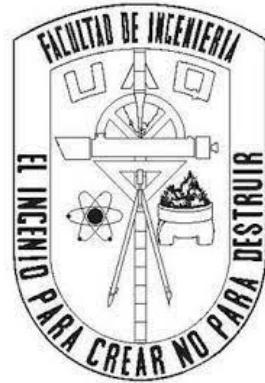


Universidad Autónoma de Querétaro

Facultad de Ingeniería



Detección de daño por corrosión en rodamientos de motores de inducción mediante algoritmos de
aprendizaje automático y fusión de datos

Opción de titulación

TESIS

Que como parte de los requisitos para obtener el grado de
Maestro en Ciencias Mecatrónica

Presenta:

Ing. José Pablo Pacheco Guerrero

Dirigido por:

Dr. Israel Zamudio Ramírez

San Juan del Río, Querétaro. Junio 2025

La presente obra está bajo la licencia:
<https://creativecommons.org/licenses/by-nc-nd/4.0/deed.es>



CC BY-NC-ND 4.0 DEED

Atribución-NoComercial-SinDerivadas 4.0 Internacional

Usted es libre de:

Compartir — copiar y redistribuir el material en cualquier medio o formato

La licenciatario no puede revocar estas libertades en tanto usted siga los términos de la licencia

Bajo los siguientes términos:



Atribución — Usted debe dar [crédito de manera adecuada](#), brindar un enlace a la licencia, e [indicar si se han realizado cambios](#). Puede hacerlo en cualquier forma razonable, pero no de forma tal que sugiera que usted o su uso tienen el apoyo de la licenciatario.



NoComercial — Usted no puede hacer uso del material con [propósitos comerciales](#).



SinDerivadas — Si [remezcla, transforma o crea a partir](#) del material, no podrá distribuir el material modificado.

No hay restricciones adicionales — No puede aplicar términos legales ni [medidas tecnológicas](#) que restrinjan legalmente a otras a hacer cualquier uso permitido por la licencia.

Avisos:

No tiene que cumplir con la licencia para elementos del material en el dominio público o cuando su uso esté permitido por una [excepción o limitación](#) aplicable.

No se dan garantías. La licencia podría no darle todos los permisos que necesita para el uso que tenga previsto. Por ejemplo, otros derechos como [publicidad, privacidad, o derechos morales](#) pueden limitar la forma en que utilice el material.



Universidad Autónoma de Querétaro



Facultad de Ingeniería

Campus San Juan del Río

Detección de daño por corrosión en rodamientos de motores de inducción mediante algoritmos de
aprendizaje automático y fusión de datos

TESIS

Que como parte de los requisitos para obtener el grado de
MAESTRO EN CIENCIAS MECATRÓNICA

Línea terminal:

MECATRÓNICA

Presenta:

Ing. José Pablo Pacheco Guerrero

Dirigido por:

Dr. Israel Zamudio Ramírez

SINODALES:

Dr. Israel Zamudio Ramírez

Presidente

Dr. José Alfonso Antonino Daviu

Secretario

Dr. Luis Morales Velázquez

Vocal

Dr. Juan Pablo Amézquita Sánchez

Suplente

Dr. Arturo Yosimar Jaen Cuellar

Suplente

AGRADECIMIENTOS

*A mi mamá y mi papá, familia, novia,
amigos y seres queridos.
Por ser mi mayor motivación.*

DEDICATORIA

Agradezco a mi mamá María Trinidad y a mi papá Pablo Pacheco por todo el apoyo y amor brindado, son mi más grande motivación. A mi familia por siempre estar incondicionalmente.

A mi novia, por ser una excelente compañera.

Al Dr. Roque Alfredo Osornio Ríos, su guía, conocimientos y apoyo han sido fundamentales durante mi desarrollo académico y profesional. Lamentablemente, falleció antes de la conclusión de este trabajo, y su ausencia deja un vacío que siempre recordaré con respeto y gratitud. Esta tesis es, en gran parte, un homenaje a su dedicación y esfuerzo.

Al Dr. Israel Zamudio Ramírez, quien asumió la responsabilidad de dirigir este trabajo con gran entusiasmo y por su valioso apoyo, un gran científico. A mis sinodales por su retroalimentación y disposición ante cualquier problema.

