

IMPLEMENTACIÓN DE ANALÍTICA DE DATOS PARA EL MANTENIMIENTO
PREDICTIVO DE MOTORES ELÉCTRICOS

CRISTIAN A. CORREA MIRA
JULIÁN A. ESCOBAR GALVIS
JORGE I. MENA PEREA

INSTITUCIÓN UNIVERSITARIA PASCUAL BRAVO
FACULTAD DE INGENIERÍA
INGENIERÍA ELÉCTRICA
2023

IMPLEMENTACIÓN DE ANALÍTICA DE DATOS PARA EL MANTENIMIENTO
PREDICTIVO DE MOTORES ELÉCTRICOS

CRISTIAN A. CORREA MIRA
JULIÁN A. ESCOBAR GALVIS
JORGE I. MENA PEREA

Trabajo de grado para optar al título de Ingeniero Electricista

Asesor técnico
Msc. Arley Villa Salazar

Asesor metodológico
Msc. Karen Lemmel Velez

INSTITUCIÓN UNIVERSITARIA PASCUAL BRAVO
FACULTAD DE INGENIERÍA
INGENIERÍA ELÉCTRICA
2023

Índice

Resumen.....	8
Abstract	9
Glosario.....	10
Introducción	15
1. Planteamiento del problema.....	17
1.1. Descripción	17
1.2. Formulación	19
2. Justificación	20
3. Objetivos	22
3.1. General.....	22
3.2. Específicos	22
4. Marco teórico	23
4.1. Tipos de mantenimiento.....	24
4.1.1. Mantenimiento de conservación.....	24
4.1.2. Mantenimiento de actualización.....	26
4.2. Mantenimiento predictivo con IOT	27
4.2.1. Análisis de vibraciones.....	28
4.2.2. Monitoreo acústico	28
4.2.3. Termografía infrarroja.....	29

	4
4.3. Analítica de datos.....	30
4.4. Analisis exploratorio de datos (EDA).....	31
4.5. Análisis de varianza (ANOVA).....	32
4.6. Test de Kruskal Wallis.....	34
4.7. Análisis supervisado	34
4.8. Análisis de confiabilidad.....	36
4.9. Aprendizaje automático	38
4.10. Análisis de fallas	40
5. Metodología	43
5.1. Tipo de proyecto	44
5.2. Método	44
5.3. Población y muestra.....	45
5.4. Descripción del proceso de analisis de datos	49
6. Resultados	50
6.1. Kruskal-Wallis y Anova	53
6.2. Analisis Exploratorio de Datos (EDA).....	56
6.2.1. Análisis Univariado.....	56
6.2.2. Análisis Bivariado.....	66
6.3. Regresión Logística	71
6.4. Árbol de Decisiones	73

6.5.	Análisis de confiabilidad con la aplicación de Python	74
6.6.	Curva de falla y confiabilidad.....	80
7.	Conclusiones	82
8.	Recomendaciones.....	88
9.	Referencias Bibliográficas	90

Lista de figuras

Tabla 1. Cantidad de datos por variables y tipo de motor.....	24
Tabla 2. Placas de motores analizados.....	27
Tabla 3. Motores analizados	28
Tabla 4. Detalles de momentos identificados como falla en la base de datos inicial	29
Tabla 5. Muestra de la base de datos utilizada.....	29

Lista de tablas

Figura 1. Operaciones de mantenimiento.	26
Figura 2. Pilares del mantenimiento.	27
Figura 3. Análisis de vibraciones con el programa Airproject SPA.	28
Figura 4. Ultrasonido acústico sonux XT.	29
Figura 5. Termografía infrarroja de piezas mecánicas y eléctricas electroindustriales.	29
Figura 6. Diagrama del proceso de analisis de datos.	29
Figura 7. Captura de pantalla con código de carga de datos.	52
Figura 8. Captura de pantalla con código de validación de tipo de datos.	53
Figura 9. Captura de pantalla con código de limpieza de base de datos.	53
Figura 10. Captura de pantalla con código del test KRUSKAL-WALLIS.	54
Figura 11. Captura de pantalla con el resultado del test KRUSKAL-WALLIS.	54
Figura 12. Captura de pantalla con código del test ANOVA.	55
Figura 13. Captura de pantalla con resultado del test ANOVA.	56
Figura 14. Captura de pantalla con código del Análisis Univariado.	29
Figura 15. Captura de pantalla resultados arrojados para el analisis Univariado del Motor 1 ...	58
Figura 16. Captura de pantalla resultados arrojados para el analisis Univariado del Motor 2 ...	59
Figura 17. Captura de pantalla resultados arrojados para el analisis Univariado del Motor 3 ...	60
Figura 18. Captura de pantalla resultados arrojados para el analisis Univariado del Motor 4 ...	62
Figura 19. Captura de pantalla resultados arrojados para el analisis Univariado del Motor 5 ...	63
Figura 20. Captura de pantalla resultados arrojados para el analisis Univariado del Motor 6 ...	64
Figura 21. Captura de pantalla resultados arrojados para el analisis Univariado del Motor 7 ...	65
Figura 22. Captura de pantalla con código del Análisis Bivariado.	66
Figura 23. Captura de pantalla con resultados arrojados para el analisis Bivariado Corriente vs Voltaje.	67
Figura 24. Captura de pantalla con resultados arrojados para el analisis Bivariado Temperatura y Corriente.	68
Figura 25. Captura de pantalla con resultados arrojados para el analisis Bivariado Voltaje y Temperatura.	69
Figura 26. Captura de pantalla con código para Regresión Logística.	71
Figura 27. Captura de pantalla con resultado obtenido tras regresión logística.	72
Figura 28. Captura de pantalla con código para Árbol de Decisiones.	73
Figura 29. Captura de pantalla con resultado obtenido tras aplicación del árbol de decisiones.	29
Figura 30. Captura de pantalla con el código de la prueba de bondad de ajuste Exponencial ...	76
Figura 31. Captura de pantalla con resultado de la prueba de bondad de ajuste Exponencial ...	76
Figura 32. Captura de pantalla con el código de la prueba de bondad de ajuste Normal.	77
Figura 33. Captura de pantalla con resultado de la prueba de bondad de ajuste Normal.	29
Figura 34. Captura de pantalla con el código de la prueba de bondad de ajuste Weibull.	79
Figura 35. Captura de pantalla con resultado de la prueba de bondad de ajuste Weibull.	79

Resumen

En este proyecto de grado, se realizó una valoración exhaustiva de diversas variables de los motores eléctricos con el objetivo de mejorar el proceso de mantenimiento predictivo. Se aplicaron técnicas estadísticas y estrategias de supervisión de datos para evaluar la importancia y el comportamiento de estas variables. Además, se llevó a cabo una evaluación de la confiabilidad de los datos obtenidos, lo cual resulta crucial para garantizar la efectividad del mantenimiento predictivo.

La implementación de estrategias de mantenimiento adecuadas es esencial para garantizar la confiabilidad y el rendimiento óptimo de los motores eléctricos en los procesos productivos. En este sentido, se propuso una solución basada en la analítica de datos para prevenir fallos y mejorar el mantenimiento predictivo; Esta solución, además de ser viable, adaptable y escalable, minimizó el impacto económico y los posibles accidentes asociados a la detención de la producción para el monitoreo del estado del motor.

Los resultados obtenidos contribuyeron a una toma de decisiones más informada y eficiente en el mantenimiento, lo que se tradujo en una mayor productividad y rentabilidad para las empresas. Asimismo, se amplió el conocimiento sobre el uso de la analítica de datos en este contexto, proporcionando una alternativa innovadora y eficaz para mejorar el mantenimiento de los motores eléctricos en el ámbito industrial.

Abstract

In this graduate project, a comprehensive assessment of various variables of electric motors was conducted with the aim of enhancing the predictive maintenance process. Statistical techniques and data monitoring strategies were employed to evaluate the significance and behavior of these variables. Additionally, a reliability evaluation of the obtained data was carried out, which is crucial for ensuring the effectiveness of predictive maintenance.

Implementing appropriate maintenance strategies is essential to ensure the reliability and optimal performance of electric motors in production processes. In this regard, a data analytics-based solution was proposed to prevent failures and enhance predictive maintenance. By acquiring and analyzing data on current, voltage, and temperature, the goal was to detect anomalies and proactively address potential motor failures. This solution proved to be viable, adaptable, and scalable while minimizing the economic impact and potential accidents associated with production downtime for motor monitoring.

The results achieved in this project led to more informed and efficient decision-making in maintenance, resulting in increased productivity and profitability for companies. Moreover, it expanded the knowledge regarding the use of data analytics in this context, offering an innovative and effective alternative to enhance the maintenance of electric motors in the industrial domain.

Glosario

Mantenimiento: Conjunto de acciones preventivas y correctivas llevadas a cabo con el objetivo de asegurar el correcto funcionamiento de una máquina, equipo o sistema en todo momento (Gómez, 2006).

Mantenimiento correctivo: Tipo de mantenimiento que se lleva a cabo después de que se produce una falla o avería en el equipo o sistema (Nava, 2013).

Mantenimiento preventivo: Tipo de mantenimiento que se lleva a cabo de forma planificada y periódica, con el objetivo de prevenir fallas y mantener el equipo o sistema en óptimas condiciones (Sánchez, 2010).

Mantenimiento predictivo: Tipo de mantenimiento que se basa en la monitorización y análisis de variables o parámetros del equipo o sistema, con el objetivo de predecir posibles fallas o averías y tomar acciones preventivas antes de que ocurran (Hernández, 2015).

Gestión de mantenimiento: Conjunto de estrategias y procesos que tienen como objetivo planificar, coordinar y controlar las actividades de mantenimiento en una organización (Valdés, 2012).

Potencia: Es la cantidad de trabajo que se realiza por unidad de tiempo. Se puede expresar en vatios (W), kilovatios (kW) o megavatios (MW). (Schwarz, 2013)

Monitoreo de motores eléctricos: Es el proceso de supervisar y medir las variables eléctricas y mecánicas de los motores eléctricos para asegurar su correcto funcionamiento y prevenir posibles fallas. (Schneider Electric, 2020).

Adquisición de datos: Es el proceso de capturar y registrar datos de un sistema o proceso mediante sensores, instrumentos o dispositivos electrónicos. (Iqbal et al, 2018).

Mantenimiento predictivo: Es una estrategia de mantenimiento que utiliza el análisis de datos y técnicas de monitoreo para predecir posibles fallas en los equipos y realizar el mantenimiento antes de que ocurra una falla. (Erdinc et al, 2019).

Análisis de variables: Es el proceso de estudiar y evaluar las variables de un sistema o proceso para identificar patrones, tendencias, correlaciones y posibles problemas. (Abdallah et al, 2018).

Interpretación de datos: Es el proceso de analizar y dar sentido a los datos obtenidos, para identificar patrones, tendencias y relaciones significativas entre las variables evaluadas. (Muhammad, 2019).

Modelamiento de sistemas: Es la creación de modelos matemáticos que describen la relación entre las variables de un sistema, con el objetivo de predecir su comportamiento y tomar decisiones informadas. (Abdallah et al, 2018).

Toma de decisiones: Es el proceso de elegir entre varias opciones para resolver un problema o alcanzar un objetivo, basado en la información disponible y en los objetivos establecidos.

(Abdallah et al, 2018).

Alarmas preventivas: Son alertas que se generan cuando se detecta una condición anómala en un sistema o proceso, con el objetivo de prevenir posibles fallas o problemas. (Iqbal et al, 2018).

Tecnología de sensores: Son dispositivos electrónicos que permiten medir y detectar cambios en las variables físicas, químicas o biológicas de un sistema o proceso. (Garcia Garrido, 2010)

Automatización industrial: Es el uso de tecnologías y sistemas para controlar y optimizar los procesos industriales, con el objetivo de mejorar la eficiencia, reducir los costos y mejorar la calidad del producto. (Iqbal et al, 2018).

Análisis exploratorio de datos: Es una técnica de análisis de datos que se utiliza para explorar y resumir los datos, con el fin de identificar patrones, tendencias, relaciones y anomalías. Esta técnica incluye métodos gráficos y estadísticos para visualizar y resumir los datos, lo que permite una mejor comprensión de la información y facilita la toma de decisiones.

ANOVA: ANOVA es el acrónimo de Análisis de la Varianza. Es una técnica estadística que se utiliza para comparar las medias de tres o más grupos independientes. ANOVA se utiliza para determinar si existe alguna diferencia significativa entre las medias de los grupos, lo que puede ayudar a identificar factores importantes en el análisis de datos.

Kruskal-Wallis: Kruskal-Wallis es una prueba estadística no paramétrica utilizada para comparar las medianas de tres o más grupos independientes. Esta prueba se utiliza cuando los datos no cumplen con los supuestos de normalidad requeridos para realizar una prueba ANOVA.

Regresión logística: Es una técnica de análisis estadístico que se utiliza para modelar la relación entre una variable dependiente binaria y una o más variables independientes. La regresión logística es útil para predecir la probabilidad de que ocurra un evento, como la ocurrencia de una enfermedad o un evento de interés, en función de las variables independientes.

Análisis supervisado: Es una técnica de aprendizaje automático que se utiliza para predecir una variable de respuesta en función de un conjunto de variables predictoras. En el análisis supervisado, se utiliza un conjunto de datos de entrenamiento para desarrollar un modelo predictivo y luego se prueba en un conjunto de datos de prueba para evaluar su precisión y capacidad predictiva.

Analítica de datos: Es una disciplina que se utiliza para analizar y extraer información útil de grandes conjuntos de datos. La analítica de datos utiliza técnicas estadísticas y de aprendizaje automático para descubrir patrones y relaciones ocultas en los datos, lo que permite una mejor toma de decisiones y la identificación de oportunidades de mejora en los procesos empresariales.

Análisis de confiabilidad: Es una técnica utilizada para evaluar la capacidad de un sistema o componente para funcionar correctamente durante un período de tiempo determinado. El análisis de confiabilidad utiliza técnicas estadísticas para predecir la vida útil de un componente y determinar los factores que afectan su confiabilidad.

Aprendizaje automático: Campo de la inteligencia artificial que se enfoca en el desarrollo de algoritmos y modelos que pueden aprender y mejorar automáticamente a partir de datos.

Análisis de falla: Es una técnica utilizada para identificar las causas raíz de una falla en un sistema o componente. El análisis de falla utiliza una variedad de herramientas y técnicas, incluyendo el análisis de datos, la inspección visual y el análisis de causa-efecto, para identificar y corregir las fallas.

Análisis univariado: Es una técnica estadística utilizada para analizar datos de una sola variable. El análisis univariado se utiliza comúnmente para describir y resumir características de una muestra de datos, como la media, la mediana, la moda y la desviación estándar.

Análisis bivariado: Es una técnica estadística utilizada para analizar la relación entre dos variables. El análisis bivariado se utiliza para determinar si existe una relación significativa entre dos variables y para medir la fuerza y dirección de esa relación.

Árbol de decisiones: Es una técnica de aprendizaje automático utilizada para tomar decisiones basadas en datos. Los árboles de decisión son una representación gráfica de las posibles decisiones y resultados en una serie de opciones.

Introducción

En este proyecto, se llevará a cabo una valoración de diferentes variables de los motores eléctricos para determinar su comportamiento y su importancia en el proceso de mantenimiento. Se utilizarán técnicas estadísticas como análisis exploratorio y de varianza para evaluar la significancia de los datos obtenidos del funcionamiento de los motores eléctricos. Además, se emplearán estrategias de supervisión de datos para las diferentes variables de los motores eléctricos, con el fin de detectar anomalías y prevenir fallas de manera temprana. Por otro lado, se evaluará la confiabilidad de los datos obtenidos de los motores eléctricos, lo que permitirá determinar la calidad de la información obtenida y su relevancia en el proceso de mantenimiento. La evaluación de la confiabilidad de los datos es crucial para garantizar la efectividad del mantenimiento predictivo.

El proyecto abordará inicialmente una conceptualización en cuanto al marco teórico que soporta este ejercicio, el cual está orientado a identificar los diferentes tipos de metodologías de análisis de datos que se aplicarán en el desarrollo del proyecto; Posteriormente en los resultados, se detallarán cada uno de los métodos de análisis desarrollados con sus respectivos resultados, los cuales incluyen análisis por Kruskal-Wallis, Test Anova, Análisis Exploratorio de Datos (EDA) tanto univariado como bivariado, la aplicación de regresión logística, árbol de decisiones, análisis de confiabilidad y curvas de falla.

En conclusión, este proyecto de grado tiene como objetivo contribuir al mejoramiento del mantenimiento predictivo de los motores eléctricos a través del uso de la analítica de datos. Se espera que los resultados obtenidos de este proyecto ayuden a las empresas a tomar decisiones

más informadas y eficientes para el mantenimiento de sus equipos, lo que se traducirá en una mayor productividad y rentabilidad. Además, se espera que este proyecto contribuya a ampliar los datos disponibles sobre la implementación de estrategias de supervisión de datos en el mantenimiento predictivo de los motores eléctricos.

1. Planteamiento del problema

1.1. Descripción

El mantenimiento de los motores eléctricos es algo que resulta fundamental en cualquier proceso de transformación y productivo debido a que, a partir de ello se garantiza la confiabilidad de estos, y el no realizarlo en los tiempos y bajo las condiciones adecuadas puede llevar a generar errores en la operatividad, propiciando así malas prácticas en la industria, con las afectaciones que pueden trascender a daños materiales, pérdidas económicas, destrucción de valor y riesgo a la integridad física de quienes interactúan con el proceso.

De acuerdo con las estadísticas levantadas alrededor del mundo por diferentes compañías productoras y empresas que se preocupan por la medición de la eficiencia en el mantenimiento, se estima que, la mayor parte del tiempo muerto (time-out), que está alrededor del 90%, se debe a que todavía muchas industrias no han implementado de manera óptima el mantenimiento preventivo, puesto que se esperan hasta que se presente una avería para su respectiva intervención (infraspeak, 2021).

A nivel mundial se reconoce como una buena práctica tener un 80% de mantenimiento preventivo y un 20% en correctivo, en Colombia estos porcentajes no se cumplen, de acuerdo con los reportes de la asociación colombiana de ingenieros (ACIEM), aunque estos datos en los últimos años también pueden verse afectados por las dificultades que se experimentaron en el sector industrial durante la pandemia debido a que el nivel productivo bajó y por tal motivo se requirió menor mantenimiento. Por su parte, las buenas prácticas del mantenimiento se

encuentran en declive entre las medianas y pequeñas empresas, debido a que reconocen esta labor como de bajo impacto en su producción. (ACIEM, 2022).

Así, estamos frente a un escenario en el cual el área de mantenimiento de las empresas productivas puede verse impactado positivamente con la implementación de nuevas tecnologías, la administración correcta de sus activos productivos y la implantación soluciones prácticas y económicas que permitan medir, controlar y mejorar la producción de las empresas en el área metropolitana. El adecuado mantenimiento predictivo de motores eléctricos es crucial para asegurar su correcto funcionamiento y evitar fallos que puedan perjudicar la productividad y rentabilidad de sistemas productivos.

A menudo, los motores eléctricos se monitorean de manera manual o ni siquiera se monitorizan, lo que aumenta el riesgo de fallos no detectados y aumenta los costes de mantenimiento correctivo. En este contexto, es necesario desarrollar una solución de monitoreo para motores eléctricos que permita establecer un sistema de mantenimiento predictivo, mediante la adquisición de datos de corriente, voltaje y temperatura. El proyecto de ingeniería eléctrica que se propone busca integrar la analítica de datos y automatización industrial para analizar datos de funcionamiento de los motores, lo que permitirá detectar anomalías y prevenir fallos.

