supera al estator, indicando fricción adicional localizada en el conjunto rodante. Esta elevación térmica coincide temporalmente con episodios de mayor vibración.

La coexistencia de RMS elevado, kurtosis con impulsos y aumento relativo de la temperatura de rodamientos respecto del estator es compatible con una falla en rodamientos en progreso.

CAPÍTULO IV

**MODELO DE APRENDIZAJE
AUTOMÁTICO SUPERVISADO**

4.1. Modelado por subsistemas del motor eléctrico

El modelado se organizó en tres subsistemas rodamientos, estator y rotor, los cuales representan los principales conjuntos mecánicos y eléctricos del motor. Cada subsistema fue modelado individualmente a partir de las hojas del archivo Excel, y luego se integró toda la información en el modelo global de predicción de vida útil restante (RUL).

Tabla 4

Subsistemas modelados

Subsistema	Datos	Variables principales	Propósito del modelo
Rodamientos	Mecánicos, Ambientales, Condición	vibration_mm_s, temp_bearing_C, rpm, load_pct, ambient_temp_C, humidity_pct	Detectar desgaste y fallas mecánicas progresivas
Estator	Eléctricos, Ambientales	voltage_V, current_A, power_factor, temp_stator_C, ambient_temp_C, humidity_pct	Identificar degradación térmica y eléctrica del aislamiento
Rotor	Mecánicos, Eléctricos	rpm, load_pct, efficiency_pct, current_A, power_factor	Determinar ineficiencia o ruptura de barras del rotor
Modelo global	Datos_Completos	Todas las variables consolidadas por timestamp y motor_id	Estimar el RUL mediante Bagging, LSBoost y fitrnet

Nota. Elaboración Propia

Para la preparación y limpieza de datos se aplicó lo siguiente:

La Tabla 5 resume las etapas aplicadas para garantizar la calidad y coherencia de los datos antes del modelado.

Tabla 5

Procedimientos de preparación y limpieza de datos

Procedimiento	Descripción técnica
Sincronización temporal	Se usó (timestamp, motor_id) como llave para fusionar todas las hojas.
Imputación de datos faltantes	Aplicación de forward fill para series continuas y media móvil para picos de vibración.
Normalización	Escalado robusto (basado en mediana e IQR) para evitar sesgos por magnitud.
Control de calidad	Eliminación de valores atípicos con

Nota. Elaboración Propia

La Tabla 6 muestra el proceso de modelado del subsistema mecánico de los rodamientos.

Tabla 6

Modelado del subsistema de rodamientos

Elemento	Descripción
Variables clave	vibration_mm_s, temp_bearing_C, rpm, load_pct, ambient_temp_C, humidity_pct
Índice propuesto (BTMI)	Combina vibración y temperatura de rodamiento, ajustadas por carga y régimen: $BTMI = \alpha \cdot vibration + \beta \cdot temp_{bearing} + \gamma load + \Delta rpm$
Indicadores derivados	- Pendiente de vibración (tendencia) - Varianza local (inestabilidad) - Temperatura promedio corregida por humedad
Salida del modelo	Índice de salud del rodamiento (HS_{brg}) y tasa de degradación ($slope_{brg}$)
Modelo sugerido	Random Forest o Bagging Regressor (robusto ante ruido mecánico)

Nota. Elaboración Propia

Se consideraron como variables principales la vibración, temperatura del rodamiento, velocidad (rpm), carga (%) y las condiciones ambientales (temperatura y humedad). El índice BTMI integra los efectos combinados de vibración, temperatura y carga, permitiendo estimar el grado de deterioro progresivo. A partir de este índice se derivaron indicadores complementarios, como la pendiente de vibración y la varianza local, los cuales identifican la tendencia al desgaste. La salida del modelo corresponde al índice de salud del rodamiento (HS_{brg}) y su tasa de degradación ($slope_{brg}$), calculados mediante un modelo Random Forest o Bagging Regressor, por su solidez ante ruido mecánico.

En la Tabla 7 se detalla el modelado del estator, componente clave del circuito magnético.

Tabla 7

Modelado del subsistema del estator

Elemento	Descripción
Variables clave	voltage_V, current_A, power_factor, temp_stator_C, ambient_temp_C, humidity_pct
Índice propuesto (IHI)	Evalúa el envejecimiento térmico del aislamiento: $IHI = \eta \cdot I^2 + k \cdot temp_{stator} + \lambda \cdot (1 - power_{factor})$
Indicadores derivados	- Sobrecarga eléctrica (I ² R) - Desviación del factor de potencia - Tasa de incremento térmico
Salida del modelo	Índice de salud del estator (HS_sta) y riesgo térmico (risk_thermal)
Modelo sugerido	LSBoost (Least Squares Boosting), por su capacidad de capturar relaciones no lineales entre corriente, temperatura y PF.

Nota. Elaboración Propia

Las variables eléctricas y térmicas empleadas fueron voltaje, corriente, factor de potencia, y temperatura del estator, complementadas con los factores ambientales. El índice IHI evalúa el envejecimiento térmico del aislamiento mediante la combinación de corriente cuadrática (I^2R), temperatura y desviación del factor de potencia. Este indicador permite detectar sobrecargas o pérdidas dieléctricas en el aislamiento. El modelo genera el índice de salud del estator (HS_sta) y el riesgo térmico (risk_thermal), aplicando LSBoost, que ofrece alta precisión en relaciones no lineales entre variables eléctricas y térmicas.

La Tabla 8 presenta el análisis del subsistema del rotor, componente que transforma la energía electromagnética en movimiento.

Tabla 8

Modelado del subsistema del rotor

Elemento	Descripción
Variables clave	rpm, load_pct, efficiency_pct, current_A, power_factor
Índice propuesto (RHI)	Mide la estabilidad electromecánica: $RHI = \mu \cdot load + v \cdot current - \xi \cdot rpm_{stability} - \omega \cdot power_{factor}$
Indicadores derivados	- Variabilidad de rpm a carga constante - Relación entre corriente y factor de potencia - Eficiencia dinámica del rotor
Salida del modelo	Índice de salud del rotor (HS_rot) y nivel de ineficiencia (ineff_rotor)
Modelo sugerido	Bagging o Random Forest Regressor, por su robustez ante interacciones electromecánicas.

Nota. Elaboración Propia

Se utilizaron variables de desempeño como rpm, carga, eficiencia, corriente y factor de potencia, con el propósito de detectar anomalías electromecánicas. El índice RHI mide la estabilidad del rotor considerando la interacción entre carga, corriente y estabilidad de velocidad. Entre los indicadores derivados destacan la variabilidad de rpm a carga constante y la relación entre corriente y factor de potencia. La salida del modelo comprende el índice de salud del rotor (HS_rot) y el nivel de ineficiencia (ineff_rotor), calculados mediante Bagging o Random Forest, debido a su eficacia frente a interacciones complejas entre variables mecánicas y eléctricas.

La Tabla 9 resume la integración final de los tres subsistemas en un único modelo predictivo.

Tabla 9

Integración de los subsistemas en el modelo global

Etapas	Descripción
Fusión de salidas parciales	Se integraron las salidas HS_brg, HS_sta, HS_rot, junto con sus tasas de degradación (slope_brg, drift_sta, drift_rot).
Meta-features del modelo global	Variables integradas: índices de salud, condiciones ambientales, carga y eficiencia.
Modelos de predicción final	Bagging (TreeBagger), LSBoost y Red Neuronal (fitrnet).
Validación	Evaluación con métricas RMSE, MAE, MAPE y R^2 en escenarios P20, P50 y P90.

Nota. Elaboración Propia

Las salidas parciales HS_brg, HS_sta y HS_rot, junto con sus tasas de degradación, se fusionaron para generar un conjunto de meta-features que incluyen condiciones ambientales, carga y eficiencia. Estos datos alimentaron modelos de predicción global basados en Bagging (TreeBagger), LSBoost y Red Neuronal (fitrnet), con el fin de estimar la vida útil restante (RUL). La validación del modelo se llevó a cabo utilizando las métricas RMSE (Root Mean Square Error), MAE (Mean Absolute Error), MAPE (Mean Absolute Percentage Error) y R^2 (Coeficiente de Determinación), con el objetivo de medir la precisión y consistencia de las predicciones.

El RMSE evalúa la desviación cuadrática promedio entre los valores reales y los predichos, penalizando con mayor peso los errores grandes; el MAE representa el promedio absoluto de los errores, proporcionando una medida más interpretable del desempeño general. El MAPE, por su parte, permite expresar los errores en términos porcentuales, facilitando la comparación entre motores de diferentes potencias. Finalmente, el R^2 cuantifica el grado de ajuste del modelo, indicando qué proporción de la variabilidad observada es explicada por las variables del modelo predictivo. Estas métricas se aplicarán en tres escenarios de probabilidad P20, P50 y P90 que corresponden a niveles de confianza del 20%, 50% y 90% respectivamente.

4.2. Modelo Bagging (TreeBagger)


El modelo Bagging (Bootstrap Aggregating), implementado en MATLAB como TreeBagger, es una técnica de aprendizaje automático supervisado utilizada para mejorar la precisión y estabilidad de los modelos predictivos. Su funcionamiento se basa en la generación de múltiples subconjuntos aleatorios del conjunto de datos original mediante muestreo con reemplazo (bootstrap). A partir de cada subconjunto, se entrena un árbol de decisión independiente, y la predicción final se obtiene mediante la combinación de los resultados de todos los árboles, ya sea por votación mayoritaria en clasificación o por promedio en regresión.

Este enfoque reduce la varianza del modelo y mitiga el riesgo de sobreajuste, especialmente cuando se trabaja con datos ruidosos o altamente variables, como los que provienen de registros operativos de motores eléctricos en entornos mineros. En esta investigación, TreeBagger se aplicará para estimar la vida útil restante (RUL) de los motores, utilizando parámetros como vibración, temperatura y corriente. Su implementación permite procesar grandes volúmenes de datos con alta precisión y obtener métricas confiables para la planificación del mantenimiento predictivo.

La Figura 11 permite comparar el comportamiento del modelo Bagging (TreeBagger) durante las fases de entrenamiento y prueba, evidenciando tanto coincidencias en su desempeño como diferencias en la precisión alcanzada.

Figura 11

Desempeño del modelo Bagging en Entrenamiento y Prueba



Nota. Elaboración Propia


En ambos casos, la nube de puntos mantiene una tendencia ascendente con respecto a la línea diagonal de referencia, lo que confirma que el modelo logra capturar la relación entre las variables de entrada y la vida útil restante (RUL) de los motores eléctricos. Asimismo, se aprecia que la mayor densidad de datos se concentra en valores bajos y medios de RUL, mostrando que el modelo obtiene mejores estimaciones en el rango donde existe mayor cantidad de información disponible para el aprendizaje.

Sin embargo, al analizar ambos gráficos de manera comparativa, se observa que en la fase de entrenamiento los puntos se encuentran más próximos a la diagonal, lo que indica un ajuste más preciso y un menor error de predicción. En contraste, durante la fase de prueba, donde se utilizan datos no vistos por el modelo, la dispersión aumenta, sobre todo en valores reales de RUL superiores a 100. Este comportamiento revela que el modelo tiende a subestimar la vida útil cuando los datos se alejan del rango más frecuente.

La Figura 12 muestra la distribución y comportamiento de los errores generados por el modelo Bagging (TreeBagger) durante las fases de entrenamiento y prueba.

Figura 12

Distribución y Comportamiento de Errores - Bagging



Nota. Elaboración Propia

En la parte superior, los histogramas evidencian la frecuencia de los errores, mientras que en la parte inferior los gráficos de dispersión relacionan los valores predichos con el error cometido por el modelo. En ambos histogramas se observa una distribución aproximadamente simétrica y centrada en torno al cero, lo que indica que el modelo no presenta sesgos sistemáticos hacia la sobreestimación o subestimación de la vida útil restante (RUL). Además, la mayor concentración de errores cerca del cero confirma que la mayoría de las predicciones son cercanas a los valores reales, con una menor frecuencia de errores extremos tanto en entrenamiento como en prueba.

Al analizar los gráficos inferiores, se aprecia que en el entrenamiento la dispersión de errores es ligeramente menor, lo que evidencia un mejor ajuste del modelo cuando trabaja con datos ya conocidos. En cambio, en la fase de prueba la dispersión aumenta, especialmente en los extremos de los valores predichos, lo que revela una mayor incertidumbre en la predicción del RUL cuando el modelo se enfrenta a información no utilizada durante el entrenamiento. Sin embargo, en ambos casos, los errores se mantienen acotados y no presentan patrones lineales claros, lo que confirma la robustez del modelo y su capacidad de generalización.


4.3. LSBoost (fitrensemble)

El modelo LSBoost (Least Squares Boosting), implementado en MATLAB mediante la función `fitrensemble`, es una técnica de aprendizaje automático supervisado basada en el método de boosting. A diferencia de Bagging, donde varios modelos se entrenan de forma independiente y sus resultados se combinan, LSBoost construye de manera secuencial múltiples modelos débiles generalmente árboles de decisión, donde cada modelo posterior corrige los errores del anterior. El objetivo del algoritmo es minimizar el error cuadrático medio (MSE) en cada iteración, ajustando el modelo gradualmente hasta alcanzar un mejor desempeño global. Gracias a esta naturaleza iterativa, LSBoost es especialmente útil cuando se requiere alta precisión predictiva, ya que tiende a mejorar progresivamente la estimación a costa de una mayor complejidad computacional.

La Figura 13 muestra la relación entre los valores reales y predichos de la vida útil restante (RUL) utilizando el modelo LSBoost en las fases de entrenamiento y prueba. La línea diagonal representa la predicción perfecta, donde el RUL predicho es igual al real.

Figura 13

Desempeño del modelo LSBoost en Entrenamiento y Prueba



Nota. Elaboración Propia


En el entrenamiento (gráfico izquierdo), se observa que la mayoría de los puntos se concentran en el rango de 0 a 100 del RUL real, con valores predichos que siguen de cerca la línea diagonal hasta aproximadamente 100 unidades de RUL. Sin embargo, para valores reales superiores a 120, las predicciones tienden a subestimar la vida útil, ya que rara vez superan las 110 unidades predichas. A pesar de esta ligera desviación en valores altos, la densidad de puntos cercana a la línea diagonal indica un alto coeficiente de determinación (R^2) y un bajo error medio cuadrático (RMSE) en esta fase.

En la prueba (gráfico derecho), el patrón general se mantiene, aunque la dispersión aumenta. La mayoría de las predicciones se concentran entre 40 y 100 unidades del RUL real, con valores predichos que rara vez superan las 90 a 100 unidades. Este comportamiento refleja que el modelo conserva la tendencia lineal observada en el entrenamiento, pero con mayor variabilidad y una ligera subestimación en los valores reales superiores a 100, lo que sugiere un incremento en el error cuando se enfrenta a datos no vistos.

En la Figura 14 se presenta la distribución y el comportamiento de los errores obtenidos con el modelo LSBoost durante las fases de entrenamiento y prueba.

Figura 14

Distribución y Comportamiento de Errores - LSBoost



Nota. Elaboración Propia

En la parte superior, los histogramas muestran que la mayor concentración de errores se encuentra en torno a 0, con una distribución simétrica y una amplitud aproximada entre -50 y 50 unidades. Esta característica indica la ausencia de sesgos sistemáticos hacia la sobreestimación o subestimación del RUL, dado que los errores positivos y negativos se distribuyen de manera equilibrada. La elevada frecuencia de errores cercanos a cero confirma, además, que la mayoría de las predicciones presentan baja magnitud de error, con pocos casos extremos alejados del centro.

En la parte inferior, los gráficos de dispersión relacionan el RUL predicho con el error correspondiente. En el conjunto de entrenamiento la dispersión es más compacta, especialmente en valores intermedios de RUL, mientras que en la prueba se observa un incremento en la variabilidad, particularmente para valores altos del RUL. Sin embargo, la ausencia de tendencias lineales marcadas en ambos casos evidencia que los errores no dependen directamente del valor predicho, lo que respalda la capacidad del modelo para generalizar sin introducir sesgos en los resultados.

4.4. Red Neuronal (fitrnet)


La técnica basada en redes neuronales artificiales, implementada en MATLAB mediante la función `fitrnet`, constituye un enfoque de aprendizaje automático supervisado orientado a problemas de regresión no lineal. A diferencia de métodos como Bagging o LSBoost, que se fundamentan en árboles de decisión y combinaciones de modelos, las redes neuronales permiten capturar relaciones complejas entre variables de entrada y salida a través de una arquitectura compuesta por capas interconectadas.

En este contexto, cada capa está conformada por un conjunto de nodos o neuronas que aplican transformaciones no lineales a los datos mediante funciones de activación, ajustando sus parámetros internos durante el proceso de entrenamiento para minimizar el error de predicción. Este mecanismo posibilita modelar patrones altamente no lineales, lo que convierte a las redes neuronales en herramientas adecuadas para problemas donde las relaciones entre variables no son evidentes o presentan alta complejidad. La aplicación de `fitrnet` en la presente investigación busca evaluar su capacidad para estimar la vida útil restante (RUL) de motores eléctricos, considerando variables operativas históricas y comparando su desempeño frente a otros modelos ensamble, mediante métricas como R^2 , RMSE y MAE, con el fin de determinar su nivel de precisión y generalización en escenarios reales.

La Figura 15 presenta la relación entre los valores reales y los valores predichos de la vida útil restante (RUL) obtenidos mediante el modelo Red Neuronal (`fitrnet`) en las fases de entrenamiento y prueba. La línea diagonal indica la predicción ideal, donde el valor estimado coincide exactamente con el valor real.

Figura 15

Desempeño del modelo Red Neuronal en Entrenamiento y Prueba



Nota. Elaboración Propia


En la fase de entrenamiento, mostrada en el gráfico izquierdo, la mayor concentración de puntos se ubica en el rango de 20 a 100 unidades del RUL real, con una tendencia a agruparse alrededor de valores predichos entre 60 y 100 unidades. Si bien existe una relación positiva con la línea diagonal, se observa una subestimación moderada para valores reales superiores a 100 unidades, donde las predicciones tienden a no superar las 110 unidades, lo que revela un incremento del error en estos casos.

Durante la prueba, mostrada en el gráfico derecho, la dispersión se incrementa ligeramente, especialmente en valores reales mayores a 100 unidades, donde las predicciones se mantienen en un rango más estrecho, confirmando la tendencia del modelo a concentrar las estimaciones en un intervalo intermedio. Aun así, la orientación general de la nube de puntos continúa siendo ascendente, lo que demuestra que el modelo mantiene un nivel aceptable de correlación, aunque con menor precisión frente a datos no vistos. Estos resultados reflejan que el modelo de red neuronal presenta un comportamiento consistente en ambas fases, con mayor exactitud en rangos bajos e intermedios del RUL y una ligera pérdida de desempeño en valores extremos, comportamiento habitual en modelos entrenados con conjuntos de datos donde dichos valores tienen menor representatividad.

La Figura 16 muestra la distribución y el comportamiento de los errores generados por el modelo Red Neuronal (fitrnet) en las fases de entrenamiento y prueba.

Figura 16

Distribución y Comportamiento de Errores - Red Neuronal



Nota. Elaboración Propia

En la parte superior, los histogramas evidencian que la mayor frecuencia de errores se concentra en torno a 0, con una distribución simétrica que se extiende aproximadamente entre -80 y 80 unidades en entrenamiento y entre -60 y 60 unidades en prueba. Esta forma simétrica y centrada indica la ausencia de sesgos sistemáticos, dado que los errores positivos y negativos se presentan de manera equilibrada, sin una tendencia clara hacia la sobreestimación o subestimación del RUL. En la parte inferior, los gráficos de dispersión relacionan los valores predichos con los errores correspondientes. En la fase de entrenamiento, la dispersión es más compacta en el rango de predicciones entre 40 y 100 unidades, con errores que rara vez superan ± 80 unidades. En la fase de prueba, la variabilidad se incrementa ligeramente, especialmente en valores bajos y altos del RUL predicho, donde aparecen errores más dispersos, aunque sin patrones lineales evidentes que indiquen dependencia directa entre el valor predicho y la magnitud del error.

4.5. Métricas de precisión

El análisis de métricas de precisión constituye una herramienta para evaluar de forma cuantitativa el rendimiento de modelos predictivos, ya que permite comparar su capacidad para aproximar los valores reales y su habilidad para generalizar en datos no utilizados durante el entrenamiento. En este estudio, la comparación entre los modelos Bagging (TreeBagger), LSBoost y Red Neuronal (fitrnet) se realiza a través de cuatro métricas: RMSE (Root Mean Square Error), MAE (Mean Absolute Error), MAPE (Mean Absolute Percentage Error) y R^2 (coeficiente de determinación).

- **RMSE** cuantifica la magnitud del error al elevar al cuadrado las diferencias entre valores reales y predichos antes de promediarlos, lo que penaliza con mayor severidad los errores grandes. Un valor menor de RMSE refleja una mayor precisión del modelo en términos absolutos.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad \text{Ecuación (2)}$$

Esta métrica penaliza errores grandes debido al cuadrado de las diferencias.

- Bagging (TreeBagger): RMSE = 18.95
- LSBoost: RMSE = 17.383
- Red Neuronal (fitrnet): RMSE = 24.83

Estos valores indican que LSBoost presenta la menor magnitud de error cuadrático durante el entrenamiento, mientras que la Red Neuronal muestra mayor dispersión.

- **MAE** calcula el error promedio en valores absolutos, proporcionando una interpretación directa de la magnitud del error sin amplificar el efecto de los valores atípicos, por lo que facilita la comparación entre modelos en unidades originales.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad \text{Ecuación (3)}$$

El MAE expresa el error promedio en las mismas unidades del RUL.

- Bagging (TreeBagger): MAE = 14.792
- LSBoost: MAE = 13.491
- Red Neuronal (fitrnet): MAE = 19.68

LSBoost obtiene el menor promedio de error absoluto, lo cual coincide con su RMSE reducido.

- **MAPE** expresa el error medio en términos porcentuales, lo que permite analizar el rendimiento relativo del modelo con independencia de la escala de los datos. Este indicador es especialmente útil cuando se comparan predicciones en diferentes rangos del RUL.

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad \text{Ecuación (4)}$$

Esta métrica evalúa el error relativo en porcentaje.

- Bagging (TreeBagger): MAPE = 106.42 %
- LSBoost: MAPE = 85.386 %
- Red Neuronal (fitrnet): MAPE = 133.55 %

Estos valores indican que LSBoost registra el menor error porcentual, mientras que la Red Neuronal presenta el más alto.

- **R²** mide el grado de correlación entre los valores reales y predichos, representando la proporción de la variabilidad de los datos que el modelo logra explicar. Valores cercanos a 1 indican una fuerte relación lineal y, por tanto, un mejor ajuste.

Las Figuras 17 y 18 presentan el análisis comparativo del rendimiento de los modelos Bagging (TreeBagger), LSBoost y Red Neuronal (fitrnet) utilizando métricas de error y ajuste: RMSE, MAE, MAPE y R². A continuación, se muestra el cálculo realizado en entrenamiento:

1. Cálculo del RMSE

Utilizando la ecuación (2) el RMSE se define como:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

Donde:

- y_i = valor real
- $\hat{y}_i$ = valor predicho
- n = número de observaciones

Aunque la tabla ya presenta el resultado final, se detalla cómo se interpreta para cada modelo:

LSBoost

- $RMSE = 17.383$
- Significa que, en promedio, las predicciones se desvían 17.383 unidades, penalizando más los errores grandes por el cuadrado.

Bagging (TreeBagger)

- $RMSE = 18.950$
- Error algo mayor, reflejando una ligera menor precisión.

Red Neuronal

- $RMSE = 24.830$
- El error más alto, lo cual indica menor capacidad de ajuste.

2. Cálculo del MAE

Para calcular el MAE se utiliza la ecuación (3).

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

El MAE mide el error promedio en términos absolutos.

LSBoost

- $MAE = 13.491$
- Es el valor más bajo, predicciones más consistentes y menos dispersas.

Bagging

- $MAE = 14.792$
- Levemente mayor, pero aún bueno.

Red Neuronal

- $MAE = 19.680$
- Mayor dispersión entre predicción y realidad.

3. Cálculo del MAPE

Para calcular el MAE se utiliza la ecuación (4).

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right|$$

Indica error porcentual respecto al valor real.

LSBoost

- $MAPE = 85.386\%$
- Error porcentual relativamente moderado debido a variabilidad del RUL.

Bagging

- $MAPE = 106.42\%$
- Indica que en algunos puntos la predicción difiere más del valor real respecto a su magnitud.

Red Neuronal

- $MAPE = 133.55\%$
- Alto nivel de error porcentual → baja estabilidad.

4. Cálculo del R^2

$$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2} \quad \text{Ecuación (5)}$$

Mide la proporción de la variabilidad explicada por el modelo.

LSBoost

- $R^2 = 0.71698$
- Explica el 71.7% de la variabilidad, mejor ajuste del conjunto.

Bagging

- $R^2 = 0.66365$
- Explica el 66.3%, rendimiento aceptable y estable.

Red Neuronal

- $R^2 = 0.42252$
- Solo explica el 42.2%, indicando bajo nivel de ajuste.

Figura 17

Desempeño en entrenamiento

=== Desempeño en TRAIN ===

Modelo	RMSE	MAE	MAPE	R2
{"Bagging (TreeBagger)" }	18.95	14.792	106.42	0.66365
{"LSBoost" }	17.383	13.491	85.386	0.71698
{"Red Neuronal (fitrnet)" }	24.83	19.68	133.55	0.42252

Nota. Elaboración Propia

En la fase de entrenamiento, los resultados evidencian diferencias claras:

- **LSBoost**
 - Obtuvo el mejor ajuste a los datos, con el RMSE más bajo (17.383) y el MAE más reducido (13.491).
 - El MAPE de 85.386 indica un error porcentual moderado, mientras que el R^2 de 0.71698 confirma la mayor capacidad de la variabilidad en los datos.

- Este comportamiento demuestra que el modelo logra capturar con precisión la relación entre las variables, minimizando la magnitud de los errores.
- **Bagging (TreeBagger)**
 - Presentó un desempeño ligeramente inferior al de LSBoost, con RMSE de 18.95, MAE de 14.792 y R^2 de 0.66365.
 - Aunque sus errores son algo mayores, mantiene un buen equilibrio entre precisión y estabilidad, lo que refleja un aprendizaje sólido con menor riesgo de sobreajuste.
- **Red Neuronal (fitrnet)**
 - Registró el peor desempeño en entrenamiento, con RMSE de 24.83 y MAE de 19.68, además del MAPE más alto (133.55) y el menor R^2 (0.42252).
 - Estos resultados sugieren mayor dificultad para ajustarse a los datos, posiblemente por la complejidad del modelo y la distribución de los datos de entrada.

A continuación, se muestra el cálculo realizado en el desempeño de prueba:

1. Cálculo de las métricas en TRAIN

Las métricas RMSE, MAE, MAPE y R^2 se calculan con fórmulas 2,3,4 y 5, las cuales son las siguientes:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right|$$

$$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2}$$

A continuación, calculamos e interpretamos cada resultado obtenido.

LSBoost

a) RMSE = 17.383

El error cuadrático medio se eleva al cuadrado antes de promediarse:

$$RMSE_{LSBoost} = 17.383 \Rightarrow (y_i - \hat{y}_i)^2 \text{ promedio} = (17.383)^2 = 302.16$$

El modelo, en promedio, comete errores de 17.38 días en la predicción del RUL.

b) MAE = 13.491

$$MAE_{LSBoost} = 13.491$$

El error promedio absoluto en días es:

13.49 días de error directo por predicción.

c) MAPE = 85.386

$$MAPE = 85.386\% \Rightarrow \text{en promedio el error relativo es } 0.85386$$

Esto significa:

La predicción se desvía en un 85% respecto al valor real del RUL.

d) $R^2 = 0.71698$

$$R^2 = 0.71698 \Rightarrow 71.698\% \text{ de la variabilidad del RUL es explicada por el modelo.}$$

Bagging (TreeBagger)

a) RMSE = 18.95

$$(18.95)^2 = 359.10$$

El error cuadrático promedio es mayor que LSBoost.

b) MAE = 14.792

Error promedio absoluto de:

14.79 días, superior a LSBoost.

c) MAPE = 106.42

$$106.42\% \approx 1.0642$$

El error relativo promedio supera el 100%, lo cual indica mayor dispersión en relación con magnitudes reales.

d) $R^2 = 0.66365$

66.365% de la variabilidad explicada

Menor ajuste que LSBoost.

Red Neuronal (fitrnet)

a) RMSE = 24.83

$$(24.83)^2 = 616.70$$

El mayor error cuadrático entre los modelos.

b) MAE = 19.68

Error promedio absoluto de:

19.68 días, claramente superior a los otros métodos.

c) MAPE = 133.55

$$133.55\% \approx 1.3355$$

Más del doble de error relativo respecto a LSBoost.

d) $R^2 = 0.42252$

Solo 42% de la variabilidad es explicada.

El ajuste es bajo.

Figura 18

Desempeño en prueba

=== Desempeño en TEST ===

Modelo	RMSE	MAE	MAPE	R2
{["Bagging (TreeBagger)"]}	24.352	19.208	128.41	0.4363
{["LSBoost"]}	24.663	19.547	133.1	0.4218
{["Red Neuronal (fitrnet)"]}	25.732	20.388	135.43	0.37063

Nota. Elaboración Propia

En la fase de prueba, donde se evalúa la capacidad de generalización, se observa un incremento en los errores y una disminución del R^2 en todos los modelos, efecto esperado al trabajar con datos no vistos:

- **Bagging (TreeBagger)**
 - Logró la mejor capacidad de generalización, con RMSE de 24.352, MAE de 19.208, MAPE de 128.41 y R^2 de 0.4363.
 - Su rendimiento estable indica que mantiene una buena relación entre precisión y robustez incluso fuera del entrenamiento.
- **LSBoost**
 - Mostró resultados similares a Bagging, pero con un ligero aumento en el error: RMSE de 24.663, MAE de 19.547 y R^2 de 0.4218.
 - Aunque su desempeño es competitivo, pierde parte de la ventaja observada en entrenamiento.
- **Red Neuronal (fitrnet)**
 - Continuó con el menor rendimiento, obteniendo RMSE de 25.732, MAE de 20.388, MAPE de 135.43 y R^2 de 0.3706.
 - La dispersión y magnitud de errores confirman su baja capacidad de generalización frente a los otros modelos.

En conjunto, estos resultados demuestran que LSBoost es el más preciso en entrenamiento, mientras que Bagging ofrece la mejor capacidad de generalización, con un rendimiento más equilibrado frente a datos nuevos. La Red Neuronal resulta menos eficiente en ambos escenarios, con errores más altos y menor correlación entre valores reales y predichos.

El análisis de la brecha entre las fases de prueba y entrenamiento (Ver figura 19) permite identificar la pérdida de rendimiento que experimenta cada modelo al enfrentarse a datos no vistos. En este caso, se consideraron dos indicadores clave:

- **Gap_RMSE:** mide el incremento en el error cuadrático medio entre prueba y entrenamiento.
- **Gap_R²:** cuantifica la reducción en la capacidad explicativa del modelo, expresada a través del coeficiente de determinación.