A los maestros, por todo el conocimiento compartido en el salón de clases y ayudarme a crecer profesional y académicamente. Al SECIHTI por el apoyo de beca otorgado (CVU: 1316019)

A los trabajadores de la Facultad, por siempre compartir sonrisas y mostrar la pasión por su trabajo.

A mis compañeros de generación, que se volvieron grandes amigos, son unos excelentes profesionistas.

ÍNDICE GENERAL

AGRADECIMIENTOS	II
DEDICATORIA	III
ÍNDICE GENERAL.....	IV
ÍNDICE DE FIGURAS	VII
ÍNDICE DE TABLAS	IX
RESUMEN	1
ABSTRACT	2
CAPÍTULO 1 INTRODUCCIÓN	3
1.1 ANTECEDENTES	5
1.2 DESCRIPCIÓN DEL PROBLEMA.....	11
1.3 JUSTIFICACIÓN.....	12
1.4 HIPÓTESIS.....	14
1.5 OBJETIVOS	14
1.5.1 Objetivo general.....	14
1.5.2 Objetivos específicos.....	14
CAPÍTULO 2 FUNDAMENTACIÓN TEÓRICA	16
2.1 MOTORES DE INDUCCIÓN.....	16
2.1.1 Partes de un motor de inducción.....	17
2.2 PRINCIPALES FALLOS EN MOTORES DE INDUCCIÓN	18
2.3 FALLO POR CORROSIÓN EN MOTORES DE INDUCCIÓN	20
2.3.1 Corrosión por humedad.....	21
2.3.2 Corrosión por fricción provocada por contacto	22
2.3.3 Corrosión por fricción debida a la vibro corrosión.....	22

2.4 MÉTODOS DE DETECCIÓN DE FALLOS.....	23
2.4.1 Algoritmos basados en el dominio del tiempo y uso de indicadores estadísticos y no estadísticos.....	25
2.4.2 Algoritmos basados en el dominio de la frecuencia	28
2.4.3 Algoritmos basados en el uso de transformadas en el tiempo-frecuencia	30
2.5 ALGORITMOS DE APRENDIZAJE AUTOMÁTICO	30
2.5.1 Máquina de soporte vectorial	33
2.5.2 Bootstrap Aggregation	34
2.6 ANÁLISIS DISCRIMINANTE LINEAL.....	35
2.7 SOBREAJUSTE Y LA TASA DE SOBREAJUSTE RELATIVO.....	36
CAPÍTULO 3. METODOLOGÍA.....	38
3.1 RODAMIENTO SELECCIONADO	40
3.2 MATRIZ DE DATOS REALIZADA.....	40
3.3 CONFIGURACIÓN DE LA BANCADA CON ELEMENTOS MECÁNICOS, ELÉCTRICOS Y SENSORES	41
3.4 INSTRUMENTACIÓN DE SENSORES	43
3.5 PUESTA EN EXPERIMENTACIÓN	46
3.6 PROCESAMIENTO DE LAS SEÑALES	47
3.7 INDICADORES ESTADÍSTICOS Y NO ESTADÍSTICOS	48
3.8 ANÁLISIS DE VARIANZA	49
3.9 USO DE ANÁLISIS DISCRIMINANTE LÍNEAL	50
3.10 USO DE MÁQUINA DE SPORTE VECTORIAL.....	51
3.11 USO DE ALGORITMO DE APRENDIZAJE POR CONJUNTOS BAGGING.....	52
3.12 ALGORITMO GENÉTICO IMPLEMENTADO	53
3.13 DIAGRAMA DE FLUJO DEL SISTEMA IMPLEMENTADO.....	55