1.2. Formulación

¿Será posible utilizar la analítica de datos con variables como corriente, voltaje y temperatura de los motores de manera que, mediante el análisis y la interpretación de las variables evaluadas, se contribuya al mantenimiento efectivo y preventivo de los motores eléctricos?

2. Justificación

En la actualidad, es cada vez más común utilizar el análisis de datos en la toma de decisiones empresariales, especialmente en áreas como el mantenimiento de sistemas productivos. Sin embargo, a menudo se subestima la importancia del uso de este tipo de estrategias en el mantenimiento predictivo o preventivo, lo que puede convertirse en la pérdida de oportunidades de mejorar la productividad y competitividad de las empresas, además de mitigar los riesgos de fallas no detectadas y la disminución de costos de mantenimiento correctivo. En este sentido, el monitoreo en tiempo real del estado y condiciones de funcionamiento del motor a través de la adquisición y análisis de datos puede mejorar significativamente el proceso de mantenimiento y brindar una oportunidad valiosa para tecnificarlo.

En este proyecto de grado, proponemos una solución enfocada en el análisis de datos para el mantenimiento predictivo o preventivo del motor. La solución consiste en utilizar tecnología de sensores y automatización industrial para recolectar y analizar datos en tiempo real, lo que permitirá detectar anomalías y prevenir fallas. Además, esta solución es viable, adaptable, escalable y no invasiva, lo que minimiza el impacto económico y los posibles accidentes que pueden generarse durante la detención de la producción para el monitoreo del estado del motor.

El objetivo principal de esta propuesta es implementar un modelo que permita ayudar a las empresas en la toma de decisiones más informadas y eficientes, a partir del uso de la analítica de datos para el mantenimiento de sus equipos, lo que se traduce en una mayor productividad y rentabilidad; Cabe destacar que, al investigar los dispositivos disponibles y las tecnologías de captura de información, se ampliarán los datos sobre la implementación de dispositivos

analizadores de corriente, lo que contribuirá a contrastarlos con otros estudios similares y analizar posibles variantes y soluciones alternativas que se le puedan dar, en aras de mejorar continuamente el proceso de mantenimiento. En conclusión, la propuesta de análisis de datos en el mantenimiento predictivo o preventivo del motor se destaca por ser una alternativa innovadora, rentable y eficaz para las empresas que buscan mejorar su productividad y competitividad en el mercado.

3. Objetivos

3.1. General

Valorar utilizando la analítica de datos el comportamiento de diferentes variables de los motores eléctricos en aras de contribuir a la toma de decisiones para el mantenimiento de estos.

3.2. Específicos

Realizar análisis exploratorio y de varianza de los datos obtenidos del funcionamiento de los motores eléctricos para determinar su significancia.

Emplear estrategias de supervisión de datos para las diferentes variables de los motores eléctricos.

Evaluar en base a los datos obtenidos de los motores eléctricos la confiabilidad de estos.

4. Marco teórico

El mantenimiento surge de la necesidad del ser humano en conservar sus herramientas para poder sobrevivir, estas solían romperse o desgastarse, por lo cual era necesario repararlas o mejorarlas para que tuviesen una mayor durabilidad. Debido a la revolución industrial y su mecanización, se llegó a un punto de inflexión donde se preocuparon por las fallas en las herramientas o en si del equipo. Como se evidencia en la Tabla 1, todo esto conllevó a una serie de estudios para el mejoramiento continuo de la industria.

Tabla 1

Estudios y aplicaciones del mantenimiento en el tiempo.

Año	Desarrollo en mantenimiento
1780	Mantenimiento Correctivo (CM).
1798	Mejora del CM.
1910	Formación de cuadrillas de Mantenimiento Correctivo.
1914	Mantenimiento Preventivo (MP).
1916	Inicio del Proceso Administrativo creado por Henry Fayol.
1927	Uso de la estadística en producción a fin de controlar el trabajo.
1931	Control Económico de la Calidad del producto Manufacturado.
1937	Conocimiento del Principio de W.
1939	Se controlan los trabajos de Mantenimiento Preventivo con estadística.
1946	Se mejora el Control Estadístico de Calidad (SQC).
1951	Se da a conocer el “Análisis de Weibull”.
1960	Se desarrolla el Mantenimiento Centrado en la Confiabilidad (RCM).

1961	Se inicia el Poka-Yoke (a prueba de errores).
1962	Se desarrollan los Círculos de Calidad (QC) basados en el MP.
1965	Se desarrolla el análisis Causa- Raíz (RCA).
1970	Difusión del uso de la computadora para la administración de Activos (CMMS).
1971	Se desarrolla el Mantenimiento Productivo Total (TPM).
1978	Se presenta la Guía MSG-3.
1980	Se desarrolla la Optimización del Mantenimiento Planificado (PMO).
1995	Se desarrolla el proceso de los 5 Pilars of the Visual Workplace (5S's).
2005	Se estudia la filosofía de la Conservación Industrial (IC).

Fuente: (Pérez Rondón, 2021)

Gracias a estos estudios y desarrollos hoy se puede determinar con mayor facilidad como deberían realizarse los mantenimientos y las estrategias para poder implementarlos de la mejor forma.

4.1. Tipos de mantenimiento

Según el libro (García Garrido, 2010), actualmente la clasificación de los tipos de mantenimiento se basa en función de si es de conservación o de actualización.

4.1.1. Mantenimiento de conservación

Está destinado a mitigar el deterioro que presenten los equipos por el uso, debido a condiciones físicas, químicas a las que fue sometido. Este puede ser de dos tipos (González Fernández, 2005).

○ **Mantenimiento correctivo:** Es un conjunto de tareas destinadas a subsanar los defectos que se presentan en los equipos. Este se divide en dos.

- **Inmediato:** Se realiza inmediatamente de aparecer el desperfecto o falla.
- **Diferido:** Cuando se produzca el desperfecto o falla, se produce un paro de la instalación o equipamiento que se vaya a tratar.

○ **Mantenimiento preventivo:** Este mantenimiento tiene como misión mantener un nivel de servicio de los equipos, programando las intervenciones soliendo ser estas sin necesidad que el equipo presente algún problema. Este se divide en tres.

- **Programado:** Este se realiza por programa de revisión, por tiempo de funcionamiento, kilometraje etc.
- **Predictivo:** Realiza las intervenciones prediciendo en momento en que el equipo queda fuera de servicio mediante un seguimiento de su funcionamiento.

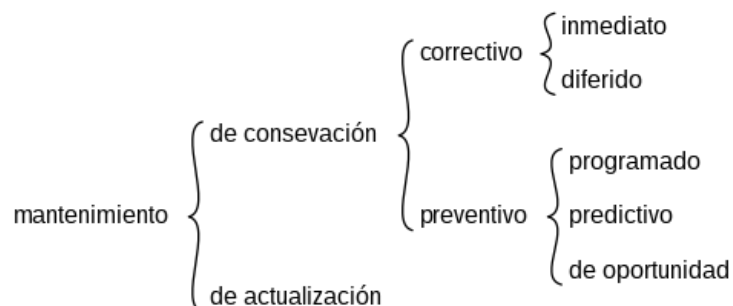
- **De oportunidad:** En este se aprovecha las paradas o periodos de no uso de los equipos para realizar operaciones de mantenimiento, puede también asociarse con el programado.

4.1.2. *Mantenimiento de actualización*

Tiene como propósito amortizar la obsolescencia tecnológica del equipo, debido a que las nuevas exigencias de manufactura así lo requieran.

En la figura 1 se puede apreciar un esquema más simplificado de los tipos de mantenimiento según su jerarquía de implementación.

Figura 1.
Operaciones de mantenimiento.



Fuente: <https://bit.ly/3Qn7t9A>

El mantenimiento trata de mitigar la degradación y los fallos de los equipos y la instalación en el tiempo, por lo cual se trata de asegurar cuatro objetivos básicos que se pueden apreciar en la figura 2.

Figura 2.
Pilares del mantenimiento.



Fuente: Autores.

4.2. Mantenimiento predictivo con IOT

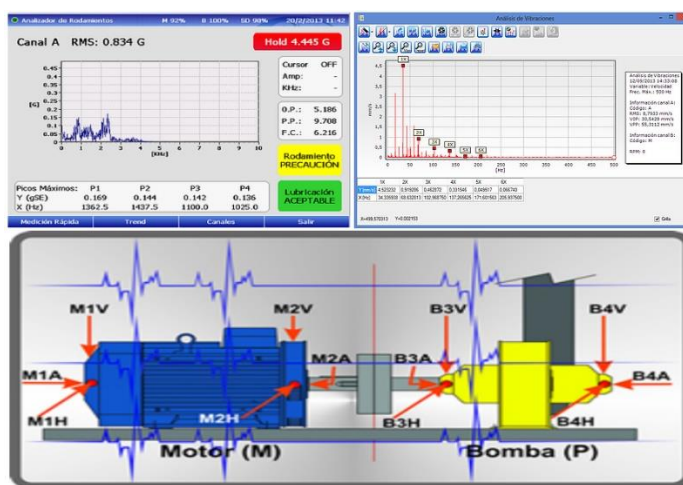
El mantenimiento predictivo por medio de sistemas inteligentes de alarma y predicción de fallas consiste en dispositivos IOT con protocolos de comunicación Message Queing Telemetry Transport (MQTT) o Time To Live (TTL) con dispositivos como sensores y otros periféricos que permitan la interpretación de datos en tiempo real y escalables en el tiempo son cada vez de menor tamaño y fáciles de conseguir en el mercado (Ramirez Mongui & Dávila Arias, 2022). Esto ha generado un gran desarrollo para la industria y su cuarta revolución, no solo con dispositivos sino también con el manejo de datos, inteligencia artificial e impresión de piezas de moldeo rápido. Por lo cual la ayuda para el sector de mantenimiento empresarial es ahora un abanico de posibilidades ilimitadas.

Los sistemas más utilizados para el mantenimiento predictivo de motores eléctricos son:

4.2.1. Análisis de vibraciones

Esta consiste en analizar las vibraciones de una maquina mediante sensores conectados al equipo como se muestra en la Figura 3. Presentando patrones de vibración acordes a la maquina cuando esta se encuentra en condiciones ideales, pero cuando los componentes se desgastan la frecuencia de estas se distorsiona presentando unas formas muy diferentes a las establecidas mediante el estándar establecido (Rodríguez, Elsaghir, & Hashi, 2018).

Figura 3.
Análisis de vibraciones con el programa Airproject SPA.



Fuente: <https://bit.ly/3EC0rLJ>

4.2.2. Monitoreo acústico

Gracias a las nuevas tecnologías de sensores es posible detectar fugas de gas, líquidos o vacíos, también detectando fricciones o tensiones en los equipos detectando rodamientos en mal estado o sin lubricación como se muestra en la Figura 4 (Méndez Freire, 2021).

Figura 4.
Ultrasonido acústico sonux XT.




Fuente: <https://bit.ly/3CTY99R>

4.2.3. *Termografía infrarroja*

Los componentes desgastados suelen emitir más calor de lo normal, mediante el uso de cámaras infrarrojas (IR) como se muestra en la Figura 5 se detectan puntos calientes en el equipo con el cual se puede determinar la zona afectada y poder corregirla (Resendiz Ochoa, 2021).

Figura 5.
Termografía infrarroja de piezas mecánicas y eléctricas electroindustriales.



Fuente: <https://bit.ly/3g5YI7z>

No solo se implementa uno de ellos en un monitoreo, también es posible hacer combinaciones de estos o bien los tres en paralelo en maquinaria crítica para el sistema.

4.3. Analítica de datos

Además, es importante mencionar la relevancia de la analítica de datos en el contexto del mantenimiento predictivo de motores eléctricos. La analítica de datos se refiere al proceso de examinar grandes cantidades de datos con el fin de descubrir patrones, correlaciones y tendencias, y poder así obtener información valiosa y tomar decisiones informadas. En el caso del monitoreo de motores eléctricos, la analítica de datos permite identificar patrones de comportamiento y detectar posibles fallos o anomalías en los datos adquiridos, lo que permite tomar medidas preventivas antes de que ocurra una falla crítica. (Boriah et al., 2008)

Por lo tanto, en el marco del proyecto de implementación de un sistema de monitoreo y mantenimiento predictivo para motores eléctricos, se recomienda realizar un análisis exhaustivo de los datos recopilados para identificar patrones y tendencias relevantes. Esto puede lograrse mediante la utilización de herramientas de analítica de datos, tales como técnicas de minería de datos y aprendizaje automático, que permiten analizar grandes cantidades de datos de manera eficiente y descubrir patrones ocultos que no son detectables a simple vista. (Alpaydin, 2010). Además, se sugiere que se implementen algoritmos de detección de anomalías para identificar y alertar sobre posibles fallas en el sistema de manera temprana, lo que permitiría tomar medidas preventivas antes de que se produzca una falla crítica. Estos algoritmos pueden ser diseñados

utilizando técnicas de aprendizaje automático, tales como redes neuronales o árboles de decisión, que permiten clasificar y predecir patrones de comportamiento en los datos adquiridos. (Boriah et al., 2008)

4.4. Análisis exploratorio de datos (EDA)

El análisis exploratorio de datos es una herramienta crucial para comprender los datos en cualquier proceso de análisis de datos. En el contexto del mantenimiento predictivo de motores eléctricos, esta técnica puede ser utilizada para detectar relaciones entre las variables de los datos, descubrir patrones de comportamiento inesperados, y generar hipótesis sobre posibles factores que pueden contribuir a los fallos del motor. Además, el análisis exploratorio de datos también puede ser útil en la identificación de variables irrelevantes o redundantes que no aportan información significativa para el análisis y que pueden ser eliminadas para mejorar la eficiencia del modelo. En general, el análisis exploratorio de datos permite a los ingenieros eléctricos tomar decisiones informadas basadas en la comprensión completa de los datos, lo que puede mejorar la precisión y la efectividad del mantenimiento predictivo. (Tukey, 1977)

El análisis exploratorio de datos también es útil para la identificación de patrones y relaciones entre variables que pueden no ser evidentes a simple vista. Al explorar los datos de los motores eléctricos, se pueden descubrir patrones de comportamiento y correlaciones que son fundamentales para comprender la dinámica del motor y predecir posibles fallas. (Tukey, 1977)

Además, el análisis exploratorio de datos puede ayudar a identificar variables irrelevantes o redundantes que pueden ser eliminadas para mejorar la eficiencia del modelo. En la industria, el análisis exploratorio de datos se utiliza para mejorar la comprensión de los datos de los motores eléctricos, lo que permite una mejor toma de decisiones. Por ejemplo, al analizar los datos de los motores eléctricos, se pueden identificar factores que contribuyen a la falla, como la sobrecarga, la vibración o la temperatura, y se pueden tomar medidas preventivas para reducir el riesgo de fallas. (Tukey, 1977)

En conclusión, el análisis exploratorio de datos es una herramienta importante en el desarrollo de soluciones de monitoreo y mantenimiento predictivo para motores eléctricos. Permite una comprensión más profunda de los datos de los motores eléctricos, identifica patrones y relaciones que pueden ser relevantes para la detección temprana de fallas y la toma de decisiones informadas para mejorar la eficiencia y rentabilidad de los sistemas productivos. (Tukey, 1977)

4.5. Análisis de varianza (ANOVA)

El análisis de varianza (ANOVA) es una técnica estadística utilizada para comparar las medias de tres o más grupos de datos. ANOVA se utiliza para determinar si las medias de los grupos son significativamente diferentes entre sí y para identificar cuál o cuáles grupos tienen una media diferente de los demás. En el contexto del mantenimiento predictivo de motores eléctricos, el ANOVA puede ser utilizado para analizar la relación entre varias variables y determinar si estas variables tienen un efecto significativo en el rendimiento del motor.

El ANOVA es una herramienta útil en el análisis de datos de motores eléctricos porque permite comparar las medias de múltiples grupos de datos y determinar si existe una diferencia significativa entre ellos. Por ejemplo, se puede utilizar el ANOVA para determinar si las fallas del motor están relacionadas con la carga, la vibración o la temperatura. Esto puede ayudar a los ingenieros eléctricos a identificar los factores que tienen el mayor impacto en el rendimiento del motor y a desarrollar estrategias de mantenimiento predictivo más efectivas para reducir el tiempo de inactividad del equipo y mejorar la eficiencia.

En la industria, el ANOVA se utiliza para mejorar la toma de decisiones en una amplia gama de aplicaciones, incluyendo la optimización de procesos y la identificación de las causas raíz de los problemas de producción. El ANOVA también se utiliza en la investigación científica y médica para determinar si hay diferencias significativas entre los grupos de datos en los estudios clínicos y experimentales.

En resumen, el análisis de varianza es una herramienta estadística valiosa en el análisis de datos de motores eléctricos, ya que permite comparar las medias de varios grupos de datos y determinar si hay diferencias significativas entre ellos. Esto puede ayudar a los ingenieros eléctricos a identificar los factores que tienen el mayor impacto en el rendimiento del motor y desarrollar estrategias de mantenimiento predictivo más efectivas para reducir el tiempo de inactividad del equipo y mejorar la eficiencia en la industria. (Maxwell and Delaney, 1990)

4.6. Test de Kruskal Wallis

Las aplicaciones del aprendizaje automático en el análisis de datos de motores son cada vez más comunes en la industria y la investigación. En la industria, el aprendizaje automático se utiliza para el monitoreo y mantenimiento predictivo de motores, permitiendo una gestión más eficiente de los recursos y reduciendo el tiempo de inactividad de los equipos. En la investigación, el aprendizaje automático se utiliza para el análisis de grandes conjuntos de datos generados por los motores, con el objetivo de identificar patrones y tendencias que permitan una mejor comprensión de su comportamiento y rendimiento. (Alpaydin, 2010).