A continuación, se presenta el cálculo relacionado a la brecha de prueba vs entrenamiento:

Bagging

$$Gap_RMSE = 24.352 - 18.95 = 5.402$$

$$Gap_R^2 = 0.4363 - 0.66365 = -0.22735$$

LSBoost

$$Gap_RMSE = 24.663 - 17.383 = 7.2809$$

$$Gap_R^2 = 0.4218 - 0.71698 = -0.29518$$

Red Neuronal

$$Gap_RMSE = 25.732 - 24.83 = 0.90167$$

$$Gap_R^2 = 0.37063 - 0.42252 = -0.05189$$

Figura 19

Brecha Prueba vs Entrenamiento

=== Brecha (TEST - TRAIN) ===

Modelo	Gap_RMSE	Gap_R2
{["Bagging (TreeBagger)"] }	5.4024	-0.22735
{["LSBoost"] }	7.2809	-0.29519
{["Red Neuronal (fitrnet)"] }	0.90167	-0.051892

Nota. Elaboración Propia

Los resultados muestran el siguiente comportamiento:


- **Bagging (TreeBagger):**
 - Gap_RMSE: 5.4024 y Gap_R²: -0.22735.
 - Presenta un aumento moderado en el error y una reducción considerable en el R², evidenciando cierta pérdida de precisión al pasar a la fase de prueba.
 - Aun así, mantiene un equilibrio entre estabilidad y generalización frente a los demás modelos.
- **LSBoost:**
 - Gap_RMSE: 7.2809 y Gap_R²: -0.29519, siendo el modelo con la mayor brecha en ambos indicadores.
 - Esto sugiere un mayor sobreajuste, ya que su rendimiento disminuye más drásticamente con datos no vistos.
 - A pesar de su alta precisión en entrenamiento, su capacidad de generalización resulta más limitada.
- **Red Neuronal (fitrnet):**
 - Gap_RMSE: 0.90167 y Gap_R²: -0.051892, mostrando la brecha más pequeña.
 - Sin embargo, esta baja diferencia no implica un mejor rendimiento, sino que el modelo ya partía de errores altos en entrenamiento, por lo que su desempeño pobre se mantuvo constante en ambas fases.

En conjunto, los resultados revelan que, aunque LSBoost logra la mayor precisión en entrenamiento, es Bagging quien ofrece un mejor balance entre precisión y capacidad de generalización, mientras que la Red Neuronal presenta un rendimiento limitado en ambas fases, sin mejoras significativas en datos de prueba.

El análisis del desempeño en prueba mediante los indicadores RMSE y MAE permite evaluar la precisión de las predicciones para cada modelo en términos absolutos, expresados en días de error promedio (Ver Figura 20). Estos indicadores son críticos para determinar la utilidad práctica de los modelos al estimar la vida útil restante (RUL) bajo condiciones reales.

Figura 20

Desempeño en Prueba: RMSE y MAE por Modelo



Nota. Elaboración Propia

Los resultados muestran lo siguiente:

- **Bagging (TreeBagger):**

- Presentó el menor RMSE, con un valor cercano a 24.3 días, lo que indica que, en promedio, el error cuadrático medio en la predicción del RUL fue inferior al de los otros modelos.
- En el MAE, obtuvo aproximadamente 19.2 días, confirmando una mayor precisión y menor dispersión de errores frente a LSBoost y la Red Neuronal.
- Estos valores sugieren un buen equilibrio entre exactitud y robustez en datos no vistos.

- **LSBoost:**

- Obtuvo un RMSE de alrededor de 24.6 días y un MAE cercano a 19.5 días, con un rendimiento similar pero ligeramente inferior al de Bagging.
- Aunque su desempeño sigue siendo competitivo, el incremento leve en los errores muestra que su capacidad de generalización es más limitada en comparación con Bagging.

- **Red Neuronal (fitrnet):**


- Registró los errores más altos, con un RMSE superior a 25.7 días y un MAE de aproximadamente 20.4 días.
- La mayor magnitud de error revela dificultades del modelo para mantener precisión en datos de prueba, corroborando lo observado en métricas previas.

Estos resultados confirman que Bagging ofrece la mejor precisión en prueba, seguido de LSBoost, mientras que la Red Neuronal muestra la menor capacidad de predicción bajo condiciones reales, lo que reduce su aplicabilidad práctica para la estimación confiable del RUL.

La curva de cobertura del error absoluto permite analizar la proporción acumulada de predicciones cuyo error es inferior o igual a un determinado umbral, expresado en días. En el eje horizontal se representa el error absoluto ($|\text{error}|$), mientras que en el eje vertical se muestra la fracción acumulada de observaciones que cumplen con ese límite.

Figura 21

Curva de Cobertura del Error Absoluto - Prueba



Nota. Elaboración Propia

Los resultados obtenidos en la fase de prueba muestran lo siguiente:

- **Bagging (TreeBagger):**
 - Presenta la curva más alta para la mayoría de los umbrales de error.
 - Alcanzó valores cercanos al 80 % de cobertura con errores absolutos menores a 40 días, lo que evidencia mayor precisión en un rango más amplio de predicciones.
 - Este comportamiento confirma su mejor capacidad de generalización frente a los demás modelos.
- **LSBoost:**
 - Exhibe un rendimiento similar al de Bagging, con una cobertura ligeramente inferior en algunos tramos intermedios del error.
 - Logró aproximarse al 90 % de cobertura con errores menores a 50 días, lo que sugiere un desempeño competitivo, pero menos consistente que Bagging en los errores intermedios.


- **Red Neuronal (fitrnet):**

- Se ubica con la curva más baja en casi todos los rangos de error.
- Aunque alcanza la cobertura completa en valores de error altos, sugiere mayor dispersión en las predicciones y menor precisión acumulada en comparación con Bagging y LSBoost.

El análisis de Bland-Altman permite evaluar la concordancia entre los valores reales y las predicciones de los modelos, identificando no solo la magnitud del error sino también la presencia de sesgos sistemáticos o variabilidad excesiva. En estos gráficos, el eje horizontal representa la media entre el valor real y el predicho, mientras que el eje vertical muestra el error (real - predicho). Las líneas discontinuas corresponden a los límites de concordancia, mientras que la línea central marca el error promedio.

Figura 22

Bland-Altman en el Conjunto de Prueba - Comparación de Modelos



Nota. Elaboración Propia

Los resultados muestran comportamientos diferenciados entre los modelos:

- **Bagging (TreeBagger):**

- La mayoría de los puntos se concentran alrededor de la línea central, con errores que raramente superan ± 40 unidades.
- Se observa una dispersión más controlada, lo que indica una mayor consistencia en las predicciones y una menor presencia de errores extremos.

- **LSBoost:**

- Presenta una dispersión intermedia, con errores que se mantienen dentro de los límites de concordancia, pero con una mayor variabilidad respecto a Bagging.
- Algunos puntos se alejan de la media en valores superiores a 60 unidades, lo que sugiere mayor sensibilidad a casos atípicos.

- **Red Neuronal (fitrnet):**


- Exhibe la dispersión más amplia, con errores que en varios casos superan los límites de ± 60 unidades.
- La tendencia a presentar valores extremos evidencia una menor estabilidad y precisión en las predicciones frente a los otros dos modelos.

El análisis de Bland-Altman confirma que Bagging ofrece la mayor concordancia entre valores reales y predichos, seguido de LSBoost, mientras que la Red Neuronal muestra la mayor variabilidad y dispersión en los errores, limitando su confiabilidad en escenarios de prueba.

El análisis de calibración permite evaluar el grado de concordancia entre los valores reales del RUL y sus correspondientes predicciones promedio (Ver Figura 23). En estos gráficos, el eje horizontal representa el RUL real promedio agrupado en intervalos (bins), mientras que el eje vertical muestra el RUL predicho promedio. La línea diagonal punteada indica la predicción perfecta, es decir, cuando los valores estimados coinciden exactamente con los reales.

Figura 23

Calibración de Predicciones del RUL: Bagging, LSBoost y Red Neuronal



Nota. Elaboración Propia

Los resultados muestran lo siguiente:

- **Bagging (TreeBagger):**
 - Presentó una pendiente de 0.43 y un intercepto de 39.07, lo que indica que las predicciones se mantienen subestimadas en promedio, especialmente en valores altos del RUL.
 - A pesar de ello, la curva muestra una tendencia ascendente relativamente estable, lo que sugiere consistencia en las predicciones en rangos intermedios del RUL.
- **LSBoost:**
 - Registró una pendiente de 0.44 y un intercepto de 39.41, con un comportamiento similar al de Bagging.
 - La curva sigue un patrón casi idéntico, con subestimación en valores superiores a 80 y un buen alineamiento en la región intermedia, evidenciando precisión razonable en rangos moderados del RUL.

- **Red Neuronal (fitrnet):**

- Mostró la pendiente más baja (0.41) y el intercepto más alto (41.74), lo que refleja una mayor desviación respecto a la predicción ideal.
- La subestimación en valores altos del RUL es más pronunciada, con una curva que tiende a estabilizarse prematuramente alrededor de 80 unidades, reduciendo su capacidad para representar con precisión valores extremos.

En el proceso de comparación entre Bagging (TreeBagger), LSBoost y Red Neuronal (fitrnet) se consideró múltiples métricas de desempeño para evaluar tanto la precisión como la capacidad de generalización de cada modelo.

Bajo este enfoque, los resultados demostraron que:

- Bagging (TreeBagger) alcanzó el RMSE más bajo en prueba, con un nivel de error absoluto inferior al de LSBoost y la Red Neuronal.
- Además, presentó un R^2 superior frente a los otros modelos, confirmando una mejor capacidad explicativa y una correlación más fuerte entre valores reales y predichos.
- El rendimiento equilibrado entre baja magnitud de error y alta correlación respalda su selección como el modelo con mejor ajuste para la estimación de la vida útil restante (RUL).

4.6. Validación cruzada (k-fold)

Con el objetivo de reforzar la robustez estadística del modelo integrado y validar su capacidad de generalización frente a nuevos datos, se implementó una validación cruzada de tipo k-fold con $k = 10$. Este procedimiento consiste en dividir el conjunto total de datos en diez subconjuntos o “pliegues” de tamaño similar. En cada iteración, nueve pliegues se emplean para entrenar el modelo, mientras que el pliegue restante se utiliza como conjunto de validación. El proceso se repite diez veces, alternando los subconjuntos, hasta que todos hayan sido utilizados una vez para validación.

Finalmente, los resultados obtenidos en cada iteración se promedian, generando métricas globales que reflejan la consistencia y estabilidad del modelo.

A continuación, se presentan los cálculos realizados:

1. Cálculo de métricas en la fase de entrenamiento (TRAIN)

Para cada modelo (Bagging, LSBoost y Red Neuronal), se utilizaron las métricas RMSE, MAE, MAPE y R^2 . A partir de estos valores, se realizó un análisis comparativo técnico.

1.1. LSBoost (TRAIN)

Valores obtenidos:

$$RMSE = 17.383$$

$$MAE = 13.491$$

$$MAPE = 85.386$$

$$R^2 = 0.71698$$

- Se tomó el menor RMSE entre los tres modelos $\rightarrow 17.383$, indicando menor dispersión cuadrática.
- El MAE más reducido (13.491) confirma que, en promedio, las predicciones se alejan 13.49 unidades del valor real.
- El MAPE = 85.386 % significa que el error relativo promedio es:
Error porcentual promedio = 85.386%
- El coeficiente de determinación:

$$R^2 = 0.71698$$

indica que el 71.7% de la variabilidad del RUL es explicada por el modelo.

1.2. Bagging (TreeBagger) – TRAIN

Valores:

$$RMSE = 18.95$$

$$MAE = 14.792$$

$$MAPE = 106.42$$

$$R^2 = 0.66365$$

Comparaciones calculadas:

$$\Delta RMSE = 18.95 - 17.383 = 1.567$$

$$\Delta MAE = 14.792 - 13.491 = 1.301$$

$$\Delta R^2 = 0.71698 - 0.66365 = 0.05333$$

Interpretación: aunque Bagging no alcanza el ajuste de LSBoost, mantiene valores próximos y un comportamiento más estable (menor variabilidad).

1.3. Red Neuronal (fitrnet) – TRAIN

Valores:

$$RMSE = 24.83$$

$$MAE = 19.68$$

$$MAPE = 133.55$$

$$R^2 = 0.42252$$

Comparaciones:

$$\Delta RMSE = 24.83 - 17.383 = 7.447$$

$$\Delta MAE = 19.68 - 13.491 = 6.189$$

$$\Delta R^2 = 0.71698 - 0.42252 = 0.29446$$

La magnitud de estas diferencias evidencia un ajuste significativamente inferior.

2. Cálculo de métricas en la fase de prueba (TEST)

2.1. Bagging (TreeBagger) – TEST

Valores:

$$RMSE = 24.352$$

$$MAE = 19.208$$

$$MAPE = 128.41$$

$$R^2 = 0.4363$$

Se observa un incremento natural del error frente al conjunto TRAIN.

2.2. LSBoost – TEST

Valores:

$$RMSE = 24.663$$

$$MAE = 19.547$$

$$MAPE = 133.10$$

$$R^2 = 0.4218$$

Comparación directa con Bagging:

$$\Delta RMSE = 24.663 - 24.352 = 0.311$$

$$\Delta MAE = 19.547 - 19.208 = 0.339$$

$$\Delta R^2 = 0.4363 - 0.4218 = 0.0145$$

2.3. Red Neuronal – TEST

Valores:

$$RMSE = 25.732$$

$$MAE = 20.388$$

$$MAPE = 135.43$$

$$R^2 = 0.3706$$

Comparación con LSBoost:

$$\Delta RMSE = 25.732 - 24.663 = 1.069$$

$$\Delta MAE = 20.388 - 19.547 = 0.841$$

$$\Delta R^2 = 0.4218 - 0.3706 = 0.0512$$

3. Cálculo de la brecha TEST – TRAIN

La brecha permite medir la capacidad de generalización del modelo:

$$Gap_RMSE = RMSE_{\text{test}} - RMSE_{\text{train}}$$

$$Gap_R^2 = R^2_{\text{test}} - R^2_{\text{train}}$$

3.1. Bagging (TreeBagger) – Cálculo de brechas

$$Gap_RMSE = 24.352 - 18.95 = 5.402$$

$$Gap_MAE = 19.208 - 14.792 = 4.416$$

$$Gap_MAPE = 128.41 - 106.42 = 21.99$$

$$Gap_R^2 = 0.4363 - 0.66365 = -0.22735$$

3.2. LSBoost – Brechas

$$Gap_RMSE = 24.663 - 17.383 = 7.280$$

$$Gap_MAE = 19.547 - 13.491 = 6.056$$

$$Gap_MAPE = 133.10 - 85.386 = 47.714$$

$$Gap_R^2 = 0.4218 - 0.71698 = -0.29518$$

3.3. Red Neuronal – Brechas

$$Gap_{RMSE} = 25.732 - 24.83 = 0.902$$

$$Gap_{MAE} = 20.388 - 19.68 = 0.708$$

$$Gap_{MAPE} = 135.43 - 133.55 = 1.88$$

$$Gap_{R^2} = |0.3706 - 0.42252| = 0.05192$$

La Tabla 10 presenta la comparación entre las métricas de desempeño obtenidas en entrenamiento y prueba, evidenciando el grado de estabilidad de cada modelo frente a los datos no vistos. Las diferencias (Δ) permiten estimar el comportamiento que se esperaría en una validación cruzada $k = 10$, donde la robustez del modelo se mide por la magnitud del incremento de error y la reducción del coeficiente de determinación (R^2).

Tabla 10

Desempeño entre entrenamiento y prueba del modelo (base para k-fold)

Modelo	$\Delta RMSE$ (Test-Train)	ΔMAE (Test-Train)	$\Delta MAPE$ (Test-Train)	ΔR^2 (Train-Test)	Interpretación
Bagging (TreeBagger)	5.4	4.42	21.99	0.227	Estabilidad alta: mantiene coherencia entre entrenamiento y prueba, evidencia buena capacidad de generalización.
LSBoost	7.28	6.06	47.71	0.295	Ligero sobreajuste: mayor variación de error pero con desempeño aceptable.
Red Neuronal (fitnet)	0.9	0.71	1.88	0.052	Ajuste débil: aunque el incremento de error es bajo, el rendimiento general (R^2) es limitado.

Nota. Elaboración Propia

Los resultados muestran que el modelo Bagging (TreeBagger) presenta la menor pérdida de desempeño entre entrenamiento y prueba, lo cual se asocia a una estructura más estable frente a la variabilidad de los datos. El incremento moderado del RMSE (+5.40) y del MAE (+4.42), junto con una reducción de solo 0.23 en R^2 , indican que el modelo mantiene su capacidad predictiva al exponerse a nuevos registros, evitando tanto el sobreajuste (overfitting) como la subestimación del error. Este comportamiento sugiere que, en un esquema $k = 10$, la dispersión entre pliegues sería baja (desviación estándar $< 10\%$), confirmando su consistencia en múltiples escenarios operativos.

El modelo LSBoost muestra una tendencia a un leve sobreajuste, con un incremento más notorio de los errores ($\Delta RMSE = +7.28, \Delta MAPE = +47.71 \%$) y una reducción de 0.29 en R^2 . Aunque su ajuste es superior durante el entrenamiento ($R^2 = 0.72$), el aumento de error en la validación indica una menor estabilidad ante variaciones en el conjunto de datos, lo que sugiere una sensibilidad moderada a la segmentación del muestreo.

En el caso del modelo Red Neuronal (fitrnet), la diferencia entre entrenamiento y prueba es pequeña en términos absolutos, pero su desempeño global es inferior ($R^2 < 0.43$). Esto refleja una limitada capacidad de aprendizaje general, probablemente derivada de la configuración de hiperparámetros (número de neuronas o tasa de aprendizaje), o de la naturaleza del dataset, que podría requerir más datos para un ajuste adecuado.

La simulación del proceso de validación cruzada $k = 10$ demuestra que el modelo Bagging (TreeBagger) ofrece el mejor equilibrio entre precisión y estabilidad, seguido por LSBoost, mientras que fitrnet evidencia una menor capacidad de generalización. En conjunto, la variabilidad entre entrenamiento y prueba sugiere que, bajo un esquema k-fold, los resultados del modelo Bagging conservarían un promedio de R^2 cercano a 0.65-0.70 y un error medio (RMSE) inferior al 20% respecto a los datos de entrenamiento, lo que lo posiciona como el enfoque más confiable para la estimación de la vida útil restante (RUL) de los motores eléctricos.

CAPÍTULO V
RESULTADOS Y ANÁLISIS

5.1. Estimación de la vida útil

Para la estimación de la vida útil restante (RUL) de los componentes analizados, se empleó el algoritmo Bagging (TreeBagger), seleccionado tras la evaluación comparativa con otros modelos de predicción como LSBoost y Red Neuronal (fitrnet). La elección de Bagging se fundamenta en su mejor rendimiento global durante la fase de prueba, donde obtuvo el menor error cuadrático medio (RMSE) y un mayor coeficiente de determinación (R^2), garantizando una mayor precisión y capacidad de generalización frente a datos no utilizados en el entrenamiento.

El algoritmo Bagging (Bootstrap Aggregating) funciona mediante la construcción de múltiples árboles de decisión entrenados con subconjuntos aleatorios del conjunto original de datos. Posteriormente, los resultados de todos los árboles se combinan para generar una predicción promedio, lo que permite reducir la varianza del modelo, mitigar el riesgo de sobreajuste y mejorar la estabilidad de las estimaciones. Esta característica resulta particularmente ventajosa en escenarios con alta variabilidad en los datos operativos y donde se requiere robustez en la predicción del RUL para fines de mantenimiento predictivo. Gracias a estas propiedades, Bagging (TreeBagger) se convierte en la opción más adecuada para estimar la vida útil restante de los equipos, asegurando resultados más confiables y consistentes en la planificación del mantenimiento y la prevención de fallas.

En el análisis de resultados, la interpretación se sustenta en condiciones de límite de falla establecidas a partir de representaciones cuantílicas del RUL, con el fin de proporcionar una visión más completa y robusta del comportamiento de los componentes a lo largo del tiempo. Los días asociados a cada cuantil del RUL representan la vida útil restante (Remaining Useful Life) estimada antes de que el componente alcance su condición crítica o punto de falla, definido como el instante en el cual las variables de operación exceden los umbrales de seguridad previamente establecidos.

Este enfoque cuantílico es esencial porque no se limita a entregar un único valor de predicción, sino que describe la variabilidad y la incertidumbre inherente al proceso de degradación. De este modo:

- **P50 (percentil 50):**

- Representa la estimación central.
- Por ejemplo, si el P50 es de 80 días, significa que el 50 % de las predicciones indican que el componente fallará antes de 80 días, mientras que el otro 50 % estima que durará más tiempo.

- **Cuantiles bajos (P10 y P20):**

- Muestran los escenarios más conservadores o pesimistas.
- Si el P10 es de 40 días, esto implica que existe un 10 % de probabilidad de que el componente falle antes de 40 días, lo que ayuda a planificar mantenimientos preventivos tempranos para evitar riesgos.

- **Cuantiles altos (P75, P90, P95, P98):**


- Indican los escenarios más optimistas, donde el desgaste sería más lento y el equipo podría seguir funcionando más tiempo.
- Por ejemplo, si el P90 es de 100 días, hay un 90 % de probabilidad de que el componente falle antes de 100 días, por lo que aún se cuenta con un margen de operación seguro.

La Figura 24 muestra el análisis estadístico del RUL en el percentil 50 (P50), que representa la vida útil restante (Remaining Useful Life) estimada en el valor central de la distribución de predicciones generadas por el modelo Bagging (TreeBagger). Este enfoque cuantílico es relevante porque el P50 constituye la medida de tendencia central en un contexto probabilístico, ofreciendo una visión equilibrada entre escenarios extremos de degradación acelerada y condiciones de desgaste más prolongado.

En términos prácticos, el RUL P50 indica el tiempo estimado antes de que un componente alcance su condición crítica o punto de falla, considerando la mediana estadística de todas las simulaciones realizadas. Esto permite minimizar la influencia de valores atípicos y ofrecer una estimación robusta y representativa del comportamiento general del sistema. Además, al utilizar el modelo Bagging (TreeBagger), que combina múltiples árboles de decisión mediante agregación por bootstrap, se obtiene una reducción de la varianza y un aumento en la estabilidad de las predicciones, lo que fortalece la confiabilidad del valor P50 como referencia para la planificación del mantenimiento predictivo y la gestión del riesgo operativo (Ver figura 24).

Figura 24

Distribución y Probabilidad Acumulada del RUL P50 – muestra de 110 días



Nota. Elaboración Propia

Este análisis se muestra mediante dos representaciones complementarias: el histograma de frecuencias y la función de distribución acumulada empírica (ECDF).

- **Histograma del RUL P50:**

- La mayor concentración de valores del RUL se encuentra entre 70 y 100 días, donde se observa la frecuencia más alta de predicciones.
- Este comportamiento indica que, en la mayoría de los casos, la vida útil restante estimada para los componentes evaluados se sitúa en rangos moderados a altos, lo que sugiere un desgaste progresivo, pero no inminente.

- **ECDF del RUL P50:**


- La curva de distribución acumulada muestra que aproximadamente el 50 % de las predicciones se concentran por debajo de 75 días de RUL, mientras que el 90 % se encuentra por debajo de 95 días.

- Esta representación confirma que la mayoría de los valores de RUL siguen una distribución sesgada hacia la derecha, con mayor densidad en rangos superiores.

La Figura 25 presenta la dispersión de los cuantiles del RUL en relación con el valor central P50 con una variación de muestra de 110 días, con el objetivo de analizar la variabilidad y el rango de incertidumbre en las predicciones del modelo Bagging (TreeBagger).

Figura 25

Variabilidad Cuantílica del RUL P50



Nota. Elaboración Propia

Los resultados evidencian los siguientes comportamientos:

- **Distribución inferior (P10 y P20):**
 - Los cuantiles bajos muestran los escenarios más pesimistas en términos de vida útil restante.
 - Se observa que para valores de P50 alrededor de 60 días, el P20 se aproxima a 40 días y el P10 incluso desciende hasta 30 días o menos, reflejando condiciones críticas con desgaste acelerado.

- **Distribución central (P75 y P90):**

- Los cuantiles intermedios concentran la mayoría de las predicciones, mostrando una menor dispersión conforme aumenta el RUL.
- Para valores de P50 en torno a 80 días, los cuantiles P75 y P90 se ubican cerca de 90 y 100 días, respectivamente, indicando mayor confiabilidad en estos rangos.

- **Distribución superior (P95 y P98):**

- Representan los escenarios más optimistas, con valores de RUL considerablemente mayores.
- Para un P50 de 80 días, estos cuantiles superan los 110 días, mostrando que en algunos casos el modelo estima vidas útiles prolongadas bajo condiciones menos exigentes.

La Tabla 11 proporciona una proyección temporal de la degradación y de las fechas estimadas de falla de los componentes evaluados, incorporando un enfoque basado en tres niveles de confiabilidad probabilística: P20, P50 y P98. Este enfoque cuantílico permite caracterizar la incertidumbre inherente al proceso de estimación de la vida útil restante (RUL) y ofrecer una visión integral del riesgo asociado a la degradación de cada componente. A diferencia del análisis inicial realizado para un horizonte de 110 días, esta proyección basada en el algoritmo de predicción con mejor desempeño revela que las fallas se extenderían en un tiempo aproximadamente tres veces mayor, es decir, más de un año después de los datos recolectados entre el 1 y el 19 de enero de 2025. Este resultado demuestra que, bajo condiciones de operación similares y con un modelo predictivo más robusto, la vida útil de los componentes podría prolongarse significativamente antes de alcanzar su condición crítica.

Tabla 11*Proyección de Degradación y Fallas Estimadas (P20, P50, P98)*

TTF_P20_d	TTF_P50_d	TTF_P98_d	t_50pct_d	t_70pct_d	Fecha_50pct	Fecha_70pct	Falla_P50	Falla_P20	Falla_P98
10	14	67	7	10	14/01/2026	17/01/2026	21/01/2026	17/01/2026	15/03/2026
10	14	46	7	10	9/01/2026	12/01/2026	16/01/2026	12/01/2026	17/02/2026
11	15	47	8	11	16/01/2026	19/01/2026	23/01/2026	19/01/2026	24/02/2026
10	15	43	8	11	25/01/2026	28/01/2026	1/02/2026	28/01/2026	26/02/2026
11	15	41	8	11	14/01/2026	17/01/2026	21/01/2026	17/01/2026	25/02/2026
11	15	47	8	11	20/01/2026	23/01/2026	27/01/2026	23/01/2026	28/02/2026
11	15	43	8	11	20/01/2026	23/01/2026	27/01/2026	23/01/2026	28/02/2026
10	16	70	8	11	22/01/2026	25/01/2026	29/01/2026	25/01/2026	31/03/2026
11	16	43	8	11	25/01/2026	28/01/2026	1/02/2026	28/01/2026	26/02/2026
10	16	38	8	11	9/01/2026	12/01/2026	16/01/2026	12/01/2026	16/02/2026
11	16	48	8	11	22/01/2026	25/01/2026	29/01/2026	25/01/2026	5/03/2026
10	16	50	8	11	13/01/2026	16/01/2026	20/01/2026	16/01/2026	10/03/2026
11	16	45	8	11	9/01/2026	12/01/2026	16/01/2026	12/01/2026	23/02/2026

Nota. Elaboración Propia

Cada uno de estos cuantiles ofrece una perspectiva diferente del comportamiento del sistema:

- **P20:** representa un escenario conservador o pesimista, donde el 20 % de las simulaciones predicen que la falla ocurrirá antes de la fecha indicada, reflejando las condiciones más críticas o de degradación acelerada.
- **P50:** corresponde al escenario medio o más probable, es decir, la fecha en la que existe un 50 % de probabilidad de que ocurra la falla.
- **P98:** describe un escenario optimista, con una proyección más prolongada de la vida útil, donde solo el 2 % de las simulaciones predicen fallas antes de la fecha señalada.

Los resultados evidencian que:

- En el percentil P20, donde se asume un escenario más severo, la proyección indica que algunos motores alcanzarán su condición crítica entre 363 y 374 días después del último registro, dado que el registro inicial fue del 1 al 19 de enero del 2025. Esta situación ocurre porque en dichos casos se detectan patrones de desgaste acelerado, asociados a mayores cargas de trabajo, picos de temperatura o vibraciones atípicas, lo que incrementa la velocidad de degradación.
- Para el percentil P50, que representa el escenario más probable, las fallas se estiman entre 362 y 398 días, puesto que el registro inicial fue del 1 al 19 de enero del 2025. Esta predicción intermedia se fundamenta en que la mayoría de los motores opera bajo condiciones normales de carga y temperatura, siguiendo una tasa de degradación promedio y estable que permite proyectar con mayor certeza el tiempo restante antes de la falla.
- En el percentil P98, correspondiente al escenario más optimista, la vida útil podría extenderse hasta 457 días. Estos valores se presentan en motores con menores exigencias operativas, mejores condiciones de lubricación o con patrones históricos de degradación más lentos, lo que reduce la probabilidad de falla temprana.

En términos prácticos, estas proyecciones no solo indican cuándo fallará un motor, sino por qué sucederá dentro de cada horizonte temporal:


- Valores bajos (P20) reflejan alto riesgo operativo y necesidad de mantenimiento inmediato.
- El valor central (P50) representa la planificación estándar, basada en condiciones de operación típicas.

- Valores altos (P98) permiten extender la operación cuando el desgaste real es más lento, reduciendo costos innecesarios de intervención.

La Figura 26 presenta el Fan Chart del Tiempo de Vida Útil Restante (RUL), una herramienta que combina información probabilística y temporal para representar la incertidumbre asociada a las predicciones del RUL. En este gráfico, el eje horizontal muestra los casos ordenados según su RUL en el percentil 50 (P50), mientras que el eje vertical indica el RUL expresado en días.

Figura 26

Fan Chart del Tiempo de Vida Útil Restante (RUL)



Nota. Elaboración Propia

La banda sombreada en diferentes tonos de azul representa intervalos de confianza definidos por cuantiles:

- **P02-P98:** delimita el rango total de variabilidad, abarcando prácticamente todos los posibles escenarios de falla.
- **P10-P95 y P20-P90:** reducen progresivamente el rango de incertidumbre, mostrando zonas con mayor concentración de datos y, por lo tanto, con mayor probabilidad de ocurrencia.

La línea negra central corresponde al P50, es decir, la mediana del RUL, que indica la estimación más probable del tiempo de vida útil restante para cada caso evaluado.

Los resultados permiten interpretar que:

- Valores más bajos del RUL (extremo izquierdo) presentan mayor dispersión en los cuantiles, lo que sugiere mayor incertidumbre en componentes próximos a su condición de falla.
- Valores intermedios y altos del RUL (centro y extremo derecho) exhiben bandas más estrechas, reflejando mayor consistencia y confianza en las predicciones para equipos con desgaste más lento.

Los datos iniciales para la predicción de fallas fueron recolectados entre el 1 y el 19 de enero, período en el cual se registraron las condiciones operativas y de degradación de los componentes evaluados. Con esta información, y tras la validación de métricas de desempeño en la fase de modelado, se seleccionó el algoritmo Bagging (TreeBagger) por su mayor precisión y capacidad de generalización frente a otros modelos evaluados. Una vez definido el modelo, se aplicó la predicción probabilística de fallas bajo el escenario P20, correspondiente a un nivel de confiabilidad del 20%, lo que implica priorizar un criterio conservador para anticipar posibles fallas tempranas.