CAPÍTULO 4. RESULTADOS	58
4.1 RODAMIENTOS BAJO FALLOS OBTENIDOS	58
4.2 SEÑALES EN EL TIEMPO OBTENIDAS	60
4.3 MUESTRAS REPRESENTATIVAS DE LAS SEÑALES EN EL TIEMPO OBTENIDAS	63
4.4 VENTANEO DE LAS SEÑALES ACOTADAS.....	65
4.5 APLICACIÓN DE ANÁLISIS ANOVA DE PARAMETROS ESTADÍSTICOS Y NO ESTADÍSTICOS.....	68
4.6 MEJOR COMBINACIÓN DE INDICADORES OBTENIDA Y ANÁLISIS DISCRIMINANTE LINEAL.....	69
4.7 RESULTADOS TRAS ANÁLISIS BAGGING	71
4.8 ANÁLISIS COMPARATIVO DE LA METODOLOGÍA PROPUESTA.....	73
4.9 COMPARATIVA CON OTRAS METODOLOGÍAS	76
CAPÍTULO 5. CONCLUSIONES Y PROSPECTIVAS	77
5.1 CONCLUSIONES	77
5.2 PROSPECTIVAS	78
REFERENCIAS BIBLIOGRAFICAS	79
ANEXOS	83
ANEXO 1: Trabajo publicado en el XVIII Coloquio de Posgrado en el libro Innovación Sustentable: IA al Servicio del Planeta	83
ANEXO 2: Presentación XVIII Coloquio de Posgrado en el libro Innovación Sustentable: IA al Servicio del Planeta	85
ANEXO 3: Artículo desarrollado para el OPTIM-ACEMP 2025	86

ÍNDICE DE FIGURAS

Figura 1 Proyección de generación de energía hacia el 2030 (Szabó, 2019).	3
Figura 2 Características básicas de un motor tipo: a) síncrono, se muestra el campo magnético generado y b) inducción, se muestra un rotor de tipo jaula de ardilla (Chapman, 2012).	17
Figura 3 a) Representación gráfica de un motor de inducción de tipo jaula de ardilla (Chapman, 2012) y b) Partes internas de un motor de inducción (Gangsar y Tiwari, 2020).	18
Figura 4 Porcentaje de ocurrencia de los fallos en motores de inducción (Bazurto et al., 2016).	20
Figura 5 Algunos casos de corrosión provocadas por: a) corrosión en aro exterior y rodillo de rodamiento, b) agua entra en contacto con lubricante y se acumula en parte inferior, c) decapado inicial en elementos rodantes y caminos de rodadura (SKF, 2017).	22
Figura 6 Corrosión por contacto provocada por: a) asiento de eje inadecuado y b) carga pesada (SKF, 2017). ...	22
Figura 7 Vibro corrosión severa en camino de rodadura en un rodamiento de bolas (SKF, 2017).	23
Figura 8 Representación gráfica de algunos parámetros de las ecuaciones de fallo características (Castellino et al., (2007)).	29
Figura 9 Diagrama de pasos para realizar un algoritmo de aprendizaje de máquinas (autoría propia).	32
Figura 10 Representación de parámetros de una Máquina de Soporte Vectorial.	34
Figura 11 Proceso Bagging (Kalirane, 2023).	35
Figura 12 Diagrama metodológico a realizar (autoría propia).	39
Figura 13 Rodamiento metálico 6203 RS/C3 (autoría propia).	40
Figura 14 Configuración de bancada y sensores (autoría propia).	42
Figura 15 Sensores utilizados: a) Sensor de flujo magnético de dispersión BM1422AGMV y b) Pinza ampermétrica Fluke i200s.	44
Figura 17 Puesta en experimentación.	47
Figura 18 Diagrama de flujo del sistema implementado.	57
Figura 19 Rodamientos bajo a) corrosión nivel 1 y b) corrosión nivel 2.	60

Figura 20 Señales en el tiempo de a) corriente, b) vibraciones y c) flujo magnético de dispersión.....	62
Figura 21 Segmentos analizados para señales de a) corriente, b) vibraciones y c) flujo magnético.	65
Figura 22 Ventaneo y solapamiento de las señales de a) corriente, b) vibraciones y c) flujo magnético de dispersión.....	67
Figura 23 Análisis de varianza para señal de corriente con a) entropía de muestreo y b) curtosis.	69
Figura 24 Análisis Discriminante Lineal con el mejor conjunto obtenido en el algoritmo genético.	71
Figura 25 Matriz de confusión obtenida tras análisis del conjunto de prueba con los datos de entrenamiento para la metodología propuesta.....	72
Figura 26 Gráficos representativos para comparar la metodología propuesta en a) precisión y b) tasa de sobreajuste relativo.....	75