El análisis de varianza Kruskal-Wallis es una herramienta estadística que se utiliza para determinar si existen diferencias significativas entre los grupos de datos, cuando estos no cumplen con los supuestos de normalidad y homogeneidad de varianza necesarios para realizar un análisis de varianza estándar. El Kruskal-Wallis es especialmente útil en el análisis de datos en los que se tienen varias muestras independientes y se desea comparar si hay diferencias significativas entre ellas, como puede ser el caso de los datos generados por los motores en distintas condiciones de operación o en diferentes momentos del tiempo. (Cordero, 2017)

4.7. Análisis supervisado

El análisis supervisado es una técnica de aprendizaje automático que utiliza un conjunto de datos etiquetados para entrenar un modelo y predecir resultados futuros. Se divide en dos tipos principales: clasificación y regresión. En la clasificación, se asigna una etiqueta o categoría a un

objeto o evento en función de sus características, mientras que en la regresión se predice un valor numérico continuo. (Alpaydin, 2010)

Entre los métodos de clasificación más utilizados se encuentran el K-vecinos más cercanos (KNN), el árbol de decisiones y el algoritmo de Naïve Bayes. El KNN se basa en la idea de que objetos similares se agrupan en la misma categoría, mientras que el árbol de decisiones utiliza una estructura en forma de árbol para representar las decisiones y sus posibles consecuencias. El algoritmo de Naïve Bayes es un método probabilístico que utiliza el teorema de Bayes para predecir la probabilidad de una etiqueta dada ciertas características. (Hastie et al., 2009)

Por otro lado, los métodos de regresión se utilizan para predecir un valor numérico continuo. Los más comunes son la regresión lineal, la regresión logística y el análisis discriminante lineal. La regresión lineal es un método que utiliza una función lineal para predecir la relación entre una variable dependiente y una o más variables independientes. La regresión logística se utiliza para predecir la probabilidad de que un objeto pertenezca a una categoría en función de sus características. El análisis discriminante lineal se utiliza para clasificar objetos en dos o más grupos en función de sus características. (Hastie et al., 2009)

En el análisis supervisado, es importante considerar la calidad de los datos y su relevancia para el problema que se está tratando de resolver. También es importante seleccionar el método adecuado y ajustar los parámetros de manera óptima para obtener los mejores resultados posibles. Además, es esencial evaluar la precisión del modelo mediante la utilización de conjuntos de datos de prueba y validación. (Alpaydin, 2010)

En resumen, el análisis supervisado es una técnica de aprendizaje automático que utiliza un conjunto de datos etiquetados para entrenar un modelo y predecir resultados futuros. Se divide en dos tipos principales: clasificación y regresión, cada uno con sus propios métodos. Es importante considerar la calidad de los datos y seleccionar el método adecuado y ajustar los parámetros de manera óptima para obtener los mejores resultados posibles. Además, es esencial evaluar la precisión del modelo mediante la utilización de conjuntos de datos de prueba y validación. (Hastie et al., 2009)

4.8. Análisis de confiabilidad

El análisis de confiabilidad es una técnica estadística utilizada para evaluar la capacidad de un sistema o componente para funcionar correctamente durante un período de tiempo determinado y bajo ciertas condiciones. Es una herramienta importante en la gestión de la calidad y la toma de decisiones en diversas industrias, desde la fabricación hasta la energía y la salud. (Singh et al., 2016)

El análisis de confiabilidad se utiliza para identificar y evaluar los problemas potenciales que pueden surgir en un sistema o componente, así como para desarrollar planes de mantenimiento y estrategias de mejora. Permite a los ingenieros y gerentes evaluar la vida útil esperada de un producto o sistema, y tomar decisiones informadas sobre cómo maximizar la confiabilidad y minimizar los costos de reparación y reemplazo. (Nagode & Kandukuri, 2015)

Además de la evaluación de la confiabilidad de los sistemas, el análisis de confiabilidad también se utiliza para realizar análisis de riesgo, en los que se evalúa el riesgo asociado con el fallo de un componente o sistema, y para el diseño de sistemas que cumplen con ciertos requisitos de confiabilidad. En la industria aeroespacial, por ejemplo, el análisis de confiabilidad se utiliza para evaluar la capacidad de un sistema para cumplir con los requisitos de seguridad y fiabilidad de la Administración Federal de Aviación (FAA) y otras agencias reguladoras. (Kazemi et al., 2017)

Existen diversas técnicas y herramientas de análisis de confiabilidad, incluyendo análisis de fallas, análisis de modo y efecto de falla (FMEA), análisis de árbol de fallas, entre otras. Cada una de estas técnicas se utiliza para evaluar diferentes aspectos de la confiabilidad de un sistema o componente, y se seleccionan en función del problema específico que se está evaluando. (Moubray, 2010)

En resumen, el análisis de confiabilidad es una técnica valiosa para la evaluación de la confiabilidad de los sistemas y componentes, y para la toma de decisiones informadas en la gestión de la calidad y la planificación del mantenimiento. Es una herramienta esencial en diversas industrias, que ayuda a garantizar la seguridad y eficiencia de los sistemas y productos que utilizamos todos los días. (Singh et al., 2016)

4.9. Aprendizaje automático

El aprendizaje automático es una técnica que se utiliza para el análisis de datos y la identificación de patrones en el comportamiento de los motores. Se basa en la utilización de algoritmos que permiten a los motores aprender de forma autónoma, a partir de la información proporcionada por sensores y otras fuentes de datos. Los algoritmos de aprendizaje automático pueden clasificarse en tres categorías principales: supervisado, no supervisado y por refuerzo. En el aprendizaje supervisado, el algoritmo se entrena con datos etiquetados previamente para identificar patrones y luego se utiliza para predecir resultados en datos no etiquetados. En el aprendizaje no supervisado, el algoritmo busca patrones y estructuras en los datos sin la necesidad de etiquetas previas. En el aprendizaje por refuerzo, el algoritmo aprende a través de la interacción con un entorno y recibe retroalimentación en forma de recompensa o castigo.

El aprendizaje automático es una herramienta útil para el análisis de datos de motores, ya que puede ayudar a identificar patrones complejos en grandes cantidades de datos. Por ejemplo, se puede utilizar para el diagnóstico de fallas en motores y para la identificación de patrones de uso que puedan indicar la necesidad de mantenimiento preventivo. Además, el aprendizaje automático puede ser utilizado para la optimización de la eficiencia del motor, al identificar patrones en los datos de rendimiento del motor y ajustar el funcionamiento en consecuencia. (Goodfellow et al., 2016).

En la aplicación del aprendizaje automático en el análisis de datos de motores, es importante tener en cuenta la calidad y cantidad de los datos utilizados. Para ello, se deben utilizar técnicas adecuadas de adquisición y preprocesamiento de datos, así como algoritmos de aprendizaje

automático apropiados para el tipo de datos y la tarea específica que se desea realizar. Además, es importante contar con un conocimiento previo del motor y de los patrones de comportamiento que se buscan identificar, para poder definir de manera adecuada las variables a considerar en el proceso de análisis de datos.

Entre las técnicas de aprendizaje automático más utilizadas en el análisis de datos de motores se encuentran las redes neuronales artificiales, los árboles de decisión, los métodos de vecinos más cercanos y los algoritmos de agrupamiento. Estas técnicas pueden ser aplicadas en diferentes áreas del análisis de datos de motores, desde la detección de anomalías y el diagnóstico de fallas, hasta la predicción de rendimiento y la optimización del funcionamiento del motor. (Murphy, 2012). Las aplicaciones del aprendizaje automático en el análisis de datos de motores son cada vez más comunes en la industria y la investigación. En la industria, el aprendizaje automático se utiliza para el monitoreo y mantenimiento predictivo de motores, permitiendo una gestión más eficiente de los recursos y reduciendo el tiempo de inactividad de los equipos. (Alpaydin, 2010)

El uso del aprendizaje automático ha cobrado una gran importancia en la industria del mantenimiento predictivo, permitiendo el análisis de datos y la identificación de patrones en el comportamiento de los motores. Al procesar grandes cantidades de información, esta herramienta se convierte en un medio eficiente para identificar relaciones complejas y predecir posibles fallas en el futuro. Es así como el aprendizaje automático se ha convertido en un aliado importante para mejorar la eficiencia y confiabilidad de los sistemas de monitoreo y mantenimiento predictivo en motores. En conclusión, el aprendizaje automático es una herramienta poderosa que ha demostrado ser útil en la identificación de patrones y en la predicción de fallas, convirtiéndose en un elemento clave para el mantenimiento predictivo de los motores.

4.10. Análisis de fallas

En la industria, los motores eléctricos son componentes críticos en muchos procesos productivos. Estos motores pueden fallar por diferentes razones, como el desgaste de los rodamientos, la deformación del eje, la sobrecarga de corriente, la contaminación, entre otras. Por lo tanto, es esencial contar con un sistema de monitoreo y mantenimiento predictivo adecuado para garantizar la eficiencia y confiabilidad del proceso productivo. (Shelley, 2013). El análisis de datos es una técnica poderosa para identificar diferentes tipos de fallas en los motores industriales. Una de las fallas más comunes es la falla del rodamiento, que puede ser detectada mediante el análisis de vibraciones. Las vibraciones son causadas por el movimiento del rotor y las partes giratorias en el motor. El análisis de vibraciones puede identificar diferentes características en las señales, como la presencia de armónicos o la frecuencia fundamental de una señal periódica. (Smith, 2007)

Otra falla común en los motores eléctricos es la sobrecarga de corriente, que puede ser detectada mediante el análisis de la corriente eléctrica que fluye a través del motor. El análisis de la corriente eléctrica puede identificar diferentes características, como picos de corriente y armónicos de la frecuencia de la línea de alimentación. Además, también puede ser utilizado para detectar problemas en el aislamiento del motor. (Ramesh Babu, 2018); Por su parte el análisis de la temperatura también es una técnica utilizada para identificar diferentes tipos de fallas en los motores eléctricos. Un aumento en la temperatura puede indicar problemas como la sobrecarga, la falta de ventilación, la contaminación o el desgaste. Además, también puede ser utilizado para identificar la falta de lubricación en el motor. (Bishop, 2010)

El análisis del ruido acústico también es una técnica utilizada para identificar diferentes tipos de fallas en los motores eléctricos. El ruido acústico puede ser causado por diferentes razones, como la deformación del eje, la falta de lubricación, la contaminación o el desgaste. El análisis del ruido acústico puede identificar diferentes características en las señales, como la presencia de armónicos o la frecuencia fundamental de una señal periódica. (Shelley, 2013)

En resumen, el análisis de datos es una técnica poderosa para identificar diferentes tipos de fallas en los motores eléctricos. Las diferentes técnicas de análisis, como el análisis de vibraciones, el análisis de corriente eléctrica, el análisis de temperatura y el análisis del ruido acústico, pueden ser utilizadas para identificar diferentes características en las señales y predecir posibles fallas en el futuro. Es esencial contar con un sistema de monitoreo y mantenimiento predictivo adecuado para garantizar la eficiencia y confiabilidad del proceso productivo. (Ramesh Babu, 2018)

Además de las fallas eléctricas, también existen fallas mecánicas en los motores industriales que pueden ser identificadas mediante el análisis de datos. Estas fallas pueden incluir desgaste en los rodamientos, desequilibrio en el rotor y problemas de alineación. Según (Nandi, 2012), el análisis de vibraciones es una técnica efectiva para identificar las fallas mecánicas en los motores. Las vibraciones mecánicas generadas por el motor pueden ser medidas y analizadas para identificar patrones que indiquen la presencia de una falla.

Otro tipo de falla que puede presentarse en los motores industriales es la falla de lubricación, la cual puede causar daños en los cojinetes y otros componentes del motor. Según (Duque, 2017), el análisis de la temperatura y la presión del aceite pueden ayudar a identificar las fallas

de lubricación en los motores. Asimismo, existen fallas que son causadas por el desgaste de los componentes internos del motor, como los anillos del pistón y las válvulas. Según (Lee, 2018), el análisis de gases de escape es una técnica que se utiliza para identificar este tipo de fallas. La presencia de ciertos gases en los gases de escape puede indicar un desgaste anormal en los componentes internos del motor.

Además de las técnicas mencionadas anteriormente, también existen otras técnicas de análisis de datos que pueden utilizarse para identificar fallas en los motores industriales. Estas técnicas incluyen el análisis de la corriente y la potencia eléctrica consumida por el motor, el análisis de la frecuencia de resonancia del motor y el análisis de la señal acústica generada por el motor. En conclusión, el análisis de datos es una herramienta valiosa para identificar diferentes tipos de fallas en los motores industriales. La identificación temprana de estas fallas puede ayudar a evitar costosos tiempos de inactividad y reparaciones, lo que a su vez puede mejorar la eficiencia y la confiabilidad del sistema.

5. Metodología

Se ha decidido utilizar una metodología de investigación cualitativa para valorar el comportamiento de diferentes variables de los motores eléctricos en aras de contribuir a la toma de decisiones para el mantenimiento de estos. Para llevar a cabo este proyecto, se realizará una revisión de la literatura existente sobre la analítica de datos y su aplicación en el mantenimiento de motores eléctricos, con el fin de identificar buenas prácticas y posibles soluciones alternativas. Se recolectarán datos de diferentes motores eléctricos en un ambiente controlado y se analizarán utilizando técnicas de análisis exploratorio de datos, así como también técnicas de análisis de varianza para determinar la significancia de los resultados.

Se emplearán estrategias de supervisión de datos para monitorear las diferentes variables de los motores eléctricos, como la temperatura, el voltaje y la corriente, y se analizarán para determinar posibles patrones y anomalías en el comportamiento del motor que puedan ser indicadores de futuras fallas o problemas en su funcionamiento. Por último, se evaluará la confiabilidad de los datos obtenidos de los motores eléctricos y se propondrán recomendaciones para la toma de decisiones en el mantenimiento de estos. El enfoque metodológico utilizado será cualitativo, puesto que se busca ofrecer descripciones detalladas de las situaciones y eventos observados, así como también de las conductas y manifestaciones que se presenten.

5.1. Tipo de proyecto

El presente proyecto de grado tiene un enfoque investigativo y experimental con el propósito de realizar análisis exploratorio y de varianza de los datos obtenidos del funcionamiento de los motores eléctricos para determinar su significancia, emplear estrategias de supervisión de datos para las diferentes variables de los motores eléctricos y evaluar en base a los datos obtenidos la confiabilidad de estos. Se utilizarán técnicas de procesamiento de señales y aprendizaje automático para el análisis de los datos.

5.2. Método

La metodología que se utilizará en este proyecto será de investigación cualitativa, la cual implica un enfoque más flexible y exploratorio en la recolección y análisis de datos. Se llevará a cabo una investigación experimental en la que se utilizarán dispositivos de monitoreo en tiempo real para la toma de mediciones del estado y condiciones de funcionamiento de motores industriales. Posteriormente, se analizarán los datos obtenidos mediante técnicas de procesamiento de señales y aprendizaje automático con el fin de identificar patrones y anomalías en el comportamiento del motor, y poder implementar un sistema predictivo de mantenimiento. Además, se realizará una revisión de la literatura existente sobre dispositivos de monitoreo y su aplicación en la industria para contextualizar los resultados obtenidos en la investigación.

5.3. Población y muestra

Para el ejercicio propuesto se trabajó con datos suministrados por la empresa Alfarera Buena Vista, ubicada en la ciudad de Medellín en la calle 31AA #106-29, la cual se dedica a la producción industrializada de ladrillos. En esta empresa, haciendo el uso de sensores instalados en los diferentes motores eléctricos, se vienen tomando registros y medidas constantemente de las variables eléctricas y térmicas del motor, para su posterior envío de la información a un dispositivo central de PLC, sin embargo, hasta la fecha no se viene aprovechando al máximo la data disponible.

Datos suministrados: La información suministrada por la empresa, se compone de una base de datos, que contempla el registro de las variables de corriente, voltaje y temperatura de diferentes motores que hacen parte de su proceso productivo. Para el ejercicio se nos fue suministrada una base da datos, que recopila lecturas diarias de operación de 7 motores, las cuales son generadas con un intervalo de una hora, cuya fecha inicial es el 02/01/2021 y su fecha final 30/12/2022.

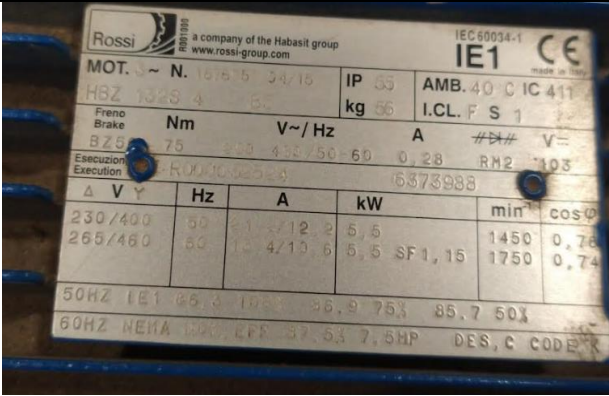


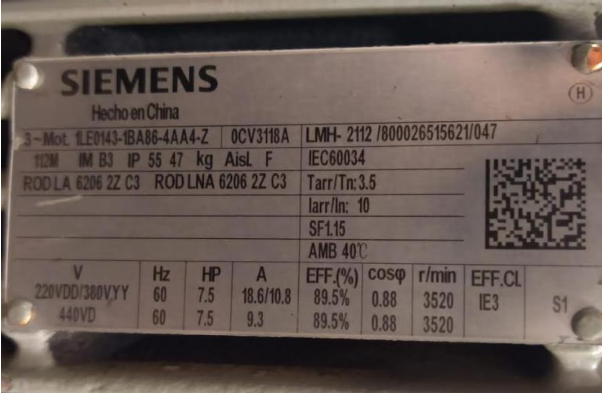
A continuación, en la Tabla 2 se evidencia un resumen de los datos suministrados, clasificados por variables y tipos de motor.

Tabla 2.
Cantidad de datos por variables y tipo de motor

Motor	Marca Motor	HP	DATOS CORRIENTE	DATOS VOLTAJE	DATOS TEMPERATURA
Motor 1	Rossi	7.5	6545	6545	6545
Motor 2	Echtop	7.5	6545	6545	6545
Motor 3	Echtop	7.5	6545	6545	6545
Motor 4	Siemens	7.5	6545	6545	6545
Motor 5	Echtop	3.6	6545	6545	6545
Motor 6	Weg	30	6545	6545	6545
Motor 7	Rossi	5	6545	6545	6545

A continuación, en la Tabla 3 se relacionan las placas de motor, de los 7 motores que fueron objeto de analisis en este ejercicio.

Tabla 3.
Placas de motores analizados

Motor 1	Motor 2
 <p>Placa de motor Rossi con especificaciones técnicas detalladas, incluyendo potencia (7.5 HP), velocidad (1450/1750 rpm) y eficiencia (IE1).</p>	 <p>Placa de motor Echtop, tres fases, potencia 7.5 HP, velocidad 1745 rpm, eficiencia IE2 89.5%.</p>
Motor 3	Motor 4
 <p>Placa de motor Echtop, tres fases, potencia 7.5 HP, velocidad 1440 rpm, eficiencia IE2 87.7%.</p>	 <p>Placa de motor Siemens, tres fases, potencia 7.5 HP, velocidad 3520 rpm, eficiencia IE3.</p>

Motor 5



Motor 6



Motor 7



La base de datos suministrada consideraba algunos momentos en que los motores entraron en falla como se muestra en la Tabla 4 y Tabla 5, información que será utilizada como parte del modelo de aprendizaje.