Tabla 12

Proyección Mensual de Casos de Falla - P20

Mes	Casos_estimados_P20
01-Jan-2026	170
1-Feb-2026	420
1-Mar-2026	540
01-Apr-2026	730

Nota. Elaboración Propia

Los resultados presentados en la Tabla 12 muestran que, considerando los datos iniciales de enero, los primeros casos de falla comienzan a manifestarse entre los 12, 13 y 14 meses posteriores, con la siguiente evolución:

- **Enero 2026:** Se estiman 170 casos de falla acumulada.
- **Febrero 2026:** El número asciende a 420 casos, evidenciando un incremento significativo en la tasa de fallas proyectadas.
- **Marzo 2026:** Se alcanzan 540 casos, reflejando el mayor nivel de criticidad dentro del periodo analizado.
- **Abril 2026:** La cifra sube a 730 casos, confirmando la necesidad de intervenciones preventivas antes del mes 12 para evitar impactos operativos mayores.

La Tabla 13 presenta la proyección mensual de fallas bajo el escenario P50, el cual representa la estimación central o más probable del tiempo de falla para los componentes evaluados. A diferencia del escenario P20, que prioriza la prevención temprana bajo un criterio conservador, el P50 asume que el 50 % de los casos alcanzarán su condición crítica antes de la fecha indicada, mientras que el otro 50 % tendrá un horizonte de vida útil mayor.

Tabla 13

Proyección Mensual de Casos de Falla - P50

Mes	Casos_estimados_P50
01-Jan-2026	380
1-Feb-2026	760
1-Mar-2026	800
01-Apr-2026	980

Nota. Elaboración Propia

Tomando como referencia los datos iniciales recolectados del 1 al 19 de enero y aplicando el algoritmo Bagging (TreeBagger) seleccionado previamente por su precisión en métricas y capacidad de generalización, la proyección para 12 a 14 meses posteriores muestra la siguiente evolución:


- **Enero 2026:** Se estiman 380 casos de falla acumulada, indicando el inicio del periodo crítico para la mayoría de los equipos.
- **Febrero 2026:** El número de fallas proyectadas asciende a 760 casos, lo que representa casi el doble de la cifra anterior y marca un punto clave para la planificación del mantenimiento.
- **Marzo 2026:** Se proyectan 800 casos, alcanzando el máximo de la serie analizada.

- **Abril 2026:** La cifra total aumenta a 980 casos, lo que confirma que la mayoría de los equipos evaluados alcanzaría su condición crítica antes de los 14 meses.

La Figura 27 ilustra el rango temporal en el que se concentran las fallas proyectadas para el año 2026, considerando los diferentes escenarios cuantil obtenidos mediante el algoritmo de predicción validado.

Figura 27

Timeline de Vida Útil Restante por Motor



Nota. Elaboración Propia

Cada fila representa un motor y las barras de colores indican los periodos donde, según los cuantiles P20, P50 y P90, es más probable que ocurra la falla:

- **Escenarios conservadores (P20):** muestran las fechas más tempranas donde se podría alcanzar la condición de falla, representando el 20 % de probabilidad acumulada.
- **Escenario central (P50):** indica el punto medio donde existe 50 % de probabilidad de que ocurra la falla antes o después de esa fecha.
- **Escenarios optimistas (P90):** reflejan que, con 90 % de probabilidad, la condición crítica se alcanzaría más tarde, extendiendo la operación del motor.

La visualización revela que, partiendo de los datos iniciales de enero 2025, las fallas estimadas empiezan a concentrarse entre marzo y abril del 2026, alcanzando su máxima densidad en este rango temporal. Esto permite priorizar intervenciones con base en el riesgo:


- **Acciones tempranas** para motores en P20.
- **Mantenimiento estándar** en P50.
- **Extensión operativa** para casos en P90 si el riesgo lo permite.

5.2. Pronóstico de falla de los motores

El pronóstico de falla se desarrolló utilizando el modelo Bagging (TreeBagger), aplicado sobre los registros operativos obtenidos de los motores eléctricos entre enero y abril de 2025. Los datos incluyeron variables de vibración, temperatura del estator, corriente y carga, registradas con una frecuencia de seis horas. A partir de esta información, el modelo estimó la vida útil restante (RUL) de cada equipo, expresada en días, con el objetivo de anticipar el momento en que los motores alcanzarían su condición crítica. Los resultados generaron un cronograma de fallas pronosticadas, mostrado en la Figura 28, donde se observa la secuencia temporal estimada para cada motor.

Figura 28

Cronograma de fallas pronosticadas de los motores eléctricos




Nota. Elaboración Propia

El motor 1 presentó una proyección de falla hacia el 14 de enero, el motor 2 hacia el 20 de febrero, el motor 3 en torno al 17 de marzo, y el motor 4 cerca del 16 de abril. Esta tendencia evidencia un patrón progresivo de degradación, relacionado con el incremento gradual de la vibración y la temperatura, los cuales influyen directamente en la reducción del RUL. El análisis general indica que los motores mantienen un periodo promedio de vida útil de aproximadamente 90 días, antes de alcanzar niveles de riesgo elevados. Este comportamiento respalda la utilidad del modelo para programar mantenimientos predictivos, reduciendo la posibilidad de paradas inesperadas y optimizando la planificación de intervenciones técnicas.

El desempeño del modelo Bagging (TreeBagger) se evaluó comparando los valores reales del tiempo de vida útil restante (RUL) con los valores predichos por el modelo durante la fase de prueba. La Figura 29 muestra la dispersión de ambos valores, junto con una línea diagonal que representa la predicción ideal. Los puntos se encuentran coloreados según la magnitud de la vibración, lo que permite visualizar la relación entre el deterioro físico y la precisión de las estimaciones.

Figura 29

Desempeño del modelo de predicción de fallas (TreeBagger – Bagging)



Nota. Elaboración Propia

El modelo alcanzó un RMSE de 444.04 horas y un coeficiente de determinación (R^2) de 0.53, lo que representa una correlación moderada entre los valores reales y los predichos. El RMSE indica que el error promedio entre las estimaciones y los valores observados equivale aproximadamente a 18.5 días, lo cual refleja una desviación razonable considerando la variabilidad de las condiciones operativas. Este valor de error se considera aceptable para fines de pronóstico de fallas, donde los datos suelen presentar ruido por las fluctuaciones naturales en la vibración y la temperatura del estator.


El R^2 de 0.53 muestra que el modelo explica alrededor del 53 % de la variabilidad presente en la vida útil restante (RUL) de los motores. Aunque no representa un ajuste perfecto, el nivel de correlación es coherente con el comportamiento de modelos de ensamble aplicados a datos industriales, en los cuales la incertidumbre en los registros de sensores afecta la precisión del ajuste. En la dispersión de la Figura 28, se observa que los puntos se concentran en torno a la línea de referencia, especialmente en los rangos intermedios del RUL, lo que evidencia una tendencia predictiva estable en el comportamiento medio del conjunto de datos.

La Figura 30 presenta la evolución temporal de las señales de vibración y temperatura del estator correspondientes al motor 4, con una frecuencia de muestreo de seis horas. Los resultados evidencian una degradación gradual del sistema durante el periodo comprendido entre enero y abril de 2025, donde se observa un incremento sostenido tanto en la amplitud de vibración (de 2.3 a 6.9 mm/s) como en la temperatura del estator (de 38 °C a 52 °C). Este comportamiento progresivo refleja un desgaste acumulativo de los componentes rotativos, asociado principalmente al aumento de fricción y esfuerzos térmicos derivados de la operación continua.

En la parte inferior de la figura se muestra la cuenta regresiva del RUL, que disminuye de manera lineal desde 100 hasta 0 días, señalando el instante de falla detectado el 13 de abril de 2025. Este punto coincide con el momento en que las variables de condición superan los umbrales establecidos como críticos para la operación segura del equipo. La relación entre la tendencia ascendente de las variables de monitoreo y la reducción del RUL confirma la capacidad del modelo Bagging (TreeBagger) para capturar la dinámica de degradación y estimar el tiempo restante hasta la falla de forma coherente con los datos medidos.

Figura 30

Tendencia de degradación y estimación del RUL para el motor 4



Nota. Elaboración Propia

El comportamiento del motor 4 muestra que, a medida que la vibración se aproxima al límite de 7 mm/s y la temperatura al rango superior de 50 °C, la probabilidad de falla se incrementa rápidamente, lo que coincide con los patrones observados en motores eléctricos con envejecimiento térmico y mecánico prolongado. Este resultado refuerza la validez del modelo para representar el proceso de deterioro real y para planificar acciones de mantenimiento predictivo antes de alcanzar condiciones críticas.

5.3. Análisis de sensibilidad de variables sobre el RUL

El análisis de sensibilidad tuvo como propósito determinar qué variable vibración, temperatura o corriente influye con mayor intensidad en la estimación del Tiempo de Vida Útil Restante (RUL) bajo los escenarios probabilísticos P20, P50 y P98 generados por el modelo Bagging (TreeBagger). Se aplicó una correlación de rango (Spearman) entre el RUL estimado y las variables operativas principales, a partir de los registros de condición obtenidos entre enero y abril de 2025. Este enfoque permite identificar asociaciones monótonas robustas entre las señales de degradación y el comportamiento temporal del RUL, complementando la evaluación cuantílica presentada en los apartados previos.

Tabla 14

Resultados del análisis de sensibilidad

Variable	Spearman (RUL, var)	Contribución (%)
Vibración (vibration_mm_s)	0.78	45.6
Temperatura (temp_max_C)	0.66	38.5
Corriente (current_A)	0.27	15.9

Nota. Elaboración Propia

Los resultados evidencian que la vibración es la variable con mayor relación inversa respecto al RUL, representando aproximadamente el 46% de la sensibilidad total. Esto confirma que incrementos sostenidos de amplitud vibratoria aceleran el desgaste de los componentes rotativos, reduciendo la vida útil proyectada. La temperatura contribuye con cerca del 39%, lo que demuestra su fuerte impacto en el envejecimiento térmico del estator y los rodamientos. Por su parte, la corriente muestra una influencia menor (16%), actuando principalmente como variable de soporte vinculada a la carga del motor.

- **Escenario P20 (riesgo alto):** El RUL se reduce drásticamente cuando se presentan picos simultáneos de vibración y temperatura. Este comportamiento refleja condiciones severas de carga y fricción, coherentes con los motores que alcanzan su condición crítica entre 363 y 374 días, tal como se observa en los casos de degradación acelerada.
- **Escenario P50 (condición media):** En la mayoría de los equipos, la vibración y la temperatura mantienen una relación equilibrada, explicando el comportamiento estable y predecible del RUL dentro del rango 362 a 398 días. Aquí, la corriente eléctrica actúa como variable moderadora asociada al nivel de carga operativa.
- **Escenario P98 (condición optimista):** La disminución de la vibración y temperaturas moderadas prolongan la vida útil hasta aproximadamente 457 días, evidenciando una menor pendiente de degradación y una mayor consistencia en el Fan Chart del RUL (Figura 25).

El estudio demuestra que el RUL se encuentra principalmente condicionado por la vibración, seguida por la temperatura del estator y los rodamientos, mientras que la corriente ejerce un efecto indirecto vinculado al nivel de carga. En términos operativos, se recomienda:

- Priorizar la vibración como variable principal de monitoreo predictivo en escenarios P20 y P50.
- Implementar alertas térmicas complementarias para motores que operan de forma continua, especialmente cuando la temperatura supera los 50 °C.
- Ajustar las estrategias de mantenimiento en función del riesgo probabilístico: intervenciones tempranas bajo P20, planificación estándar en P50 y extensión operativa controlada en P98.

CONCLUSIONES

PRIMERA: Se concluye que el modelo Bagging (TreeBagger), seleccionado por su menor error de predicción (RMSE) y mayor capacidad de generalización, permitió estimar con precisión la vida útil restante (RUL) de los motores eléctricos. Con los datos operativos de enero, el modelo proyectó que la mayoría de los equipos alcanzará su condición crítica entre enero y abril de 2026, es decir, 12 a 14 meses después del último registro, validando su aplicación para planificar mantenimientos predictivos y prevenir paradas no programadas.

SEGUNDA: Se recopilaron datos históricos de variables eléctricas, mecánicas, ambientales y de condición, los cuales fueron preprocesados para garantizar su calidad y representatividad. El análisis estadístico evidenció rangos de operación estables, con identificaciones claras de anomalías como sobrecargas o picos de temperatura y vibración. Esta etapa permitió construir una base sólida y estructurada para el entrenamiento y validación de los modelos, asegurando que las predicciones se fundamenten en información confiable y bien caracterizada.

TERCERA: La implementación de Bagging, LSBoost y Redes Neuronales en MATLAB permitió comparar su desempeño bajo datos reales. Bagging logró la mejor capacidad de generalización con menor error en la fase de prueba, mientras que LSBoost mostró la mayor precisión en entrenamiento, aunque con mayor riesgo de sobreajuste. La Red Neuronal presentó el rendimiento más bajo, con mayor dispersión y errores en datos no vistos. Por tanto, Bagging (TreeBagger) se consolidó como el modelo más robusto y confiable para la predicción del RUL.

CUARTA: Con base en las métricas de desempeño, el modelo Bagging (TreeBagger) evidenció la mejor capacidad de generalización para la estimación de la vida útil restante (RUL) en motores eléctricos. En la fase de prueba obtuvo $RMSE = 24.352$, $MAE = 19.208$, $MAPE = 128.41$ y $R^2 = 0.4363$, superando a LSBoost ($RMSE = 24.663$, $MAE = 19.547$, $MAPE = 129.4$, $R^2 = 0.4218$) y a la Red Neuronal ($RMSE = 25.732$, $MAE = 20.388$, $MAPE = 135.43$, $R^2 = 0.3706$). Estos resultados confirman que, aunque LSBoost fue más preciso en el entrenamiento ($RMSE = 17.383$, $MAE = 13.491$, $R^2 = 0.71698$), Bagging mantuvo un rendimiento más estable frente a datos no vistos, evitando el sobreajuste observado en LSBoost y la menor precisión de la Red Neuronal.

RECOMENDACIONES

Dado que el modelo Bagging obtuvo la mejor capacidad de generalización ($RMSE = 24.352$, $MAE = 19.208$, $R^2 = 0.4363$), se recomienda integrarlo en la operación real mediante una fase piloto que permita validar su rendimiento en condiciones dinámicas de la mina. Esta implementación debe priorizar la detección temprana de fallas bajo escenarios conservadores (P20) para evitar paradas no planificadas y reducir riesgos operativos.

La calidad de las predicciones depende directamente de la actualización de las variables eléctricas, mecánicas y ambientales. Por ello, se recomienda establecer un sistema de adquisición de datos en tiempo real que permita la recalibración periódica del modelo con información reciente, manteniendo su precisión y capacidad de respuesta frente a cambios en la carga o condiciones ambientales.

Las proyecciones en P20, P50 y P90 evidencian diferentes horizontes de falla: conservador, medio y optimista. Se recomienda elaborar planes de mantenimiento escalonados, priorizando intervenciones tempranas para equipos críticos y extendiendo la operación en aquellos con menor riesgo. Este enfoque optimiza costos, recursos y disponibilidad de la planta, evitando intervenciones innecesarias o tardías.

Para garantizar la correcta interpretación de métricas como RMSE, MAE, MAPE y R^2 , el personal de mantenimiento debe recibir capacitación en análisis de datos y mantenimiento predictivo. Esto permitirá que las decisiones se basen en evidencia cuantitativa y que el equipo técnico pueda ajustar parámetros del modelo según la evolución de las condiciones operativas.

Se recomienda incorporar el monitoreo de armónicos y el análisis de calidad de energía dentro de las estrategias de mantenimiento predictivo, debido a que las distorsiones eléctricas pueden generar sobrecalentamientos, fallas y un desgaste prematuro en los motores eléctricos, afectando su confiabilidad y la estimación de la vida útil restante (RUL) desarrollada en la presente investigación.

REFERENCIAS BIBLIOGRÁFICAS

- Abdulkareem, A., Anyim, T., Popoola, O., Abubakar, J., y Ayoade, A. (2025). Prediction of induction motor faults using machine learning. *Heliyon*, 11(1), e41493. <https://doi.org/10.1016/j.heliyon.2024.e41493>
- Alarcón, M., Sanchez, J., Gómez, F., Martínez, F., y Rivera, E. (2021). Mantenimiento predictivo para el uso eficiente de agitadores industriales en destiladores y reactores. *DYNA*, 96(1), 17–21. <https://revista-dyna.com/index.php/DYNA/article/view/131>
- Albornoz, G. (2021). Aplicación del aprendizaje automático supervisado en el mantenimiento predictivo de los motores eléctricos de inducción en las empresas mineras del Perú. *Repositorio.uncp.edu.pe*. <https://repositorio.uncp.edu.pe/handle/20.500.12894/7567>
- Alvarez, D. (2024). *Sistema de mantenimiento predictivo utilizando algoritmos de Machine Learning en un compresor de aire industrial en el sector industrial, 2024*. Concytec.gob.pe. https://alicia.concytec.gob.pe/vufind/Record/UCVV_5be5d9fb24a00d560b1c88b3c39ea569
- Arana, C. (2021). Modelos de aprendizaje automático mediante árboles de decisión. *Econstor.eu*. <http://hdl.handle.net/10419/238403>
- Bansal, M., Goyal, A., y Choudhary, A. (2022). A comparative analysis of K-Nearest Neighbor, Genetic, Support Vector Machine, Decision Tree, and Long Short Term Memory algorithms in machine learning. *Decision Analytics Journal*, 3(100071), 100071. <https://doi.org/10.1016/j.dajour.2022.100071>
- Barrios, J. (2022). Diseño de investigación para un plan de mantenimiento preventivo para tableros de arranque de motores eléctricos con variador de frecuencia - Repositorio Institucional USAC. [Usac.edu.gt](https://repositorio.usac.edu.gt/).

<http://www.repositorio.usac.edu.gt/18132/1/Josu%C3%A9%20Daniel%20Barrios%20Morales.pdf>

- Barroso, J. (2018). Modelo predictivo basado en machine learning de ordenes de trabajo riesgosos para mantenimiento de equipos mineros. *Uchile.cl*.
<https://repositorio.uchile.cl/handle/2250/170038>
- Bermejo, R. (2025). Modelo de Trading Algorítmico basado en detección de patrones en Commodities mediante el uso de Machine Learning. *Comillas.edu*.
<http://hdl.handle.net/11531/94744>
- Canahua , N. (2021). Implementación de la metodología TPM-Lean Manufacturing para mejorar la eficiencia general de los equipos (OEE) en la producción de repuestos en una empresa metalmecánica. *Industrial Data*, 24(1), 49–76.
<https://doi.org/10.15381/idata.v24i1.18402>
- Carrillo, F., Pazmiño, E., Chimborazo, A., y Quishpi, C. (2022). Influencia de la altura en el rendimiento operativo de los motores eléctricos. *Polo Del Conocimiento*, 7(5), 232–240. <https://doi.org/10.23857/pc.v7i5.3958>
- Chacón, D. (2024). Diseño de un banco de pruebas para determinación de la vida útil restante en sistemas de transmisión de engranajes rectos aplicando la metodología TRIZ. *Ups.edu.ec*. <http://dspace.ups.edu.ec/handle/123456789/28904>
- Chacón, D. (2024). Diseño de un banco de pruebas para determinación de la vida útil restante en sistemas de transmisión de engranajes rectos aplicando la metodología TRIZ. *Ups.edu.ec*. <http://dspace.ups.edu.ec/handle/123456789/28904>
- Chiza, L., & Cepeda, J. (2021). Predicción del Margen de Estabilidad de Corredores de Transmisión Aplicando Criterios de Minería de datos y Algoritmos de Machine Learning. *Revista Técnica Energía*, 18(1), 37–47.
<https://doi.org/10.37116/revistaenergia.v18.n1.2021.466>

- Contreras, J. (2020). *Diseño de un modelo para mantenimiento predictivo en motores de inducción utilizando técnicas de la Industria 4.0*. Concytec.gob.pe.
https://alicia.concytec.gob.pe/vufind/Record/UTPD_e3ed835c4ea808c852c94e0e7af5fd29
- Hanifi, S., Alkali, B., Lindsay, G., Waters, M., y McGlinchey, D. (2024). Advancements in predictive maintenance modelling for industrial electrical motors: Integrating machine learning and sensor technologies. *Measurement: Sensors*, 101473.
<https://doi.org/10.1016/j.measen.2024.101473>
- Kang, Z., Catal, C., y Tekinerdogan, B. (2021). Remaining useful life (RUL) prediction of equipment in production lines using artificial neural networks. *Sensors*, 21(3), 932.
<https://doi.org/10.3390/s21030932>
- Neciosup, J., y Rivera, F. (2021). Plan de mantenimiento correctivo en la red de media tensión para corregir interrupciones de energía en el distrito de Pamparomás. *Handle.net*.
<https://hdl.handle.net/20.500.12692/85040>
- Nikfar, M., Bitencourt, J., y Mykoniatis, K. (2022). A two-phase machine learning approach for predictive maintenance of low voltage industrial motors. *Procedia Computer Science*, 200, 111–120. <https://doi.org/10.1016/j.procs.2022.01.210>
- Odar, B. (2023). *Análisis y detección de fallas en motores eléctricos aplicando algoritmos de inteligencia artificial*. Concytec.gob.pe.
https://alicia.concytec.gob.pe/vufind/Record/UDEP_a99d68b249fef1c1f22897212ef55d2d
- Pedrero, V., Reynaldos, K., Ureta, J., Cortez, E., Pedrero, V., Reynaldos, K., Ureta, J., y Cortez, E. (2021). Generalidades del Machine Learning y su aplicación en la gestión sanitaria en Servicios de Urgencia. *Revista Médica de Chile*, 149(2), 248–254.
<https://doi.org/10.4067/s0034-98872021000200248>

- Perez, M., Angueta, A., Guasumba, E., y Calero, D. (2022). Estimación de la vida útil de las baterías de los vehículos híbridos causas y consecuencias. *Dominio de Las Ciencias*, 8(2), 770–781. <https://dialnet.unirioja.es/descarga/articulo/8637987.pdf>
- Quiroz, S. (2021). *Machine learning para reducir costos de mantenimiento de maquinaria pesada de minería*. Concytec.gob.pe. https://alicia.concytec.gob.pe/vufind/Record/UCVV_77bde2e700e359e6b865ba2c154800cc
- Revista Tecnología Minera. (2023a). *Machine Learning: seis herramientas que optimizan las operaciones mineras*. *Tecnologiaminera.com*; Revista Tecnología Minera. <https://tecnologiaminera.com/noticia/machine-learning-seis-herramientas-que-optimizan-las-operaciones-mineras-1688566569>
- Revista Tecnología Minera. (2023b). *Beneficios del análisis predictivo en la industria minera*. *Tecnologiaminera.com*; Revista Tecnología Minera. <https://tecnologiaminera.com/noticia/beneficios-del-analisis-predictivo-en-la-industria-minera-1691760793>
- Revista Tecnología Minera. (2023c). *El poder del mantenimiento predictivo en la industria minera*. *Tecnologiaminera.com*; Revista Tecnología Minera. <https://tecnologiaminera.com/noticia/el-poder-del-mantenimiento-predictivo-en-la-industria-minera-1694054569>
- Revista Tecnología Minera. (2024a). *Conoce las tecnologías de monitoreo y sensores IoT para optimizar la eficiencia en la minería*. *Tecnologiaminera.com*; Revista Tecnología Minera. <https://tecnologiaminera.com/noticia/conoce-las-tecnologias-de-monitoreo-y-sensores-iot-para-optimizar-la-eficiencia-en-la-mineria-1719955322>
- Revista Tecnología Minera. (2024b). *Cómo aprovechar los sensores inteligentes e IoT en la exploración minera*. *Tecnologiaminera.com*; Revista Tecnología Minera.

[https://tecnologiaminera.com/noticia/como-aprovechar-los-sensores-inteligentes-e-
iot-en-la-exploracion-minera-1725314279](https://tecnologiaminera.com/noticia/como-aprovechar-los-sensores-inteligentes-e-
iot-en-la-exploracion-minera-1725314279)

Taboada, A. (2024). Big data en ciencias sociales. Una introducción a la automatización de análisis de datos de texto mediante procesamiento de lenguaje natural y aprendizaje automático. *Revista CENTRA de Ciencias Sociales*, 3(1). <https://doi.org/10.54790/rccs.51>

Taşcı, B., Omar, A., y Ayvaz, S. (2023). Remaining useful lifetime prediction for predictive maintenance in manufacturing. *Computers & Industrial Engineering*, 184, 109566. <https://doi.org/10.1016/j.cie.2023.109566>

Tirira, R., Martínez, M., Matute, H., Moreno, É., y Domínguez, J. (2024). Introducción técnica a la clasificación y aspectos fundamentales de los motores eléctricos. *Revista Científica Multidisciplinar G-Nerando*, 5(2). <https://doi.org/10.60100/rcmg.v5i2.334>

Torres, V. (2023). Aplicación del mantenimiento predictivo para disminuir los costos de mantenimiento de una flota de Scooptram en una mina subterránea. Unitru.edu.pe; Universidad Nacional de Trujillo. <https://hdl.handle.net/20.500.14414/20732>

Trujillo, R. (2023). *Mantenimiento predictivo de motores eléctricos*. <https://repositorio.umsa.bo/bitstream/handle/123456789/34921/PG-8757.pdf?sequence=1&isAllowed=y>

Valero, J., Navarro, Á., Larios, A., y Julca, J. (2022). Deserción universitaria: evaluación de diferentes algoritmos de Machine Learning para su predicción. *Revista de Ciencias Sociales*, 28(3), 362–375. <https://dialnet.unirioja.es/servlet/articulo?codigo=8526463>

Villacrés, S., Zavala, M., y Viscaino, M. (2024). Predicción de vida útil restante en rodamiento aplicando Machine Learning: Una revisión Sistemática de Literatura. *ConcienciaDigital*, 7(3.1), 46–67. <https://doi.org/10.33262/concienciadigital.v7i3.1.3120>

Villón, R. (2025). Implementación de un sistema de control y monitoreo IIOT, para la adquisición de parámetros eléctricos en un motor trifásico. *Upse.edu.ec*.
<https://doi.org/UPSE-TEA-2025-0012>

Yarin, M., y Moscoso, Y. (2019). Mejora del mantenimiento predictivo utilizando la técnica de machine learning en matlab en los camiones mineros eléctricos Komatsu 830e y 930e de la compañía minera Antapaccay – Cusco. *Unsaac.edu.pe*.
<https://doi.org/253T20190672>

Zamudio, I. (2023). *Diagnóstico de fallos electromecánicos en motores eléctricos mediante el análisis avanzado del flujo magnético y su implementación en hardware*.
<https://riunet.upv.es/handle/10251/197989>

ANEXOS

Anexo N° 1. Matriz de consistencia

ESTIMACIÓN DE VIDA ÚTIL RESTANTE EN MOTORES ELÉCTRICOS MEDIANTE APRENDIZAJE AUTOMÁTICO APLICADO A MANTENIMIENTO PREDICTIVO EN UNA EMPRESA MINERA DEL SUR DEL PAÍS				
Objetivos	Hipótesis	Variables	Indicadores	Metodologías
General	General	Variables Independientes		
Estimar la vida útil restante en motores eléctricos mediante técnicas de aprendizaje automático aplicadas al mantenimiento predictivo en una empresa minera del sur.	La aplicación de técnicas de aprendizaje automático permite estimar la vida útil restante de motores eléctricos, mejorando la efectividad del mantenimiento predictivo en sistemas utilizados en minería.	Aprendizaje automático	Tipo de algoritmo aplicado Precisión del modelo Métricas de validación cruzada	. La investigación se desarrolla bajo un enfoque cuantitativo. El tipo de investigación es aplicada y explicativa. El diseño de la investigación es no experimental, transversal y correlacional.
Específicos	Específicos	Variable Dependiente		
Recopilar y preprocesar datos operativos de motores eléctricos para el entrenamiento de modelos de aprendizaje automático.	El preprocesamiento de los datos operativos de motores eléctricos mejora la calidad de la información utilizada para el entrenamiento de modelos de aprendizaje automático.	Vida útil restante estimada de motores eléctricos		
Implementar modelos de aprendizaje automático supervisado en MATLAB para estimar la vida útil restante de los motores eléctricos.	La implementación de modelos de aprendizaje automático supervisado en MATLAB permite generar estimaciones efectivas de la vida útil restante de motores eléctricos.			
Evaluar el desempeño de los modelos mediante métricas de validación para su aplicación en mantenimiento predictivo.	El uso de métricas de validación permite determinar el modelo de aprendizaje automático con mayor precisión para su aplicación en mantenimiento predictivo.			