ÍNDICE DE TABLAS

Tabla 1 Parámetros estadísticos y no estadísticos, además de sus ecuaciones.....	27
Figura 16 Tarjetas de adquisición de datos usadas para a) flujo magnético de dispersión y vibraciones y b) corriente.....	44
Tabla 3 Datos de sensores y tarjetas de adquisición.....	45
Tabla 4 Selección de hiperparámetros del Bagging.	53
Tabla 5 Hiperparámetros del algoritmo genético.	55
Tabla 6 Comparativa entre bloques de la metodología propuesta	74
Tabla 7 Comparativa con otras metodologías.	76

RESUMEN

La detección de fallos en motores de inducción ha sido un tema de gran interés en la comunidad científica debido a la necesidad de evitar problemas graves y paros en los procesos de producción. Se ha encontrado que los motores eléctricos son las máquinas más usadas a nivel mundial, y, por ende, son una de las mayores fuentes de consumo de energía mundial, por lo que, al verse comprometida su eficiencia, incrementa el uso de recursos contaminantes para la generación de energía complementaria. Según las estadísticas, los rodamientos en los motores de inducción representan el 40% de los fallos generales, siendo así, los componentes con mayor probabilidad de fallo. Dentro de los métodos de detección se reporta que se utilizan métodos de aprendizaje de máquinas e inteligencia artificial por su alta eficiencia, sin embargo, existen métodos capaces de reducir los problemas de sobreajuste y mejorar la capacidad de generalización como los modelos de ensamblaje de aprendizaje automático, capaces de obtener una clasificación más robusta de los niveles de daño. En este trabajo se analizaron las señales en el tiempo del flujo magnético de dispersión, corriente y vibraciones generadas en un motor de inducción bajo tres condiciones: sano, corrosión nivel 1 y corrosión nivel 2. Para la clasificación, primero se realizó un análisis dinámico de las señales con el fin de extraer indicadores estadísticos y no estadísticos. Luego, se empleó un algoritmo genético para seleccionar los indicadores más relevantes, optimizando así las características de entrada del modelo de clasificación. Los indicadores seleccionados fueron procesados mediante un método de reducción de dimensionalidad basado en el análisis discriminante lineal (LDA del inglés *Linear Discriminant Analysis*), del cual se eligieron las dos mejores características. Estas características fueron utilizadas como entrada del modelo de ensamblaje Bagging (del inglés *Bootstrap Aggregation*), cuyo clasificador base es una máquina de soporte vectorial (SVM del inglés *Support Vector Machine*), mejorando así la precisión del sistema de clasificación. Se compararon diferentes combinaciones de las estructuras propuestas: SVM con LDA, SVM sin LDA ni Bagging, y Bagging sin LDA. Los resultados mostraron que el enfoque propuesto, que integra LDA, SVM y Bagging, alcanzó la mayor precisión, superando el 99%.

Palabras clave: Motores de Inducción, Detección de Fallos, Corrosión, Aprendizaje de Máquinas, Máquina de Soporte Vectorial, Bootstrap Aggregation, Vibraciones, Flujo magnético de dispersión, Corriente.

ABSTRACT

Fault detection in induction motors has been a topic of great interest in the scientific community due to the need to prevent severe issues and production process stoppages. It has been found that electric motors are the most widely used machines worldwide and, consequently, one of the largest sources of global energy consumption. Therefore, when their efficiency is compromised, the use of pollutant resources for supplementary energy generation increases. According to statistics, bearings in induction motors account for 40% of general failures, making them the components with the highest fault probability. Among the detection methods, machine learning and artificial intelligence techniques are widely used due to their high efficiency. However, some approaches can reduce overfitting issues and improve generalization capabilities, such as ensemble learning models, which provide a more robust classification of damage levels. In this study, time-domain signals of leakage magnetic flux, current, and vibrations generated in an induction motor were analyzed under three conditions: healthy, corrosion level 1, and corrosion level 2. For classification, a dynamic signal analysis was first performed to extract statistical and non-statistical indicators. Then, a genetic algorithm was employed to select the most relevant indicators, optimizing the input features for the classification model. The selected indicators were processed using a dimensionality reduction method based on Linear Discriminant Analysis (LDA), from which the two best features were chosen. These features served as input for the Bagging (Bootstrap Aggregation) ensemble model, with Support Vector Machine (SVM) as the base classifier, enhancing classification accuracy. Different combinations of the proposed structures were compared: SVM with LDA, SVM without LDA or Bagging, and Bagging without LDA. The results showed that the proposed approach, integrating LDA, SVM, and Bagging, achieved the highest accuracy, exceeding 99%.