Tabla 4.
Motores analizados

Motor	Marca Motor	ESTADO	CANTIDAD DE DATOS ASOCIADOS A ESTADOS DE FALLA
Motor 1	Rossi	OPERANDO	19635
Motor 2	Echtop	FALLA	51
		OPERANDO	12267
Motor 3		FALLA	30
		OPERANDO	19575
Motor 4	Siemens	OPERANDO	19635
Motor 5	Echtop	OPERANDO	19635
Motor 6	Weg	OPERANDO	19635
Motor 7	Rossi	OPERANDO	19635

Tabla 5.
Detalles de momentos identificados como falla en la base de datos inicial

FECHA	HORA	Motor	Marca Motor	HP	CORRIENTE	VOLTAJE	TEMPERATURA	ESTADO
18/01/2021	8:00:00 a. m.	Motor 2	Echtop	7.5	30.66	220.16	76.43	FALLA
18/01/2021	9:00:00 a. m.	Motor 2	Echtop	7.5	29.33	220.13	73.19	FALLA
18/01/2021	10:00:00 a. m.	Motor 2	Echtop	7.5	29.09	220.39	73.95	FALLA
18/01/2021	11:00:00 a. m.	Motor 2	Echtop	7.5	31.15	220.45	79.51	FALLA
18/01/2021	12:00:00 p. m.	Motor 2	Echtop	7.5	35.51	221.21	76.67	FALLA
29/01/2021	8:00:00 a. m.	Motor 2	Echtop	7.5	30.59	221.29	76.18	FALLA
29/01/2021	9:00:00 a. m.	Motor 2	Echtop	7.5	30.68	221.88	82.17	FALLA
29/01/2021	10:00:00 a. m.	Motor 2	Echtop	7.5	31.17	221.07	81.05	FALLA
29/01/2021	11:00:00 a. m.	Motor 2	Echtop	7.5	31.25	221.55	79.93	FALLA
29/01/2021	12:00:00 p. m.	Motor 2	Echtop	7.5	31.73	221.53	85.1	FALLA
29/01/2021	1:00:00 p. m.	Motor 2	Echtop	7.5	32.10	221.7	89.78	FALLA
29/01/2021	2:00:00 p. m.	Motor 2	Echtop	7.5	33.48	221.08	90.94	FALLA
10/04/2021	9:00:00 a. m.	Motor 3	Echtop	7.5	27.42	197.82	71.82	FALLA
10/04/2021	10:00:00 a. m.	Motor 3	Echtop	7.5	28.47	197.17	88.57	FALLA
10/04/2021	11:00:00 a. m.	Motor 3	Echtop	7.5	28.23	196.83	88.63	FALLA
10/04/2021	12:00:00 p. m.	Motor 3	Echtop	7.5	28.29	196.89	90.89	FALLA
10/04/2021	1:00:00 p. m.	Motor 3	Echtop	7.5	29.05	197.05	88.35	FALLA
10/04/2021	2:00:00 p. m.	Motor 3	Echtop	7.5	28.91	199.91	82.11	FALLA
10/04/2021	3:00:00 p. m.	Motor 3	Echtop	7.5	27.67	200.17	82.17	FALLA
14/10/2021	2:00:00 p. m.	Motor 3	Echtop	7.5	29.35	219.95	75.45	FALLA
14/10/2021	3:00:00 p. m.	Motor 3	Echtop	7.5	29.49	219.99	80.29	FALLA
14/10/2021	4:00:00 p. m.	Motor 3	Echtop	7.5	30.23	220.23	89.83	FALLA
1/12/2021	1:00:00 p. m.	Motor 2	Echtop	7.5	29.55	219.65	78.37	FALLA
1/12/2021	2:00:00 p. m.	Motor 2	Echtop	7.5	30.27	219.17	74.2	FALLA
1/12/2021	3:00:00 p. m.	Motor 2	Echtop	7.5	29.50	219.3	75.32	FALLA
1/12/2021	4:00:00 p. m.	Motor 2	Echtop	7.5	29.62	219.32	75.36	FALLA
1/12/2021	5:00:00 p. m.	Motor 2	Echtop	7.5	29.46	219.46	74.29	FALLA

5.4. Descripción del proceso de análisis de datos

Figura 6.

Diagrama del proceso de análisis de datos



6. Resultados

El presente proyecto de grado se enfocó en el desarrollo de un modelo de que permita el monitoreo para el mantenimiento predictivo de motores industriales, utilizando técnicas de procesamiento de señales y aprendizaje automático para analizar los datos. En este sentido, se logró cumplir con los objetivos planteados en el proyecto, los cuales consistían en realizar análisis exploratorio y de varianza de los datos del funcionamiento de los motores eléctricos indicados en la Tabla 6, emplear estrategias de supervisión de datos para las diferentes variables de los motores eléctricos, y evaluar en base a los datos de los motores eléctricos la confiabilidad de estos.

Tabla 6.
Muestra de la base de datos utilizada

FECHA	HORA	Motor	Marca Motor	HP	CORRIENTE	VOLTAJE	TEMPERATURA	ESTADO
2/01/2021	7:00:00 a. m.	Motor 1	Rossi	7.5	25.84	220.78	69.28	OPERANDO
2/01/2021	7:00:00 a. m.	Motor 2	Echtop	7.5	26.94	220.94	65.88	OPERANDO
2/01/2021	7:00:00 a. m.	Motor 3	Echtop	7.5	26.78	221.58	71.88	OPERANDO
2/01/2021	7:00:00 a. m.	Motor 4	Siemens	7.5	26.58	221.58	70.78	OPERANDO
2/01/2021	7:00:00 a. m.	Motor 5	Echtop	3.6	5.88	220.98	70.98	OPERANDO
2/01/2021	7:00:00 a. m.	Motor 6	Weg	30	41.28	220.88	73.68	OPERANDO
2/01/2021	7:00:00 a. m.	Motor 7	Rossi	5	20.68	220.88	61.28	OPERANDO
2/01/2021	8:00:00 a. m.	Motor 1	Rossi	7.5	25.38	220.73	65.93	OPERANDO
2/01/2021	8:00:00 a. m.	Motor 2	Echtop	7.5	26.88	220.78	73.03	OPERANDO
2/01/2021	8:00:00 a. m.	Motor 3	Echtop	7.5	26.63	221.43	70.83	OPERANDO
2/01/2021	8:00:00 a. m.	Motor 4	Siemens	7.5	25.93	221.53	69.73	OPERANDO
2/01/2021	8:00:00 a. m.	Motor 5	Echtop	3.6	7.93	220.83	62.43	OPERANDO
2/01/2021	8:00:00 a. m.	Motor 6	Weg	30	41.33	220.93	73.73	OPERANDO
2/01/2021	8:00:00 a. m.	Motor 7	Rossi	5	15.93	220.73	62.43	OPERANDO
2/01/2021	9:00:00 a. m.	Motor 1	Rossi	7.5	26.93	220.87	73.07	OPERANDO
2/01/2021	9:00:00 a. m.	Motor 2	Echtop	7.5	26.83	220.93	72.67	OPERANDO
2/01/2021	9:00:00 a. m.	Motor 3	Echtop	7.5	25.97	221.07	71.97	OPERANDO
2/01/2021	9:00:00 a. m.	Motor 4	Siemens	7.5	26.07	221.37	65.97	OPERANDO
2/01/2021	9:00:00 a. m.	Motor 5	Echtop	3.6	7.07	220.87	60.97	OPERANDO
2/01/2021	9:00:00 a. m.	Motor 6	Weg	30	50.77	220.97	73.77	OPERANDO
2/01/2021	9:00:00 a. m.	Motor 7	Rossi	5	18.07	220.97	62.47	OPERANDO

Para cumplir con estos objetivos, se partió de una base de datos suministrada por una empresa en la cual en medio de su proceso productivo se tomaron mediciones del estado y condiciones de funcionamiento de los motores industriales mediante dispositivos de monitoreo. Posteriormente, se procedió a realizar un análisis exploratorio y de varianza de los datos obtenidos, con el fin de determinar su significancia. En este proceso se utilizó software especializado de análisis de datos, lo cual permitió identificar patrones y anomalías en el comportamiento de los motores.

Además, se emplearon estrategias de supervisión de datos para las diferentes variables de los motores eléctricos, lo que permitió monitorear su comportamiento en tiempo real. Esto resultó fundamental para la identificación temprana de cualquier anomalía o patrón que pudiera indicar la presencia de una falla en el motor. En este sentido, se implementaron técnicas de procesamiento de señales y aprendizaje automático, lo que permitió identificar patrones y tendencias en los datos obtenidos, y utilizarlos para generar modelos predictivos que permitieran anticipar la ocurrencia de fallas en los motores.

A continuación, se procede a describir el proceso de la construcción del código necesario para la aplicación de los conceptos y metodologías indicadas:

Inicialmente cargamos la base de datos y validamos que esta se hubiera cargado con los datos de manera adecuada a partir de la generación de una impresión, con una muestra de los datos que se utilizarán durante el ejercicio como se evidencia en la Figura 7.

Figura 7.

Captura de pantalla con código de carga de datos

```

✓ [1] import pandas as pd
import numpy as np

from google.colab import drive
drive.mount('/content/gdrive', force_remount=True)
root_dir="/content/gdrive/My Drive"

✓ [2] import os
base_dir = "/content/gdrive/My Drive/Colab Notebooks/Datos/"
print(base_dir)

0s ✓ ▶ print(base_dir)
df = pd.read_csv(base_dir + "Base_datos_motores_CSV.csv")
df.head()

```

	Motor	Marca Motor	HP	CORRIENTE	VOLTAJE	TEMPERATURA	ESTADO
0	Motor 1	Rossi	7.5	25.84	220.78	69.28	OPERANDO
1	Motor 2	Echtop	7.5	26.94	220.94	65.88	OPERANDO
2	Motor 3	Echtop	7.5	26.78	221.58	71.88	OPERANDO
3	Motor 4	Siemens	7.5	26.58	221.58	70.78	OPERANDO
4	Motor 5	Echtop	3.6	5.88	220.98	70.98	OPERANDO

Realizamos una validación del tipo de datos que he cargado, con la finalidad de garantizar que los datos importados cuentan con las características adecuadas para ser modelados de acuerdo con nuestra necesidad, donde como se evidencia en la Figura 8 la respuesta permite evidenciar que hay 7 columnas en el DataFrame, cada una con un nombre de columna y un tipo de datos (Dtype) asignado. Hay 4 columnas con valores numéricos de tipo float64, que son números de coma flotante con 64 bits de precisión, y 3 columnas de tipo object, que son columnas de texto o cadenas.

Figura 8.

Captura de pantalla con código de validación de tipo de datos

```

✓ # ver la información general de los datos
0s print(df.info())

<class 'pandas.core.frame.DataFrame'>
RangeIndex: 45815 entries, 0 to 45814
Data columns (total 7 columns):
#   Column      Non-Null Count  Dtype
---  ---
0   Motor       45815 non-null  object
1   Marca Motor 45815 non-null  object
2   HP          45815 non-null  float64
3   CORRIENTE  45815 non-null  float64
4   VOLTAJE    45815 non-null  float64
5   TEMPERATURA 45815 non-null  float64
6   ESTADO     45815 non-null  object
dtypes: float64(4), object(3)
memory usage: 2.4+ MB
None

```

6.1. Kruskal-Wallis y Anova

Ahora se procede con la implementación de las pruebas de KRUSKAL-WALLIS y ANOVA, pero antes de esto se realiza una limpieza a la base de datos haciendo uso del código que se muestra en la figura 9, con la finalidad de eliminar aquellos datos en cero o inconsistentes, que pudieran volver impreciso el análisis, como se evidencia a continuación:

Figura 9.

Captura de pantalla con código de limpieza de base de datos

```

# LIMPIAR BASE DE DATOS DE NUMEROS ANTES DE PROCESAR

# Eliminar filas con valores faltantes o 0 en la columna CORRIENTE
df = df[df['CORRIENTE'] != 0] # Elimina valores 0
df = df.dropna(subset=['CORRIENTE']) # Elimina valores faltantes

# Eliminar filas con valores faltantes o 0 en la columna VOLTAJE
df = df[df['VOLTAJE'] != 0] # Elimina valores 0
df = df.dropna(subset=['VOLTAJE']) # Elimina valores faltantes

# Eliminar filas con valores faltantes o 0 en la columna TEMPERATURA
df = df[df['TEMPERATURA'] != 0] # Elimina valores 0
df = df.dropna(subset=['TEMPERATURA']) # Elimina valores faltantes

```

Ahora si aplicamos la prueba de KRUSKAL-WALLIS como se refleja en el código de la

Figura 10:

Figura 10.

Captura de pantalla con código del test KRUSKAL-WALLIS

```
# APLICACIÓN DEL TEST DE KRUSKAL-WALLIS

# Obtener nombres de columnas
nombres_columnas = df.columns

# Crear lista para guardar p-valores
p_valores = []

# Iterar por cada columna de interés
for col in ['CORRIENTE', 'VOLTAJE', 'TEMPERATURA']:

    # Obtener los valores únicos de la columna
    valores_unicos = df[col].unique()

    # Si hay menos de dos valores únicos, no se puede hacer el test
    if len(valores_unicos) < 2:
        print(f"No se puede hacer el test de Kruskal-Wallis para {col}")
        continue

    # Crear una lista con los datos de cada grupo
    grupos = [df[df['Motor'] == motor][col] for motor in df['Motor'].unique()]

    # Hacer el test de Kruskal-Wallis
    resultado_test = kruskal(*grupos)

    # Obtener el p-valor del resultado del test
    p_valor = resultado_test.pvalue

    # Guardar el p-valor en la lista
    p_valores.append(p_valor)

    # Imprimir el p-valor del test
    print(f"P-valor de Kruskal-Wallis para {col}: {p_valor}")

# Imprimir el resultado final del test
if all(p_valor >= 0.05 for p_valor in p_valores):
    print("No se puede rechazar la hipótesis nula: no hay diferencias significativas entre los grupos.")
else:
    print("Se rechaza la hipótesis nula: hay al menos una diferencia significativa entre los grupos.")
```

El cual nos arroja los resultados indicados en la Figura 11:

Figura 11.

Captura de pantalla con el resultado del test KRUSKAL-WALLIS

```
P-valor de Kruskal-Wallis para CORRIENTE: 0.0
P-valor de Kruskal-Wallis para VOLTAJE: 1.3071481629932617e-09
P-valor de Kruskal-Wallis para TEMPERATURA: 2.0623902425992866e-146
Se rechaza la hipótesis nula: hay al menos una diferencia significativa entre los grupos.
```

Los resultados del test de Kruskal-Wallis indican que hay al menos una diferencia significativa entre los grupos de datos para las variables CORRIENTE, VOLTAJE y TEMPERATURA. El p-valor obtenido para cada variable es muy pequeño, lo que indica que la probabilidad de que las diferencias observadas sean debidas al azar es extremadamente baja. Esto nos lleva a rechazar la hipótesis nula de que no hay diferencias significativas entre los grupos. En otras palabras, los resultados indican que hay evidencia estadística de que los diferentes motores en la base de datos presentan diferencias significativas en cuanto a los valores de CORRIENTE, VOLTAJE y TEMPERATURA. Estos resultados pueden ser útiles para los ingenieros encargados del mantenimiento y reparación de los motores, ya que pueden utilizar esta información para identificar posibles problemas y tomar medidas preventivas o correctivas de manera oportuna.

Ahora procedemos con implementar el test de ANOVA como se evidencia en el siguiente código:

Figura 12.

Captura de pantalla con código del test ANOVA

```
# APLICAR TEST DE ANOVA

# Crear una lista para guardar los p-valores del ANOVA
p_valores_anova = []

# Iterar por cada columna de interés
for col in ['CORRIENTE', 'VOLTAJE', 'TEMPERATURA']:

    # Crear una lista con los datos de cada grupo
    grupos = [df[df['Motor'] == motor][col] for motor in df['Motor'].unique()]

    # Aplicar test ANOVA
    resultado_anova = f_oneway(*grupos)

    # Obtener el p-valor del resultado del test
    p_valor_anova = resultado_anova.pvalue

    # Guardar el p-valor en la lista
    p_valores_anova.append(p_valor_anova)

    # Imprimir el p-valor del test
    print(f"P-valor de ANOVA para {col}: {p_valor_anova}")

# Imprimir el resultado final del test
if all(p_valor_anova >= 0.05 for p_valor_anova in p_valores_anova):
    print("No se puede rechazar la hipótesis nula: no hay diferencias significativas entre los grupos.")
else:
    print("Se rechaza la hipótesis nula: hay al menos una diferencia significativa entre los grupos.")
```

El cual nos arroja los resultados indicados en la Figura 13:

Figura 13.

Captura de pantalla con resultado del test ANOVA

```
P-valor de ANOVA para CORRIENTE: 0.0  
P-valor de ANOVA para VOLTAJE: 2.2573406836071446e-06  
P-valor de ANOVA para TEMPERATURA: 0.0  
Se rechaza la hipótesis nula: hay al menos una diferencia significativa entre los grupos.
```

El resultado del test ANOVA indica que hay al menos una diferencia significativa entre los grupos de datos para las tres variables: corriente, voltaje y temperatura. Esto significa que la media de al menos uno de los grupos es significativamente diferente a la media de los otros grupos. En otras palabras, al menos uno de los grupos tiene un efecto significativo en los valores de la variable en cuestión. El p-valor obtenido en el test ANOVA es muy pequeño en los tres casos, lo que sugiere que las diferencias observadas entre los grupos son altamente improbables que se deban al azar. Por lo tanto, podemos concluir que hay una diferencia significativa entre los grupos para cada una de las variables. Esto nos indica que hay una relación importante entre las variables y los grupos, lo cual puede ser de gran utilidad para identificar patrones y mejorar el desempeño del sistema.

6.2. Analisis Exploratorio de Datos (EDA)

Ahora se procede con la implementación del analisis exploratorio de datos tanto bajo el analisis UNIVARIADO como BIVARIADO:

6.2.1. Análisis Univariado

Se genera el código del análisis Univariado como se evidencia en la Figura 14:

Figura 14.

Captura de pantalla con código del Análisis Univariado

```
# ANÁLISIS EXPLORATORIO UNIVARIADO

motores = df['Motor'].unique()
print(motores)

for motor in motores:
    df_motor = df[df['Motor'] == motor]

    # Histograma de la corriente para el motor actual
    plt.hist(df_motor['CORRIENTE'], bins=20)
    plt.title('Distribución de la corriente para el motor {}'.format(motor))
    plt.xlabel('Corriente (A)')
    plt.ylabel('Frecuencia')
    plt.show()

    # Histograma del voltaje para el motor actual
    plt.hist(df_motor['VOLTAJE'], bins=20)
    plt.title('Distribución del voltaje para el motor {}'.format(motor))
    plt.xlabel('Voltaje (V)')
    plt.ylabel('Frecuencia')
    plt.show()

    # Histograma de la temperatura para el motor actual
    plt.hist(df_motor['TEMPERATURA'], bins=20)
    plt.title('Distribución de la temperatura para el motor {}'.format(motor))
    plt.xlabel('Temperatura (°C)')
    plt.ylabel('Frecuencia')
    plt.show()

    # Diagrama de caja y bigotes de la corriente para el motor actual
    sns.boxplot(x='ESTADO', y='CORRIENTE', data=df_motor)
    plt.title('Corriente para el motor {} según si la falla ocurrió o no'.format(motor))
    plt.xlabel('Falla')
    plt.ylabel('Corriente (A)')
    plt.show()

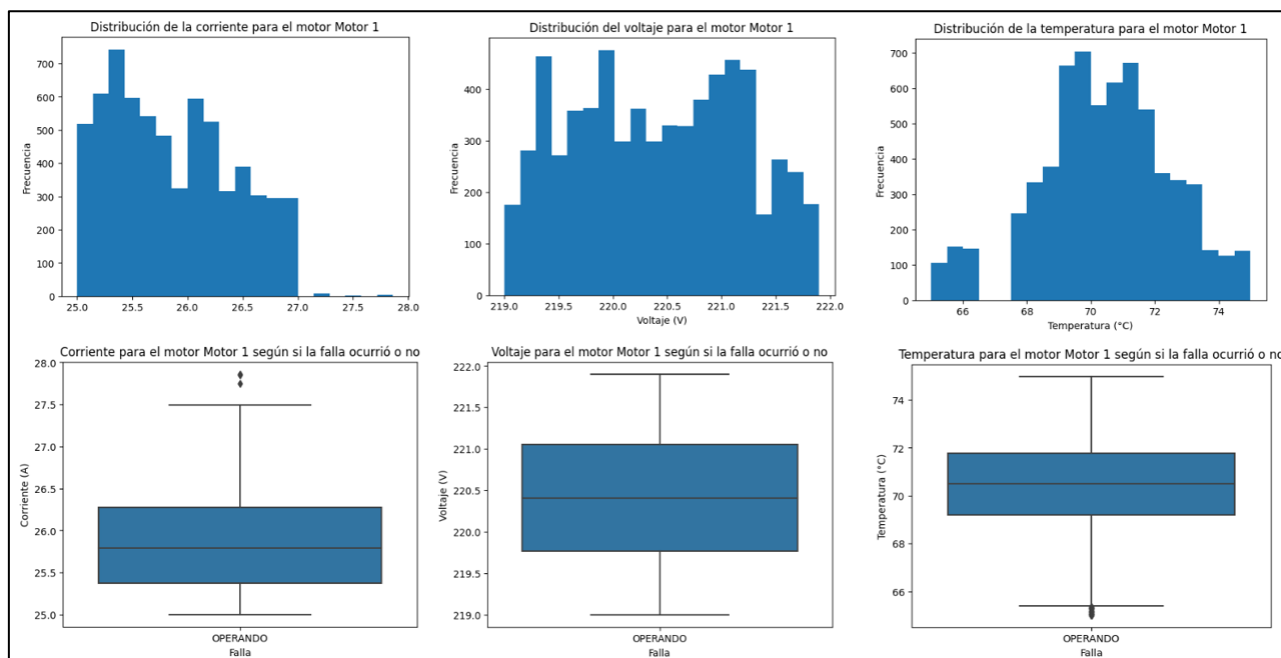
    # Diagrama de caja y bigotes del voltaje para el motor actual
    sns.boxplot(x='ESTADO', y='VOLTAJE', data=df_motor)
    plt.title('Voltaje para el motor {} según si la falla ocurrió o no'.format(motor))
    plt.xlabel('Falla')
    plt.ylabel('Voltaje (V)')
    plt.show()

    # Diagrama de caja y bigotes de la temperatura para el motor actual
    sns.boxplot(x='ESTADO', y='TEMPERATURA', data=df_motor)
    plt.title('Temperatura para el motor {} según si la falla ocurrió o no'.format(motor))
    plt.xlabel('Falla')
    plt.ylabel('Temperatura (°C)')
    plt.show()
```

El cual nos arroja los resultados que se muestran en las Figura 15, 16, 17, 18, 19, 20, y 21:

Figura 15.