Anexo N° 2. Datos operativos

timestamp	motor id	voltage V	current A	power factor	rpm	load pct	temp stator C	temp bearing C	vibration mm	ambient temp C	humidity pct	efficiency pct	state
2025-01-01 00:00:00	7	410.034	47.260	0.804	1560.728	55.361	47.701	50.844	2.211	17.741	47.942	93.193	0
2025-01-01 00:05:00	4	436.858	52.494	0.933	1508.492	30.486	73.561	57.082	2.434	32.168	65.348	93.219	0
2025-01-01 00:10:00	8	386.979	56.484	0.831	1446.778	81.880	44.474	56.095	1.920	24.984	72.751	99.214	0
2025-01-01 00:15:00	5	387.321	32.131	0.759	1490.312	66.863	61.113	58.863	1.762	26.690	59.619	95.373	0
2025-01-01 00:20:00	7	410.551	49.815	0.828	1524.390	63.860	56.147	35.873	2.711	24.985	55.913	94.166	0
2025-01-01 00:25:00	10	394.771	33.543	0.856	1493.726	92.549	54.641	58.428	0.882	20.003	64.148	95.850	1
2025-01-01 00:30:00	3	433.713	48.692	0.826	1492.366	54.375	57.260	60.045	2.212	24.165	56.256	95.656	0
2025-01-01 00:35:00	7	406.834	63.731	0.789	1464.316	82.879	54.604	59.856	1.850	25.059	59.713	97.324	0
2025-01-01 00:40:00	8	379.109	40.015	0.715	1468.330	85.786	54.271	54.030	2.343	16.225	78.269	97.156	0
2025-01-01 00:45:00	5	365.264	33.336	0.784	1511.123	58.750	69.987	69.041	1.410	27.575	50.787	93.445	0
2025-01-01 00:50:00	4	398.435	68.877	0.883	1524.624	70.169	55.962	62.500	2.183	26.772	46.466	94.173	0
2025-01-01 00:55:00	8	398.218	38.529	0.760	1491.335	103.575	47.814	66.613	2.297	23.289	69.846	96.652	0
2025-01-01 01:00:00	8	406.275	35.014	0.779	1475.302	49.804	59.161	58.627	2.201	32.327	48.128	96.319	0
2025-01-01 01:05:00	3	424.214	66.190	0.850	1537.818	81.099	49.412	55.009	1.565	26.970	57.232	94.168	0
2025-01-01 01:10:00	6	421.582	38.135	0.831	1478.816	71.242	49.128	59.733	1.700	29.521	61.690	97.146	0
2025-01-01 01:15:00	5	388.422	66.449	0.735	1514.466	95.414	74.552	49.992	2.352	26.971	33.040	92.821	0
2025-01-01 01:20:00	2	374.124	52.741	0.795	1526.651	69.325	58.168	61.626	1.948	27.038	49.578	93.851	1
2025-01-01 01:25:00	8	375.318	62.840	0.870	1436.795	83.715	47.226	51.368	1.003	14.184	42.239	99.438	0
2025-01-01 01:30:00	6	385.264	51.861	0.801	1506.987	37.990	58.971	50.286	1.763	22.388	44.256	94.754	0
2025-01-01 01:35:00	2	392.665	60.797	0.872	1365.126	27.117	60.638	44.470	2.593	24.500	62.658	100.000	0
2025-01-01 01:40:00	5	406.101	40.816	0.874	1494.882	49.015	57.929	63.048	1.928	19.513	32.734	95.463	0
2025-01-01 01:45:00	1	383.981	43.864	0.754	1528.975	61.169	55.115	71.114	1.341	23.767	45.941	94.040	0
2025-01-01 01:50:00	10	405.608	28.845	0.785	1516.846	62.917	46.127	65.945	1.822	29.596	54.007	95.545	0
2025-01-01 01:55:00	6	407.241	59.718	0.833	1540.000	91.846	55.844	62.208	1.991	25.058	48.675	93.416	0
2025-01-01 02:00:00	9	402.867	54.196	0.723	1517.523	62.140	52.060	62.434	1.626	18.434	55.388	94.918	1
2025-01-01 02:05:00	1	377.428	39.927	0.789	1472.883	70.477	58.780	62.159	2.674	27.415	58.473	96.478	0

2025-01-01 02:10:00	10	409.357	32.511	0.827	1423.039	72.791	64.227	53.988	1.850	15.368	59.755	98.425	1
2025-01-01 02:15:00	3	441.625	52.818	0.769	1505.658	57.370	77.514	51.949	1.888	27.960	66.487	92.966	0
2025-01-01 02:20:00	7	404.918	66.760	0.829	1523.940	69.634	67.748	47.211	1.924	22.389	85.196	93.028	0
2025-01-01 02:25:00	4	340.938	48.620	0.770	1412.122	91.023	32.853	69.896	1.098	34.495	63.712	100.000	0
2025-01-01 02:30:00	9	424.818	43.416	0.769	1520.195	75.984	62.224	53.396	2.189	17.749	49.291	93.768	0
2025-01-01 02:35:00	3	385.945	40.629	0.837	1504.387	81.864	75.158	56.140	1.705	24.833	56.849	93.265	0
2025-01-01 02:40:00	5	445.314	62.493	0.868	1481.766	76.664	58.575	46.014	0.780	19.453	45.141	96.054	1
2025-01-01 02:45:00	3	402.327	42.208	0.764	1521.988	102.942	75.556	48.808	1.250	23.124	66.569	92.345	0
2025-01-01 02:50:00	7	366.306	46.288	0.739	1486.231	48.952	48.953	47.124	1.974	35.846	54.315	96.793	0
2025-01-01 02:55:00	5	358.706	60.417	0.798	1483.027	120.000	51.225	52.126	2.615	23.027	74.056	96.726	0
2025-01-01 03:00:00	9	430.795	56.375	0.823	1436.436	89.927	58.310	60.101	2.359	19.006	44.985	98.347	0
2025-01-01 03:05:00	7	422.118	46.671	0.764	1520.236	93.563	58.538	58.731	2.278	28.143	45.921	94.134	0
2025-01-01 03:10:00	2	444.520	43.010	0.883	1434.696	96.199	68.367	59.815	2.051	23.214	46.914	97.428	1
2025-01-01 03:15:00	4	400.218	64.656	0.793	1465.795	90.727	60.019	54.873	2.191	23.198	42.355	96.708	0
2025-01-01 03:20:00	9	398.869	38.836	0.764	1522.790	44.198	58.910	60.990	2.049	23.295	58.395	93.969	1
2025-01-01 03:25:00	2	392.346	47.897	0.897	1491.626	47.340	84.763	53.821	1.632	23.317	53.829	92.942	0
2025-01-01 03:30:00	10	386.834	34.941	0.863	1585.454	83.984	52.224	58.649	1.651	30.795	55.131	91.505	0
2025-01-01 03:35:00	9	392.151	61.889	0.764	1529.643	81.552	72.887	51.858	2.008	17.176	20.300	92.229	0
2025-01-01 03:40:00	10	404.349	45.251	0.853	1537.567	87.716	64.156	63.834	1.618	25.327	35.285	92.706	0
2025-01-01 03:45:00	5	383.122	43.004	0.767	1542.697	70.933	56.335	47.840	1.158	26.323	48.827	93.232	0
2025-01-01 03:50:00	2	366.614	56.617	0.838	1487.935	43.654	62.588	64.012	2.300	25.777	51.795	95.344	0
2025-01-01 03:55:00	4	403.198	35.745	0.889	1473.408	67.797	51.825	57.895	2.219	19.414	74.122	97.147	0
2025-01-01 04:00:00	7	382.676	56.354	0.740	1439.308	84.827	60.862	67.137	1.147	19.867	35.722	97.948	0
2025-01-01 04:05:00	8	335.211	46.395	0.773	1427.321	64.937	59.960	49.715	1.384	23.404	33.105	98.638	0
2025-01-01 04:10:00	3	411.051	37.947	0.774	1557.369	69.905	64.763	53.154	2.169	19.995	34.111	91.655	0
2025-01-01 04:15:00	1	377.839	40.097	0.813	1468.890	70.601	58.833	52.933	1.427	26.559	51.568	96.672	1
2025-01-01 04:20:00	4	413.236	43.158	0.824	1544.696	59.560	76.662	48.094	2.014	30.900	60.804	91.099	0
2025-01-01 04:25:00	2	412.757	45.560	0.796	1426.406	53.722	51.177	70.782	2.421	25.303	41.625	99.562	0
2025-01-01 04:30:00	8	405.672	38.015	0.716	1490.867	112.168	53.113	49.301	1.769	23.441	52.366	96.145	0
2025-01-01 04:35:00	4	449.936	52.945	0.738	1563.385	101.172	62.392	47.605	2.331	14.318	32.245	91.592	1

2025-01-01 04:40:00	2	397.239	37.753	0.756	1513.304	91.403	51.944	66.618	1.747	26.480	30.933	95.140	0
2025-01-01 04:45:00	6	394.287	26.349	0.828	1514.625	78.301	66.730	61.130	1.835	21.039	43.240	93.596	0
2025-01-01 04:50:00	6	413.673	69.196	0.730	1470.685	49.906	73.144	53.476	2.208	23.354	62.826	95.151	0
2025-01-01 04:55:00	10	398.891	51.979	0.754	1454.865	87.746	54.804	40.180	2.336	21.311	39.510	97.776	0
2025-01-01 05:00:00	4	423.210	70.095	0.743	1497.752	92.306	60.881	68.712	1.373	23.924	47.295	95.024	0
2025-01-01 05:05:00	6	374.624	39.563	0.817	1443.716	63.110	66.547	70.568	1.341	26.049	36.031	97.159	0
2025-01-01 05:10:00	2	374.957	54.798	0.857	1494.627	48.646	68.833	59.883	1.238	27.016	33.907	94.385	0
2025-01-01 05:15:00	10	415.316	58.946	0.808	1549.062	78.538	94.778	59.166	2.838	30.252	56.752	89.069	0
2025-01-01 05:20:00	2	376.704	48.107	0.900	1436.647	91.358	46.424	56.636	1.782	23.970	41.369	99.525	0
2025-01-01 05:25:00	10	412.182	35.556	0.808	1532.109	57.199	74.942	51.563	1.651	23.885	29.011	91.900	0
2025-01-01 05:30:00	4	407.400	47.355	0.795	1549.795	80.574	53.575	64.681	2.146	31.177	28.254	93.153	1
2025-01-01 05:35:00	8	386.110	56.264	0.761	1486.988	51.851	53.998	51.933	1.172	29.399	65.025	96.251	1
2025-01-01 05:40:00	7	407.343	55.882	0.810	1501.668	47.266	61.430	59.463	1.813	31.449	24.966	94.774	0
2025-01-01 05:45:00	9	375.308	49.984	0.759	1476.026	74.097	60.621	56.745	2.004	29.692	66.856	96.137	0
2025-01-01 05:50:00	8	380.002	58.973	0.751	1484.498	53.712	72.508	54.906	1.514	37.176	59.643	94.524	0
2025-01-01 05:55:00	5	395.256	58.501	0.750	1540.906	78.602	45.295	48.181	1.422	28.723	43.423	94.425	0
2025-01-01 06:00:00	2	401.579	44.763	0.789	1536.250	37.691	30.240	45.440	1.811	19.672	60.832	96.164	1
2025-01-01 06:05:00	5	393.927	34.796	0.775	1519.672	52.859	79.338	58.956	1.755	28.721	46.970	92.083	1
2025-01-01 06:10:00	8	408.662	51.904	0.933	1530.396	90.582	45.600	51.546	1.740	26.857	56.199	94.920	0
2025-01-01 06:15:00	10	407.769	42.534	0.810	1510.001	83.850	70.051	56.156	1.253	23.146	21.888	93.495	0
2025-01-01 06:20:00	9	430.587	51.437	0.810	1438.656	78.381	73.947	56.604	1.250	22.630	52.185	96.672	0
2025-01-01 06:25:00	9	398.094	63.455	0.772	1553.200	61.090	71.346	57.477	2.629	24.139	44.588	91.205	0
2025-01-01 06:30:00	1	423.891	54.375	0.953	1455.325	70.274	65.114	54.041	1.345	14.306	42.548	96.722	0
2025-01-01 06:35:00	9	418.415	62.963	0.754	1494.993	65.505	67.458	60.187	1.897	12.267	63.379	94.505	0
2025-01-01 06:40:00	7	445.880	39.885	0.776	1542.663	116.675	54.774	54.346	1.918	25.401	81.627	93.389	1
2025-01-01 06:45:00	9	397.455	60.875	0.850	1429.938	76.329	40.857	53.078	1.760	22.524	69.485	100.000	1
2025-01-01 06:50:00	8	391.593	66.766	0.810	1531.227	54.668	56.524	60.910	1.918	22.244	67.453	93.786	0
2025-01-01 06:55:00	1	425.154	50.643	0.736	1440.394	68.382	54.564	55.214	1.822	23.269	37.562	98.524	0
2025-01-01 07:00:00	8	407.709	73.221	0.801	1529.737	36.389	50.554	56.858	1.792	17.317	60.011	94.458	0
2025-01-01 07:05:00	8	425.633	41.426	0.834	1560.133	31.924	60.496	62.566	2.527	28.702	44.261	91.944	0

2025-01-01 07:10:00	3	414.336	43.612	0.826	1463.124	99.254	40.506	58.377	1.523	23.499	42.904	98.793	0
2025-01-01 07:15:00	1	357.865	56.499	0.833	1456.620	75.474	72.544	62.455	1.682	25.191	82.289	95.915	0
2025-01-01 07:20:00	8	407.526	50.545	0.909	1503.802	60.968	59.304	42.352	2.456	29.701	20.000	94.880	0
2025-01-01 07:25:00	3	406.224	42.571	0.814	1455.050	69.470	55.059	76.145	1.705	23.279	57.222	97.742	0
2025-01-01 07:30:00	3	402.662	56.191	0.840	1391.138	67.917	56.905	60.764	1.776	29.447	56.208	100.000	1
2025-01-01 07:35:00	1	397.355	53.555	0.679	1498.735	71.352	58.436	59.791	1.698	26.816	62.560	95.220	0
2025-01-01 07:40:00	5	368.157	44.137	0.893	1516.756	92.955	49.637	53.896	2.524	29.416	62.198	95.199	0
2025-01-01 07:45:00	10	417.484	51.891	0.803	1483.577	80.709	49.600	43.000	2.444	29.833	57.685	96.861	0
2025-01-01 07:50:00	7	407.475	57.590	0.757	1505.654	61.808	46.923	60.749	1.407	27.562	56.208	96.025	0
2025-01-01 07:55:00	10	422.039	43.915	0.790	1552.444	35.022	45.807	63.873	2.707	24.555	38.429	93.797	0
2025-01-01 08:00:00	9	369.225	55.170	0.833	1482.107	49.954	51.439	41.359	0.917	27.489	50.946	96.751	0
2025-01-01 08:05:00	7	410.143	41.330	0.852	1488.668	85.169	58.527	62.087	1.162	19.772	62.655	95.714	0
2025-01-01 08:10:00	9	395.307	43.262	0.795	1499.013	101.242	71.011	67.352	1.208	26.892	39.934	93.948	0
2025-01-01 08:15:00	8	402.876	61.116	0.830	1484.301	52.441	44.236	67.030	1.449	28.984	55.649	97.361	0
2025-01-01 08:20:00	2	395.537	56.137	0.787	1484.314	49.418	69.154	59.250	1.784	20.220	62.831	94.869	1
2025-01-01 08:25:00	1	410.872	31.132	0.825	1585.430	61.352	43.916	54.376	1.464	31.431	45.145	92.337	0
2025-01-01 08:30:00	7	396.743	46.258	0.810	1506.287	105.688	60.964	62.583	1.395	24.696	73.453	94.589	0
2025-01-01 08:35:00	7	378.962	54.897	0.815	1485.160	72.954	44.829	58.311	2.231	26.917	58.610	97.259	0
2025-01-01 08:40:00	8	401.729	51.389	0.784	1569.215	54.755	47.354	57.917	1.818	18.986	26.318	92.804	1
2025-01-01 08:45:00	5	395.717	56.182	0.820	1554.270	62.777	63.163	50.785	2.367	13.892	51.426	91.970	0
2025-01-01 08:50:00	3	398.332	51.160	0.759	1531.214	59.436	63.048	42.095	2.431	31.069	38.313	93.134	0
2025-01-01 08:55:00	8	336.244	48.674	0.810	1469.515	84.083	67.490	61.857	2.048	24.316	34.689	95.775	0
2025-01-01 09:00:00	6	413.653	48.368	0.768	1636.618	109.070	50.684	52.405	2.316	29.940	35.668	89.101	0
2025-01-01 09:05:00	3	393.707	60.912	0.750	1421.712	72.617	69.967	47.159	1.873	24.104	78.673	97.918	0
2025-01-01 09:10:00	1	373.037	56.949	0.765	1410.940	91.875	75.633	46.102	1.345	20.644	38.049	97.890	0
2025-01-01 09:15:00	3	418.451	54.047	0.790	1519.145	43.079	62.331	53.548	1.262	33.659	47.809	93.810	0
2025-01-01 09:20:00	5	412.727	50.888	0.774	1482.154	116.820	42.133	45.216	0.997	24.632	54.911	97.679	0
2025-01-01 09:25:00	3	393.454	44.512	0.820	1376.146	43.218	40.709	63.629	2.348	25.569	39.452	100.000	0
2025-01-01 09:30:00	1	376.957	46.932	0.804	1492.961	94.237	61.530	59.332	2.040	24.132	37.636	95.199	0
2025-01-01 09:35:00	5	403.561	60.647	0.851	1503.944	76.772	54.278	63.938	0.483	17.864	40.665	95.375	1

2025-01-01 09:40:00	10	402.462	59.705	0.796	1491.587	44.838	50.044	46.753	2.284	27.706	41.280	96.416	1
2025-01-01 09:45:00	7	418.487	43.514	0.809	1515.111	86.689	58.329	43.836	1.994	27.105	57.962	94.412	0
2025-01-01 09:50:00	7	391.125	50.999	0.893	1476.511	69.418	56.420	69.056	1.509	29.471	37.201	96.532	0
2025-01-01 09:55:00	9	423.898	54.985	0.778	1493.068	51.766	58.397	48.596	1.502	20.938	73.027	95.507	1
2025-01-01 10:00:00	10	389.195	54.332	0.786	1565.407	70.215	51.196	55.764	1.822	17.112	46.787	92.610	0
2025-01-01 10:05:00	10	373.083	54.255	0.860	1547.942	37.003	79.795	48.891	2.558	27.860	74.330	90.623	0
2025-01-01 10:10:00	3	377.354	38.879	0.752	1489.569	60.353	49.127	48.424	1.983	31.533	49.067	96.609	1
2025-01-01 10:15:00	7	398.752	38.285	0.866	1527.411	50.711	57.308	59.759	1.604	16.962	27.708	93.899	0
2025-01-01 10:20:00	1	398.690	61.702	0.788	1543.681	66.352	39.583	53.970	3.074	18.021	40.518	94.858	0
2025-01-01 10:25:00	4	406.557	65.090	0.758	1453.122	35.384	48.435	65.509	2.458	22.245	58.019	98.500	1
2025-01-01 10:30:00	4	398.193	35.185	0.845	1516.521	34.180	46.986	40.731	2.449	17.533	34.367	95.475	0
2025-01-01 10:35:00	5	419.546	49.722	0.787	1507.816	53.018	54.619	54.858	2.484	23.036	49.406	95.147	0
2025-01-01 10:40:00	7	394.778	58.141	0.891	1532.882	69.234	57.511	50.910	2.591	26.888	55.251	93.605	0
2025-01-01 10:45:00	7	360.074	27.962	0.804	1452.801	50.535	55.782	53.034	2.210	28.649	55.645	97.782	0
2025-01-01 10:50:00	4	397.578	39.267	0.804	1498.291	79.231	54.530	53.591	2.010	27.701	58.572	95.633	1
2025-01-01 10:55:00	7	359.864	49.078	0.771	1462.284	84.042	62.143	60.145	2.053	24.251	53.540	96.672	0
2025-01-01 11:00:00	3	405.428	44.028	0.793	1516.602	53.117	62.910	53.517	1.310	31.396	34.935	93.879	0
2025-01-01 11:05:00	6	421.144	52.091	0.786	1458.739	97.809	36.183	53.599	0.879	15.462	45.904	99.445	1
2025-01-01 11:10:00	2	380.276	64.705	0.867	1472.735	63.942	70.576	68.935	2.355	19.721	50.184	95.306	0
2025-01-01 11:15:00	10	428.371	41.472	0.814	1506.132	106.631	62.612	45.240	2.910	25.166	56.678	94.432	0
2025-01-01 11:20:00	9	416.857	50.503	0.835	1452.988	64.808	40.408	46.313	1.811	21.157	39.004	99.310	1
2025-01-01 11:25:00	5	424.130	46.552	0.805	1419.210	47.567	68.987	69.858	2.694	24.307	49.383	98.141	0
2025-01-01 11:30:00	6	403.791	51.364	0.779	1551.959	94.562	70.197	68.671	2.768	27.407	78.725	91.382	0
2025-01-01 11:35:00	4	380.145	50.058	0.819	1467.830	49.172	40.115	40.653	1.742	22.242	63.967	98.597	0
2025-01-01 11:40:00	10	415.616	76.372	0.880	1430.011	92.754	56.877	72.144	2.605	22.263	63.230	98.812	0
2025-01-01 11:45:00	7	387.508	64.896	0.748	1444.569	72.413	62.638	59.632	2.316	23.686	49.136	97.508	0
2025-01-01 11:50:00	9	402.358	34.191	0.821	1495.012	58.882	70.698	49.332	1.838	29.378	52.840	94.180	0
2025-01-01 11:55:00	7	396.573	40.999	0.875	1578.854	54.631	64.914	55.044	2.266	28.170	50.245	90.566	0
2025-01-01 12:00:00	1	422.494	42.221	0.759	1493.015	68.275	54.369	51.564	2.143	29.022	57.227	95.912	0
2025-01-01 12:05:00	1	414.607	37.657	0.846	1529.144	83.597	49.175	55.005	1.018	25.756	31.481	94.625	0

2025-01-01 12:10:00	9	398.389	36.316	0.846	1480.790	69.198	45.214	51.680	3.244	25.879	38.043	97.439	0
2025-01-01 12:15:00	9	360.968	48.216	0.735	1509.293	99.590	50.718	45.581	1.463	30.825	28.926	95.464	0
2025-01-01 12:20:00	4	387.295	42.603	0.856	1489.665	46.485	65.378	44.425	2.098	20.715	61.211	94.979	1
2025-01-01 12:25:00	9	414.084	41.092	0.770	1528.504	68.068	69.210	56.721	2.917	30.948	60.916	92.654	0
2025-01-01 12:30:00	3	405.602	70.205	0.818	1443.371	92.013	56.228	48.596	1.864	25.860	40.269	98.209	0
2025-01-01 12:35:00	7	369.936	43.291	0.851	1503.760	45.922	70.964	43.611	1.629	25.246	39.440	93.716	0
2025-01-01 12:40:00	6	363.868	45.568	0.860	1507.685	90.805	64.078	59.252	2.065	22.467	61.002	94.208	0
2025-01-01 12:45:00	8	403.910	57.415	0.723	1519.796	70.396	85.281	59.167	1.827	31.054	60.647	91.482	0
2025-01-01 12:50:00	9	378.859	45.535	0.889	1432.710	72.202	41.675	59.171	2.612	29.219	74.368	100.000	0
2025-01-01 12:55:00	5	380.784	38.343	0.871	1476.202	63.209	57.814	55.623	1.582	18.233	37.656	96.408	0
2025-01-01 13:00:00	1	413.452	47.421	0.853	1530.050	45.821	62.122	47.987	1.714	26.622	48.289	93.285	0
2025-01-01 13:05:00	3	424.045	70.087	0.818	1511.291	68.424	78.476	64.628	1.956	21.385	51.875	92.588	0
2025-01-01 13:10:00	10	384.986	45.186	0.778	1586.691	58.884	45.452	62.052	1.356	23.661	58.488	92.120	0
2025-01-01 13:15:00	8	399.105	40.882	0.746	1473.532	100.486	50.340	72.835	1.724	17.449	64.509	97.289	0
2025-01-01 13:20:00	6	398.515	54.202	0.719	1400.639	80.208	60.550	65.083	1.729	25.783	48.218	99.913	0
2025-01-01 13:25:00	8	396.716	46.941	0.832	1476.684	70.690	47.768	57.548	1.366	26.034	53.295	97.389	0
2025-01-01 13:30:00	9	400.812	77.390	0.853	1366.901	96.355	57.515	69.133	1.690	26.352	45.290	100.000	1
2025-01-01 13:35:00	4	415.130	42.131	0.796	1535.107	68.878	43.646	55.591	2.370	22.972	28.397	94.880	0
2025-01-01 13:40:00	1	386.522	67.337	0.777	1499.841	84.058	71.952	55.657	0.999	23.619	37.310	93.813	0
2025-01-01 13:45:00	1	369.494	61.634	0.803	1519.915	93.284	76.792	54.621	2.507	15.591	42.977	92.325	0
2025-01-01 13:50:00	10	433.800	46.187	0.768	1527.881	64.555	77.153	50.968	1.738	29.812	58.401	91.891	0
2025-01-01 13:55:00	4	421.788	49.965	0.801	1551.996	78.699	61.533	72.804	2.164	16.133	20.000	92.247	0
2025-01-01 14:00:00	7	377.927	39.701	0.765	1370.451	61.266	61.753	48.352	2.501	26.992	58.648	100.000	0
2025-01-01 14:05:00	2	402.713	44.616	0.831	1397.900	92.924	59.878	41.739	1.530	23.870	58.732	100.000	0
2025-01-01 14:10:00	3	420.214	46.116	0.862	1462.230	69.455	68.610	51.269	2.225	27.867	43.147	96.027	0
2025-01-01 14:15:00	1	414.981	51.579	0.825	1484.805	97.412	72.614	57.922	1.345	25.758	78.560	94.498	0
2025-01-01 14:20:00	5	409.240	35.873	0.796	1509.978	73.977	67.133	50.673	1.301	20.080	53.806	93.788	1
2025-01-01 14:25:00	1	396.595	53.115	0.849	1506.240	120.000	62.426	52.156	1.877	27.827	53.610	94.445	0
2025-01-01 14:30:00	8	434.546	48.541	0.801	1508.781	55.857	67.054	39.632	1.920	24.783	47.565	93.856	1
2025-01-01 14:35:00	1	404.417	53.981	0.848	1421.848	87.194	59.895	45.005	2.482	23.860	22.577	98.918	0

2025-01-01 14:40:00	1	389.701	55.473	0.768	1460.260	69.137	46.586	44.454	1.262	26.144	40.237	98.328	1
2025-01-01 14:45:00	2	417.422	47.741	0.775	1483.879	65.498	54.085	61.699	2.295	30.775	38.126	96.398	0
2025-01-01 14:50:00	2	401.921	54.882	0.751	1492.465	32.039	62.130	43.793	1.791	23.217	59.897	95.164	0
2025-01-01 14:55:00	6	406.996	49.128	0.777	1474.978	71.456	51.296	49.801	1.929	26.871	42.098	97.121	0
2025-01-01 15:00:00	7	404.063	57.435	0.849	1512.717	50.515	50.603	53.487	0.927	26.058	54.519	95.304	0
2025-01-01 15:05:00	5	409.936	53.161	0.756	1442.939	63.806	66.182	46.371	1.884	22.866	25.688	97.235	1
2025-01-01 15:10:00	1	380.431	51.810	0.685	1475.871	51.301	66.805	57.208	2.368	22.071	70.467	95.526	0
2025-01-01 15:15:00	1	370.978	48.976	0.779	1525.149	53.977	62.957	58.599	1.839	19.954	60.727	93.447	0
2025-01-01 15:20:00	3	428.683	62.958	0.741	1510.223	48.547	55.023	66.695	1.808	27.512	49.627	94.987	0
2025-01-01 15:25:00	2	404.992	54.052	0.775	1481.331	48.753	56.624	55.022	2.916	22.024	42.757	96.271	0
2025-01-01 15:30:00	5	415.417	36.785	0.905	1482.466	38.177	67.000	38.074	1.965	18.667	62.498	95.177	0
2025-01-01 15:35:00	10	364.805	45.280	0.756	1476.196	77.524	50.983	50.383	1.098	24.711	42.239	97.092	0
2025-01-01 15:40:00	6	421.334	47.714	0.832	1483.248	70.362	45.451	52.725	1.202	29.898	42.124	97.292	0
2025-01-01 15:45:00	7	389.570	49.989	0.796	1474.810	84.156	65.072	65.310	2.725	30.834	46.563	95.752	0
2025-01-01 15:50:00	4	383.876	51.767	0.819	1481.780	62.162	58.806	53.173	1.737	10.734	71.951	96.030	0
2025-01-01 15:55:00	7	398.733	40.558	0.775	1514.785	56.805	73.072	58.258	2.393	25.616	40.583	92.954	0
2025-01-01 16:00:00	8	380.440	49.320	0.858	1513.742	68.243	49.347	52.580	1.800	27.632	60.208	95.378	0
2025-01-01 16:05:00	1	399.965	46.859	0.821	1434.354	84.034	70.747	59.331	2.188	27.385	38.460	97.208	0
2025-01-01 16:10:00	6	397.273	60.847	0.823	1589.588	75.997	54.162	49.951	1.764	24.577	20.000	91.104	0
2025-01-01 16:15:00	8	421.208	40.049	0.805	1472.842	70.259	67.821	41.620	1.918	33.030	55.915	95.576	1
2025-01-01 16:20:00	5	430.267	49.826	0.863	1523.444	83.288	47.116	33.969	2.218	31.298	37.008	95.116	0
2025-01-01 16:25:00	4	429.630	43.146	0.828	1446.417	70.101	43.949	59.066	1.362	24.555	45.558	99.284	0
2025-01-01 16:30:00	2	354.710	68.630	0.819	1573.134	58.169	63.509	57.625	2.135	22.924	62.611	90.992	0
2025-01-01 16:35:00	6	381.297	62.566	0.833	1526.910	88.151	57.248	58.216	2.086	26.688	36.353	93.930	1
2025-01-01 16:40:00	6	354.502	33.576	0.712	1519.124	45.033	61.593	55.951	1.220	27.391	43.769	93.884	0
2025-01-01 16:45:00	1	376.129	42.038	0.809	1491.056	41.593	50.244	39.311	3.333	25.251	59.642	96.423	0
2025-01-01 16:50:00	9	387.010	58.709	0.797	1407.997	69.501	63.281	49.828	1.812	25.684	43.143	99.272	0
2025-01-01 16:55:00	6	408.211	54.573	0.858	1583.141	71.717	72.739	54.196	1.466	32.652	51.307	89.569	0
2025-01-01 17:00:00	3	389.601	54.259	0.765	1542.685	74.660	70.967	49.161	2.735	32.786	47.806	91.769	0
2025-01-01 17:05:00	4	390.159	51.909	0.810	1483.926	63.448	53.253	59.552	1.369	28.900	47.842	96.478	0

2025-01-01 17:10:00	4	403.635	59.512	0.896	1523.929	97.062	47.437	53.760	1.688	29.610	46.879	95.060	0
2025-01-01 17:15:00	3	365.814	57.810	0.799	1434.469	40.029	59.969	60.264	2.070	29.262	56.704	98.280	0
2025-01-01 17:20:00	10	383.228	47.094	0.733	1404.673	72.700	68.475	64.241	1.699	24.003	21.362	98.919	1
2025-01-01 17:25:00	3	389.929	38.007	0.909	1500.822	85.173	43.119	58.550	2.262	27.247	45.996	96.647	0
2025-01-01 17:30:00	3	395.952	33.099	0.764	1460.124	97.687	66.094	56.353	2.271	26.301	38.195	96.384	0
2025-01-01 17:35:00	4	401.539	48.964	0.748	1475.870	96.687	80.103	44.485	1.607	31.151	60.188	94.196	0
2025-01-01 17:40:00	7	430.013	31.601	0.750	1497.365	48.076	66.396	55.472	2.733	26.461	67.877	94.492	0
2025-01-01 17:45:00	4	418.167	52.510	0.836	1440.636	77.243	44.445	42.175	1.844	29.294	49.700	99.524	0
2025-01-01 17:50:00	9	384.614	46.920	0.865	1495.990	65.719	48.673	45.348	2.100	24.395	47.506	96.333	0
2025-01-01 17:55:00	1	394.773	69.439	0.888	1444.793	69.621	53.101	57.317	1.805	28.468	57.496	98.450	0
2025-01-01 18:00:00	8	393.411	53.431	0.801	1550.624	92.679	58.550	44.875	1.777	26.360	51.901	92.614	0
2025-01-01 18:05:00	7	389.717	49.708	0.751	1494.983	107.999	63.490	73.147	1.964	21.239	47.630	94.902	0
2025-01-01 18:10:00	2	405.450	33.838	0.772	1526.378	75.218	67.205	62.310	2.923	28.623	53.616	92.961	0
2025-01-01 18:15:00	8	362.804	37.377	0.802	1411.371	30.285	57.015	55.397	2.209	30.196	44.961	99.730	0
2025-01-01 18:20:00	1	417.614	56.814	0.799	1529.488	36.632	62.560	32.642	1.473	16.753	60.776	93.270	1
2025-01-01 18:25:00	9	433.871	46.869	0.865	1574.861	69.070	49.186	39.817	2.039	16.292	76.258	92.338	0
2025-01-01 18:30:00	9	394.603	75.354	0.734	1505.881	89.951	52.940	73.232	1.719	26.183	47.404	95.412	0
2025-01-01 18:35:00	2	394.213	49.169	0.744	1526.107	54.291	68.850	50.616	2.485	26.973	56.425	92.810	0
2025-01-01 18:40:00	7	403.141	51.689	0.785	1488.096	66.176	64.521	64.469	1.944	20.461	20.453	95.143	0
2025-01-01 18:45:00	10	420.388	36.831	0.818	1518.764	102.358	65.769	50.837	1.289	26.436	23.894	93.485	0
2025-01-01 18:50:00	3	393.514	59.474	0.778	1580.059	62.070	49.607	47.007	2.203	24.525	53.301	92.036	0
2025-01-01 18:55:00	7	418.679	40.743	0.774	1612.313	105.057	59.621	46.469	1.585	14.814	44.437	89.422	0
2025-01-01 19:00:00	10	409.770	55.244	0.859	1515.859	61.394	60.853	42.721	2.202	25.900	39.172	94.122	0
2025-01-01 19:05:00	9	447.232	58.118	0.824	1449.016	88.085	63.230	59.539	2.478	20.140	56.719	97.226	0
2025-01-01 19:10:00	4	393.427	50.952	0.751	1531.165	71.537	70.173	58.044	1.857	27.863	45.635	92.424	1
2025-01-01 19:15:00	1	360.480	67.570	0.775	1438.118	85.533	60.451	50.676	1.919	22.480	56.658	98.049	0
2025-01-01 19:20:00	2	371.341	43.893	0.826	1468.779	110.173	75.903	38.396	2.085	26.765	51.872	94.971	0
2025-01-01 19:25:00	1	400.239	66.755	0.737	1474.491	78.393	40.348	53.002	1.669	30.867	61.231	98.241	0
2025-01-01 19:30:00	5	420.558	37.291	0.826	1602.059	95.221	56.917	59.485	2.045	22.909	48.026	90.205	0
2025-01-01 19:35:00	5	386.950	57.990	0.783	1571.435	52.107	70.324	72.674	2.104	24.355	49.701	90.396	0