Keywords: *Induction Motors, Failure Detection, Corrosion, Machine Learning, Support Vector Machine, Bootstrap Aggregation, Vibrations, Stray Magnetic Flux, Current.*

CAPÍTULO 1 INTRODUCCIÓN

Los motores de inducción son una herramienta que llegó para revolucionar la industria por su amplia gama de aplicaciones, su bajo costo, confiabilidad y nobleza, además de sus características físicas que lo convierten en máquinas con una buena relación calidad-precio. Cabe resaltar la relevancia de las máquinas eléctricas como los motores de inducción en el consumo de energía global y su contribución al uso de elementos contaminantes para el ambiente al ser las máquinas más usadas a nivel mundial, esto debido a que cuando su eficiencia se ve comprometida, se requiere mayor generación de electricidad. Entonces, Szabó (2019) proporciona en su texto científico una gráfica sobre la previsión de energía eléctrica generada con una comparativa de 20 años (desde 2011 hasta 2030) mostrada en la Figura 1. En la gráfica se puede apreciar un incremento del 60% en cuanto a la generación de energía eléctrica en este lapso, con un incremento de aproximadamente 3% por año. Es demasiado notorio el esfuerzo por introducir la generación de energía por medio de recursos renovables, pasando del 4 al 12% hacia el 2030. Por otra parte, el uso de combustibles fósiles se ve reducido (en porcentaje) del 68 al 61%. Sin embargo, hablando en cuanto a valor absoluto, se requerirá una mayor cantidad de recursos por combustibles fósiles, y esto, se traducirá en un aumento sustancial de la contaminación ambiental, y, por ello, el mantenimiento y mejora de los equipos eléctricos, además de la eficiencia energética, tomará cada vez mayor valor.

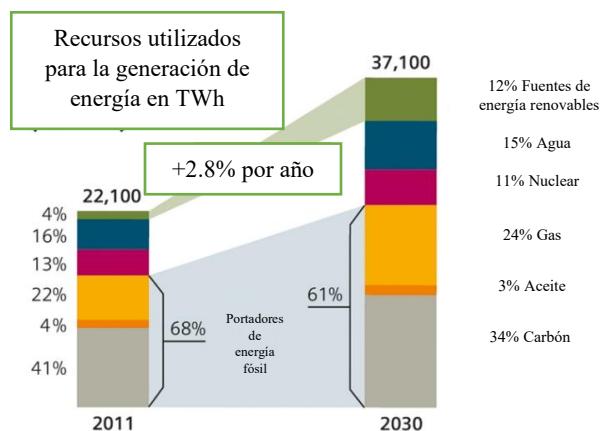


Figura 1 Proyección de generación de energía hacia el 2030 (Szabó, 2019).