Captura de pantalla con resultados arrojados para el analisis Univariado del Motor 1



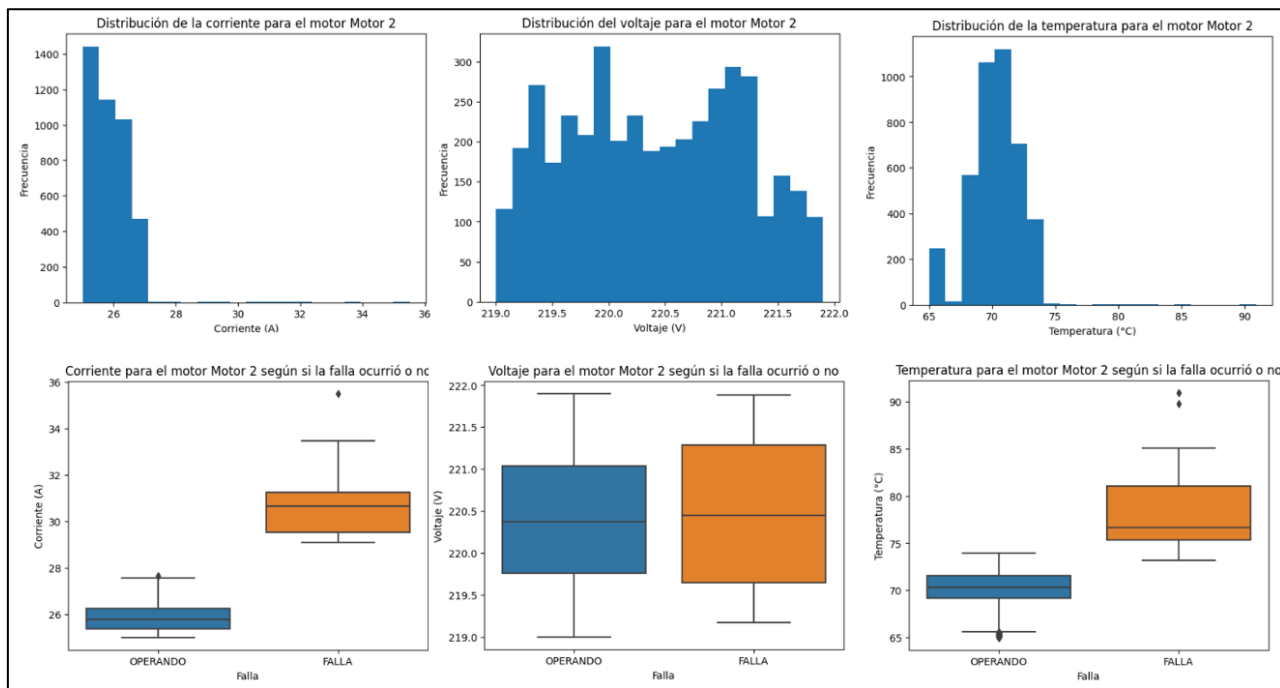
En este caso se trata del Motor 1, de marca Rossi, el cual en ninguno de los momentos analizados presentó una posible condición de falla, por lo que al realizar el analisis univariado, el cual refleja el comportamiento de cada variable de forma independiente, se logra identificar un comportamiento uniforme, donde la corriente, el voltaje y la temperatura de se comportan dentro de los márgenes adecuados para este tipo de motor.

En este caso los histogramas muestran los valores en los que se concentran la mayor cantidad de lecturas para cada una de las variables.

Por su parte el diagrama de bigotes evidencia los rangos entre los que se mueven los datos de forma regular cuando el motor se encuentra en condiciones de operación normal.

Figura 16.

Captura de pantalla con resultados arrojados para el analisis Univariado del Motor 2



En este caso se trata del Motor 2, de marca Ectop, el cual en algunos de los momentos analizados presentó una condición de FALLA, por lo que al realizar el analisis univariado, este nos permite identificar claramente las condiciones en las cuales los motores presentan una falla.

Para el caso de los histogramas, debido a la escala de este, el volumen de datos y los pocos eventos asociados a una condición de falla, este no permite visualizar fácilmente los valores asociados a la falla.

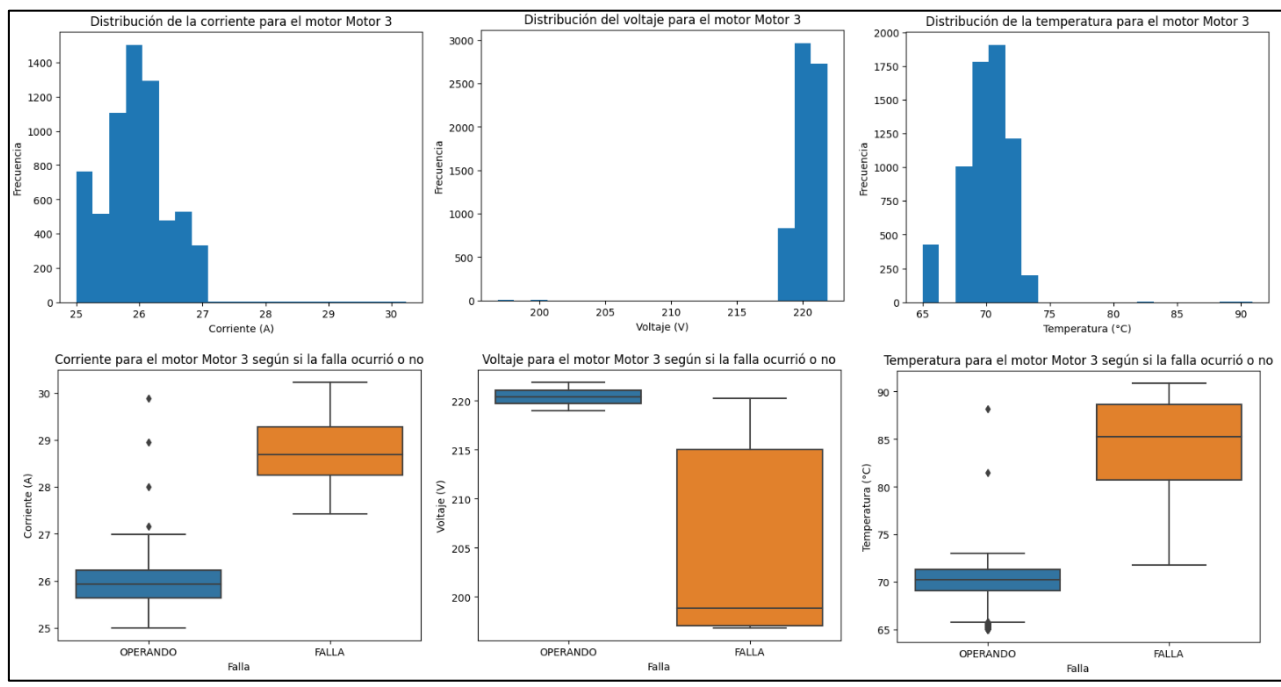
Sin embargo, el diagrama de bigotes si resulta una herramienta muy útil para identificar el comportamiento de cada una de las variables monitoreadas en condición de FALLA.

La corriente evidencia de para un motor de las características del motor 2, las fallas se presentan cuando se tienen corrientes que oscilan entre los 29 y los 30 Amperios, respecto a la corriente optima de operación, que estaría cercana a los 26 Amperios.

El voltaje, aunque este si se comporta de una forma mas estable, igualmente evidencia una pequeña oscilación tanto por encima como por debajo de las condiciones de voltaje normales de operación.

Por último, la temperatura al ser esta una condición o efecto dependiente de las otras dos variables, claramente evidencia una elevación en la temperatura del motor por encima de los 76° centígrados, llegando en ocasiones a rondar los 80° en condición de FALLA.

Figura 17.
Captura de pantalla con resultados arrojados para el analisis Univariado del Motor 3



En este caso se trata del Motor 3, también de marca Ecltop, el cual en algunos de los momentos analizados presentó una condición de FALLA, por lo que al realizar el análisis univariado, este nos permite identificar claramente las condiciones en las cuales los motores presentan una falla.

Para el caso de los histogramas, debido a la escala de este, el volumen de datos y los pocos eventos asociados a una condición de falla, este no permite visualizar fácilmente los valores asociados a la falla.

Sin embargo, el diagrama de bigotes si resulta una herramienta muy útil para identificar el comportamiento de cada una de las variables monitoreadas en condición de FALLA.

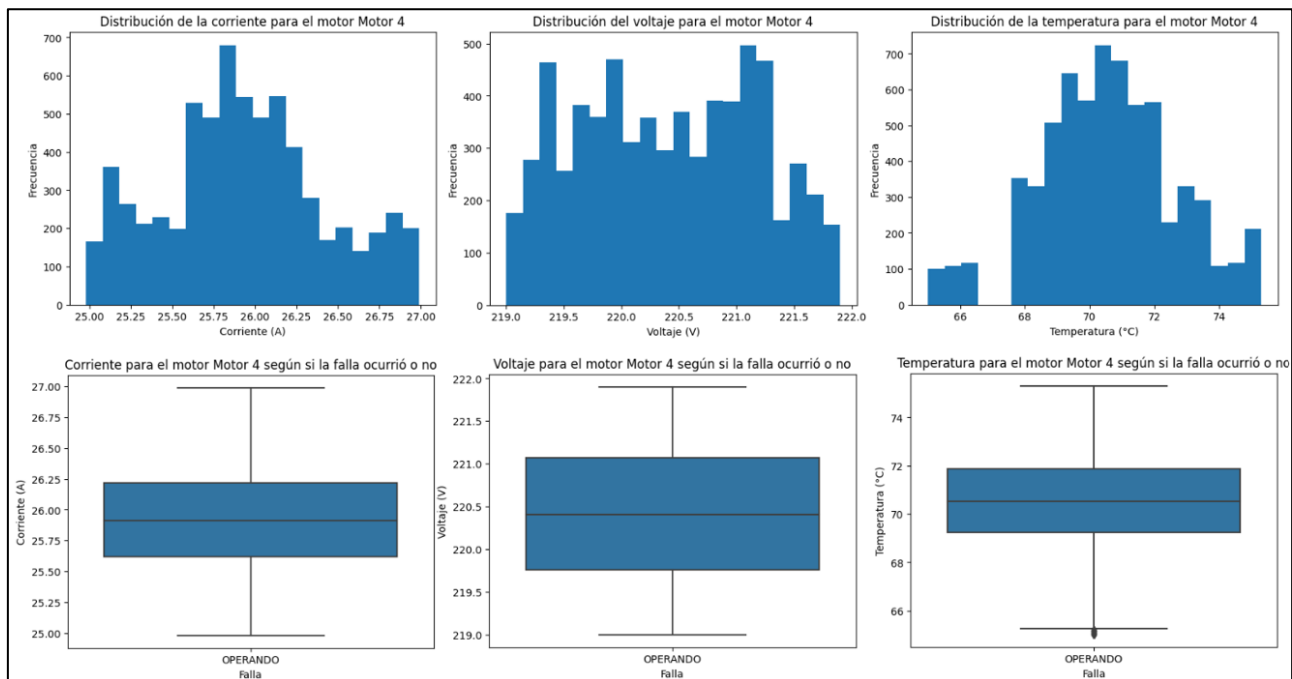
La corriente evidencia de para un motor de las características del motor 3, las fallas se presentan cuando se tienen corrientes que oscilan entre los 30 y los 31 Amperios, respecto a la corriente optima de operación, que estaría cercana a los 25 y 26 Amperios.

El voltaje, aunque este si se comporta de una forma más estable, igualmente evidencia una pequeña oscilación tanto por encima como por debajo de las condiciones de voltaje normales de operación.

Por último, la temperatura, al ser esta una condición o efecto dependiente de las otras dos variables, claramente evidencia una elevación en la temperatura del motor que ronda en promedio los 85° centígrados, llegando en ocasiones a rondar los 90° en condición de FALLA.

Figura 18.

Captura de pantalla con resultados arrojados para el analisis Univariado del Motor 4



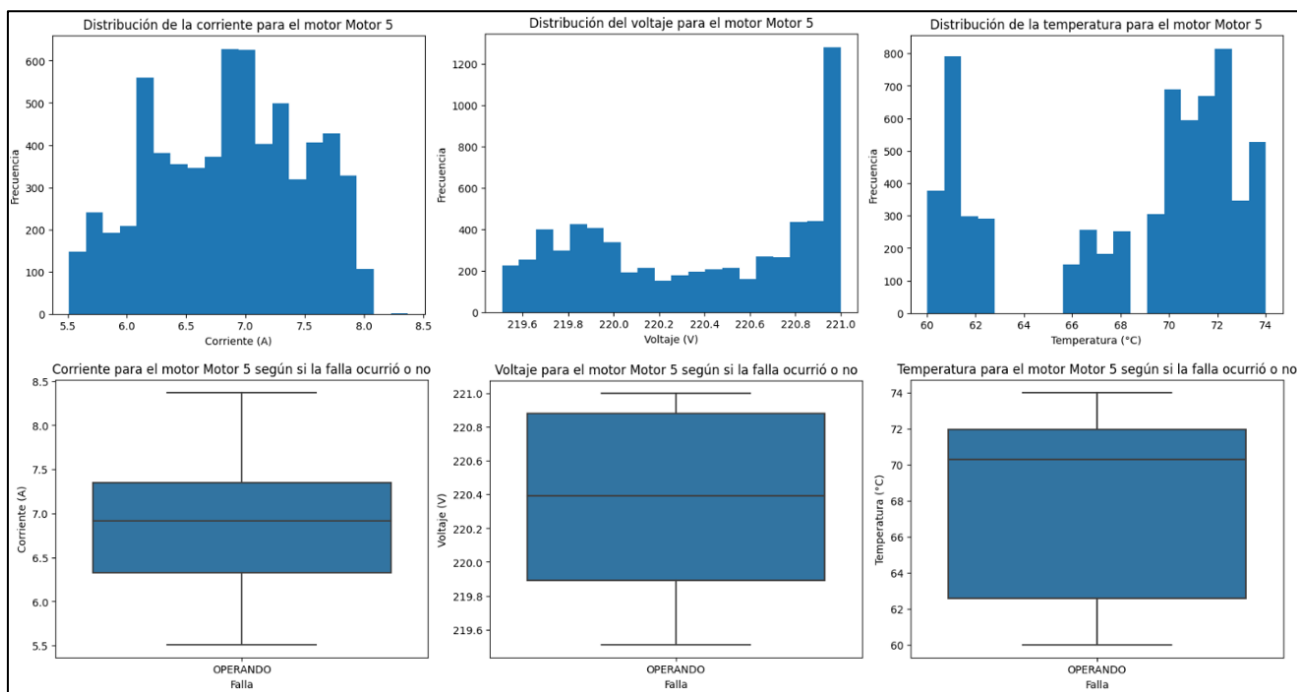
En este caso se trata del Motor 4, de marca Siemens, el cual en ninguno de los momentos analizados presentó una posible condición de falla, por lo que al realizar el analisis univariado, el cual refleja el comportamiento de cada variable de forma independiente, se logra identificar un comportamiento uniforme, donde la corriente, el voltaje y la temperatura de se comportan dentro de los márgenes adecuados para este tipo de motor.

En este caso los histogramas muestran los valores en los que se concentran la mayor cantidad de lecturas para cada una de las variables.

Por su parte el diagrama de bigotes evidencia los rangos entre los que se mueven los datos de forma regular cuando el motor se encuentra en condiciones de operación normal.

Figura 19.