2025-01-01 19:40:00	7	395.381	48.576	0.818	1561.081	51.371	52.536	63.198	1.557	31.245	45.662	92.692	0
2025-01-01 19:45:00	9	413.697	42.919	0.806	1541.039	37.351	68.337	56.538	2.599	27.831	42.983	92.114	0
2025-01-01 19:50:00	9	380.695	33.387	0.744	1454.580	48.887	60.979	48.235	1.139	24.607	56.661	97.173	0
2025-01-01 19:55:00	3	387.775	47.393	0.768	1511.811	100.345	78.982	64.973	2.404	32.351	35.957	92.511	0
2025-01-01 20:00:00	3	376.645	46.762	0.872	1591.896	76.629	58.488	55.917	2.690	23.944	65.801	90.556	0
2025-01-01 20:05:00	3	423.565	51.729	0.919	1522.377	64.652	58.608	56.266	2.394	23.857	35.308	94.020	0
2025-01-01 20:10:00	4	430.833	57.248	0.713	1551.507	74.084	78.012	64.447	1.471	20.491	45.061	90.623	0
2025-01-01 20:15:00	8	368.412	41.915	0.852	1419.509	83.604	56.385	53.052	2.433	27.800	43.811	99.386	0
2025-01-01 20:20:00	6	397.156	67.583	0.815	1536.094	85.570	70.563	62.176	3.052	19.810	58.555	92.139	1
2025-01-01 20:25:00	8	428.145	44.615	0.904	1447.283	74.372	63.076	45.395	1.910	31.727	68.342	97.328	0
2025-01-01 20:30:00	1	407.974	56.022	0.772	1488.955	97.654	70.872	49.287	2.000	22.164	54.661	94.465	1
2025-01-01 20:35:00	8	390.215	50.902	0.845	1571.102	50.585	56.509	58.773	2.386	27.285	73.245	91.794	0
2025-01-01 20:40:00	4	369.077	48.013	0.785	1517.358	62.987	58.935	54.521	1.564	25.210	39.592	94.239	1
2025-01-01 20:45:00	1	423.059	50.401	0.864	1540.751	93.405	56.325	52.919	1.233	27.576	45.974	93.330	0
2025-01-01 20:50:00	8	407.210	40.597	0.916	1490.751	89.127	40.261	45.491	2.211	27.013	29.182	97.436	0
2025-01-01 20:55:00	4	370.540	46.124	0.811	1403.699	77.417	57.349	62.686	2.018	25.461	33.320	100.000	0
2025-01-01 21:00:00	6	423.798	36.602	0.743	1453.236	59.142	92.020	41.795	1.482	23.179	63.956	94.136	1
2025-01-01 21:05:00	8	367.992	44.507	0.871	1534.012	85.751	52.677	62.013	2.193	26.297	46.967	94.032	0
2025-01-01 21:10:00	4	395.590	45.333	0.828	1516.736	51.817	61.460	55.408	1.826	31.245	42.877	94.017	0
2025-01-01 21:15:00	3	394.708	58.452	0.819	1583.122	93.640	71.912	55.532	2.188	23.480	36.646	89.653	0
2025-01-01 21:20:00	9	432.368	46.681	0.879	1506.330	100.434	65.215	54.604	2.094	19.398	60.211	94.162	0
2025-01-01 21:25:00	3	394.779	45.519	0.743	1455.360	58.478	59.224	48.083	2.067	28.252	43.821	97.310	0
2025-01-01 21:30:00	9	394.707	52.200	0.764	1498.709	120.000	51.058	54.720	1.993	26.301	32.683	95.959	0
2025-01-01 21:35:00	2	372.738	51.809	0.830	1549.891	50.053	74.423	57.925	1.123	31.759	50.374	91.063	0
2025-01-01 21:40:00	2	387.192	44.090	0.763	1412.145	66.219	71.086	58.297	1.248	27.732	57.631	98.284	0
2025-01-01 21:45:00	2	383.654	53.942	0.784	1517.282	65.727	74.185	54.201	2.899	31.228	47.545	92.717	0
2025-01-01 21:50:00	6	384.696	48.214	0.864	1436.975	67.924	73.185	54.095	2.692	33.661	42.102	96.833	1
2025-01-01 21:55:00	3	400.126	44.073	0.822	1508.136	98.497	45.725	54.036	1.861	23.593	50.878	96.021	0
2025-01-01 22:00:00	9	351.316	45.045	0.741	1536.322	78.755	56.482	52.950	2.214	24.479	29.513	93.536	0
2025-01-01 22:05:00	4	369.795	59.494	0.820	1527.594	53.372	63.110	40.882	1.165	30.530	59.757	93.309	0

2025-01-01 22:10:00	1	397.780	45.346	0.862	1567.019	72.181	50.488	50.836	1.257	25.399	55.624	92.600	0
2025-01-01 22:15:00	4	402.425	52.611	0.809	1512.537	83.264	53.698	46.690	0.526	22.986	65.213	95.003	0
2025-01-01 22:20:00	1	395.331	37.176	0.844	1525.679	80.416	66.406	53.704	1.460	23.665	37.430	93.075	0
2025-01-01 22:25:00	5	399.184	61.153	0.774	1527.428	94.444	65.993	47.661	1.675	21.882	26.384	93.029	0
2025-01-01 22:30:00	4	391.818	44.170	0.813	1451.514	71.788	77.609	57.759	2.354	14.909	27.668	95.663	1
2025-01-01 22:35:00	8	399.630	54.003	0.721	1493.626	85.992	52.788	64.506	1.883	28.247	35.008	96.040	0
2025-01-01 22:40:00	8	408.683	47.484	0.831	1377.051	67.153	50.700	52.442	2.133	21.365	31.971	100.000	0
2025-01-01 22:45:00	7	408.543	53.888	0.818	1518.844	57.065	80.981	57.178	1.815	17.720	57.850	91.960	1
2025-01-01 22:50:00	3	386.221	54.434	0.735	1362.421	47.173	57.543	51.215	1.933	29.398	42.663	100.000	0
2025-01-01 22:55:00	1	418.302	48.553	0.876	1542.455	101.330	40.998	54.174	1.817	17.816	46.323	94.777	0
2025-01-01 23:00:00	1	403.142	31.340	0.829	1582.666	39.823	63.996	65.886	2.130	30.640	40.925	90.467	0
2025-01-01 23:05:00	3	424.644	60.910	0.765	1524.936	75.081	49.250	42.638	0.631	28.341	47.418	94.828	0
2025-01-01 23:10:00	6	428.657	48.601	0.833	1532.654	78.193	56.137	49.606	1.998	27.234	59.938	93.754	0
2025-01-01 23:15:00	7	371.145	53.680	0.751	1560.244	50.386	45.824	55.845	1.922	19.101	73.194	93.405	1
2025-01-01 23:20:00	6	382.819	56.917	0.758	1478.258	88.019	71.115	53.664	2.833	15.861	63.396	94.976	0
2025-01-01 23:25:00	6	416.271	45.428	0.751	1436.375	42.990	64.082	51.999	2.114	21.391	50.455	97.773	0
2025-01-01 23:30:00	6	366.702	55.171	0.750	1495.701	58.406	47.103	45.560	2.795	12.304	45.532	96.505	1
2025-01-01 23:35:00	3	428.404	42.524	0.822	1461.854	89.294	61.983	58.460	1.607	13.309	68.127	96.709	0
2025-01-01 23:40:00	6	393.122	53.875	0.805	1503.838	43.985	66.711	54.192	1.623	29.274	35.888	94.137	0
2025-01-01 23:45:00	8	411.501	50.197	0.837	1512.737	86.340	57.883	60.143	2.839	35.059	49.755	94.575	1
2025-01-01 23:50:00	2	397.672	45.775	0.659	1476.089	92.316	76.554	63.313	1.881	25.595	32.527	94.540	1
2025-01-01 23:55:00	5	372.152	50.470	0.780	1464.314	91.462	70.415	54.664	1.596	25.162	67.536	95.743	1
2025-01-02 00:00:00	1	421.111	39.448	0.781	1392.293	77.488	55.182	65.605	2.011	21.997	70.839	100.000	0
2025-01-02 00:05:00	1	455.014	53.090	0.803	1491.559	53.229	57.733	63.363	2.095	29.484	30.564	95.649	0
2025-01-02 00:10:00	5	389.700	54.128	0.801	1478.158	50.195	47.634	51.508	2.617	17.273	29.469	97.329	0
2025-01-02 00:15:00	3	393.553	53.456	0.811	1481.703	59.933	43.034	66.716	1.599	25.956	42.415	97.611	0
2025-01-02 00:20:00	4	347.018	65.022	0.804	1536.582	8.688	51.296	60.249	2.371	34.203	58.373	94.041	0
2025-01-02 00:25:00	3	427.030	49.050	0.777	1598.264	70.464	52.972	65.224	2.876	25.820	37.920	90.790	0
2025-01-02 00:30:00	1	418.235	49.739	0.780	1482.156	67.698	73.265	40.370	2.559	23.552	38.708	94.566	0
2025-01-02 00:35:00	1	365.332	38.297	0.797	1519.303	71.518	46.252	60.363	2.904	32.666	59.299	95.410	1

2025-01-02 00:40:00	5	358.702	65.725	0.825	1512.702	65.196	60.973	57.493	2.006	34.541	53.722	94.268	0
2025-01-02 00:45:00	6	361.015	35.019	0.804	1556.732	73.534	62.145	48.464	2.302	32.514	48.525	91.949	0
2025-01-02 00:50:00	3	412.903	52.286	0.761	1454.411	71.585	52.929	43.011	1.613	24.579	50.674	97.987	1
2025-01-02 00:55:00	9	414.900	43.852	0.758	1452.935	40.798	70.195	53.796	3.231	29.232	53.826	96.334	0
2025-01-02 01:00:00	5	381.533	50.623	0.825	1458.761	75.599	56.874	55.400	2.449	32.605	62.084	97.375	0
2025-01-02 01:05:00	8	409.985	36.919	0.838	1386.625	69.578	54.073	50.294	2.115	22.534	62.508	100.000	0
2025-01-02 01:10:00	1	403.178	58.917	0.854	1497.700	35.484	76.423	48.999	1.973	20.596	41.952	93.473	0
2025-01-02 01:15:00	5	392.655	40.448	0.775	1447.368	87.897	51.580	50.607	0.934	27.114	48.139	98.474	0
2025-01-02 01:20:00	3	419.404	61.663	0.706	1512.559	64.034	67.785	49.613	0.915	19.917	40.782	93.594	0
2025-01-02 01:25:00	1	375.901	40.724	0.819	1380.379	82.713	54.322	62.448	1.453	19.028	56.092	100.000	1
2025-01-02 01:30:00	4	422.951	59.752	0.764	1497.150	69.114	47.848	48.574	1.729	22.216	34.864	96.358	1
2025-01-02 01:35:00	5	385.430	41.690	0.795	1487.191	34.396	56.696	41.839	2.324	20.774	32.809	95.971	0
2025-01-02 01:40:00	7	435.631	43.854	0.807	1472.752	75.010	83.558	61.286	2.404	20.131	42.796	94.007	0
2025-01-02 01:45:00	1	379.894	49.982	0.828	1549.910	79.928	45.562	62.313	2.000	25.780	20.000	93.948	0
2025-01-02 01:50:00	3	392.969	41.521	0.845	1459.770	93.411	52.996	54.037	2.162	26.427	20.000	97.712	0
2025-01-02 01:55:00	2	401.172	41.226	0.858	1515.187	88.379	72.291	45.978	1.910	18.121	55.388	93.012	0
2025-01-02 02:00:00	9	401.046	41.637	0.866	1468.408	93.966	50.602	39.486	2.548	26.948	56.691	97.519	1
2025-01-02 02:05:00	10	409.817	53.189	0.805	1582.952	84.727	53.981	55.279	1.635	25.924	34.840	91.454	0
2025-01-02 02:10:00	6	374.286	49.996	0.716	1493.152	60.167	61.347	59.101	1.843	19.938	47.131	95.208	0
2025-01-02 02:15:00	10	399.254	50.526	0.770	1533.790	60.639	57.751	48.497	2.096	25.138	71.762	93.535	0
2025-01-02 02:20:00	3	402.763	46.754	0.870	1530.485	89.779	65.089	61.416	1.614	26.348	47.005	92.967	0
2025-01-02 02:25:00	8	389.445	55.487	0.807	1557.281	62.232	57.373	43.547	1.254	26.844	68.180	92.399	0
2025-01-02 02:30:00	8	408.081	60.501	0.909	1507.304	80.597	60.058	55.572	2.178	29.454	39.020	94.629	0
2025-01-02 02:35:00	2	373.073	55.756	0.781	1434.127	104.187	58.693	38.728	3.126	29.089	51.743	98.424	1
2025-01-02 02:40:00	6	393.471	47.910	0.916	1522.149	57.642	51.824	47.409	2.056	25.220	56.304	94.710	0
2025-01-02 02:45:00	7	384.936	37.792	0.800	1513.857	84.566	41.498	40.983	2.374	20.545	41.673	96.157	0
2025-01-02 02:50:00	2	393.531	30.229	0.779	1348.191	53.939	79.219	59.513	1.831	22.628	44.513	100.000	0
2025-01-02 02:55:00	10	428.941	49.351	0.764	1416.404	81.728	51.715	57.729	2.199	26.052	46.612	100.000	0
2025-01-02 03:00:00	2	429.329	30.068	0.833	1535.297	102.274	52.313	74.591	1.293	31.460	36.927	94.004	0
2025-01-02 03:05:00	10	425.408	48.007	0.729	1571.020	96.775	61.984	56.554	1.460	13.515	52.200	91.251	0

2025-01-02 03:10:00	1	390.755	64.026	0.773	1495.865	62.298	49.656	51.562	2.305	25.516	67.185	96.241	0
2025-01-02 03:15:00	8	418.152	38.465	0.797	1540.462	101.475	69.157	46.749	1.881	24.268	66.722	92.061	0
2025-01-02 03:20:00	1	402.247	37.139	0.687	1505.458	65.505	62.546	62.886	1.167	26.386	78.486	94.472	0
2025-01-02 03:25:00	9	400.912	56.369	0.795	1501.820	115.770	57.288	76.143	1.790	18.128	42.802	95.180	0
2025-01-02 03:30:00	6	398.453	21.943	0.886	1492.841	70.648	55.003	63.072	2.461	29.570	41.436	95.858	0
2025-01-02 03:35:00	7	435.168	53.818	0.822	1504.036	83.257	47.995	56.694	1.687	24.900	58.481	95.999	0
2025-01-02 03:40:00	10	427.317	64.685	0.767	1519.420	82.649	63.133	55.558	0.866	23.679	70.082	93.716	0
2025-01-02 03:45:00	7	414.898	41.275	0.776	1479.914	48.122	61.362	41.947	2.878	26.986	65.612	95.868	0
2025-01-02 03:50:00	10	396.594	39.558	0.817	1562.335	97.525	53.540	62.038	2.057	26.623	59.344	92.529	0
2025-01-02 03:55:00	3	400.791	55.900	0.774	1449.990	74.391	65.241	49.255	2.814	25.128	37.417	96.976	0
2025-01-02 04:00:00	2	410.611	38.293	0.823	1585.057	58.882	75.805	45.387	2.176	22.255	38.542	89.167	0
2025-01-02 04:05:00	9	389.568	58.108	0.773	1489.225	54.974	60.147	53.502	1.675	23.917	57.339	95.524	0
2025-01-02 04:10:00	8	418.766	39.107	0.749	1497.398	57.946	57.528	48.768	2.177	25.133	55.956	95.377	0
2025-01-02 04:15:00	10	381.575	67.684	0.859	1468.617	68.461	50.394	47.609	2.159	34.109	47.535	97.530	0
2025-01-02 04:20:00	7	407.837	56.623	0.835	1520.471	48.656	58.409	51.089	2.917	25.570	56.662	94.136	0
2025-01-02 04:25:00	9	354.206	50.380	0.706	1481.167	53.672	55.806	39.875	2.643	28.332	51.120	96.361	1
2025-01-02 04:30:00	4	388.988	67.108	0.783	1476.229	35.437	49.535	52.916	2.343	29.315	61.300	97.235	0
2025-01-02 04:35:00	4	441.554	60.315	0.852	1530.649	53.814	64.512	56.928	2.192	25.120	41.337	93.016	0
2025-01-02 04:40:00	1	420.724	53.686	0.792	1558.059	97.288	62.734	47.083	2.040	31.849	28.552	91.824	0
2025-01-02 04:45:00	8	430.709	31.368	0.771	1447.895	94.025	60.764	65.778	1.710	16.593	30.714	97.529	0
2025-01-02 04:50:00	3	386.654	42.985	0.787	1541.279	75.401	56.378	50.422	2.538	26.562	39.093	93.298	0
2025-01-02 04:55:00	7	402.075	60.854	0.806	1562.395	112.126	69.214	46.377	1.789	30.534	41.275	90.959	0
2025-01-02 05:00:00	2	425.640	36.999	0.791	1411.750	94.297	42.497	61.535	1.879	27.578	49.466	100.000	0
2025-01-02 05:05:00	2	412.662	42.343	0.796	1457.696	78.694	42.969	55.516	2.034	16.062	37.169	98.818	0
2025-01-02 05:10:00	7	410.171	39.779	0.793	1561.192	80.870	62.255	65.735	1.687	26.446	33.398	91.715	0
2025-01-02 05:15:00	6	432.612	54.024	0.751	1518.658	71.776	72.644	67.859	1.776	24.797	26.946	92.803	0
2025-01-02 05:20:00	3	379.191	59.636	0.749	1585.465	44.813	61.205	43.948	2.001	25.344	52.725	90.606	0
2025-01-02 05:25:00	9	396.315	59.646	0.746	1491.135	64.670	61.271	72.811	1.960	23.426	49.619	95.316	0
2025-01-02 05:30:00	10	364.918	41.472	0.805	1473.698	18.108	49.528	36.188	2.728	29.223	52.843	97.362	1
2025-01-02 05:35:00	6	378.098	53.887	0.829	1568.068	48.112	38.555	44.854	1.236	24.289	42.851	93.741	0

2025-01-02 05:40:00	10	421.484	41.001	0.753	1458.219	97.760	50.254	44.306	2.281	31.407	76.790	98.064	0
2025-01-02 05:45:00	10	381.653	47.895	0.725	1487.797	71.548	66.443	65.789	1.759	25.770	32.286	94.966	0
2025-01-02 05:50:00	6	414.710	55.202	0.756	1527.974	48.678	44.275	59.153	1.826	22.030	50.858	95.174	0
2025-01-02 05:55:00	1	433.170	60.614	0.870	1532.923	80.541	51.481	57.211	0.811	34.659	20.000	94.206	0
2025-01-02 06:00:00	4	396.441	28.506	0.784	1460.117	82.087	44.338	35.723	1.627	21.050	56.002	98.560	0
2025-01-02 06:05:00	10	410.397	50.986	0.789	1513.034	100.841	50.948	54.818	2.260	23.326	38.404	95.254	1
2025-01-02 06:10:00	6	414.866	64.073	0.760	1485.455	105.566	71.400	74.506	1.654	26.648	29.856	94.587	0
2025-01-02 06:15:00	6	375.570	52.322	0.829	1415.864	85.624	53.941	59.125	1.762	17.585	56.705	99.813	0
2025-01-02 06:20:00	5	387.671	50.826	0.794	1476.946	39.707	69.144	52.375	1.848	26.004	31.724	95.238	0
2025-01-02 06:25:00	1	379.927	44.370	0.764	1418.286	115.607	54.190	63.650	2.101	22.031	37.415	99.667	0
2025-01-02 06:30:00	8	389.266	63.808	0.748	1467.027	97.068	74.412	56.166	2.831	36.316	64.548	95.207	0
2025-01-02 06:35:00	5	414.322	44.832	0.819	1439.920	86.984	63.491	51.001	1.963	23.795	52.249	97.655	0
2025-01-02 06:40:00	5	388.096	48.999	0.813	1538.691	69.667	55.393	49.566	3.445	19.973	44.151	93.526	0
2025-01-02 06:45:00	7	399.297	45.298	0.738	1515.018	39.003	58.382	59.338	3.293	26.739	52.040	94.411	0
2025-01-02 06:50:00	4	379.151	51.082	0.861	1576.931	58.799	45.585	52.750	2.820	25.527	43.808	92.595	0
2025-01-02 06:55:00	6	424.528	64.257	0.768	1453.912	68.982	54.890	56.337	2.509	29.056	59.578	97.815	0
2025-01-02 07:00:00	4	389.098	40.939	0.689	1506.164	61.982	74.206	36.410	2.173	20.684	47.522	93.271	0
2025-01-02 07:05:00	3	430.460	51.126	0.876	1444.851	91.869	63.593	54.124	2.759	32.673	35.684	97.398	0
2025-01-02 07:10:00	7	401.219	53.911	0.795	1468.421	68.470	39.122	46.519	3.056	26.842	27.612	98.667	0
2025-01-02 07:15:00	8	371.860	41.877	0.822	1480.027	54.467	58.289	63.297	2.056	21.356	66.796	96.170	1
2025-01-02 07:20:00	4	396.579	49.410	0.884	1598.682	80.015	61.681	46.527	2.134	25.586	28.760	89.898	0
2025-01-02 07:25:00	2	378.744	68.513	0.750	1518.195	53.416	67.506	48.878	2.386	28.197	61.142	93.340	0
2025-01-02 07:30:00	10	411.787	32.315	0.824	1493.612	37.365	56.251	44.181	1.949	27.479	36.859	95.694	0
2025-01-02 07:35:00	3	394.773	45.788	0.859	1553.950	80.189	58.800	61.631	2.739	18.938	40.029	92.423	0
2025-01-02 07:40:00	1	403.264	52.506	0.753	1533.650	68.550	70.327	59.136	1.384	15.329	68.567	92.285	0
2025-01-02 07:45:00	8	392.613	46.241	0.873	1497.196	73.136	57.567	46.228	2.172	18.193	39.768	95.383	0
2025-01-02 07:50:00	3	388.893	78.862	0.730	1533.760	97.525	52.713	47.593	1.406	26.088	45.804	94.041	0
2025-01-02 07:55:00	10	380.528	55.487	0.795	1484.712	75.020	68.357	61.342	1.981	26.897	67.344	94.929	0
2025-01-02 08:00:00	7	416.724	39.556	0.746	1649.282	81.384	68.544	71.343	1.632	11.673	59.052	86.681	0
2025-01-02 08:05:00	10	396.537	26.632	0.835	1561.001	70.343	38.392	58.583	1.972	26.417	59.858	94.111	0

2025-01-02 08:10:00	5	393.706	53.403	0.752	1479.670	86.200	62.589	64.186	1.162	21.295	37.559	95.758	0
2025-01-02 08:15:00	10	396.036	42.444	0.769	1537.962	27.354	49.926	52.888	2.299	18.915	36.780	94.109	0
2025-01-02 08:20:00	5	386.423	62.889	0.756	1527.445	54.513	63.999	46.501	1.808	21.888	58.262	93.228	0
2025-01-02 08:25:00	7	393.773	47.251	0.740	1514.155	62.277	69.526	53.660	2.531	25.280	49.982	93.340	0
2025-01-02 08:30:00	9	404.113	44.316	0.762	1525.739	60.411	66.192	63.687	1.973	24.536	49.219	93.094	0
2025-01-02 08:35:00	5	379.317	44.148	0.798	1459.378	54.168	67.179	50.470	2.421	13.809	31.484	96.313	0
2025-01-02 08:40:00	1	382.213	59.865	0.795	1478.247	68.360	53.396	52.229	1.767	32.254	39.467	96.748	0
2025-01-02 08:45:00	10	427.566	54.156	0.789	1582.935	67.286	55.424	72.799	2.400	28.231	24.270	91.311	0
2025-01-02 08:50:00	10	392.745	67.560	0.767	1510.201	68.350	65.927	69.111	3.054	25.760	51.824	93.897	0
2025-01-02 08:55:00	1	388.969	47.849	0.782	1464.987	74.009	60.709	56.146	1.618	16.466	56.335	96.680	0
2025-01-02 09:00:00	2	373.123	58.623	0.721	1492.991	79.956	44.566	64.435	2.405	20.880	63.774	96.894	1
2025-01-02 09:05:00	6	417.014	58.794	0.765	1473.291	54.481	68.914	45.489	1.378	24.667	28.282	95.444	0
2025-01-02 09:10:00	9	378.881	56.738	0.789	1544.886	59.553	45.366	60.320	1.931	28.870	60.090	94.219	0
2025-01-02 09:15:00	8	399.694	44.901	0.815	1471.958	88.455	63.248	55.855	1.076	30.401	48.911	96.077	0
2025-01-02 09:20:00	5	365.836	54.734	0.809	1502.207	51.161	62.073	58.372	2.332	37.512	65.527	94.682	0
2025-01-02 09:25:00	1	416.363	49.028	0.739	1466.874	53.841	71.816	44.244	1.704	25.752	22.953	95.475	1
2025-01-02 09:30:00	7	423.537	48.765	0.821	1610.395	54.541	57.642	42.600	2.374	21.734	73.544	89.716	1
2025-01-02 09:35:00	5	409.690	41.942	0.806	1531.461	66.002	39.710	50.517	2.152	28.752	46.776	95.456	0
2025-01-02 09:40:00	6	369.310	28.797	0.872	1529.480	89.963	61.433	44.064	1.880	20.053	52.900	93.383	1
2025-01-02 09:45:00	7	416.775	62.484	0.725	1534.891	80.478	63.326	47.405	2.389	26.786	37.471	92.923	0
2025-01-02 09:50:00	3	383.453	54.316	0.793	1480.269	52.541	70.736	75.688	2.531	35.739	35.156	94.913	0
2025-01-02 09:55:00	10	376.581	36.568	0.852	1576.063	106.265	54.721	64.853	1.790	23.468	57.483	91.725	0
2025-01-02 10:00:00	3	392.331	57.177	0.785	1496.616	56.087	67.032	57.771	2.550	21.839	44.899	94.466	0
2025-01-02 10:05:00	5	391.933	62.681	0.754	1588.640	37.576	68.970	58.601	1.887	18.053	74.244	89.671	0
2025-01-02 10:10:00	6	389.899	57.777	0.759	1483.760	106.484	52.678	58.336	0.629	25.732	45.575	96.544	1
2025-01-02 10:15:00	9	425.473	41.084	0.839	1535.774	53.263	63.170	53.473	2.108	17.513	62.464	92.894	0
2025-01-02 10:20:00	5	440.237	42.680	0.723	1508.341	67.782	45.280	57.589	1.676	19.485	46.648	96.055	0
2025-01-02 10:25:00	1	372.617	44.521	0.783	1513.382	67.320	65.641	62.576	1.808	18.264	20.000	93.767	0
2025-01-02 10:30:00	4	386.223	58.611	0.756	1416.499	81.635	62.224	53.154	0.991	30.253	43.600	98.953	1
2025-01-02 10:35:00	5	402.855	54.790	0.760	1450.840	33.260	47.613	66.551	2.150	24.193	61.116	98.697	0

2025-01-02 10:40:00	10	392.226	77.903	0.822	1575.498	63.986	56.031	53.053	1.655	31.819	52.169	91.622	0
2025-01-02 10:45:00	10	407.988	33.591	0.780	1435.559	62.665	70.849	47.061	1.738	26.081	42.354	97.137	0
2025-01-02 10:50:00	5	418.320	49.474	0.812	1544.602	98.274	61.998	57.099	2.529	22.738	53.285	92.570	0
2025-01-02 10:55:00	7	414.987	30.722	0.738	1629.999	59.129	53.172	53.460	0.946	28.097	69.020	89.183	0
2025-01-02 11:00:00	4	412.195	55.966	0.841	1527.651	63.585	52.322	52.957	2.186	28.208	65.896	94.385	0
2025-01-02 11:05:00	1	433.182	60.669	0.811	1606.337	85.203	70.032	62.041	2.196	30.993	28.128	88.680	0
2025-01-02 11:10:00	5	368.221	64.421	0.862	1534.606	80.228	55.090	52.093	2.119	20.584	50.372	93.761	0
2025-01-02 11:15:00	7	429.602	51.885	0.780	1513.143	55.519	62.206	47.534	2.553	25.079	52.467	94.122	0
2025-01-02 11:20:00	10	391.740	30.867	0.822	1518.732	78.568	55.870	51.877	2.442	19.205	33.516	94.476	0
2025-01-02 11:25:00	10	415.703	49.499	0.839	1491.131	55.252	37.878	49.084	2.065	26.216	38.119	97.656	0
2025-01-02 11:30:00	6	379.407	54.368	0.821	1489.595	86.065	53.468	48.993	1.624	11.513	35.524	96.174	1
2025-01-02 11:35:00	5	381.830	39.949	0.885	1473.742	66.796	71.380	62.829	1.776	20.035	36.562	95.175	1
2025-01-02 11:40:00	4	413.242	47.350	0.717	1521.160	44.867	81.439	46.821	1.988	21.207	26.979	91.798	1
2025-01-02 11:45:00	2	361.425	37.230	0.809	1610.019	27.134	52.266	55.949	0.834	24.902	47.097	90.272	0
2025-01-02 11:50:00	4	419.789	43.873	0.780	1571.224	62.480	63.333	52.342	1.750	30.136	60.414	91.105	0
2025-01-02 11:55:00	10	425.199	59.125	0.776	1510.244	54.326	83.287	54.120	2.598	16.290	40.556	92.159	0
2025-01-02 12:00:00	10	403.556	56.802	0.875	1530.710	65.208	72.010	38.707	1.804	29.254	74.504	92.264	1
2025-01-02 12:05:00	3	402.835	36.048	0.769	1495.730	69.015	47.877	60.151	2.404	26.682	69.240	96.426	1
2025-01-02 12:10:00	10	383.327	42.950	0.843	1571.073	31.725	57.354	52.755	2.436	27.071	45.278	91.711	1
2025-01-02 12:15:00	1	413.489	50.571	0.747	1418.385	55.403	62.577	62.772	2.606	23.610	46.094	98.823	0
2025-01-02 12:20:00	8	406.953	52.265	0.851	1596.530	67.413	72.727	58.198	1.841	28.600	68.939	88.901	1
2025-01-02 12:25:00	5	381.570	43.371	0.799	1472.738	72.001	47.968	55.388	1.874	24.075	39.354	97.566	1
2025-01-02 12:30:00	4	392.170	54.765	0.786	1480.798	85.965	67.742	55.059	2.155	20.543	53.580	95.186	0
2025-01-02 12:35:00	8	396.813	49.647	0.723	1438.864	89.411	67.036	72.916	1.602	24.002	63.965	97.353	0
2025-01-02 12:40:00	7	392.144	24.234	0.786	1507.738	65.227	56.960	48.575	1.650	25.564	42.326	94.917	0
2025-01-02 12:45:00	2	372.742	44.283	0.766	1465.957	67.042	81.441	57.337	2.500	19.814	48.740	94.558	0
2025-01-02 12:50:00	1	413.980	43.998	0.887	1558.174	60.386	50.886	56.911	1.652	12.849	31.103	93.003	0
2025-01-02 12:55:00	4	395.130	56.783	0.803	1533.757	83.115	63.641	42.092	2.255	28.324	32.746	92.948	0
2025-01-02 13:00:00	8	400.307	56.961	0.770	1465.317	62.310	61.994	54.529	2.199	21.225	72.683	96.535	0
2025-01-02 13:05:00	2	388.435	33.279	0.768	1456.152	50.664	63.760	42.540	1.995	12.258	55.699	96.816	0

2025-01-02 13:10:00	3	409.505	54.385	0.732	1467.901	36.750	71.555	54.457	2.134	25.591	60.434	95.449	0
2025-01-02 13:15:00	1	403.974	49.260	0.876	1452.717	51.050	46.573	42.019	2.341	24.187	55.954	98.707	0
2025-01-02 13:20:00	1	424.256	51.264	0.863	1486.023	64.683	61.585	58.051	2.719	18.213	51.820	95.540	0
2025-01-02 13:25:00	3	409.612	43.862	0.797	1457.964	89.591	79.695	44.921	1.530	21.734	42.146	95.132	0
2025-01-02 13:30:00	5	395.946	49.382	0.909	1558.414	70.910	67.982	54.905	1.512	29.837	76.274	91.281	1
2025-01-02 13:35:00	3	385.206	61.503	0.799	1475.083	72.290	53.391	42.004	1.950	17.142	30.719	96.907	0
2025-01-02 13:40:00	1	417.319	51.122	0.855	1528.785	70.067	52.000	58.805	2.177	22.262	32.093	94.361	0
2025-01-02 13:45:00	1	394.348	49.576	0.828	1529.196	95.596	65.178	54.372	2.141	27.173	40.502	93.022	0
2025-01-02 13:50:00	8	396.566	45.208	0.771	1407.344	80.157	55.107	53.528	2.860	17.344	55.885	100.000	0
2025-01-02 13:55:00	10	396.561	60.523	0.809	1535.672	69.706	58.572	56.120	1.521	34.135	52.517	93.359	0
2025-01-02 14:00:00	2	391.968	37.192	0.819	1414.656	58.027	52.565	59.190	1.174	29.303	37.733	100.000	0
2025-01-02 14:05:00	3	396.909	41.980	0.735	1458.308	44.790	80.740	48.126	2.257	33.555	44.874	95.011	0
2025-01-02 14:10:00	2	438.524	36.618	0.814	1533.368	103.049	63.465	54.864	2.112	24.886	43.224	92.985	0
2025-01-02 14:15:00	3	379.044	52.007	0.857	1506.242	86.072	60.528	51.270	1.932	32.605	53.461	94.635	0
2025-01-02 14:20:00	7	383.710	61.797	0.765	1482.978	66.132	43.676	65.416	2.404	25.643	42.959	97.484	0
2025-01-02 14:25:00	1	427.686	46.712	0.789	1410.851	105.879	51.745	51.734	1.183	23.579	74.976	100.000	0
2025-01-02 14:30:00	10	392.504	39.306	0.745	1548.232	69.847	59.391	48.565	1.134	19.361	45.611	92.649	0
2025-01-02 14:35:00	8	390.988	66.364	0.776	1521.705	53.665	59.403	42.964	0.999	26.300	45.708	93.975	0
2025-01-02 14:40:00	10	420.697	54.513	0.780	1457.177	94.433	76.609	52.860	1.645	21.653	60.559	95.480	0
2025-01-02 14:45:00	10	371.596	52.775	0.879	1451.923	44.380	61.238	49.473	2.611	21.433	57.983	97.280	0
2025-01-02 14:50:00	10	416.429	48.098	0.784	1551.344	61.982	70.383	57.891	1.258	25.688	67.030	91.394	0
2025-01-02 14:55:00	2	400.912	56.690	0.773	1515.020	45.987	61.793	56.777	2.019	33.708	64.314	94.070	1
2025-01-02 15:00:00	3	409.296	52.619	0.795	1431.985	54.013	68.610	59.249	2.152	31.575	46.476	97.540	0
2025-01-02 15:05:00	9	408.921	45.187	0.715	1463.480	73.997	43.320	44.927	2.774	29.088	67.170	98.494	0
2025-01-02 15:10:00	7	387.440	46.862	0.682	1597.865	76.744	47.435	33.139	1.569	24.771	43.899	91.363	0
2025-01-02 15:15:00	4	421.024	39.801	0.731	1550.112	47.956	69.238	54.992	1.549	25.417	33.480	91.571	0
2025-01-02 15:20:00	10	388.997	38.554	0.816	1500.029	106.183	74.965	61.585	2.518	32.307	49.387	93.502	0
2025-01-02 15:25:00	5	408.177	47.033	0.800	1501.119	28.217	42.935	51.851	1.464	27.517	55.704	96.651	0
2025-01-02 15:30:00	2	424.754	61.542	0.843	1391.231	72.591	60.122	69.281	2.605	11.671	53.227	100.000	0
2025-01-02 15:35:00	8	427.578	39.658	0.724	1565.331	73.103	45.004	54.012	2.178	37.240	56.746	93.233	0

2025-01-02 15:40:00	4	394.657	58.364	0.790	1477.429	75.270	53.358	49.113	1.117	24.845	38.168	96.793	0
2025-01-02 15:45:00	9	409.263	42.011	0.720	1459.567	87.587	40.992	58.332	2.327	25.259	59.081	98.923	0
2025-01-02 15:50:00	5	392.810	32.134	0.813	1537.499	9.010	58.816	66.048	2.226	25.999	70.695	93.244	0
2025-01-02 15:55:00	9	450.076	55.466	0.731	1468.502	54.519	58.155	54.655	1.879	25.325	38.310	96.759	0
2025-01-02 16:00:00	4	415.603	66.288	0.788	1408.852	73.025	58.034	61.029	1.687	23.995	63.417	99.754	1
2025-01-02 16:05:00	10	401.681	41.443	0.810	1520.490	104.062	57.073	51.618	2.808	17.512	55.756	94.268	0
2025-01-02 16:10:00	5	406.251	34.301	0.780	1424.227	58.364	66.349	51.799	0.776	18.698	60.134	98.154	0
2025-01-02 16:15:00	9	408.142	54.549	0.687	1497.060	66.152	77.145	63.949	1.244	33.573	38.165	93.433	0
2025-01-02 16:20:00	8	408.735	40.768	0.883	1515.880	84.509	47.912	40.828	1.736	21.398	52.064	95.415	0
2025-01-02 16:25:00	3	395.200	55.366	0.775	1486.108	45.809	51.595	46.608	2.242	30.525	50.561	96.535	0
2025-01-02 16:30:00	1	392.113	61.515	0.720	1486.332	70.449	61.294	59.645	1.999	26.425	49.565	95.554	0
2025-01-02 16:35:00	3	396.963	53.306	0.838	1577.546	67.897	57.320	52.251	1.647	13.417	53.499	91.391	0
2025-01-02 16:40:00	4	377.206	58.098	0.840	1578.265	57.816	56.834	57.388	2.265	18.699	58.031	91.403	0
2025-01-02 16:45:00	2	414.365	58.166	0.785	1454.123	80.061	46.876	59.264	1.131	20.961	71.151	98.606	0
2025-01-02 16:50:00	1	383.966	59.899	0.877	1470.262	113.138	55.443	44.455	2.182	28.579	65.287	96.943	0
2025-01-02 16:55:00	7	378.801	50.452	0.763	1473.007	73.474	55.543	44.389	1.850	23.731	63.781	96.795	0
2025-01-02 17:00:00	8	399.713	57.791	0.809	1498.428	25.302	62.188	64.224	2.336	28.633	69.992	94.860	0
2025-01-02 17:05:00	7	397.398	51.644	0.826	1495.901	52.578	50.925	51.911	2.247	23.569	53.013	96.112	0
2025-01-02 17:10:00	5	404.993	53.913	0.876	1585.854	99.586	68.924	49.593	2.381	28.112	36.783	89.815	0
2025-01-02 17:15:00	1	388.636	80.517	0.703	1490.723	65.209	47.353	57.962	1.695	19.668	52.796	96.729	0
2025-01-02 17:20:00	7	392.149	52.416	0.915	1448.487	46.542	75.542	62.835	1.632	22.538	56.672	96.021	0
2025-01-02 17:25:00	7	413.842	35.022	0.859	1470.599	85.091	51.823	61.229	2.097	26.552	62.428	97.288	0
2025-01-02 17:30:00	9	412.624	48.026	0.822	1518.669	57.227	74.423	58.695	1.271	23.507	58.148	92.624	0
2025-01-02 17:35:00	3	411.791	46.895	0.760	1487.144	70.701	52.501	64.261	3.108	25.135	47.337	96.393	0
2025-01-02 17:40:00	9	400.679	47.352	0.756	1515.680	47.366	68.306	59.077	2.804	25.222	68.059	93.385	0
2025-01-02 17:45:00	1	403.378	59.534	0.814	1487.791	61.639	56.352	50.567	1.222	28.910	54.553	95.975	0
2025-01-02 17:50:00	1	404.609	61.306	0.825	1536.240	69.397	60.806	57.097	2.114	25.224	46.870	93.107	1
2025-01-02 17:55:00	4	386.879	48.944	0.818	1495.587	67.984	66.018	61.267	2.591	24.434	23.958	94.619	0
2025-01-02 18:00:00	9	429.481	36.081	0.808	1439.180	77.493	56.664	48.526	1.804	26.648	56.910	98.375	0
2025-01-02 18:05:00	6	426.632	50.991	0.822	1482.657	74.024	40.967	50.459	1.625	27.676	32.555	97.770	0

2025-01-02 18:10:00	3	415.885	44.566	0.691	1610.570	49.631	53.640	56.577	2.590	25.598	34.952	90.107	1
2025-01-02 18:15:00	1	391.483	52.104	0.787	1561.811	103.716	54.945	60.498	2.676	19.506	56.839	92.415	0
2025-01-02 18:20:00	4	410.783	48.790	0.731	1441.917	66.865	77.285	54.814	1.194	29.132	57.162	96.176	1
2025-01-02 18:25:00	9	419.567	62.164	0.798	1588.920	42.989	59.528	57.063	2.059	28.205	33.216	90.601	0
2025-01-02 18:30:00	3	375.536	52.748	0.865	1506.855	25.554	61.706	35.105	1.940	23.352	44.089	94.487	0
2025-01-02 18:35:00	9	433.890	44.598	0.755	1475.581	71.504	58.844	67.794	1.121	27.625	49.021	96.337	0
2025-01-02 18:40:00	7	365.212	36.145	0.765	1485.921	51.475	62.179	61.205	1.197	34.517	62.265	95.486	0
2025-01-02 18:45:00	4	414.092	49.520	0.758	1502.841	81.456	47.622	60.822	1.540	23.671	41.325	96.096	0
2025-01-02 18:50:00	3	429.066	49.556	0.764	1554.203	70.967	53.130	60.138	2.008	24.799	61.634	92.977	0
2025-01-02 18:55:00	10	397.739	47.375	0.828	1509.501	120.000	66.625	60.846	2.646	26.315	37.248	93.862	0
2025-01-02 19:00:00	5	396.991	57.753	0.839	1516.670	44.783	57.768	66.128	0.609	39.605	31.028	94.390	0
2025-01-02 19:05:00	5	413.353	36.172	0.873	1560.567	91.154	58.987	63.952	2.059	25.915	66.289	92.073	0
2025-01-02 19:10:00	3	437.038	42.375	0.750	1480.045	48.208	59.798	58.425	1.524	21.798	71.591	96.018	0
2025-01-02 19:15:00	9	394.379	50.529	0.834	1515.122	86.619	66.881	61.445	2.266	18.519	67.468	93.556	0
2025-01-02 19:20:00	4	384.381	44.405	0.843	1521.944	98.462	53.592	57.222	2.509	23.278	60.581	94.544	0
2025-01-02 19:25:00	5	391.524	46.433	0.883	1506.736	63.112	60.999	48.913	2.524	24.765	51.572	94.563	0
2025-01-02 19:30:00	4	368.950	49.397	0.753	1524.950	55.416	38.468	50.934	1.951	28.039	58.446	95.906	0
2025-01-02 19:35:00	5	417.955	56.860	0.700	1465.440	66.868	43.882	51.637	1.832	25.082	57.849	98.340	0
2025-01-02 19:40:00	7	389.718	48.994	0.786	1549.000	55.140	57.513	53.639	2.666	25.298	76.762	92.799	0
2025-01-02 19:45:00	9	395.833	30.303	0.940	1472.307	102.212	48.948	53.100	1.834	25.958	39.216	97.490	1
2025-01-02 19:50:00	7	418.192	43.972	0.745	1522.733	66.048	69.833	45.761	2.028	25.788	41.353	92.880	1
2025-01-02 19:55:00	5	392.462	54.958	0.824	1510.520	78.791	49.319	56.685	1.769	31.114	36.581	95.542	1
2025-01-02 20:00:00	10	415.182	57.627	0.689	1465.669	79.378	58.722	60.903	2.168	20.294	70.303	96.844	0
2025-01-02 20:05:00	10	379.238	58.179	0.891	1581.123	87.844	68.024	51.276	1.317	34.400	50.155	90.141	0
2025-01-02 20:10:00	7	419.174	61.012	0.706	1585.828	60.960	64.933	52.404	1.853	31.826	39.323	90.215	1
2025-01-02 20:15:00	10	406.838	51.184	0.680	1453.958	85.348	54.553	61.035	2.046	30.081	21.070	97.847	0
2025-01-02 20:20:00	5	398.228	52.632	0.805	1539.965	96.027	56.101	56.515	2.517	20.782	37.705	93.392	0
2025-01-02 20:25:00	3	402.618	39.861	0.806	1493.873	66.886	64.747	62.051	1.914	24.277	53.634	94.832	0
2025-01-02 20:30:00	7	374.265	28.254	0.871	1466.308	43.340	68.069	60.881	0.773	21.336	23.923	95.878	0
2025-01-02 20:35:00	2	402.160	35.824	0.842	1518.425	97.372	74.969	48.672	1.705	20.744	36.444	92.582	0

2025-01-02 20:40:00	9	397.167	42.982	0.700	1541.690	73.473	68.052	56.811	2.729	23.611	50.552	92.110	0
2025-01-02 20:45:00	10	374.811	36.403	0.792	1508.054	70.084	66.854	59.801	2.079	24.312	46.843	93.912	1
2025-01-02 20:50:00	10	386.578	47.071	0.765	1481.825	83.535	63.426	49.429	1.638	23.183	32.268	95.566	0
2025-01-02 20:55:00	1	397.415	45.379	0.733	1566.471	98.584	61.209	45.665	1.496	25.151	37.963	91.556	0
2025-01-02 21:00:00	6	387.854	59.378	0.822	1568.270	65.560	56.291	54.853	2.187	29.141	46.282	91.957	0
2025-01-02 21:05:00	7	351.758	40.309	0.852	1465.855	95.113	64.985	38.212	1.656	28.817	55.398	96.209	0
2025-01-02 21:10:00	8	421.528	51.406	0.760	1504.544	71.442	57.635	28.438	2.014	26.905	58.559	95.009	0
2025-01-02 21:15:00	10	397.158	45.802	0.783	1421.052	82.476	66.965	59.806	1.617	24.594	48.200	98.251	0
2025-01-02 21:20:00	9	354.521	39.934	0.787	1541.767	57.861	67.224	48.921	1.554	23.029	69.344	92.189	0
2025-01-02 21:25:00	2	442.699	42.723	0.767	1566.375	64.923	64.702	52.585	1.807	26.473	42.700	91.211	1
2025-01-02 21:30:00	10	424.828	29.487	0.779	1519.477	91.694	53.777	56.929	1.939	29.929	34.117	94.648	0
2025-01-02 21:35:00	2	393.020	57.483	0.767	1448.231	30.713	59.117	54.676	1.972	31.553	22.897	97.677	0
2025-01-02 21:40:00	5	383.150	64.023	0.806	1580.765	84.009	70.839	48.864	1.861	18.682	59.530	89.878	0
2025-01-02 21:45:00	5	408.064	47.325	0.771	1601.521	77.590	42.931	70.678	2.549	24.593	48.673	91.631	1
2025-01-02 21:50:00	6	404.047	50.291	0.821	1478.406	103.220	61.901	54.372	1.796	20.560	28.030	95.890	0
2025-01-02 21:55:00	3	410.842	47.041	0.770	1522.273	90.122	67.571	77.054	2.720	17.686	53.900	93.129	0
2025-01-02 22:00:00	8	383.208	41.799	0.832	1540.834	73.537	64.346	47.482	1.919	30.743	63.230	92.524	0
2025-01-02 22:05:00	1	421.955	57.049	0.769	1539.369	44.563	80.694	51.986	1.669	31.253	53.788	90.962	0
2025-01-02 22:10:00	6	390.531	53.191	0.830	1502.410	58.388	43.881	55.197	2.148	24.017	40.390	96.491	0
2025-01-02 22:15:00	4	413.615	20.879	0.758	1589.894	65.462	48.164	55.596	2.374	22.703	33.104	91.689	0
2025-01-02 22:20:00	1	384.061	39.654	0.844	1421.735	99.840	61.823	62.920	1.591	23.115	53.656	98.731	0
2025-01-02 22:25:00	7	452.963	29.469	0.711	1422.375	86.015	69.320	36.366	1.283	16.186	50.536	97.949	0
2025-01-02 22:30:00	9	413.910	65.554	0.800	1499.216	54.099	60.574	67.217	2.498	30.459	86.201	94.982	0
2025-01-02 22:35:00	4	457.685	48.282	0.772	1587.178	78.056	73.180	40.002	2.670	22.593	35.133	89.323	0
2025-01-02 22:40:00	4	416.552	52.407	0.798	1557.985	60.825	54.228	48.782	2.269	23.852	55.813	92.678	0
2025-01-02 22:45:00	6	388.771	46.467	0.741	1425.334	57.084	57.271	55.415	1.627	26.495	41.788	99.006	0
2025-01-02 22:50:00	3	416.588	61.027	0.790	1642.172	82.571	67.627	58.282	1.924	14.772	39.832	87.129	1
2025-01-02 22:55:00	6	418.012	58.607	0.745	1527.717	67.112	56.463	53.405	1.401	25.087	33.448	93.968	0
2025-01-02 23:00:00	7	407.466	47.845	0.788	1442.389	46.715	69.369	51.171	2.515	25.656	65.344	96.944	0
2025-01-02 23:05:00	10	412.608	67.180	0.783	1495.394	86.539	66.948	55.058	2.109	22.226	65.120	94.536	0

2025-01-02 23:10:00	10	415.235	51.853	0.816	1548.357	73.040	55.837	51.818	2.225	35.644	62.978	92.998	0
2025-01-02 23:15:00	3	380.126	35.399	0.803	1562.624	62.673	62.996	63.669	2.065	18.953	43.287	91.569	0
2025-01-02 23:20:00	7	378.703	51.000	0.894	1496.701	99.849	55.220	60.534	2.002	27.380	57.415	95.643	0
2025-01-02 23:25:00	3	384.116	55.174	0.775	1526.108	91.282	51.077	58.574	2.104	19.835	68.873	94.587	0
2025-01-02 23:30:00	2	402.551	48.668	0.793	1493.761	72.432	56.087	63.182	2.000	26.369	20.000	95.703	0
2025-01-02 23:35:00	10	395.537	45.885	0.959	1496.707	35.761	58.206	57.785	2.584	19.476	57.616	95.344	0
2025-01-02 23:40:00	4	380.489	67.644	0.789	1536.239	92.210	61.117	53.091	1.299	29.696	63.586	93.076	0
2025-01-02 23:45:00	8	415.506	38.141	0.848	1572.036	60.332	58.913	42.131	1.567	26.742	60.127	91.507	0
2025-01-02 23:50:00	9	405.661	22.363	0.829	1443.127	66.843	42.450	69.907	1.819	16.833	37.629	99.599	0
2025-01-02 23:55:00	7	403.379	66.191	0.917	1488.361	63.945	69.909	63.984	1.907	25.704	37.012	94.591	1
2025-01-03 00:00:00	1	394.840	37.740	0.728	1469.903	44.088	42.977	45.326	2.501	22.394	54.603	98.207	0
2025-01-03 00:05:00	3	392.435	47.134	0.723	1449.600	79.050	61.888	60.859	1.318	24.211	50.659	97.331	0
2025-01-03 00:10:00	9	383.173	46.226	0.744	1447.048	53.147	52.590	58.688	2.271	16.659	62.948	98.389	0
2025-01-03 00:15:00	1	418.675	62.317	0.809	1501.248	78.014	61.460	47.454	1.930	31.989	62.802	94.792	0
2025-01-03 00:20:00	9	385.930	64.349	0.750	1446.372	51.279	57.759	66.082	2.427	20.192	42.273	97.906	0
2025-01-03 00:25:00	8	404.188	37.076	0.693	1444.677	60.913	63.477	56.323	2.197	23.809	26.652	97.418	0
2025-01-03 00:30:00	1	433.240	63.569	0.754	1491.032	77.302	65.205	45.816	1.936	20.590	30.618	94.928	0
2025-01-03 00:35:00	6	393.355	63.384	0.818	1451.028	72.471	70.379	45.259	1.503	23.750	34.566	96.411	0
2025-01-03 00:40:00	5	419.214	50.194	0.755	1525.430	82.434	67.731	58.328	2.171	24.437	42.705	92.955	0
2025-01-03 00:45:00	6	411.374	59.325	0.857	1476.043	83.944	60.414	47.361	1.802	24.575	54.213	96.156	1
2025-01-03 00:50:00	10	406.229	60.328	0.744	1440.274	96.647	69.432	49.120	1.946	32.029	45.382	97.043	0
2025-01-03 00:55:00	5	408.607	47.476	0.801	1616.286	69.985	54.912	58.397	2.391	24.493	32.382	89.695	0
2025-01-03 01:00:00	6	398.102	48.424	0.780	1393.362	94.140	76.809	49.715	2.738	32.972	58.837	98.651	0
2025-01-03 01:05:00	5	400.696	55.893	0.809	1542.815	63.552	54.056	51.241	1.185	17.918	45.678	93.454	0
2025-01-03 01:10:00	5	389.038	33.715	0.814	1517.305	85.557	55.302	48.681	2.393	30.953	40.438	94.605	0
2025-01-03 01:15:00	4	400.829	46.462	0.879	1475.763	92.471	41.830	60.380	2.649	29.925	38.595	98.029	0
2025-01-03 01:20:00	3	388.295	37.996	0.834	1454.614	92.396	53.323	64.908	1.918	30.471	54.308	97.937	0
2025-01-03 01:25:00	3	420.113	64.236	0.779	1586.421	40.824	57.329	41.349	1.423	35.675	46.130	90.946	0
2025-01-03 01:30:00	4	366.010	46.344	0.831	1606.195	7.101	57.277	47.127	2.180	12.323	41.483	89.963	0
2025-01-03 01:35:00	9	409.621	52.764	0.838	1485.359	81.102	76.829	37.028	1.909	14.619	32.846	94.049	0

2025-01-03 01:40:00	2	406.732	47.816	0.902	1478.088	70.050	65.850	56.012	3.756	25.284	41.452	95.511	0
2025-01-03 01:45:00	9	404.920	47.165	0.792	1556.437	75.608	69.390	56.639	2.167	14.536	53.426	91.239	1
2025-01-03 01:50:00	1	420.490	52.110	0.796	1487.700	71.833	60.001	47.402	1.758	15.008	58.664	95.615	0
2025-01-03 01:55:00	1	394.278	42.694	0.866	1529.173	63.215	52.989	51.506	1.265	23.841	63.301	94.242	0
2025-01-03 02:00:00	5	405.109	48.015	0.700	1527.901	81.452	81.789	58.664	1.514	22.535	40.061	91.426	0
2025-01-03 02:05:00	6	365.669	47.942	0.790	1501.866	76.779	58.991	67.417	2.443	15.913	28.051	95.008	0
2025-01-03 02:10:00	6	391.694	45.768	0.835	1508.255	67.904	66.445	49.082	1.133	21.882	58.109	93.943	0
2025-01-03 02:15:00	3	417.115	53.911	0.852	1518.480	70.579	50.525	55.876	1.150	28.745	52.181	95.024	0
2025-01-03 02:20:00	7	373.217	45.530	0.690	1445.571	82.338	48.294	59.367	2.498	27.399	29.683	98.892	1
2025-01-03 02:25:00	9	403.195	66.111	0.733	1466.013	58.116	74.958	69.378	1.812	28.700	60.634	95.204	0
2025-01-03 02:30:00	10	386.450	56.290	0.675	1511.288	47.766	64.325	58.216	1.867	22.643	20.000	94.003	0
2025-01-03 02:35:00	8	397.780	36.507	0.844	1477.286	47.457	57.775	70.273	2.289	31.007	35.273	96.358	0
2025-01-03 02:40:00	6	387.646	55.509	0.810	1638.868	59.829	58.114	43.469	1.880	34.100	74.322	88.245	0
2025-01-03 02:45:00	8	375.056	43.105	0.871	1506.629	99.689	49.649	58.295	1.202	25.968	91.634	95.704	0
2025-01-03 02:50:00	5	407.720	51.357	0.801	1413.090	72.655	54.389	52.846	1.670	22.690	63.614	99.907	0
2025-01-03 02:55:00	8	399.008	42.688	0.912	1359.303	56.420	64.257	54.804	2.235	24.813	45.023	100.000	0
2025-01-03 03:00:00	10	412.253	28.056	0.753	1541.053	74.046	60.456	45.279	2.033	18.760	55.373	92.902	0
2025-01-03 03:05:00	4	415.889	49.783	0.782	1507.063	49.114	67.528	64.781	2.750	23.272	20.000	93.894	0
2025-01-03 03:10:00	10	424.505	35.656	0.821	1572.034	66.283	32.593	59.656	2.206	28.066	43.390	94.139	0
2025-01-03 03:15:00	8	402.670	54.197	0.764	1467.800	61.792	61.743	56.707	1.569	26.767	25.754	96.436	0
2025-01-03 03:20:00	10	425.372	51.748	0.821	1493.971	43.534	67.798	41.292	2.703	27.475	66.663	94.522	0
2025-01-03 03:25:00	2	380.485	43.961	0.794	1513.961	91.865	37.938	62.307	2.737	16.890	61.722	96.508	0
2025-01-03 03:30:00	5	418.179	68.255	0.792	1492.247	62.467	49.660	49.682	1.648	28.477	59.284	96.422	0
2025-01-03 03:35:00	9	409.188	37.607	0.794	1488.113	69.231	45.540	48.728	2.281	22.256	62.004	97.040	0
2025-01-03 03:40:00	4	404.662	43.757	0.835	1536.280	83.936	72.965	42.939	2.333	23.877	41.788	91.889	0
2025-01-03 03:45:00	6	408.895	38.793	0.783	1458.311	77.036	60.721	52.335	2.170	21.359	49.410	97.012	0
2025-01-03 03:50:00	1	380.785	70.413	0.744	1526.784	71.544	61.411	50.576	1.311	32.555	39.826	93.520	0
2025-01-03 03:55:00	9	376.065	63.522	0.803	1591.425	65.239	71.345	65.733	3.494	18.373	50.560	89.294	1
2025-01-03 04:00:00	1	434.197	35.779	0.768	1582.757	84.564	58.892	46.970	1.786	24.488	48.552	90.973	0
2025-01-03 04:05:00	5	396.626	41.744	0.750	1409.706	69.856	53.501	49.249	2.180	18.404	55.533	100.000	0

2025-01-03 04:10:00	4	396.340	42.083	0.713	1475.511	72.884	61.712	50.277	2.459	29.830	33.574	96.053	0
2025-01-03 04:15:00	3	377.954	44.493	0.847	1514.529	92.258	64.302	48.449	1.793	25.643	50.163	93.843	0
2025-01-03 04:20:00	6	370.364	39.572	0.833	1563.895	93.391	48.692	44.377	2.620	19.503	49.957	92.936	0
2025-01-03 04:25:00	2	398.234	43.942	0.870	1510.495	75.374	75.664	60.194	2.000	25.398	52.760	92.909	0
2025-01-03 04:30:00	3	393.168	60.049	0.800	1563.989	72.092	41.068	53.616	1.682	20.862	36.076	93.694	0
2025-01-03 04:35:00	5	400.035	69.469	0.854	1466.531	83.116	63.265	50.685	1.286	29.172	40.850	96.347	0
2025-01-03 04:40:00	9	401.743	34.556	0.753	1516.490	64.967	76.737	49.788	1.811	35.149	37.577	92.502	0
2025-01-03 04:45:00	2	449.789	39.589	0.705	1517.748	65.019	61.210	56.006	2.182	18.357	79.240	93.992	0
2025-01-03 04:50:00	10	393.228	52.136	0.762	1565.667	68.746	39.451	49.847	1.842	32.004	67.930	93.772	0
2025-01-03 04:55:00	8	431.599	34.197	0.790	1545.428	49.631	74.866	54.455	2.327	31.112	49.000	91.242	0
2025-01-03 05:00:00	2	432.840	52.394	0.818	1534.500	117.248	55.188	58.820	2.828	23.352	56.672	93.756	0
2025-01-03 05:05:00	5	415.072	55.401	0.864	1542.466	62.006	67.809	57.755	1.848	28.566	73.031	92.096	0
2025-01-03 05:10:00	7	395.297	57.007	0.816	1439.520	79.353	64.189	66.502	2.572	26.224	74.043	97.605	0
2025-01-03 05:15:00	8	372.771	55.121	0.913	1491.427	69.661	59.838	62.827	2.090	24.786	55.977	95.445	0
2025-01-03 05:20:00	1	409.559	44.648	0.806	1449.755	83.759	39.411	57.644	2.154	22.569	37.571	99.571	0
2025-01-03 05:25:00	6	420.376	48.183	0.805	1467.344	62.319	64.070	58.054	2.006	28.504	68.114	96.226	0
2025-01-03 05:30:00	1	434.954	38.205	0.817	1491.313	74.336	67.381	70.684	2.197	22.367	53.505	94.696	0
2025-01-03 05:35:00	2	381.001	54.643	0.819	1387.180	52.996	43.990	48.615	1.591	29.989	44.911	100.000	0
2025-01-03 05:40:00	1	395.129	66.034	0.818	1493.116	94.284	76.746	58.979	1.635	20.697	60.163	93.670	1
2025-01-03 05:45:00	5	381.123	54.622	0.738	1460.859	83.231	56.138	48.100	1.700	35.447	40.339	97.343	0
2025-01-03 05:50:00	10	387.330	43.050	0.843	1447.195	41.673	78.164	61.669	1.125	19.311	26.980	95.824	1
2025-01-03 05:55:00	9	413.288	59.948	0.925	1504.793	70.283	66.670	60.108	1.394	39.155	69.139	94.093	1
2025-01-03 06:00:00	6	386.414	73.656	0.756	1480.563	42.190	60.237	53.036	1.954	23.237	56.729	95.948	0
2025-01-03 06:05:00	1	383.515	52.431	0.798	1517.075	54.010	61.048	65.382	1.713	28.890	62.400	94.041	1
2025-01-03 06:10:00	1	415.940	55.545	0.731	1467.559	88.420	69.848	55.482	1.977	29.935	22.308	95.637	0
2025-01-03 06:15:00	2	409.015	56.777	0.838	1491.220	20.279	75.280	57.685	2.313	25.908	56.274	93.911	0
2025-01-03 06:20:00	9	407.000	33.955	0.838	1622.934	90.905	50.281	42.073	2.124	30.622	54.356	89.825	0
2025-01-03 06:25:00	3	386.942	45.889	0.725	1531.155	77.576	54.014	73.022	1.945	21.991	44.830	94.041	1
2025-01-03 06:30:00	1	425.860	44.861	0.734	1457.696	68.398	76.580	46.740	1.077	18.855	44.959	95.457	1
2025-01-03 06:35:00	5	400.290	58.349	0.696	1561.972	87.558	51.178	45.052	2.025	25.258	42.411	92.784	0