Captura de pantalla con resultados arrojados para el analisis Univariado del Motor 5



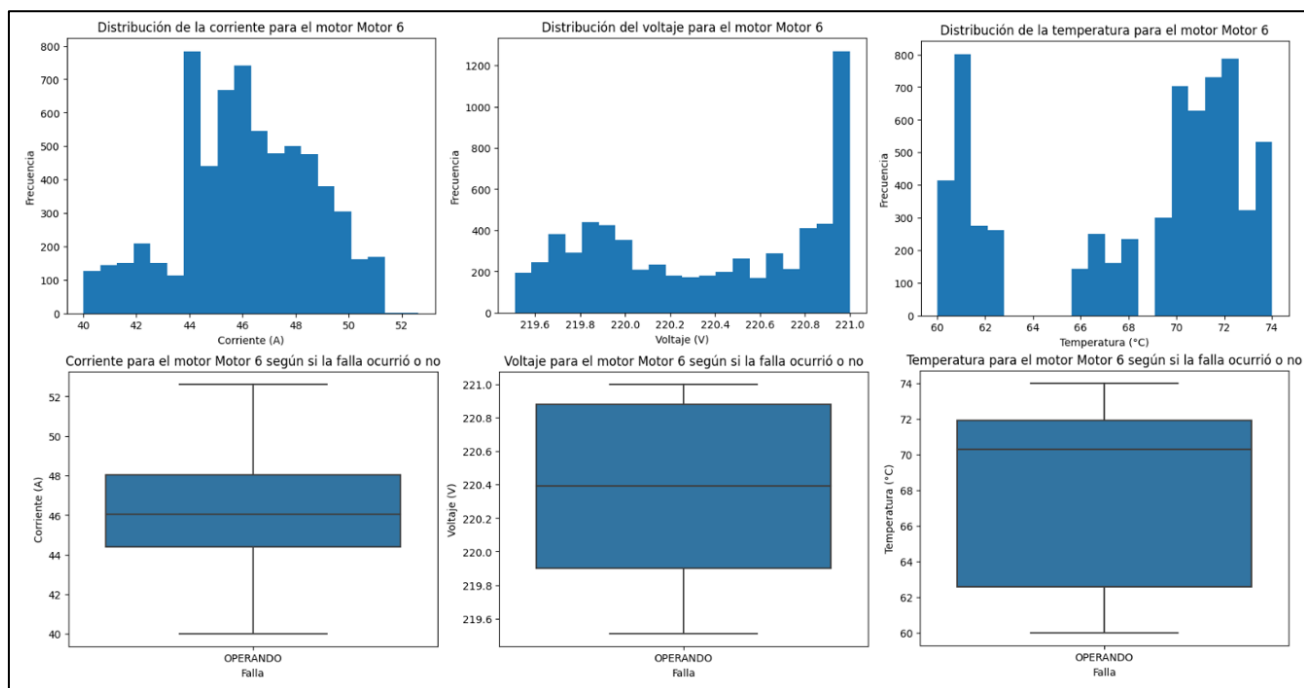
En este caso se trata del Motor 5, de marca Ectop, el cual en ninguno de los momentos analizados evidenció una posible condición de falla, por lo que al realizar el analisis univariado, el cual refleja el comportamiento de cada variable de forma independiente, se logra identificar un comportamiento uniforme, donde la corriente, el voltaje y la temperatura de se comportan dentro de los márgenes adecuados para este tipo de motor.

En este caso los histogramas muestran los valores en los que se concentran la mayor cantidad de lecturas para cada una de las variables.

Por su parte el diagrama de bigotes evidencia los rangos entre los que se mueven los datos de forma regular cuando el motor se encuentra en condiciones de operación normal.

Figura 20.

Captura de pantalla con resultados arrojados para el analisis Univariado del Motor 6



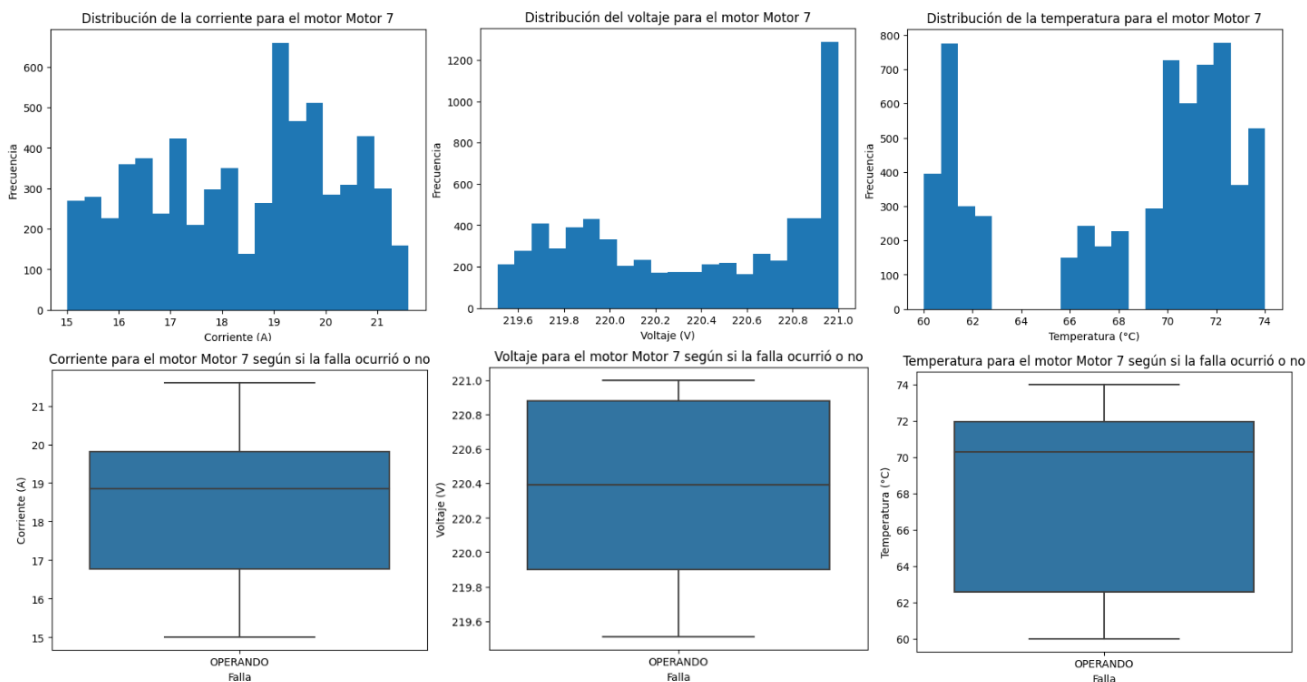
En este caso se trata del Motor 6, de marca WEG, el cual en ninguno de los momentos analizados evidenció una posible condición de falla, por lo que al realizar el analisis univariado, el cual refleja el comportamiento de cada variable de forma independiente, se logra identificar un comportamiento uniforme, donde la corriente, el voltaje y la temperatura de se comportan dentro de los márgenes de valor adecuados para este tipo de motor.

En este caso los histogramas muestran los valores en los que se concentran la mayor cantidad de lecturas para cada una de las variables.

Por su parte el diagrama de bigotes evidencia los rangos entre los que se mueven los datos de forma regular cuando el motor se encuentra en condiciones de operación normal.

Figura 21.

Captura de pantalla con resultados arrojados para el analisis Univariado del Motor 7



En este caso se trata del Motor 7, de marca Rossi, el cual en ninguno de los momentos analizados evidenció una posible condición de falla, por lo que al realizar el analisis univariado, el cual refleja el comportamiento de cada variable de forma independiente, se logra identificar un comportamiento uniforme, donde la corriente, el voltaje y la temperatura de se comportan dentro de los márgenes de valor adecuados para este tipo de motor.

En este caso los histogramas muestran los valores en los que se concentran la mayor cantidad de lecturas para cada una de las variables.

Por su parte el diagrama de bigotes evidencia los rangos entre los que se mueven los datos de forma regular cuando el motor se encuentra en condiciones de operación normal.

6.2.2. Análisis Bivariado

Se genera el código del análisis Bivariado como se evidencia en la Figura 22:

Figura 22.

Captura de pantalla con código del Análisis Bivariado

```
# ANÁLISIS EXPLORATORIO BIVARIADO

# Gráfico de dispersión de corriente vs voltaje por motor
sns.scatterplot(x='CORRIENTE', y='VOLTAJE', hue='Motor', style='ESTADO', data=df)
plt.title('Corriente vs Voltaje')
plt.xlabel('Corriente (A)')
plt.ylabel('Voltaje (V)')
plt.show()

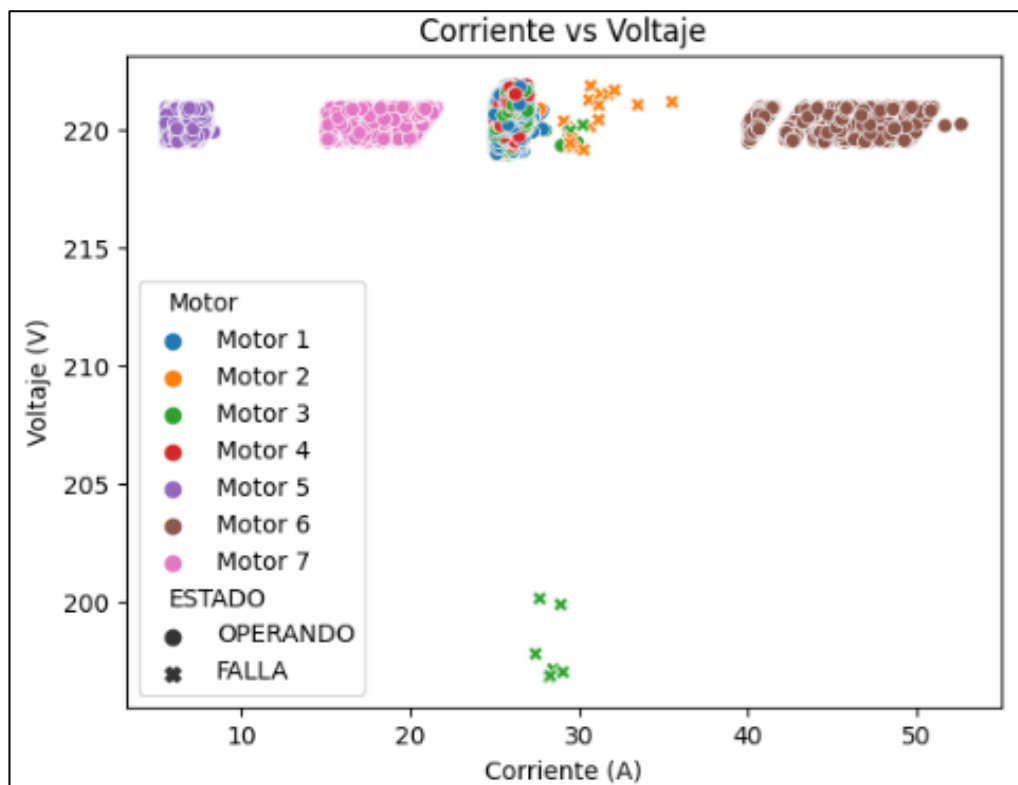
# Gráfico de dispersión de corriente vs temperatura por motor
sns.scatterplot(x='CORRIENTE', y='TEMPERATURA', hue='Motor', style='ESTADO', data=df)
plt.title('Corriente vs Temperatura')
plt.xlabel('Corriente (A)')
plt.ylabel('Temperatura (°C)')
plt.show()

# Gráfico de dispersión de voltaje vs temperatura por motor
sns.scatterplot(x='VOLTAJE', y='TEMPERATURA', hue='Motor', style='ESTADO', data=df)
plt.title('Voltaje vs Temperatura')
plt.xlabel('Voltaje (V)')
plt.ylabel('Temperatura (°C)')
plt.show()
```

El cual nos arroja los resultados indicados en las Figuras 23, 24 y 25:

Figura 23.

Captura de pantalla con resultados arrojados para el análisis Bivariado Corriente vs Voltaje

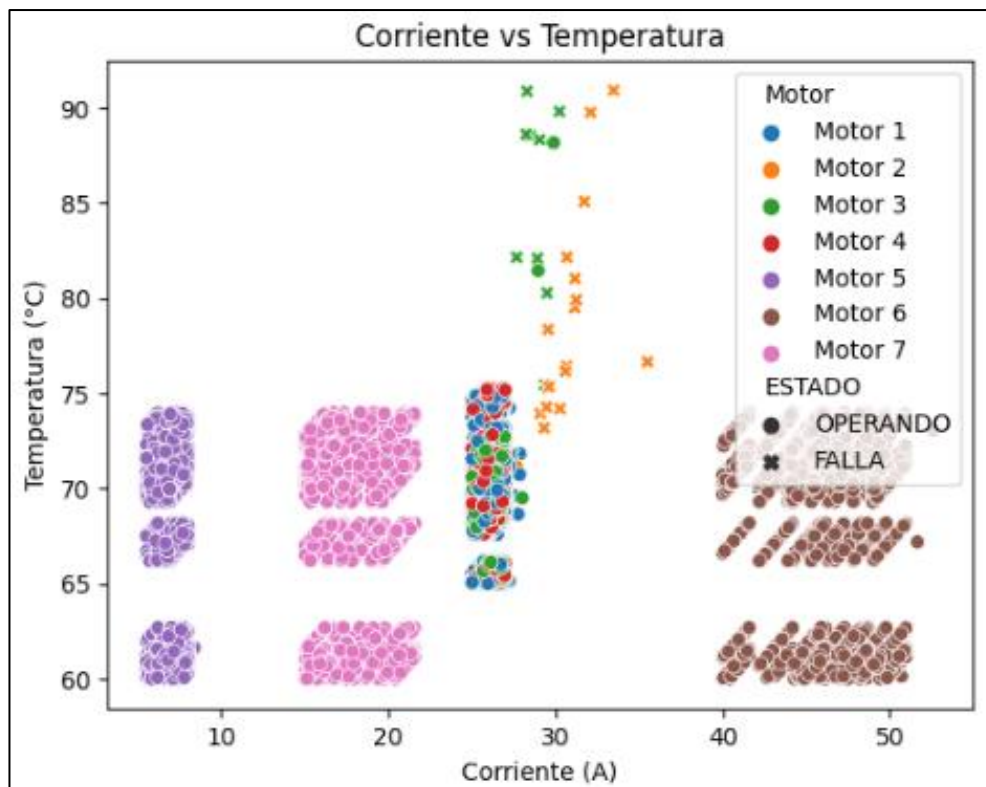


El análisis bivariado entre el voltaje y la corriente de un motor permite comprender la relación que existe entre estas dos variables eléctricas. Ambas variables están relacionadas entre sí por la ley de Ohm, que establece que la corriente que circula por un conductor es directamente proporcional al voltaje aplicado e inversamente proporcional a la resistencia del circuito, razón por la cual para el caso de los motores 2 y 3 que son los que fallaron, el análisis bivariado también permite identificar posibles valores atípicos o anomalías en los datos, que claramente corresponderían a los momentos en que los motores entraron en condición de FALLA.

Por lo tanto, este análisis puede ser una herramienta útil para el mantenimiento predictivo y la detección temprana de posibles fallos en los motores eléctricos.

Figura 24.

Captura de pantalla con resultados arrojados para el análisis Bivariado Temperatura y Corriente



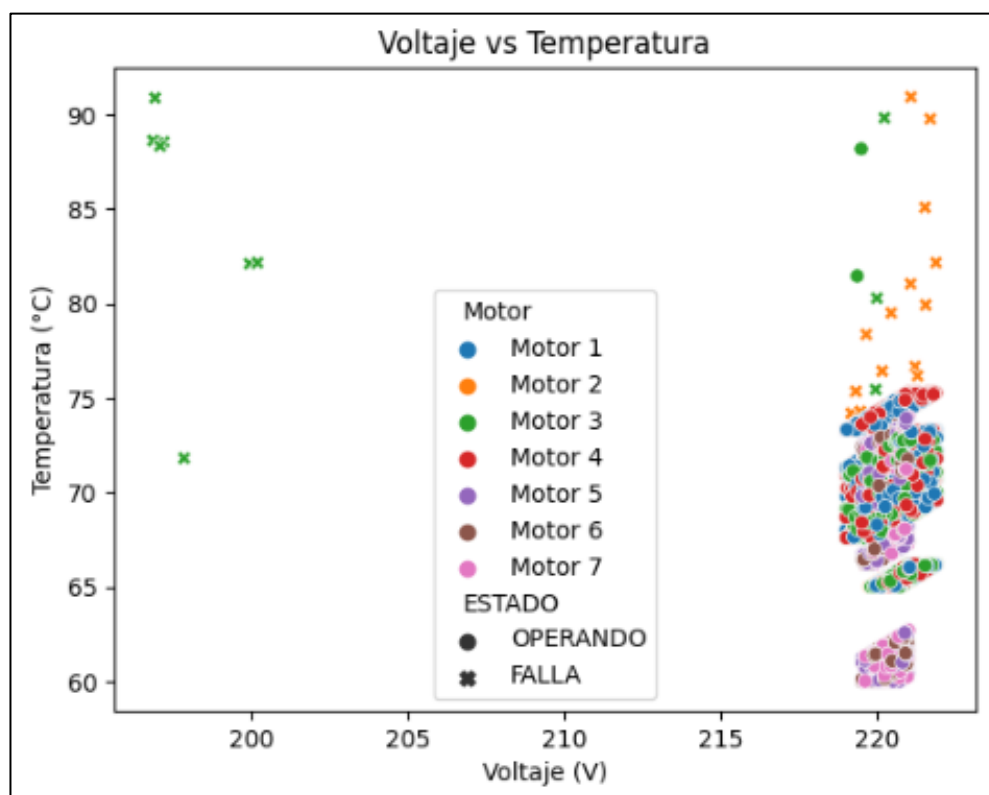
El análisis bivariado entre la temperatura y la corriente de un motor permite comprender la relación que existe entre estas dos variables eléctricas y térmicas. La temperatura en un motor está relacionada con la corriente que circula por él, ya que cuando la corriente aumenta, también lo hace la temperatura. Para los motores 2 y 3 que fallaron, el análisis bivariado también permite identificar posibles valores atípicos o anomalías en los datos, que claramente corresponden a los momentos en que los motores entraron en condición de FALLA.

Por lo tanto, este análisis puede ser una herramienta útil para el mantenimiento predictivo y la detección temprana de posibles fallos en los motores eléctricos, ya que permite identificar

patrones en los datos que pueden indicar una futura falla en el motor. Al analizar la relación entre la temperatura y la corriente, se pueden establecer límites de operación seguros para evitar que la temperatura del motor se eleve demasiado y se produzcan fallas. Además, la identificación temprana de fallas puede permitir una intervención oportuna y evitar costosas reparaciones o reemplazos de motores.

Figura 25.

Captura de pantalla con resultados arrojados para el análisis Bivariado Voltaje y Temperatura



El análisis bivariado entre el voltaje y la temperatura de un motor permite comprender la relación que existe entre estas dos variables. Ambas variables están relacionadas entre sí debido a que el voltaje que se aplica a un motor afecta su temperatura, ya que a medida que aumenta el

voltaje, aumenta la temperatura del motor. Para el caso de los motores 2 y 3 que fallaron, el análisis bivariado también permite identificar posibles valores atípicos o anomalías en los datos, que claramente corresponderían a los momentos en que los motores entraron en condición de FALLA.

Por lo tanto, este análisis puede ser una herramienta útil para el mantenimiento predictivo y la detección temprana de posibles fallos en los motores eléctricos, ya que si se detectan valores atípicos en la relación entre el voltaje y la temperatura de un motor, se puede tomar acción antes de que ocurra una falla catastrófica del motor. Además, este análisis bivariado también puede ayudar a identificar posibles problemas en la calidad del voltaje suministrado a los motores, lo que puede ayudar a mejorar la eficiencia y durabilidad de los mismos.

6.3. Regresión Logística

Ahora se procede con realizar un análisis de regresión logística para así establecer posteriormente el modelo predictivo, haciendo uso del código que se muestra en la Figura 26.

Figura 26.