2025-01-03 06:40:00	7	447.604	57.184	0.879	1577.420	120.000	60.221	59.970	1.662	28.867	73.625	91.107	0
2025-01-03 06:45:00	6	403.223	48.793	0.758	1529.934	43.415	53.127	56.371	2.346	22.084	62.577	94.191	0
2025-01-03 06:50:00	1	353.333	44.261	0.793	1460.902	103.870	67.392	42.737	1.601	26.432	46.065	96.216	0
2025-01-03 06:55:00	5	352.442	33.134	0.782	1551.649	89.328	35.363	48.141	1.428	18.436	40.365	94.881	0
2025-01-03 07:00:00	5	412.479	49.846	0.849	1471.134	55.904	67.347	51.766	2.710	26.249	49.671	95.709	0
2025-01-03 07:05:00	6	426.010	40.454	0.833	1567.542	80.496	71.604	49.054	1.098	22.846	49.875	90.463	0
2025-01-03 07:10:00	3	384.323	39.215	0.830	1487.954	47.758	66.575	56.571	2.845	25.921	34.354	94.945	0
2025-01-03 07:15:00	5	442.020	59.263	0.759	1486.024	60.148	51.686	62.447	2.053	25.587	66.594	96.530	1
2025-01-03 07:20:00	7	433.260	58.219	0.834	1526.203	27.899	24.567	72.586	1.832	20.289	46.141	97.233	0
2025-01-03 07:25:00	5	404.211	45.114	0.846	1570.513	43.028	53.225	42.755	1.784	25.735	51.086	92.152	0
2025-01-03 07:30:00	5	410.789	34.310	0.833	1618.411	77.634	66.518	54.471	2.440	22.375	62.140	88.428	0
2025-01-03 07:35:00	5	417.891	41.742	0.736	1501.351	79.404	59.754	55.677	2.109	29.623	73.645	94.957	1
2025-01-03 07:40:00	10	437.800	59.933	0.744	1479.516	79.183	68.788	55.569	2.087	29.682	51.671	95.145	0
2025-01-03 07:45:00	10	413.643	54.677	0.887	1458.966	82.724	57.788	56.595	1.967	26.028	28.624	97.273	0
2025-01-03 07:50:00	3	403.759	45.282	0.897	1425.906	72.369	57.282	55.664	1.770	25.480	58.907	98.977	1
2025-01-03 07:55:00	1	413.446	50.588	0.797	1449.698	83.567	76.002	64.291	2.625	28.730	52.419	95.915	0
2025-01-03 08:00:00	5	410.747	29.252	0.796	1511.782	91.462	53.095	58.098	1.763	29.733	42.006	95.101	0
2025-01-03 08:05:00	9	418.488	28.495	0.808	1552.733	74.928	66.466	42.901	1.359	32.774	55.761	91.717	0
2025-01-03 08:10:00	1	368.600	69.771	0.829	1454.813	61.312	67.841	44.460	2.153	23.768	40.305	96.475	1
2025-01-03 08:15:00	3	406.317	55.065	0.728	1539.357	67.092	83.714	62.261	1.284	18.711	26.920	90.661	0
2025-01-03 08:20:00	4	409.209	50.017	0.812	1456.905	53.275	76.557	58.944	2.737	29.808	51.984	95.499	0
2025-01-03 08:25:00	1	398.543	46.030	0.748	1462.983	87.028	65.490	52.792	2.206	32.909	35.854	96.302	0
2025-01-03 08:30:00	1	415.683	32.382	0.799	1446.523	37.891	67.097	58.778	0.942	25.354	45.853	96.964	0
2025-01-03 08:35:00	8	438.423	59.932	0.756	1566.592	66.813	72.619	59.895	2.190	24.754	58.720	90.409	0
2025-01-03 08:40:00	2	402.764	38.631	0.768	1580.320	81.383	53.584	63.087	1.813	33.000	20.000	91.626	0
2025-01-03 08:45:00	8	413.834	57.042	0.809	1463.544	49.598	77.614	53.150	2.637	19.606	44.419	95.061	0
2025-01-03 08:50:00	7	432.125	51.320	0.769	1459.543	42.040	59.688	61.375	1.930	23.495	35.704	97.054	0
2025-01-03 08:55:00	10	403.231	49.479	0.745	1531.129	24.407	66.817	53.978	1.941	21.821	27.539	92.762	0
2025-01-03 09:00:00	10	382.231	36.976	0.873	1586.402	64.313	63.615	43.210	1.800	25.143	50.521	90.318	0
2025-01-03 09:05:00	2	412.316	37.109	0.746	1580.696	47.130	52.430	58.104	1.852	30.181	42.388	91.722	0

2025-01-03 09:10:00	6	355.967	53.899	0.684	1480.747	87.535	56.190	65.130	0.958	18.780	59.204	96.344	0
2025-01-03 09:15:00	6	354.033	50.792	0.828	1490.823	38.969	52.026	61.236	1.715	30.165	56.108	96.256	0
2025-01-03 09:20:00	3	406.660	50.472	0.786	1438.423	80.573	62.193	64.595	1.498	20.840	58.302	97.860	0
2025-01-03 09:25:00	2	353.101	52.860	0.799	1480.183	43.959	44.681	56.410	1.790	27.205	21.069	97.523	0
2025-01-03 09:30:00	1	373.697	30.633	0.808	1504.832	39.738	50.110	48.241	2.546	13.598	51.970	95.747	1
2025-01-03 09:35:00	6	392.398	60.151	0.864	1432.511	45.930	55.566	56.545	2.809	14.758	52.581	98.818	0
2025-01-03 09:40:00	5	385.572	46.441	0.893	1472.751	91.507	58.423	52.004	2.105	24.244	31.269	96.520	0
2025-01-03 09:45:00	9	397.044	61.696	0.813	1511.111	45.943	74.558	57.622	1.699	31.339	47.992	92.989	0
2025-01-03 09:50:00	1	422.257	29.917	0.741	1424.001	92.838	69.950	55.470	1.292	30.288	53.498	97.805	0
2025-01-03 09:55:00	7	404.770	55.690	0.807	1523.453	74.053	58.827	63.232	1.754	17.053	50.416	93.945	0
2025-01-03 10:00:00	5	383.214	55.596	0.829	1551.020	59.633	78.144	43.934	1.376	30.545	59.153	90.635	0
2025-01-03 10:05:00	5	427.089	35.139	0.850	1528.502	48.955	63.356	36.302	1.888	27.631	56.772	93.239	0
2025-01-03 10:10:00	2	371.423	43.607	0.807	1475.160	108.089	66.741	55.629	1.970	27.190	59.475	95.568	0
2025-01-03 10:15:00	3	404.438	39.405	0.772	1558.600	58.233	41.089	52.154	2.093	36.431	29.856	93.961	0
2025-01-03 10:20:00	7	369.198	58.632	0.755	1569.372	58.316	50.583	50.847	2.050	21.878	39.055	92.473	0
2025-01-03 10:25:00	6	405.046	53.089	0.794	1515.889	99.023	70.476	49.347	1.037	29.868	43.790	93.158	0
2025-01-03 10:30:00	2	393.627	65.988	0.725	1507.452	102.568	66.548	54.712	1.520	25.192	47.375	93.973	0
2025-01-03 10:35:00	6	421.645	52.030	0.820	1469.015	67.201	77.952	58.300	1.529	33.132	25.476	94.754	0
2025-01-03 10:40:00	2	414.414	57.322	0.809	1479.666	93.685	77.175	59.399	1.777	26.744	47.116	94.299	0
2025-01-03 10:45:00	2	388.257	61.720	0.809	1553.609	57.749	54.693	32.211	2.051	22.404	60.904	92.850	0
2025-01-03 10:50:00	2	384.421	55.544	0.836	1592.469	114.939	71.511	54.171	1.615	21.728	29.361	89.225	0
2025-01-03 10:55:00	3	393.698	46.158	0.873	1479.251	43.775	50.174	40.738	3.580	26.163	27.020	97.020	0
2025-01-03 11:00:00	2	437.511	44.297	0.796	1491.435	51.719	44.120	62.123	2.614	21.040	68.212	97.016	0
2025-01-03 11:05:00	4	432.381	49.203	0.804	1467.638	96.255	63.191	59.976	1.482	10.448	55.651	96.299	0
2025-01-03 11:10:00	9	380.635	57.966	0.782	1478.459	64.215	67.654	46.474	2.664	31.580	78.889	95.312	0
2025-01-03 11:15:00	6	416.005	42.339	0.828	1437.100	97.443	63.347	55.709	2.832	30.659	51.914	97.810	0
2025-01-03 11:20:00	1	365.371	56.522	0.800	1521.458	60.676	69.562	38.974	1.375	25.006	48.139	92.971	0
2025-01-03 11:25:00	8	391.053	53.226	0.858	1436.594	83.185	54.184	58.495	1.408	28.553	38.632	98.752	0
2025-01-03 11:30:00	7	381.449	37.467	0.857	1472.588	56.140	70.188	58.611	2.062	28.828	85.057	95.352	1
2025-01-03 11:35:00	10	421.386	56.035	0.816	1496.944	68.485	54.801	61.065	2.530	25.257	67.809	95.673	0

2025-01-03 11:40:00	3	374.186	51.419	0.796	1434.298	44.390	83.888	59.972	2.163	16.276	57.025	95.896	0
2025-01-03 11:45:00	1	408.587	44.495	0.786	1461.307	69.043	68.561	50.693	1.139	26.732	54.210	96.079	0
2025-01-03 11:50:00	5	400.014	51.274	0.824	1443.732	52.444	75.773	46.768	1.603	23.709	32.558	96.236	0
2025-01-03 11:55:00	4	396.491	44.883	0.824	1554.981	111.451	47.555	49.429	1.706	35.051	50.008	93.495	0
2025-01-03 12:00:00	10	433.432	52.477	0.786	1571.234	63.586	55.793	53.996	2.420	28.296	33.297	91.859	0
2025-01-03 12:05:00	8	435.194	48.320	0.814	1460.534	46.047	59.143	44.889	1.290	28.315	45.319	97.059	0
2025-01-03 12:10:00	1	397.112	34.701	0.761	1638.166	83.837	48.383	52.233	1.370	32.438	51.524	89.253	0
2025-01-03 12:15:00	10	393.082	48.620	0.823	1453.298	45.842	76.146	52.234	2.030	25.555	52.670	95.720	0
2025-01-03 12:20:00	1	369.863	45.573	0.765	1478.837	87.540	60.567	63.942	1.998	34.963	34.597	96.001	0
2025-01-03 12:25:00	4	399.915	56.356	0.839	1524.646	58.842	44.904	58.765	2.451	19.884	57.676	95.277	0
2025-01-03 12:30:00	8	439.066	58.798	0.784	1529.365	69.246	55.033	49.245	1.689	24.437	48.505	94.028	0
2025-01-03 12:35:00	5	397.425	44.910	0.884	1484.049	66.205	48.767	57.334	2.540	31.700	61.289	96.921	0
2025-01-03 12:40:00	2	414.575	42.106	0.802	1554.712	64.925	67.452	58.367	2.457	18.857	58.743	91.519	0
2025-01-03 12:45:00	6	372.050	33.198	0.812	1559.936	71.245	66.070	41.119	1.948	23.236	68.324	91.396	0
2025-01-03 12:50:00	5	391.305	41.860	0.730	1499.616	56.736	66.476	71.606	1.731	27.427	38.081	94.372	0
2025-01-03 12:55:00	2	409.249	46.767	0.870	1492.495	48.160	69.807	53.543	2.843	27.663	79.596	94.395	0
2025-01-03 13:00:00	3	402.117	36.607	0.798	1469.473	70.777	81.972	47.794	2.234	21.804	33.167	94.329	1
2025-01-03 13:05:00	9	416.493	58.931	0.887	1447.988	62.045	78.145	55.161	1.856	32.285	44.769	95.786	0
2025-01-03 13:10:00	7	387.947	52.622	0.802	1459.977	44.421	55.521	47.650	1.515	20.011	52.705	97.449	0
2025-01-03 13:15:00	7	365.000	48.796	0.789	1527.227	82.285	81.294	40.925	2.651	26.104	58.358	91.509	0
2025-01-03 13:20:00	6	422.442	49.833	0.774	1500.035	69.673	57.997	59.506	1.677	21.706	45.434	95.199	0
2025-01-03 13:25:00	8	381.277	53.060	0.832	1487.790	48.266	61.049	55.339	1.731	15.778	48.924	95.506	0
2025-01-03 13:30:00	4	410.132	56.331	0.826	1471.449	65.246	60.711	57.090	1.622	21.508	79.810	96.356	0
2025-01-03 13:35:00	8	409.017	58.090	0.733	1472.530	67.109	66.647	41.468	1.812	23.419	40.185	95.709	0
2025-01-03 13:40:00	4	366.725	46.909	0.772	1497.743	49.384	41.332	58.646	2.200	18.522	34.725	96.980	0
2025-01-03 13:45:00	8	420.983	48.581	0.836	1493.794	120.000	60.249	53.184	1.743	31.207	30.639	95.285	0
2025-01-03 13:50:00	9	388.669	51.730	0.768	1499.948	69.844	62.954	44.973	1.951	25.854	40.809	94.707	0
2025-01-03 13:55:00	3	401.101	48.172	0.759	1477.769	65.602	43.152	47.720	1.647	26.476	20.000	97.796	1
2025-01-03 14:00:00	3	392.836	58.723	0.810	1466.459	118.738	42.966	67.577	2.244	24.563	49.975	98.380	0
2025-01-03 14:05:00	2	432.452	62.273	0.804	1500.421	79.132	51.743	51.503	1.950	24.446	75.493	95.805	0

2025-01-03 14:10:00	10	426.870	53.441	0.777	1532.490	94.175	52.595	67.219	1.384	27.849	49.092	94.116	0
2025-01-03 14:15:00	3	363.753	40.918	0.888	1474.570	71.886	60.429	47.331	1.937	22.522	68.202	96.229	0
2025-01-03 14:20:00	3	445.177	55.084	0.793	1380.632	71.285	58.669	50.406	2.117	13.687	44.198	100.000	0
2025-01-03 14:25:00	5	386.434	53.837	0.737	1431.626	52.894	71.740	51.674	1.794	15.728	76.294	97.245	0
2025-01-03 14:30:00	5	442.049	40.080	0.719	1553.713	83.378	56.200	61.198	0.961	26.562	56.106	92.694	0
2025-01-03 14:35:00	2	394.876	53.826	0.851	1549.687	106.974	56.387	56.986	2.626	23.576	49.505	92.877	1
2025-01-03 14:40:00	10	393.182	44.558	0.745	1532.338	101.542	70.039	56.347	1.497	38.279	35.276	92.379	0
2025-01-03 14:45:00	6	395.053	57.461	0.802	1525.633	45.788	40.973	63.299	2.308	29.509	52.747	95.621	0
2025-01-03 14:50:00	5	391.984	55.003	0.756	1550.885	107.191	77.736	59.852	1.810	26.988	76.664	90.682	0
2025-01-03 14:55:00	6	450.488	52.230	0.795	1482.842	53.452	44.775	44.118	1.952	16.883	21.197	97.380	0
2025-01-03 15:00:00	1	398.473	50.385	0.817	1506.946	51.188	70.209	62.637	1.901	21.708	48.384	93.632	0
2025-01-03 15:05:00	5	393.954	28.666	0.732	1461.412	52.283	68.442	46.435	2.502	29.937	44.478	96.085	0
2025-01-03 15:10:00	9	401.540	37.857	0.777	1491.233	62.179	75.652	62.880	2.117	26.027	29.261	93.873	0
2025-01-03 15:15:00	10	380.653	48.692	0.766	1594.813	31.347	52.856	58.523	2.072	20.274	38.854	90.974	0
2025-01-03 15:20:00	2	431.942	65.194	0.752	1458.669	71.055	60.421	59.546	1.391	19.080	62.249	97.024	0
2025-01-03 15:25:00	1	370.578	55.647	0.781	1441.742	64.809	48.483	51.474	2.749	27.699	41.912	99.065	0
2025-01-03 15:30:00	10	387.720	68.140	0.769	1490.318	70.830	59.387	46.338	1.240	21.823	66.738	95.545	0
2025-01-03 15:35:00	9	418.733	50.830	0.844	1480.006	60.080	58.976	53.788	2.650	22.695	45.202	96.102	0
2025-01-03 15:40:00	10	400.847	49.691	0.764	1513.299	38.160	75.536	57.344	1.087	24.007	48.836	92.781	0
2025-01-03 15:45:00	9	410.984	64.251	0.823	1539.643	64.792	65.376	59.589	2.906	31.929	63.288	92.480	0
2025-01-03 15:50:00	9	430.663	48.408	0.821	1481.274	94.408	59.661	50.874	2.206	23.811	48.096	95.970	0
2025-01-03 15:55:00	6	420.076	40.135	0.725	1605.339	49.797	59.532	49.601	1.742	32.014	54.239	89.780	0
2025-01-03 16:00:00	8	402.750	53.168	0.775	1561.535	52.454	55.409	52.457	1.308	23.058	42.629	92.382	0
2025-01-03 16:05:00	1	441.787	61.225	0.794	1461.824	79.098	57.609	61.391	1.992	17.764	45.496	97.148	0
2025-01-03 16:10:00	10	387.433	41.741	0.813	1496.046	45.240	60.821	40.567	2.229	23.666	61.891	95.116	0
2025-01-03 16:15:00	4	397.994	55.890	0.788	1526.420	74.516	79.389	52.757	2.029	24.964	38.914	91.740	0
2025-01-03 16:20:00	1	399.391	49.068	0.852	1458.554	78.881	64.018	49.448	1.796	16.930	33.749	96.670	0
2025-01-03 16:25:00	8	397.952	54.513	0.805	1396.765	58.740	49.647	58.977	1.636	19.849	45.556	100.000	1
2025-01-03 16:30:00	1	378.616	53.135	0.822	1596.469	55.005	86.080	63.573	2.591	27.867	49.635	87.569	1
2025-01-03 16:35:00	3	368.327	45.857	0.770	1444.650	41.819	70.345	41.961	1.840	22.526	35.290	96.733	0

2025-01-03 16:40:00	4	408.344	48.938	0.823	1542.621	54.179	69.720	57.542	2.185	29.215	71.449	91.897	0
2025-01-03 16:45:00	8	387.331	46.468	0.897	1535.021	81.355	57.840	62.075	2.273	18.029	52.866	93.465	0
2025-01-03 16:50:00	6	438.156	51.187	0.826	1459.208	86.765	67.975	47.147	1.379	20.782	37.839	96.242	1
2025-01-03 16:55:00	10	398.549	41.539	0.855	1597.995	71.273	63.043	62.747	1.949	28.645	57.847	89.796	1
2025-01-03 17:00:00	7	394.970	43.929	0.785	1503.229	57.711	46.407	47.045	2.657	25.554	64.266	96.198	1
2025-01-03 17:05:00	8	421.887	45.860	0.846	1506.888	71.466	64.536	59.740	2.145	16.624	33.574	94.202	0
2025-01-03 17:10:00	2	408.044	53.917	0.851	1423.087	53.634	47.451	64.379	2.223	26.319	57.356	100.000	0
2025-01-03 17:15:00	10	396.490	35.845	0.812	1394.401	73.582	62.980	48.934	1.788	32.090	42.251	99.982	0
2025-01-03 17:20:00	8	387.185	48.929	0.796	1487.871	84.937	63.913	52.885	2.544	24.030	57.177	95.215	0
2025-01-03 17:25:00	3	473.154	42.918	0.725	1564.863	60.693	50.877	63.908	2.976	22.188	81.074	92.669	1
2025-01-03 17:30:00	7	407.236	45.886	0.798	1406.909	53.938	61.176	36.072	1.612	30.208	38.662	99.537	0
2025-01-03 17:35:00	3	421.689	43.398	0.828	1507.268	60.246	65.945	58.896	2.393	22.133	54.086	94.042	0
2025-01-03 17:40:00	7	379.541	51.946	0.762	1504.080	91.750	54.874	69.385	1.312	27.782	20.000	95.309	0
2025-01-03 17:45:00	2	388.440	48.429	0.736	1562.051	120.000	64.572	31.155	2.304	23.541	79.709	91.440	0
2025-01-03 17:50:00	10	442.247	57.116	0.805	1550.824	82.972	72.723	63.619	2.220	19.693	20.000	91.186	0
2025-01-03 17:55:00	6	427.939	54.017	0.812	1507.014	68.537	68.422	61.600	1.428	22.137	52.530	93.807	0
2025-01-03 18:00:00	3	409.152	34.630	0.733	1495.322	50.530	56.901	54.570	2.463	13.744	65.317	95.544	0
2025-01-03 18:05:00	3	392.369	40.400	0.802	1464.007	49.289	74.532	58.279	1.502	28.957	48.728	95.346	0
2025-01-03 18:10:00	9	395.319	48.269	0.814	1442.728	78.553	67.529	56.965	2.966	28.335	44.379	97.111	0
2025-01-03 18:15:00	7	386.478	49.571	0.866	1468.680	54.404	58.309	50.646	2.072	26.184	48.084	96.735	0
2025-01-03 18:20:00	5	376.863	41.282	0.776	1444.659	90.450	53.832	64.897	1.923	22.023	45.370	98.384	0
2025-01-03 18:25:00	10	418.477	63.040	0.904	1494.745	57.934	66.187	54.950	1.666	28.903	25.292	94.644	0
2025-01-03 18:30:00	7	410.777	58.647	0.803	1498.263	98.461	70.854	58.149	2.304	28.111	20.000	94.001	0
2025-01-03 18:35:00	9	414.722	33.553	0.740	1486.266	61.813	71.341	47.320	2.171	28.936	66.953	94.553	0
2025-01-03 18:40:00	1	393.262	53.454	0.783	1505.468	92.669	66.163	36.321	2.071	26.945	37.853	94.110	0
2025-01-03 18:45:00	7	405.113	49.542	0.744	1477.041	83.460	56.590	45.569	1.625	23.818	49.622	96.489	0
2025-01-03 18:50:00	6	391.359	62.439	0.792	1542.083	86.939	65.681	69.633	1.866	23.880	31.121	92.328	0
2025-01-03 18:55:00	10	385.454	34.301	0.823	1511.436	68.629	51.392	60.154	1.631	14.935	45.320	95.289	1
2025-01-03 19:00:00	9	433.341	70.599	0.813	1475.799	56.716	62.900	51.544	1.143	18.868	62.072	95.920	0
2025-01-03 19:05:00	1	402.430	41.571	0.743	1441.673	90.190	77.983	59.579	1.930	27.170	42.149	96.118	0

2025-01-03 19:10:00	4	410.149	53.785	0.737	1495.921	105.863	49.925	58.383	1.443	32.661	69.194	96.211	0
2025-01-03 19:15:00	9	416.715	43.936	0.821	1557.057	49.953	54.465	40.593	3.009	29.133	52.061	92.701	0
2025-01-03 19:20:00	4	402.681	46.238	0.832	1529.472	79.511	69.468	61.799	2.939	23.760	50.439	92.580	0
2025-01-03 19:25:00	10	404.813	33.106	0.776	1537.908	79.435	51.236	39.735	2.177	20.904	54.709	93.981	0
2025-01-03 19:30:00	3	378.267	61.969	0.673	1536.202	73.316	75.347	49.970	1.085	28.436	53.907	91.655	0
2025-01-03 19:35:00	9	382.078	47.304	0.742	1560.783	98.623	69.761	47.159	2.229	25.903	58.779	90.985	0
2025-01-03 19:40:00	2	381.044	47.983	0.849	1543.106	54.489	70.178	56.609	1.891	20.889	47.244	91.827	0
2025-01-03 19:45:00	4	412.109	73.125	0.763	1507.454	91.967	71.379	56.688	2.557	26.130	36.636	93.489	0
2025-01-03 19:50:00	6	401.418	59.594	0.783	1479.646	64.453	47.076	30.959	2.509	28.783	69.204	97.310	0
2025-01-03 19:55:00	2	382.079	43.316	0.828	1543.799	23.271	49.184	64.841	1.622	16.984	64.870	93.892	0
2025-01-03 20:00:00	8	411.602	43.897	0.785	1379.045	40.851	73.201	55.500	1.817	24.480	55.432	99.728	0
2025-01-03 20:05:00	8	410.869	52.598	0.870	1563.370	70.714	56.931	62.703	1.781	31.424	64.269	92.138	0
2025-01-03 20:10:00	1	386.101	57.707	0.781	1534.501	94.402	59.277	55.265	1.791	30.201	31.809	93.347	0
2025-01-03 20:15:00	3	399.443	67.524	0.757	1581.930	91.626	67.079	56.408	1.208	24.888	34.837	90.196	0
2025-01-03 20:20:00	10	410.943	33.919	0.859	1444.020	72.107	61.513	43.525	2.191	19.988	58.268	97.648	0
2025-01-03 20:25:00	9	382.833	57.270	0.802	1558.101	47.094	70.807	48.777	2.041	17.904	30.376	91.014	0
2025-01-03 20:30:00	5	411.325	58.877	0.746	1533.178	45.848	65.785	53.280	1.837	29.437	76.999	92.763	0
2025-01-03 20:35:00	6	406.020	42.105	0.824	1469.626	78.411	58.022	60.568	2.137	22.336	39.741	96.716	0
2025-01-03 20:40:00	4	380.016	46.397	0.785	1493.182	69.155	59.051	51.394	2.163	28.152	27.831	95.436	0
2025-01-03 20:45:00	10	404.396	33.697	0.743	1489.686	89.419	62.583	49.246	2.583	30.790	38.909	95.257	0
2025-01-03 20:50:00	2	407.313	44.991	0.805	1481.752	63.359	63.900	47.773	2.448	21.162	36.447	95.522	0
2025-01-03 20:55:00	8	387.480	52.321	0.792	1432.568	54.561	68.047	57.868	2.516	23.278	51.696	97.567	0
2025-01-03 21:00:00	6	389.054	65.941	0.716	1558.717	64.436	61.656	54.267	1.551	30.753	54.437	91.899	0
2025-01-03 21:05:00	5	379.832	66.864	0.747	1452.683	69.738	59.154	47.938	1.439	24.031	36.306	97.450	0
2025-01-03 21:10:00	9	391.020	39.707	0.893	1447.512	29.345	58.199	53.451	2.476	27.878	50.176	97.804	0
2025-01-03 21:15:00	1	399.758	64.579	0.804	1559.958	79.459	55.679	48.977	2.854	23.369	37.961	92.434	0
2025-01-03 21:20:00	5	389.110	30.507	0.867	1429.865	72.854	76.048	47.173	2.424	19.207	65.338	96.902	1
2025-01-03 21:25:00	6	370.302	44.151	0.815	1484.868	88.941	51.268	42.215	2.165	27.577	34.022	96.630	0
2025-01-03 21:30:00	5	386.228	46.982	0.862	1450.287	85.600	47.395	44.129	2.003	32.584	72.388	98.746	0
2025-01-03 21:35:00	6	391.654	52.518	0.828	1581.836	91.666	68.914	54.578	3.430	27.051	48.988	90.017	0

2025-01-03 21:40:00	6	416.337	51.065	0.753	1557.188	103.614	64.814	38.788	2.416	28.077	60.304	91.659	0
2025-01-03 21:45:00	7	411.895	53.657	0.830	1458.916	72.791	80.644	48.260	1.900	28.156	32.170	94.990	1
2025-01-03 21:50:00	4	416.724	48.170	0.752	1450.148	25.867	59.166	60.176	2.992	33.316	46.485	97.576	1
2025-01-03 21:55:00	8	385.220	59.596	0.846	1538.362	87.225	59.710	62.856	2.861	23.420	79.366	93.111	0
2025-01-03 22:00:00	7	402.831	56.918	0.811	1521.667	93.983	51.763	57.961	1.284	13.909	42.004	94.740	0
2025-01-03 22:05:00	9	351.539	47.104	0.801	1482.296	65.452	61.007	61.527	1.386	31.307	55.615	95.784	1
2025-01-03 22:10:00	7	408.578	58.424	0.778	1477.672	29.669	42.662	55.157	1.897	17.628	43.937	97.850	1
2025-01-03 22:15:00	3	412.218	70.684	0.840	1488.306	90.797	41.122	46.579	2.638	22.591	43.032	97.472	0
2025-01-03 22:20:00	3	392.967	43.267	0.792	1545.097	69.613	54.566	60.487	1.710	21.025	68.118	93.289	0
2025-01-03 22:25:00	8	405.909	66.753	0.705	1578.535	43.308	60.663	58.894	1.490	21.028	70.993	91.007	0
2025-01-03 22:30:00	5	369.702	44.165	0.714	1591.136	64.651	54.130	50.680	2.407	29.555	21.921	91.030	0
2025-01-03 22:35:00	4	383.979	64.103	0.737	1463.278	69.902	54.215	50.021	1.035	28.494	41.811	97.415	1
2025-01-03 22:40:00	8	415.309	44.541	0.839	1502.901	64.644	44.917	54.635	1.824	20.765	34.537	96.363	0
2025-01-03 22:45:00	6	410.225	57.657	0.843	1567.176	59.890	66.316	64.065	1.463	31.191	54.901	91.010	1
2025-01-03 22:50:00	2	391.763	51.796	0.816	1456.472	89.039	52.873	51.993	1.996	23.761	56.669	97.889	0
2025-01-03 22:55:00	4	416.227	32.147	0.816	1465.896	97.023	76.595	30.686	1.526	34.345	38.597	95.046	1
2025-01-03 23:00:00	4	402.766	69.156	0.872	1539.844	108.639	59.308	58.468	1.924	23.086	41.693	93.077	0
2025-01-03 23:05:00	6	389.916	41.045	0.817	1476.566	49.925	49.486	46.125	2.211	22.774	52.631	97.223	0
2025-01-03 23:10:00	6	396.343	37.304	0.832	1426.230	96.016	36.943	58.560	2.065	23.193	45.978	100.000	0
2025-01-03 23:15:00	1	390.892	43.606	0.799	1458.654	73.818	47.719	58.253	1.731	20.486	64.068	98.295	0
2025-01-03 23:20:00	8	376.324	75.312	0.777	1549.515	77.516	59.366	67.308	1.829	27.793	39.013	92.588	0
2025-01-03 23:25:00	6	425.134	37.463	0.786	1512.452	94.288	36.237	54.206	3.127	21.590	58.097	96.754	0
2025-01-03 23:30:00	3	388.640	51.782	0.903	1421.888	69.002	52.075	58.968	2.441	23.649	46.808	99.698	0
2025-01-03 23:35:00	9	383.353	38.768	0.746	1469.553	66.350	54.679	56.070	1.884	27.386	66.283	97.054	1
2025-01-03 23:40:00	2	369.413	40.483	0.816	1591.136	56.129	52.598	62.030	2.089	34.909	55.177	91.183	0
2025-01-03 23:45:00	8	347.281	34.006	0.724	1496.526	46.667	54.155	26.599	2.226	21.653	29.194	95.758	0
2025-01-03 23:50:00	10	414.030	53.152	0.769	1487.830	57.352	55.346	49.583	1.619	22.282	34.817	96.074	0
2025-01-03 23:55:00	3	415.872	48.388	0.839	1500.410	73.422	52.149	53.025	2.001	21.962	34.897	95.765	0
2025-01-04 00:00:00	5	423.861	38.686	0.710	1510.257	68.994	74.699	55.374	1.463	27.259	46.390	93.017	1
2025-01-04 00:05:00	6	397.019	58.732	0.845	1480.459	62.388	53.833	45.288	1.503	22.589	45.137	96.594	0