Captura de pantalla con código para Regresión Logística

```
# REGRESIÓN LOGISTICA

import pandas as pd
import numpy as np
from sklearn.linear_model import LogisticRegression
from sklearn.model_selection import train_test_split
from sklearn.metrics import classification_report
from sklearn.preprocessing import LabelEncoder
import matplotlib.pyplot as plt

from google.colab import drive
drive.mount('/content/gdrive', force_remount=True)
root_dir = "/content/gdrive/My Drive"
base_dir = "/content/gdrive/My Drive/Colab Notebooks/Datos/"
df = pd.read_csv(base_dir + "Base_datos_motores_CSVM2M3.csv")

# Convertir la variable categórica 'ESTADO' en valores numéricos
le = LabelEncoder()
df['ESTADO'] = le.fit_transform(df['ESTADO'])

# Seleccionar características y objetivo
X = df[['CORRIENTE', 'VOLTAJE', 'TEMPERATURA']]
y = df['ESTADO']

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

# Entrenar modelo de regresión logística
model = LogisticRegression()
model.fit(X_train, y_train)


# Predecir resultados y generar reporte de clasificación
y_pred = model.predict(X_test)
print(classification_report(y_test, y_pred))

# Graficar resultados
fig, ax = plt.subplots()
ax.scatter(X_test['CORRIENTE'], X_test['TEMPERATURA'], c=y_pred, cmap='bwr')
ax.set_xlabel('CORRIENTE')
ax.set_ylabel('TEMPERATURA')
plt.show()
```

Lo cual nos arroja los resultados mostrados en la figura 27:

Figura 27.

Captura de pantalla con resultado obtenido tras regresión logística



De lo anterior pudiendo concluir que el resultado del análisis de árboles de decisión muestra que el modelo es capaz de predecir con una precisión del 100% la presencia o ausencia de fallas en los motores a partir de las variables de corriente, voltaje y temperatura. Esto significa que el modelo es altamente efectivo en clasificar correctamente los casos de motores con fallas y sin fallas, lo que sugiere que las variables utilizadas son altamente discriminativas para este problema en particular.

Es importante tener en cuenta que, aunque el modelo haya demostrado ser altamente preciso en la clasificación, aún es necesario tener un enfoque crítico al interpretar los resultados y asegurarse de que los datos utilizados para entrenar el modelo sean representativos de la población de interés. Además, es posible que el modelo no sea capaz de generalizar bien a datos

nuevos que no se hayan utilizado en el entrenamiento, por lo que es importante realizar una evaluación continua y actualización del modelo si es necesario.

6.4. Árbol de Decisiones

Ahora se procede con realizar un análisis por medio de un árbol de decisiones haciendo uso del código que se muestra en la Figura 28, para con este implementar un modelo predictivo, que, al analizar nuevos datos, me permita predecir si existe la posibilidad de que se presente una falla en el motor como se muestra en la Figura 29.

Figura 28.

Captura de pantalla con código para Árbol de Decisiones

```
# importar datos de entrenamiento
df_train = pd.read_csv(root_dir + "/Colab Notebooks/Datos/Base_datos_motores_CSVM2M3.csv")

# preprocesar datos de entrenamiento
df_train = df_train[df_train['CORRIENTE'] != 0] # eliminar valores 0
df_train = df_train.dropna(subset=['CORRIENTE']) # eliminar valores faltantes
df_train = df_train[df_train['VOLTAJE'] != 0] # eliminar valores 0
df_train = df_train.dropna(subset=['VOLTAJE']) # eliminar valores faltantes
df_train = df_train[df_train['TEMPERATURA'] != 0] # eliminar valores 0
df_train = df_train.dropna(subset=['TEMPERATURA']) # eliminar valores faltantes

X_train = df_train[['CORRIENTE', 'VOLTAJE', 'TEMPERATURA']].values
y_train = df_train['ESTADO'].map({'OPERANDO': 0, 'FALLA': 1})

# crear el modelo y entrenarlo
model = DecisionTreeClassifier(random_state=42)
model.fit(X_train, y_train)

# cargar los datos de prueba
df_test = pd.read_csv(root_dir + "/Colab Notebooks/Datos/Base_datos_motores_CSV - DatosPrueba.csv")

# preprocesar los datos de prueba
df_test = df_test[df_test['CORRIENTE'] != 0] # eliminar valores 0
df_test = df_test.dropna(subset=['CORRIENTE']) # eliminar valores faltantes
df_test = df_test[df_test['VOLTAJE'] != 0] # eliminar valores 0
df_test = df_test.dropna(subset=['VOLTAJE']) # eliminar valores faltantes
df_test = df_test[df_test['TEMPERATURA'] != 0] # eliminar valores 0
df_test = df_test.dropna(subset=['TEMPERATURA']) # eliminar valores faltantes

X_test = df_test[['CORRIENTE', 'VOLTAJE', 'TEMPERATURA']].values

# hacer predicciones sobre los datos de prueba
y_pred = model.predict(X_test)

# agregar predicciones al dataframe de prueba
df_test['PREDICCION'] = ['OPERANDO' if i == 0 else 'POSIBLE FALLA' for i in y_pred]

# crear una función que devuelve el formato a aplicar
def highlight_falla(row):
    if row['PREDICCION'] == 'POSIBLE FALLA':
        return ['background-color: red']*len(row)
    else:
        return ['']*len(row)

# aplicar el formato condicional usando la función anterior
df_test.style.apply(highlight_falla, axis=1)
```

Figura 29.

Captura de pantalla con resultado obtenido tras aplicación del árbol de decisiones

Mounted at /content/gdrive

	Motor	HP	CORRIENTE	VOLTAJE	TEMPERATURA	PREDICION
0	Motor Prueba	7.500000	29.450000	220.980000	95.660000	POSIBLE FALLA
1	Motor Prueba	7.500000	30.660000	220.550000	98.230000	POSIBLE FALLA
2	Motor Prueba	7.500000	31.330000	220.510000	99.390000	POSIBLE FALLA
3	Motor Prueba	7.500000	28.490000	220.570000	73.450000	POSIBLE FALLA
4	Motor Prueba	7.500000	28.350000	221.230000	75.110000	POSIBLE FALLA
5	Motor Prueba	7.500000	29.510000	220.790000	80.670000	POSIBLE FALLA
6	Motor Prueba	7.500000	31.570000	221.150000	92.430000	POSIBLE FALLA
7	Motor Prueba	7.500000	35.530000	220.800000	95.680000	POSIBLE FALLA
8	Motor Prueba	7.500000	28.780000	221.260000	84.540000	POSIBLE FALLA
9	Motor Prueba	7.500000	27.740000	221.010000	81.190000	POSIBLE FALLA
10	Motor Prueba	7.500000	26.790000	221.560000	79.840000	OPERANDO
11	Motor Prueba	7.500000	26.000000	220.550000	71.450000	OPERANDO
12	Motor Prueba	7.500000	26.350000	220.190000	74.490000	OPERANDO
13	Motor Prueba	7.500000	26.490000	220.830000	69.830000	OPERANDO
14	Motor Prueba	7.500000	26.730000	220.960000	68.660000	OPERANDO
15	Motor Prueba	7.500000	26.360000	220.300000	68.600000	OPERANDO
16	Motor Prueba	7.500000	26.900000	220.540000	75.740000	OPERANDO
17	Motor Prueba	7.500000	26.140000	220.070000	68.870000	OPERANDO

Concluyendo sobre lo anterior que el modelo predictivo opera de manera correcta, puesto que, al cargarle una nueva base de datos, con nuevas lecturas sobre las variables de corriente, voltaje y temperatura, me logra generar alerta en aquellos casos en que identifica una POSIBLE FALLA.

6.5. Análisis de confiabilidad con la aplicación de Python

Por último, se evaluó la confiabilidad de los datos obtenidos de los motores eléctricos, lo cual resultó fundamental para la precisión de los modelos predictivos. Para ello, se realizaron pruebas estadísticas para determinar la confiabilidad de los datos, lo que permitió garantizar la precisión

y fiabilidad de los resultados obtenidos. En este proceso se identificaron los principales factores que afectan la confiabilidad de los datos, lo que permitió establecer recomendaciones para mejorar la calidad de los datos obtenidos en futuros proyectos.

En este caso se plantean pruebas de bondad de ajuste, haciendo uso del código que se muestra en la Figura 30, las cuales son utilizadas para evaluar si un conjunto de datos se ajusta o sigue una distribución específica, como la distribución exponencial, normal o Weibull. Estas pruebas son útiles en el análisis de datos para determinar si los datos observados siguen un patrón esperado según la distribución teórica.

La prueba de bondad de ajuste para la distribución exponencial como se muestra en la Figura 31 permite verificar si los datos se distribuyen de manera similar a una función exponencial. Esta distribución es comúnmente utilizada para modelar eventos que ocurren de manera aleatoria y se caracteriza por tener una tasa constante de ocurrencia.

La prueba de bondad de ajuste para la distribución normal, por su parte, permite evaluar si los datos se ajustan a una distribución en forma de campana, conocida como distribución normal. Esta distribución es ampliamente utilizada en estadística debido a su simetría y propiedades bien conocidas.

La prueba de bondad de ajuste para la distribución Weibull se utiliza para determinar si los datos siguen una distribución Weibull, que es ampliamente utilizada en el análisis de supervivencia y modelado de tiempos de vida. Esta distribución es flexible y puede modelar diferentes formas de distribuciones, incluyendo la exponencial y la distribución de Rayleigh.

En resumen, estas pruebas de bondad de ajuste nos permiten evaluar si los datos observados se ajustan a una distribución teórica específica. Esto es importante para comprender y describir los datos, así como para seleccionar el modelo adecuado en diferentes análisis estadísticos y de modelado.

Figura 30.

Captura de pantalla con el código de la prueba de bondad de ajuste Exponencial

```
# PRUEBA DE BONDAD DE AJUSTE - EXPONENCIAL
ks_stat_exp, p_value_exp = kstest(corriente, 'expon', args=(0, corriente.mean()))
print("Prueba de bondad de ajuste - Exponencial (CORRIENTE)")
print("Estadístico KS:", ks_stat_exp)
print("P-valor:", p_value_exp)

ks_stat_exp, p_value_exp = kstest(voltaje, 'expon', args=(0, voltaje.mean()))
print("Prueba de bondad de ajuste - Exponencial (VOLTAJE)")
print("Estadístico KS:", ks_stat_exp)
print("P-valor:", p_value_exp)

ks_stat_exp, p_value_exp = kstest(temperatura, 'expon', args=(0, temperatura.mean()))
print("Prueba de bondad de ajuste - Exponencial (TEMPERATURA)")
print("Estadístico KS:", ks_stat_exp)
print("P-valor:", p_value_exp)
```

Figura 31.

Captura de pantalla con resultado de la prueba de bondad de ajuste Exponencial

```
Prueba de bondad de ajuste - Exponencial (CORRIENTE)
Estadístico KS: 0.618804701959458
P-valor: 0.0
Prueba de bondad de ajuste - Exponencial (VOLTAJE)
Estadístico KS: 0.629135552526952
P-valor: 0.0
Prueba de bondad de ajuste - Exponencial (TEMPERATURA)
Estadístico KS: 0.6041343020514679
P-valor: 0.0
```

Al ejecutar el código que se muestra en las Figuras 30, 32 y 34, se realizan pruebas de bondad de ajuste para verificar si los datos de las variables 'CORRIENTE', 'VOLTAJE' y 'TEMPERATURA' siguen distribuciones específicas. Obteniendo los siguientes resultados, que a su vez se muestran en las Figuras 31, 33 y 35:

Para la prueba de bondad de ajuste con la distribución exponencial, se obtuvieron los siguientes resultados:

- **CORRIENTE:** El estadístico KS (Kolmogorov-Smirnov) es 0.6188 y el p-valor es 0.0. Esto sugiere que los datos de la corriente no siguen una distribución exponencial.
- **VOLTAJE:** El estadístico KS es 0.6291 y el p-valor es 0.0. Esto indica que los datos del voltaje tampoco siguen una distribución exponencial.
- **TEMPERATURA:** El estadístico KS es 0.6041 y el p-valor es 0.0. De manera similar, los datos de temperatura no se ajustan bien a una distribución exponencial.

Figura 32.

Captura de pantalla con el código de la prueba de bondad de ajuste Normal

```
# PRUEBA DE BONDAD DE AJUSTE - NORMAL
ks_stat_norm, p_value_norm = kstest(corriente, 'norm', args=(corriente.mean(), corriente.std()))
print("\nPrueba de bondad de ajuste - Normal (CORRIENTE)")
print("Estadístico KS:", ks_stat_norm)
print("P-valor:", p_value_norm)

ks_stat_norm, p_value_norm = kstest(voltaje, 'norm', args=(voltaje.mean(), voltaje.std()))
print("Prueba de bondad de ajuste - Normal (VOLTAJE)")
print("Estadístico KS:", ks_stat_norm)
print("P-valor:", p_value_norm)

ks_stat_norm, p_value_norm = kstest(temperatura, 'norm', args=(temperatura.mean(), temperatura.std()))
print("Prueba de bondad de ajuste - Normal (TEMPERATURA)")
print("Estadístico KS:", ks_stat_norm)
print("P-valor:", p_value_norm)
```

Figura 33.

Captura de pantalla con resultado de la prueba de bondad de ajuste Normal

```
Prueba de bondad de ajuste - Normal (CORRIENTE)
Estadístico KS: 0.05145452639551903
P-valor: 6.333640370494814e-25
Prueba de bondad de ajuste - Normal (VOLTAJE)
Estadístico KS: 0.0756868955203018
P-valor: 1.8448921333678921e-53
Prueba de bondad de ajuste - Normal (TEMPERATURA)
Estadístico KS: 0.0534285924750679
P-valor: 7.675713051224132e-27
```

En cuanto a la prueba de bondad de ajuste con la distribución normal, los resultados son los siguientes:

- **CORRIENTE:** El estadístico KS es 0.0515 y el p-valor es muy pequeño (6.3336e-25). Esto sugiere que los datos de corriente no siguen una distribución normal.
- **VOLTAJE:** El estadístico KS es 0.0757 y el p-valor es extremadamente pequeño (1.8449e-53). Por lo tanto, los datos del voltaje tampoco se ajustan bien a una distribución normal.
- **TEMPERATURA:** El estadístico KS es 0.0534 y el p-valor es muy pequeño (7.6757e-27). Esto indica que los datos de temperatura no siguen una distribución normal.

Figura 34.

Captura de pantalla con el código de la prueba de bondad de ajuste Weibull

```
# PRUEBA DE BONDAD DE AJUSTE - WEIBULL
params_corriente = weibull_min.fit(corriente, floc=0)
weibull_stat, weibull_p_value = kstest(corriente, 'weibull_min', args=params_corriente)
print("\nPrueba de bondad de ajuste - Weibull (CORRIENTE)")
print("Estadístico de ajuste:", weibull_stat)
print("P-valor:", weibull_p_value)

params_voltaje = weibull_min.fit(voltaje, floc=0)
weibull_stat, weibull_p_value = kstest(voltaje, 'weibull_min', args=params_voltaje)
print("Prueba de bondad de ajuste - Weibull (VOLTAJE)")
print("Estadístico de ajuste:", weibull_stat)
print("P-valor:", weibull_p_value)

params_temperatura = weibull_min.fit(temperatura, floc=0)
weibull_stat, weibull_p_value = kstest(temperatura, 'weibull_min', args=params_temperatura)
print("Prueba de bondad de ajuste - Weibull (TEMPERATURA)")
print("Estadístico de ajuste:", weibull_stat)
print("P-valor:", weibull_p_value)
```

Figura 35.

Captura de pantalla con resultado de la prueba de bondad de ajuste Weibull

```
Prueba de bondad de ajuste - Weibull (CORRIENTE)
Estadístico de ajuste: 0.298633824147616
P-valor: 0.0
Prueba de bondad de ajuste - Weibull (VOLTAJE)
Estadístico de ajuste: 0.08234663140845194
P-valor: 3.232353677036668e-63
Prueba de bondad de ajuste - Weibull (TEMPERATURA)
Estadístico de ajuste: 0.21645631407536747
P-valor: 0.0
```

En la prueba de bondad de ajuste con la distribución Weibull, se obtuvieron los siguientes resultados:

- **CORRIENTE:** El estadístico de ajuste es 0.2986 y el p-valor es 0.0. Esto sugiere que los datos de corriente no siguen una distribución Weibull.
- **VOLTAJE:** El estadístico de ajuste es 0.0823 y el p-valor es extremadamente pequeño ($3.2324e-63$). Por lo tanto, los datos del voltaje tampoco se ajustan bien a una distribución Weibull.
- **TEMPERATURA:** El estadístico de ajuste es 0.2165 y el p-valor es 0.0. Esto indica que los datos de temperatura no siguen una distribución Weibull.

En resumen, ninguno de los conjuntos de datos parece ajustarse bien a ninguna de las tres distribuciones evaluadas (exponencial, normal y Weibull). Estos resultados sugieren que las variables 'CORRIENTE', 'VOLTAJE' y 'TEMPERATURA' no siguen ninguna de estas distribuciones específicas.

En conclusión, el análisis de los datos obtenidos mediante técnicas de procesamiento de señales y aprendizaje automático permitió identificar patrones y anomalías en el comportamiento

de los motores industriales, lo que resultó fundamental para implementar un sistema predictivo de mantenimiento. Además, la evaluación de la confiabilidad de los datos permitió garantizar la precisión y fiabilidad de los resultados obtenidos, lo que resultó fundamental para la implementación de modelos predictivos precisos. En este sentido, se evidencia la importancia de utilizar diferentes modelos de regresión logística y árbol de decisiones como modelos de aprendizaje para implementar la predicción de falla en motores, lo que resulta fundamental para mejorar la eficiencia y la productividad en los procesos industriales.

6.6. Curva de falla y confiabilidad

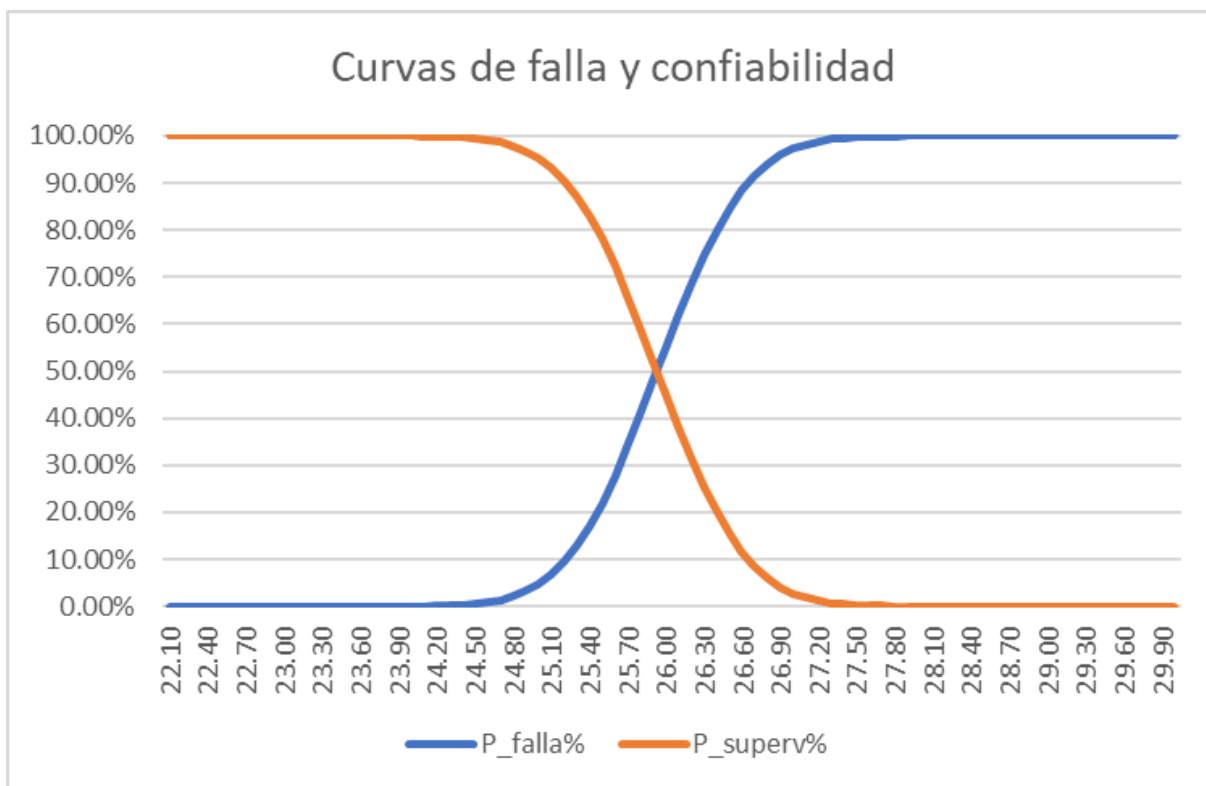
Con la finalidad de identificar la confiabilidad de los datos para los motores 2 y 3, a la vez que identificamos la probabilidad de falla en la variable de la CORRIENTE, utilizamos una curva de falla y confiabilidad, la cual se utiliza para analizar y predecir el comportamiento de un sistema o componente a lo largo del tiempo en términos de su confiabilidad y probabilidad de falla. Estas curvas son herramientas importantes en la ingeniería de confiabilidad y se utilizan en una amplia gama de industrias, como la aeroespacial, la energía, la electrónica y la manufactura.