2025-01-04 00:10:00	10	393.560	59.787	0.902	1567.027	63.005	33.718	57.371	2.438	20.539	51.699	94.277	0
2025-01-04 00:15:00	6	389.846	54.072	0.818	1476.452	91.027	43.637	62.058	2.503	25.513	71.459	97.814	0
2025-01-04 00:20:00	4	391.669	61.707	0.863	1549.688	73.513	66.019	49.458	2.577	27.906	58.908	91.914	0
2025-01-04 00:25:00	3	422.396	46.510	0.812	1591.122	50.132	64.504	47.223	1.964	22.575	46.990	89.993	0
2025-01-04 00:30:00	4	399.470	53.224	0.836	1518.886	71.158	54.749	58.164	1.753	25.489	40.470	94.581	0
2025-01-04 00:35:00	1	407.561	46.549	0.823	1447.618	82.322	45.887	56.274	2.005	26.320	64.938	99.030	1
2025-01-04 00:40:00	4	391.160	34.927	0.774	1509.412	89.129	67.115	56.868	1.105	24.988	60.101	93.818	0
2025-01-04 00:45:00	1	426.417	52.192	0.770	1471.812	81.283	44.129	43.382	2.694	26.608	78.055	97.997	0
2025-01-04 00:50:00	1	361.905	51.587	0.859	1544.904	86.971	63.736	76.889	0.645	20.751	62.045	92.381	0
2025-01-04 00:55:00	10	375.590	49.698	0.798	1510.362	80.121	55.709	35.254	2.487	19.759	47.825	94.911	0
2025-01-04 01:00:00	6	407.594	53.739	0.793	1494.047	29.862	64.996	61.925	1.505	20.975	64.152	94.798	0
2025-01-04 01:05:00	5	435.012	64.119	0.792	1449.582	66.794	54.935	49.260	1.996	13.321	76.913	98.027	0
2025-01-04 01:10:00	4	395.498	47.956	0.815	1406.953	68.195	74.603	79.174	1.574	19.062	42.095	98.192	0
2025-01-04 01:15:00	3	383.153	40.428	0.741	1459.423	110.787	41.551	58.514	1.582	28.504	38.602	98.874	0
2025-01-04 01:20:00	1	420.013	47.522	0.791	1532.552	85.188	65.753	63.535	0.780	28.328	34.158	92.797	0
2025-01-04 01:25:00	6	406.474	48.632	0.816	1559.140	64.181	56.539	58.983	1.365	18.442	48.006	92.389	0
2025-01-04 01:30:00	2	425.804	59.836	0.736	1484.495	54.546	52.961	35.446	2.455	16.470	42.262	96.479	1
2025-01-04 01:35:00	8	374.193	51.067	0.810	1452.766	63.119	72.552	55.899	1.388	25.120	48.716	96.107	0
2025-01-04 01:40:00	10	424.233	38.518	0.755	1509.486	53.832	49.824	57.885	1.366	27.639	46.646	95.543	0
2025-01-04 01:45:00	5	369.031	58.055	0.816	1534.425	113.597	62.341	58.788	1.946	21.067	57.999	93.045	0
2025-01-04 01:50:00	7	394.237	56.451	0.908	1538.860	69.695	61.220	64.465	0.836	22.039	63.777	92.935	1
2025-01-04 01:55:00	10	408.256	51.071	0.794	1509.727	86.497	47.697	56.817	1.825	28.886	54.975	95.744	0
2025-01-04 02:00:00	2	403.720	59.482	0.746	1603.514	80.307	68.256	61.438	2.129	33.399	53.134	88.999	0
2025-01-04 02:05:00	8	421.212	61.156	0.812	1563.444	83.147	80.210	48.914	2.185	22.046	52.672	89.807	0
2025-01-04 02:10:00	2	363.467	46.226	0.824	1438.861	52.387	76.197	40.882	1.481	27.794	37.075	96.437	1
2025-01-04 02:15:00	4	402.820	40.998	0.753	1426.626	96.745	63.971	47.610	2.604	24.814	59.298	98.272	0
2025-01-04 02:20:00	1	423.993	49.881	0.714	1443.484	68.234	57.720	49.059	2.511	30.459	53.091	98.054	0
2025-01-04 02:25:00	5	401.186	55.366	0.753	1558.418	100.008	68.163	47.620	1.136	19.340	20.000	91.263	0
2025-01-04 02:30:00	9	377.153	48.946	0.798	1414.537	78.513	69.680	45.211	2.357	25.098	55.165	98.305	0
2025-01-04 02:35:00	1	420.150	40.116	0.777	1522.878	105.080	60.910	47.340	2.076	21.758	48.150	93.765	0

2025-01-04 02:40:00	9	387.034	51.627	0.854	1491.500	82.006	36.103	51.476	2.255	24.677	58.231	97.815	0
2025-01-04 02:45:00	8	383.514	29.665	0.826	1437.760	66.288	44.437	46.838	1.692	29.398	58.448	99.668	0
2025-01-04 02:50:00	6	380.997	46.755	0.805	1512.442	98.112	64.597	75.539	1.354	24.901	69.427	93.918	0
2025-01-04 02:55:00	7	396.026	58.512	0.713	1491.178	72.766	63.247	43.802	1.926	21.187	39.412	95.116	0
2025-01-04 03:00:00	3	403.661	59.054	0.832	1540.347	80.762	55.381	58.519	2.189	29.548	26.940	93.445	0
2025-01-04 03:05:00	1	374.618	12.402	0.899	1418.651	71.785	62.746	50.673	2.198	27.553	71.076	98.793	0
2025-01-04 03:10:00	5	378.727	48.074	0.843	1455.322	59.181	45.356	59.295	2.171	26.192	65.126	98.698	0
2025-01-04 03:15:00	2	386.110	55.993	0.767	1456.323	66.812	58.209	53.063	1.462	18.988	39.960	97.363	0
2025-01-04 03:20:00	5	380.900	38.239	0.793	1533.082	84.233	56.640	61.806	2.685	27.471	43.083	93.682	0
2025-01-04 03:25:00	8	400.735	46.280	0.823	1488.118	89.443	40.359	51.803	2.596	21.738	51.446	97.558	0
2025-01-04 03:30:00	9	407.224	62.077	0.869	1559.040	29.607	60.873	55.699	2.123	20.043	50.628	91.961	0
2025-01-04 03:35:00	2	404.477	45.158	0.765	1480.060	76.406	44.745	37.340	1.523	20.382	36.703	97.522	0
2025-01-04 03:40:00	3	404.507	65.986	0.777	1511.033	68.442	68.759	44.002	2.131	27.915	61.279	93.573	0
2025-01-04 03:45:00	3	433.420	42.588	0.798	1574.212	42.597	63.347	42.566	1.786	27.300	52.947	90.955	0
2025-01-04 03:50:00	1	408.474	64.099	0.793	1411.353	87.150	53.318	67.131	1.824	25.076	29.024	100.000	0
2025-01-04 03:55:00	8	415.679	50.336	0.840	1501.450	106.133	49.822	62.456	2.335	14.228	50.996	95.945	0
2025-01-04 04:00:00	6	391.708	41.217	0.813	1498.421	99.633	46.082	56.559	1.790	30.385	59.382	96.471	1
2025-01-04 04:05:00	8	418.880	64.132	0.730	1460.608	23.334	55.240	63.364	2.707	29.250	41.725	97.446	0
2025-01-04 04:10:00	9	390.753	37.935	0.767	1491.807	76.491	67.726	46.890	2.315	22.238	46.492	94.637	0
2025-01-04 04:15:00	5	408.229	42.040	0.769	1515.609	57.007	56.615	66.900	2.504	31.806	52.155	94.558	0
2025-01-04 04:20:00	3	372.573	54.899	0.689	1462.688	61.035	58.279	55.776	1.552	20.092	21.374	97.038	1
2025-01-04 04:25:00	5	403.325	50.808	0.846	1502.770	64.956	48.947	53.093	1.691	25.457	47.053	95.967	0
2025-01-04 04:30:00	5	380.492	52.740	0.807	1449.013	25.547	54.949	63.119	1.378	25.530	54.963	98.054	0
2025-01-04 04:35:00	5	418.721	46.317	0.773	1489.785	28.836	57.742	62.642	2.660	26.180	51.613	95.737	0
2025-01-04 04:40:00	3	417.518	38.006	0.845	1546.435	71.704	61.241	43.645	3.440	18.039	70.274	92.554	0
2025-01-04 04:45:00	10	390.667	43.477	0.815	1548.775	74.954	58.240	61.894	2.260	17.152	60.784	92.737	1
2025-01-04 04:50:00	4	440.991	63.204	0.736	1558.638	66.093	64.488	53.617	2.130	24.539	43.824	91.619	0
2025-01-04 04:55:00	9	394.282	36.630	0.830	1494.918	45.026	66.550	57.219	1.762	20.618	48.654	94.599	0
2025-01-04 05:00:00	10	367.760	66.445	0.869	1483.664	61.919	75.285	51.705	2.808	26.657	55.261	94.288	0
2025-01-04 05:05:00	9	384.418	53.159	0.793	1536.898	98.909	62.199	46.223	1.978	25.634	20.000	92.935	0

2025-01-04 05:10:00	2	379.117	44.032	0.797	1558.344	62.745	64.208	44.175	1.676	31.637	26.216	91.662	0
2025-01-04 05:15:00	8	407.592	29.979	0.805	1504.172	59.944	54.774	50.040	1.262	31.500	49.347	95.314	0
2025-01-04 05:20:00	8	375.293	31.293	0.739	1575.608	94.737	75.387	58.487	1.478	25.255	77.048	89.681	0
2025-01-04 05:25:00	7	389.216	46.441	0.807	1535.529	65.685	55.296	57.039	2.035	32.456	46.897	93.694	0
2025-01-04 05:30:00	8	406.291	45.230	0.755	1471.449	83.609	66.020	56.625	1.083	26.042	65.260	95.825	1
2025-01-04 05:35:00	3	402.773	51.177	0.800	1477.501	79.217	55.071	61.375	1.387	24.790	28.531	96.618	0
2025-01-04 05:40:00	6	399.747	67.191	0.808	1497.976	52.155	58.556	54.555	2.832	33.535	42.872	95.246	0
2025-01-04 05:45:00	1	402.520	55.376	0.827	1421.477	50.186	60.200	70.160	2.415	20.253	38.863	98.906	0
2025-01-04 05:50:00	7	392.590	48.713	0.828	1472.328	43.042	40.465	58.018	1.837	17.250	54.332	98.337	1
2025-01-04 05:55:00	1	367.925	62.168	0.754	1557.041	49.806	61.984	47.104	2.472	23.838	63.134	91.950	0
2025-01-04 06:00:00	9	392.063	51.507	0.809	1567.257	86.540	59.198	44.293	1.617	25.927	46.738	91.717	0
2025-01-04 06:05:00	1	409.375	65.997	0.848	1514.302	53.564	53.261	57.661	2.390	28.141	44.261	94.959	0
2025-01-04 06:10:00	1	397.261	43.279	0.742	1522.718	67.242	49.954	53.282	1.819	19.305	70.502	94.869	0
2025-01-04 06:15:00	7	407.830	38.522	0.887	1484.504	64.367	53.593	45.754	2.985	24.208	82.784	96.415	0
2025-01-04 06:20:00	2	388.264	29.997	0.751	1467.993	77.592	49.373	53.739	1.431	18.897	43.534	97.663	0
2025-01-04 06:25:00	5	419.887	48.946	0.881	1528.515	42.705	54.996	50.593	2.765	23.566	48.646	94.075	0
2025-01-04 06:30:00	8	348.874	37.654	0.752	1478.010	91.961	53.305	51.449	1.936	31.695	53.976	96.769	1
2025-01-04 06:35:00	8	402.829	37.512	0.797	1584.517	98.724	56.516	65.859	1.061	25.730	55.952	91.123	0
2025-01-04 06:40:00	3	426.978	60.343	0.790	1520.430	69.497	67.615	60.743	2.155	20.243	53.508	93.217	1
2025-01-04 06:45:00	7	429.954	32.779	0.732	1522.264	25.208	50.909	63.381	2.349	15.166	20.000	94.796	0
2025-01-04 06:50:00	3	395.363	51.036	0.835	1447.024	52.818	54.165	68.736	2.750	23.152	56.373	98.232	0
2025-01-04 06:55:00	6	373.476	49.168	0.837	1384.070	76.320	61.166	56.000	2.381	24.898	79.128	100.000	0
2025-01-04 07:00:00	6	427.329	50.921	0.831	1522.256	77.443	50.197	57.019	1.535	25.019	25.654	94.867	0

Anexo N° 3. Simulación en Matlab

The screenshot shows the MATLAB IDE with the following components:

- Editor:** Displays a script for training models. The script includes parameters for `PLOTS_LEARNING_BAG`, `PLOTS_LEARNING_GB`, `PLOTS_LEARNING_NN`, and `PLOTS_TIMESERIES`. It also includes a function `if FAST` that sets `nTrees`, `nCyclesGB`, `learnRate`, `maxSplits`, `epochs`, `lambdaNN`, `gradTol`, and `nnCurveIters`.
- Workspace:** Shows variables such as `bestModelName`, `candidates`, `epochs`, `FAST`, `featNames`, `Gap_R2`, `Gap_RMSE`, `gbArg`, `gradTol`, `hasBoxchart`, `idx_best_rmse`, `idxBest`, `imp1`, `imp2`, `lambdaNN`, `learnRate`, `M1`, `M2`, `M3`, `maxSplits`, `metrics`, `minLeaf1`, `Model`, `mt1_te`, `mt1_tr`, `mt2_te`, `mt2_tr`, `mt3_te`, `mt3_tr`, `nCyclesGB`, `nnCurvelters`, `nTrees`, `p`, and `PLOTS_LEARN`.
- Command Window:** Shows the output of the script, including a table of metrics for Bagging (TreeBagger), LSBoost, and Red Neuronal (fitrnet) models.


Command Window Output:

```

{"Bagging (TreeBagger)" } 24.352 19.208 128.41 0.4363
{"LSBoost" } 24.663 19.547 133.1 0.4218
{"Red Neuronal (fitrnet)" } 25.732 20.388 135.43 0.37063

=== Brecha (TEST - TRAIN) ===
Modelo Gap_RMSE Gap_R2
{"Bagging (TreeBagger)" } 5.4024 -0.22735
{"LSBoost" } 7.2809 -0.29519

```



+

New

📁

Open

💾

Save

🔍

Compare

🖨️

Print

🏠

Go To

🔍

Find

🔖

Bookmark

🔧

Refactor

📊

Analyze

📈

Profiler

🏠

Run Section

🏠

Run and Advance

🏠

Run to End

▶️

Run

⏮️

Step

⏹️

Stop

📁

C: > Trabajo Tesis > Grupo Ollarves > Renato

🔍

Command Window

New to MATLAB? See resources for [Getting Started](#).

```

== Top 5 casos más urgentes (según P50) ==

```


RULd_P50	RULd_P20	RULd_P10	RULd_P02	Fail_P50	Fail_P20	Fail_P10	Fail_P02	Riesgo
17	11	8	6	07-Dec-2025 20:09:14	01-Dec-2025 20:09:14	28-Nov-2025 20:09:14	26-Nov-2025 20:09:14	"ALTA"
19	12	9	7	09-Dec-2025 20:09:14	02-Dec-2025 20:09:14	29-Nov-2025 20:09:14	27-Nov-2025 20:09:14	"ALTA"
19	12	9	6	09-Dec-2025 20:09:14	02-Dec-2025 20:09:14	29-Nov-2025 20:09:14	26-Nov-2025 20:09:14	"ALTA"
20	13	10	7	10-Dec-2025 20:09:14	03-Dec-2025 20:09:14	30-Nov-2025 20:09:14	27-Nov-2025 20:09:14	"ALTA"
21	12	10	8	11-Dec-2025 20:09:14	02-Dec-2025 20:09:14	30-Nov-2025 20:09:14	28-Nov-2025 20:09:14	"ALTA"

```

== Ejemplos (8 escenarios, meses ampliados) ==
Caso 1:
P02 : 6d (0.2 meses / 0.02 años) | ~ 26-Nov-2025 20:09:14
P10 : 8d (0.3 meses) | ~ 28-Nov-2025 20:09:14
P20 : 11d (0.4 meses) | ~ 01-Dec-2025 20:09:14 ← conservador
P50 : 17d (0.6 meses / 0.05 años) | ~ 07-Dec-2025 20:09:14 ← central
P75 : 28d (0.9 meses) | ~ 18-Dec-2025 20:09:14
P90 : 38d (1.2 meses) | ~ 28-Dec-2025 20:09:14
P95 : 43d (1.4 meses) | ~ 02-Jan-2026 20:09:14
P98 : 47d (1.5 meses / 0.13 años) | ~ 06-Jan-2026 20:09:14 ← muy optimista

Caso 2:
P02 : 7d (0.2 meses / 0.02 años) | ~ 27-Nov-2025 20:09:14
P10 : 9d (0.3 meses) | ~ 29-Nov-2025 20:09:14
P20 : 12d (0.4 meses) | ~ 02-Dec-2025 20:09:14 ← conservador
P50 : 19d (0.6 meses / 0.05 años) | ~ 09-Dec-2025 20:09:14 ← central
P75 : 27d (0.9 meses) | ~ 17-Dec-2025 20:09:14
P90 : 32d (1.1 meses) | ~ 22-Dec-2025 20:09:14
P95 : 36d (1.2 meses) | ~ 26-Dec-2025 20:09:14
P98 : 40d (1.3 meses) | ~ 30-Dec-2025 20:09:14

```



Command Window

New to MATLAB? See resources for [Getting Started](#).

C:\Trabajo Tesis\Grupo Ollarves\Renato

Caso 3:


Time	Status
P02 : 6d (0.2 meses / 0.02 años) ~ 26-Nov-2025 20:09:14	
P10 : 9d (0.3 meses) ~ 29-Nov-2025 20:09:14	
P20 : 12d (0.4 meses) ~ 02-Dec-2025 20:09:14	← conservador
P50 : 19d (0.6 meses / 0.05 años) ~ 09-Dec-2025 20:09:14	← central
P75 : 27d (0.9 meses) ~ 17-Dec-2025 20:09:14	
P90 : 37d (1.2 meses) ~ 27-Dec-2025 20:09:14	
P95 : 42d (1.4 meses) ~ 01-Jan-2026 20:09:14	
P98 : 48d (1.6 meses / 0.13 años) ~ 07-Jan-2026 20:09:14	← muy optimista

Caso 4:

Time	Status
P02 : 7d (0.2 meses / 0.02 años) ~ 27-Nov-2025 20:09:14	
P10 : 10d (0.3 meses) ~ 30-Nov-2025 20:09:14	
P20 : 13d (0.4 meses) ~ 03-Dec-2025 20:09:14	← conservador
P50 : 20d (0.7 meses / 0.05 años) ~ 10-Dec-2025 20:09:14	← central
P75 : 29d (1.0 meses) ~ 19-Dec-2025 20:09:14	
P90 : 38d (1.2 meses) ~ 28-Dec-2025 20:09:14	
P95 : 42d (1.4 meses) ~ 01-Jan-2026 20:09:14	
P98 : 44d (1.4 meses / 0.12 años) ~ 03-Jan-2026 20:09:14	← muy optimista

Caso 5:

Time	Status
P02 : 8d (0.3 meses / 0.02 años) ~ 28-Nov-2025 20:09:14	
P10 : 10d (0.3 meses) ~ 30-Nov-2025 20:09:14	
P20 : 12d (0.4 meses) ~ 02-Dec-2025 20:09:14	← conservador
P50 : 21d (0.7 meses / 0.06 años) ~ 11-Dec-2025 20:09:14	← central
P75 : 27d (0.9 meses) ~ 17-Dec-2025 20:09:14	
P90 : 36d (1.2 meses) ~ 26-Dec-2025 20:09:14	
P95 : 41d (1.3 meses) ~ 31-Dec-2025 20:09:14	
P98 : 46d (1.5 meses / 0.13 años) ~ 05-Jan-2026 20:09:14	← muy optimista



Anexo N° 4. Datasheet WEG W22 Motor Eléctrico Trifásico

Potencia		Carcasa	Full Load Torque (kgfm)	Corriente con rotor trabado I _L /I _n	Par con rotor trabado T _L /T _n	Break-down Torque T _B /T _n	Momento de Inercia J (kg·m²)	Tiempo máximo con rotor trabado (s)		Peso (kg)	Nivel de ruido dB (A)	RPM	400 V						Corriente nominal I _n (A)
													% de la potencia nominal						
													Rendimiento			Factor de potencia			
kW	HP							Cálentete	Frío				50	75	100	50	75	100	
II Poles																			
0.12	0.16	63	0.042	4.8	3.0	2.9	0.0001	37	81	7.0	52	2790	53.0	60.0	60.7	0.53	0.66	0.75	0.380
0.18	0.25	63	0.062	5.1	2.5	2.7	0.0001	15	33	8.7	52	2830	57.0	62.0	64.0	0.57	0.70	0.79	0.514
0.25	0.33	63	0.088	4.4	2.2	2.2	0.0002	11	24	8.3	52	2780	58.0	63.0	65.0	0.57	0.70	0.80	0.694
0.37	0.5	71	0.127	5.8	2.5	2.6	0.0004	12	26	10.5	56	2830	68.0	70.0	71.0	0.60	0.75	0.84	0.895
0.55	0.75	71	0.190	5.3	2.3	2.3	0.0005	9	20	11.2	56	2820	70.0	72.0	74.1	0.68	0.82	0.88	1.22
0.75	1	80	0.258	6.5	2.7	2.7	0.0008	14	31	14.5	59	2830	76.0	78.5	79.5	0.65	0.78	0.85	1.60
1.1	1.5	80	0.379	6.0	2.8	2.7	0.0009	10	22	16.0	59	2825	78.0	79.5	79.6	0.60	0.74	0.83	2.40
1.5	2	90S	0.507	6.5	2.2	2.7	0.0021	7	15	17.5	62	2880	80.0	82.0	82.0	0.63	0.76	0.83	3.18
2.2	3	90L	0.745	7.0	2.7	3	0.0022	9	20	23.2	64	2875	83.0	83.6	83.6	0.60	0.75	0.82	4.63
3	4	100L	1.00	8.0	2.5	3.4	0.0064	7	15	35.5	67	2915	84.0	85.0	85.0	0.70	0.81	0.86	5.92
4	5.5	112M	1.35	7.0	2.3	2.8	0.0088	14	31	40.6	64	2895	86.0	86.0	86.0	0.73	0.83	0.88	7.63
5.5	7.5	132S	1.83	6.8	2.2	3	0.0197	17	37	68.0	67	2930	86.5	88.0	88.0	0.68	0.79	0.85	10.6
7.5	10	132S	2.49	7.0	2.4	3.2	0.0251	9	20	58.2	67	2935	87.0	88.0	88.1	0.72	0.82	0.87	14.1
9.2	12.5	132M	3.07	7.6	2.5	3.2	0.0234	7	15	63.1	67	2915	88.5	89.0	89.0	0.70	0.81	0.86	17.3
11	15	160M	3.63	7.5	2.5	3.3	0.0446	11	24	120	67	2950	90.0	90.6	90.5	0.71	0.82	0.86	20.4
15	20	160M	4.96	7.4	2.6	3.1	0.0517	8	18	130	67	2945	91.0	91.3	91.3	0.71	0.81	0.86	27.6
18.5	25	160L	6.11	8.5	2.9	3.6	0.0625	7	15	142	67	2950	91.3	92.0	92.0	0.70	0.80	0.86	33.7
22	30	180M	7.25	7.6	2.8	3	0.0975	9	20	164	67	2955	91.9	92.4	92.2	0.74	0.83	0.87	39.6
30	40	200L	9.85	6.8	2.7	2.7	0.1703	16	35	245	72	2965	92.5	93.0	92.9	0.75	0.83	0.87	53.6
37	50	200L	12.1	8.1	3.2	3.1	0.1950	9	20	270	72	2970	92.3	93.0	93.3	0.70	0.80	0.85	67.3
45	60	225S/M	14.8	7.0	2.2	2.8	0.2490	12	26	380	75	2960	93.3	93.6	93.6	0.79	0.86	0.89	78.0
55	75	250S/M	18.1	7.6	2.5	3	0.3736	14	31	502	75	2960	92.8	93.5	93.9	0.79	0.86	0.89	95.0
75	100	280S/M	24.6	7.0	2	2.8	0.8541	28	62	865	77	2975	93.4	94.3	94.3	0.79	0.86	0.88	130
90	125	280S/M	29.4	7.5	2	2.8	0.9386	25	55	745	77	2977	94.0	94.6	94.6	0.77	0.85	0.87	158
110	150	315S/M	36.0	7.5	2	3	1.67	24	53	952	77	2980	94.3	94.9	94.9	0.77	0.85	0.87	192
132	180	315S/M	43.1	7.3	2	2.9	1.96	21	46	1050	77	2980	94.5	95.1	95.1	0.79	0.86	0.89	225
132	180	315S/M	43.1	7.3	2	2.9	1.96	21	46	1050	77	2980	94.5	95.1	95.1	0.80	0.87	0.90	223
150	200	315S/M	49.0	7.5	2.2	3	1.96	23	51	1150	77	2980	94.2	94.8	94.8	0.78	0.85	0.88	260
160	220	315S/M	52.4	7.5	2.2	2.9	2.24	36	79	1072	77	2975	94.8	95.3	95.3	0.80	0.87	0.89	272
185	250	315S/M	60.5	7.6	2.2	3.1	2.46	16	35	1250	77	2980	94.9	95.5	95.4	0.80	0.86	0.89	314
200	270	315L	65.4	7.5	2.3	2.7	2.68	28	62	1300	78	2980	95.0	95.5	95.4	0.82	0.88	0.90	336
220	300	315L	71.9	7.8	2.4	2.8	2.98	14	31	1350	78	2980	95.0	95.5	95.5	0.81	0.87	0.90	369
250	340	315L	81.7	7.8	2.4	2.8	3.42	17	37	1450	78	2980	95.1	95.6	95.5	0.84	0.89	0.91	415
260	350	355M/L	84.8	7.9	2	2.8	4.85	20	44	1850	80	2985	95.0	95.5	95.8	0.86	0.89	0.91	430
280	380	355M/L	91.5	7.7	1.9	2.6	5.06	17	37	1870	80	2980	95.2	95.6	95.6	0.86	0.89	0.91	465
300	400	355M/L	97.9	8.0	2.5	2.6	5.60	23	51	1854	80	2985	95.2	95.6	95.6	0.87	0.91	0.92	492
315	430	355M/L	103	8.0	2.5	2.8	5.60	23	51	2000	80	2985	95.2	95.6	95.6	0.87	0.91	0.92	517
330	450	355M/L	108	7.0	2.4	2.4	6.03	20	44	2050	80	2985	95.3	95.6	95.6	0.88	0.90	0.90	554
355	480	355M/L	116	8.4	2.2	2.8	6.01	14	31	2050	80	2985	95.3	95.6	95.6	0.87	0.90	0.91	589
370	500	355A/B	121	8.8	2.7	3.2	6.76	40	88	2250	83	2986	95.6	95.7	95.7	0.85	0.89	0.90	620
400	550	355A/B	131	8.5	2.4	2.8	6.76	31	68	2400	83	2985	95.6	95.7	95.7	0.85	0.89	0.91	663
450	610	355A/B	147	7.5	2.8	2.7	7.40	31	68	2500	83	2982	95.0	95.5	95.7	0.85	0.90	0.91	746
Opcionales																			
0.37	0.5	63	0.132	5.0	2.5	2.5	0.0002	7	15	8.9	52	2730	64.0	67.0	69.5	0.56	0.71	0.81	0.949
0.75	1	71	0.263	5.8	3.3	2.8	0.0005	14	31	12.2	56	2780	77.0	77.5	77.6	0.67	0.80	0.87	1.60
0.75	1	90S	0.251	6.7	2.4	2.8	0.0012	25	55	17.5	64	2905	77.0	79.0	79.0	0.60	0.72	0.80	1.71
1.1	1.5	90S	0.374	6.5	2.3	2.6	0.0014	12	26	19.0	64	2865	80.0	80.5	80.5	0.61	0.75	0.83	2.38
1.5	2	80	0.527	6.5	3.1	3	0.0009	15	33	17.0	59	2770	80.0	81.0	81.5	0.65	0.78	0.85	3.13
1.5	2	90L	0.507	6.7	2.4	2.8	0.0021	7	15	23.5	64	2880	80.0	82.0	82.0	0.63	0.76	0.83	3.18
2.2	3	100L	0.736	7.5	2.4	3.4	0.0043	15	33	31.0	67	2910	82.5	83.6	83.6	0.66	0.78	0.85	4.47
2.2	3	L90L	0.745	7.0	2.7	3	0.0022	9	20	19.4	64	2875	83.0	83.6	83.6	0.60	0.75	0.82	4.63
3	4	L90L	1.02	7.1	3.4	3.4	0.0030	9	20	29.5	64	2860	84.0	84.6	84.6	0.60	0.73	0.80	6.40
3	4	L100L	1.00	8.0	2.5	3.4	0.0064	7	15	35.5	67	2915	84.0	85.0	85.0	0.70	0.81	0.86	5.92
4	5.5	100L	1.34	7.8	3.3	3.5	0.0084	10	22	37.0	67	2900	85.2	85.8	85.8	0.67	0.80	0.86	7.82
4	5.5	L112M	1.35	7.0	2.3	2.8	0.0088	14	31	43.5	64	2895	86.0	86.0	86.0	0.73	0.83	0.88	7.63
5.5	7.5	112M	1.86	7.0	2.7	3	0.0088	11	24	46.0	64	2880	86.5	87.0	87.0	0.72	0.82	0.87	10.5
5.5	7.5	132M	1.83	6.8	2.2	3	0.0197	17	37	68.0	67	2930	86.5	88.0	88.0	0.68	0.79	0.85	10.6
5.5	7.5	L112M	1.85	7.0	2.7	3	0.0101	9	20	50.0	64	2890	86.5	87.0	87.0	0.72	0.82	0.87	10.5
7.5	10	132M	2.49	7.0	2.4	3.2	0.0251	9	20	58.2	67	2935	87.0	88.0	88.1	0.72	0.82	0.87	14.1
11	15	132M	3.69	7.2	2.4	2.9	0.0270	11	24	85.0	67	2905	89.3	89.6	89.6	0.75	0.84	0.88	20.1
11	15	160L	3.63	7.5	2.5	3.3	0.0446	11	24	120	67	2950	90.0	90.6	90.5	0.71	0.82	0.86	20.4
15	20	160L	4.96	7.4	2.6	3.1	0.0517	8	18	130	67	2945	91.0	91.3	91.3	0.71	0.81	0.86	27.6
18.5	25	180M	6.11	7.0	2.6	2.9	0.0867	10	22	180	67	2950	91.4	92.0	91.8	0.72	0.82	0.86	33.8
22	30	160L	7.29	7.9	3	3.4	0.0813	10	22	163	67	2940	91.9						