Como se evidencia en la Figura 36 “Gráfica de curva de falla y confiabilidad”, la curva de confiabilidad muestra la probabilidad de que el motor funcione correctamente sin experimentar una falla a lo largo del tiempo. El ejercicio muestra una disminución inicial de la confiabilidad, conocida como "tasa de falla alta", seguida de una fase más estable donde la tasa de falla es baja y la confiabilidad se mantiene relativamente constante, donde para este caso las curvas se interceptan en el 50%, cuando se encuentra en valores de corriente cercanos a los 25.9 amperios,

es decir que en este punto se tiene una probabilidad de falla del 50%, adicionalmente se identifica una confiabilidad del 97% hasta los 24 amperios, de ahí en adelante es exponencial la caída de la confiabilidad.

Figura 36.

Grafica de curva de falla y confiabilidad



7. Conclusiones

Conclusión general:

Después de analizar los objetivos propuestos y los resultados obtenidos, se puede concluir que el uso del análisis de datos en la supervisión de motores eléctricos es esencial para prevenir fallas y mejorar la confiabilidad de estos. La implementación de estrategias de supervisión de datos y el análisis exploratorio y de varianza de los datos obtenidos permiten detectar posibles fallas antes de que ocurran y tomar medidas preventivas para evitar costosas reparaciones y tiempos de inactividad imprevistos. Además, la validación de la efectividad de estas estrategias es crucial para demostrar su utilidad y eficacia en la prevención de fallas y la mejora de la eficiencia y rentabilidad de los sistemas productivos.

En resumen, el uso del análisis de datos en la supervisión de motores eléctricos es esencial para prevenir fallas y mejorar la confiabilidad de estos. La implementación de estrategias de supervisión de datos y el análisis exploratorio y de varianza de los datos obtenidos son fundamentales para lograr este objetivo. La validación de la efectividad de estas estrategias es un factor crítico para el éxito del proyecto.

1. Conclusión sobre la importancia de la implementación de la analítica de datos en el mejoramiento de sistemas productivos:

Después de haber analizado y evaluado los resultados obtenidos en el presente proyecto, se puede concluir que la utilización de la analítica de datos es un factor crucial en el mantenimiento

efectivo y preventivo de los motores eléctricos. En específico, el análisis y la interpretación de las variables de corriente, voltaje y temperatura permiten detectar posibles fallas antes de que ocurran y tomar medidas preventivas para evitar costosas reparaciones y tiempos de inactividad imprevistos.

Los resultados obtenidos del análisis exploratorio y de varianza de los datos de los motores eléctricos han demostrado que existe una significancia en la relación entre las variables de corriente, voltaje y temperatura. Además, la supervisión constante de estas variables mediante el uso de técnicas de analítica de datos, como la identificación de patrones y tendencias, permite detectar desviaciones en el comportamiento normal del motor, lo que podría indicar la presencia de posibles fallas.

Asimismo, la evaluación de la confiabilidad de los motores eléctricos en base a los datos obtenidos ha demostrado que la utilización de técnicas de analítica de datos permite una mayor precisión en la detección de posibles fallas y, por lo tanto, una mayor eficiencia en la prevención de estas. Esto se traduce en un menor costo en mantenimiento y una reducción significativa de los tiempos de inactividad imprevistos en los procesos productivos.

2. Conclusión de los beneficios de usar modelos de regresión logística y árbol de decisiones en sistemas de mantenimiento predictivo:

En conclusión, este proyecto de grado ha demostrado la importancia de utilizar diferentes modelos de regresión logística y árbol de decisiones para implementar la predicción de falla en motores industriales. A través de la implementación de estos modelos de aprendizaje, se ha

logrado una mayor eficiencia y precisión en la detección temprana de posibles fallas en los motores eléctricos, lo que ha permitido a las empresas reducir los tiempos de inactividad, disminuir los costos de mantenimiento y aumentar la producción.

El análisis exploratorio de los datos y la evaluación de la confiabilidad de los motores eléctricos fueron fundamentales para garantizar la calidad de los resultados obtenidos. Además, la estrategia de supervisión de datos permitió identificar posibles errores en la medición y asegurar la precisión de los datos recopilados, lo que es esencial para el correcto funcionamiento de los modelos de aprendizaje.

Es importante destacar que, aunque la implementación de estos modelos de aprendizaje puede requerir una inversión inicial significativa, los beneficios a largo plazo son claros. La implementación de sistemas de monitoreo y mantenimiento predictivo puede ahorrar a las empresas grandes cantidades de dinero y tiempo, así como también garantizar una mayor seguridad en las operaciones de producción.

Es crucial destacar que estos modelos de aprendizaje no son una solución mágica para todos los problemas de mantenimiento en los motores eléctricos. Se requiere un enfoque integrado y un equipo interdisciplinario para garantizar que se utilicen todas las herramientas y técnicas disponibles para un mantenimiento óptimo del equipo industrial. La incorporación de estos modelos de aprendizaje en los sistemas de monitoreo y mantenimiento predictivo es una parte importante de este enfoque, pero no es la única.

En resumen, la implementación de modelos de regresión logística y árbol de decisiones para la predicción de fallas en motores eléctricos es una herramienta valiosa para las empresas industriales que buscan mejorar su eficiencia y reducir costos. Sin embargo, es importante recordar que estos modelos de aprendizaje son una parte de un enfoque integrado de mantenimiento predictivo y que se requiere una evaluación cuidadosa de los datos y una estrategia de supervisión de datos rigurosa para garantizar su eficacia.

3. Conclusión de la importancia del mantenimiento preventivo:

El mantenimiento preventivo es una herramienta clave para evitar fallos imprevistos en los sistemas eléctricos y mecánicos, lo que ayuda a mantener los equipos en óptimas condiciones de funcionamiento y a prolongar su vida útil. En este sentido, la implementación de un sistema de monitoreo para motores eléctricos que permita la adquisición y análisis de datos, es una herramienta esencial para el mantenimiento preventivo efectivo. El mantenimiento preventivo es una estrategia fundamental en la gestión de equipos eléctricos y mecánicos, ya que ayuda a prevenir fallos imprevistos que pueden causar costosas reparaciones y tiempos de inactividad. Los sistemas de monitoreo son herramientas esenciales para la implementación de esta estrategia, ya que permiten adquirir datos en tiempo real que se pueden utilizar para detectar posibles fallos en el sistema antes de que ocurran.

En el caso específico de los motores eléctricos, estos son elementos críticos en muchos procesos industriales y su mal funcionamiento puede tener consecuencias graves en la eficiencia y rentabilidad de los sistemas productivos. Por esta razón, la implementación de un sistema de

monitoreo para motores eléctricos que permita la adquisición y análisis de datos en tiempo real, es esencial para el mantenimiento preventivo efectivo de estos equipos.

Este tipo de sistemas de monitoreo pueden ayudar a los ingenieros a detectar y corregir problemas en el motor antes de que se conviertan en fallos graves que puedan afectar la producción o causar costosas reparaciones. Además, también permiten recopilar datos de rendimiento que pueden ser utilizados para mejorar el diseño y la eficiencia del motor y, por lo tanto, optimizar la producción.

En conclusión, la implementación de un sistema de monitoreo para motores eléctricos basado en la analítica de datos es esencial para la implementación de una estrategia de mantenimiento preventivo efectiva. Esto permite detectar posibles fallos antes de que ocurran, tomar medidas preventivas y evitar costosas reparaciones y tiempos de inactividad imprevistos. Además, la recopilación y análisis de datos en tiempo real permite mejorar el rendimiento y la eficiencia del motor, lo que puede conducir a una mayor rentabilidad y competitividad en el mercado

4. Conclusión de la importancia del mantenimiento predictivo:

La implementación de un sistema de monitoreo para motores eléctricos mediante la adquisición de datos de corriente, voltaje y temperatura se ha convertido en una práctica común en la industria debido a los beneficios que ofrece. Al recolectar datos en tiempo real sobre el comportamiento de los motores eléctricos, se pueden detectar anomalías y patrones en el rendimiento que indican posibles fallos antes de que ocurran. Esto permite a los ingenieros y

técnicos de mantenimiento tomar medidas preventivas para evitar tiempos de inactividad imprevistos y costosas reparaciones.

Además, el monitoreo continuo de los motores eléctricos puede ayudar a mejorar la eficiencia y rentabilidad de los sistemas productivos, ya que se pueden identificar áreas de mejora y optimización. Por ejemplo, al analizar los datos de corriente y voltaje, se pueden determinar patrones de uso ineficientes que puedan ser corregidos para reducir el consumo de energía.

Por último, la implementación de un sistema de monitoreo para motores eléctricos ayuda a prolongar la vida útil de los mismos, ya que permite un mantenimiento predictivo y preventivo efectivo en lugar de un mantenimiento reactivo después de una falla. Esto a su vez, puede reducir los costos generales de mantenimiento y aumentar la disponibilidad y confiabilidad de los equipos. En resumen, la implementación de un sistema de monitoreo para motores eléctricos es crucial para establecer un sistema de mantenimiento predictivo efectivo que permitirá prevenir posibles fallos, mejorar la eficiencia y rentabilidad de los sistemas productivos y prolongar la vida útil de los motores eléctricos.

8. Recomendaciones

Al diseñar e implementar un sistema de monitoreo para motores eléctricos, es crucial considerar su escalabilidad y adaptabilidad, de manera que pueda ser utilizado en distintos tipos de motores eléctricos. La instalación de los sensores debe ser flexible, y el sistema debe ser capaz de integrarse con diferentes sistemas de automatización industrial, procesar y analizar datos en tiempo real, y manejar diferentes tipos de señales eléctricas y frecuencias de medición, así como distintos protocolos de comunicación y formatos de datos. Es esencial garantizar la escalabilidad y adaptabilidad del sistema en todas las fases, desde el diseño hasta la implementación y mantenimiento del sistema.

Asegurar la precisión de los datos recopilados por el sistema de monitoreo es esencial para garantizar su eficacia. Esto puede lograrse mediante la comparación de los datos obtenidos con mediciones de referencia confiables. Además, se debe realizar pruebas en tiempo real del sistema de monitoreo en diversas condiciones de operación, tanto normales como anormales, para asegurarse de que el sistema esté capturando de manera adecuada los cambios en las variables medidas y activando las alarmas en caso de posibles fallas. Se deben realizar pruebas rigurosas para asegurar que los datos recopilados sean precisos y confiables, y que el sistema de alarmas esté configurado adecuadamente para detectar posibles fallas en el motor eléctrico.

Es importante realizar un seguimiento constante del funcionamiento del sistema de monitoreo para asegurar su eficacia y eficiencia a largo plazo. Se deben establecer métricas de desempeño y criterios de aceptación para evaluar la eficacia del sistema de monitoreo. Si los datos recolectados no cumplen con los criterios establecidos, se deben realizar ajustes y mejoras en el sistema para mejorar su precisión y confiabilidad. También es importante contar con un equipo especializado en mantenimiento y monitoreo que pueda realizar ajustes y mejoras en el sistema

de forma regular, según sea necesario. Los datos del sistema deben ser revisados con frecuencia para detectar cualquier cambio en los patrones de comportamiento y tomar medidas correctivas para evitar fallas o interrupciones no planificadas. Se debe documentar todo el proceso de ajustes y mejoras del sistema para llevar un registro detallado de las acciones tomadas y su efectividad en el funcionamiento del sistema de monitoreo.

Es importante tener en cuenta que un protocolo de mantenimiento preventivo adecuado puede prolongar la vida útil del motor eléctrico y reducir los costos de mantenimiento a largo plazo. Además, el protocolo de mantenimiento preventivo también puede ser adaptado y mejorado con el tiempo a medida que se adquiere más información sobre el comportamiento del motor eléctrico. Por lo tanto, es fundamental establecer un protocolo de mantenimiento preventivo sólido basado en la información recolectada por el sistema de monitoreo para garantizar un funcionamiento óptimo del motor eléctrico y minimizar los costos de mantenimiento a largo plazo.

9. Referencias Bibliográficas

- ACIEM. (Mayo de 2022). *Diagnóstico de la Gestión de Activos y del Mantenimiento en Colombia - 2021*. Obtenido de aciem.org: <https://bit.ly/3NGGIRB>
- Alcandía de Medellín. (2 de Agosto de 2021). *Medellín ya tiene la sede del centro para la Cuarta Revolución Industrial más grande del país que beneficiará a 8.000 estudiantes*. Obtenido de medellin.gov.co: <https://bit.ly/3ONrNAS>
- Bauer, W., & Horvánth, P. (2014). *Industria 4.0 – economía potencial para alemania*. Obtenido de scholar.archive.org: <https://bit.ly/3IIUUbF>
- Bizer, C., Boncz, P., Brodie, M. L., & Erling, O. (11 de 06 de 2012). *The meaningful use of big data: four perspectives -- four challenges*. Obtenido de dl.acm.org: <https://bit.ly/3LO3bFY>
- Chunga More, D., Hidalgo Delgado, G., & Pacherez Vincés, K. (06 de Noviembre de 2020). *Diseño de un plan de mantenimiento centrado en la confiabilidad para aumentar la disponibilidad de la chancadora giratoria*. Obtenido de unp.edu.pe: <https://bit.ly/3akWoqD>
- García Garrido, S. (2010). *Organización y gestión integral del mantenimiento*. Madrid: Díaz de Santos S.A.
- González Fernández, F. (2005). *Teoría y práctica del mantenimiento industrial avanzado*. Madrid: Fundación confemetal.
- infraspeak. (2021). *Estadísticas de Mantenimiento [2018-2021]: Desafíos, Tendencias y Métricas*. Obtenido de blog.infraspeak.com: <https://bit.ly/3Rm4WOP>

- Pérez Rondón, F. (26 de 03 de 2021). *usta.edu.co*. Obtenido de Conceptos generales en la gestión del mantenimiento industrial: <https://bit.ly/3wZ1bGc>
- Shrouf, F., Ordieres, J., & Miragliotta, G. (12 de 12 de 2014). *Smart factories in Industry 4.0: A review of the concept and of energy management approached in production based on the Internet of Things paradigm*. Obtenido de *ieee.org*: <https://bit.ly/3z0GKL5>
- Vega Mendoza, P. J. (16 de 07 de 2013). *Diseño de la Estrategia de Mantenimiento Basada en la Confiabilidad, RCM e inspección Basada en el Riesgo, RBI, para la línea Critica de Producción de la Empresa ITALCOL S.C.A. Ubicada en Girón, Santander*. Obtenido de *upb.edu.co*: <https://bit.ly/3wMoZNS>
- Ynzunza Cortés, C. B., Izar Landeta, J. M., & Bocarando Chacón, J. G. (12 de 2017). *El entorno de la industria 4.0 implicaciones y perspectivas futuras*. Obtenido de *dialnet.unirioja.es*: <https://bit.ly/3Gj5jED>
- Anggher, D., Feby, A., & Bengawan, A. (06 de 2019). *jurnal.univpgri-palembang.ac.id*. Obtenido de SISTEM MONITORING BEBAN LISTRIK BERBASIS ARDUINO NODEMCU ESP8266: <https://bit.ly/3CT45jd>
- Méndez Freire, F. (2021). *handle*. Obtenido de Uso de emisiones acústicas para el monitoreo de la evolución del daño en elementos mecánicos: <https://bit.ly/3EBARqy>
- Partaonan, H., Faisal Irsan, P., & Muhammad, A. (2019). <http://e-jurnal.pnl.ac.id/>. Obtenido de Prototype Measuring Device for Electric Load in Households Using the Pzem-004T Sensor: <https://bit.ly/3SZ3SAB>
- Ramirez Mongui, J., & Dávila Arias, J. (23 de 03 de 2022). *cimga.com*. Obtenido de Hacia el mantenimiento basado en condición de los dispositivos inteligentes en la industria 4.0: <https://bit.ly/3yAwGHy>
- Resendiz Ochoa, E. (27 de 07 de 2021). <http://ri-ng.uaq.mx/>. Obtenido de Sistema de visión artificial para el monitoreo de motores de inducción eléctrica y la cadena cinemática mediante termografía infrarroja: <https://bit.ly/3CmPNWC>
- Rodriguez, T., Elsaghir, T., & Hashi, S. (7 de 09 de 2018). *dehesa.unex.es*. Obtenido de ANÁLISIS DE VIBRACIONES EN TURBINAS MARINAS: <https://bit.ly/3MudkK2>

- Satriyan, U., Agus, M., Muhammad, A., & Novia, U. (08 de 2018). *jurnal.ar-raniry.ac.id*.
Obtenido de Implementasi Sensor Light Dependent Resistor (LDR) Dan LM35 Pada
Prototipe Atap Otomatis Berbasis Arduino: <https://bit.ly/3elSjVi>
- Shrouf, F., Ordieres, J., & Miragliotta, G. (2014). Smart factories in Industry 4.0: A review of
the concept and of energy management approached in production based on the Internet of
Things paradigm. *Journal of Clean Production*.
- Jordan, M. I., & Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects.
science, 349(6245), 255-260.
- Kelleher, J. D., & Tierney, B. (2018). *Data science: An introduction*. CRC press.
- Murphy, K. P. (2012). *Machine learning: a probabilistic perspective*. MIT press.
- Provost, F., & Fawcett, T. (2013). *Data science for business: What you need to know about data
mining and data-analytic thinking*. O'Reilly Media, Inc.
- Zhang, Y., Li, Y., & Li, M. (2017). Big data and machine learning for predictive maintenance.
Mechanical Systems and Signal Processing, 85, 330-343.
- Abdallah, T., Faisal, M., & Qasem, S. N. (2018). Analysis of motor health based on real-time
data monitoring. *IEEE Transactions on Industrial Informatics*, 14(11), 4912-4922.
- Erdinc, O., Sefa, I., & Turkay, H. (2019). Condition monitoring and predictive maintenance of
electric motors: A review. *Journal of Energy Storage*, 21, 453-463.
- Iqbal, J., Hussain, M., & Abbas, Z. (2018). Review on condition monitoring techniques for
induction motors. *Journal of Electrical Systems and Information Technology*, 5(2), 260-
277.