En dicho artículo se menciona que el solo hecho de mejorar un punto porcentual la eficiencia de los equipos eléctricos, podría permitir un ahorro mundial de cerca de 1600 millones de litros de petróleo. De igual manera, se visualiza que el 42% de la energía mundial es usada en la industria y dos terceras partes se atribuye a los motores eléctricos, es decir, el 28% de la energía mundial se les atribuye a dichas máquinas eléctricas. Por otro lado, investigadores, como Gavrila et al. (2017) mencionan en su artículo que los motores de inducción de tipo jaula de ardilla son las máquinas eléctricas más usadas a nivel mundial, por lo tanto, resolver los fallos de estas máquinas podría significar una reducción importante en el consumo de energía mundial. Dicho lo anterior, se sabe que los motores de inducción son susceptibles a diversos fallos debido a los periodos largos de falta de mantenimiento. Esto se debe principalmente a su naturaleza, ya que pueden seguir operando con normalidad a pesar de presentar fallos, incluso en condiciones adversas como las que se presentan regularmente en estos motores como sobrecargas, variaciones de voltaje, contaminación por polvo, humedad, altas temperaturas, etc. lo cual lleva a un desgaste progresivo en sus componentes. Por ejemplo, Bazuerto et al. (2016) clasifican los fallos en mecánicos y eléctricos y proporcionan una distribución estadística de aparición de los fallos, donde el 45% se concentra en los rodamientos, 35% en el estator, 10% en el rotor y el restante 10% en otras categorías. Al ser los fallos en los rodamientos de los motores de inducción los más comunes, es importante realizar análisis de detección para posteriormente programar mantenimientos y evitar así, altos consumos de energía o una baja en la eficiencia de la máquina. En el ambiente industrial, al estar bajo condiciones de alta temperatura y humedad, en combinación con otros factores como mala lubricación o sellos ineficaces, los rodamientos comienzan a presentar corrosión, el cual es uno de los principales fallos en los rodamientos. De igual manera, se sabe que este tipo de fallos pueden provocar fricción entre los elementos, calor e incremento de energía, lo que provoca que la eficiencia se vea reducida considerablemente como lo estudió García et al. (2018).

En este trabajo, se aborda la discriminación de tres condiciones específicas en rodamientos metálicos de bolas en motores de inducción: estado sano, corrosión nivel 1 y corrosión nivel 2. Para lograrlo se usó una sustancia corrosiva, que permite simular el proceso del deterioro que sufriría un rodamiento bajo los efectos de la corrosión. De igual manera se realiza un análisis de la literatura con el propósito de entender cuál es el estado del arte y saber qué estudios se han abordado sobre la detección de fallos en rodamientos de motores de inducción, para posteriormente proponer estrategias que permitan mejorar las metodologías existentes en el diagnóstico de fallos. La metodología propuesta se basa en el análisis y procesamiento de señales en el tiempo, para este caso particular, de corriente eléctricas, flujo

magnético de dispersión y de vibraciones, mediante el uso de indicadores estadísticos para realizar un análisis dinámico de las señales. Posteriormente, se utiliza el algoritmo de Análisis Discriminante Lineal para reducir la dimensionalidad de los datos, lo que facilita su interpretación y optimiza el procesamiento. Finalmente se implementa un algoritmo de aprendizaje por conjuntos, utilizando las máquinas de soporte vectorial como modelo base para realizar el entrenamiento y con el objetivo de incrementar y mejorar la precisión en la detección de daño por corrosión por humedad que se presenta en los rodamientos de motores de inducción como una de las fallas principales, como se menciona anteriormente. Con la ayuda de este enfoque, el cual es capaz de combinar técnicas de análisis de señales, reducción de dimensionalidad y aprendizaje automático, se busca avanzar en la detección de fallos y poder proporcionar una herramienta que se pueda aplicar en entornos industriales y que sea robusta.

1.1 ANTECEDENTES

Con el paso de los años los métodos de detección de fallos han ido evolucionando, desde el uso de los métodos tradicionales como el análisis de la firma de corriente o parámetros del comportamiento dinámico de la señal como el valor cuadrático medio (RMS del inglés *Root Mean Square*) y demás, hasta métodos y algoritmos inteligentes basados en el aprendizaje de máquinas como redes neuronales artificiales (ANN del inglés *Artificial Neural Network*), etc. Entonces, Yadav et al. (2022) realizaron un recuento de diversos materiales de rodamientos para analizar sus efectos, además de una comparativa entre las distintas técnicas de detección de fallos que existen. Entre las técnicas que se destacan y que obtuvieron correctos resultados se tienen las que utilizan emisiones acústicas, medición de vibraciones, mediciones térmicas, análisis de residuos de desgaste y técnicas de aprendizaje automático e inteligencia artificial, destacando que estas últimas permiten un resultado más preciso como lo describen Nakamura et al. (2022). Además, las técnicas convencionales para detección de fallos presentan algunos problemas, como lo es la subjetividad y la incapacidad para manejar grandes volúmenes de datos, por lo que las técnicas de aprendizaje de máquinas e inteligencia artificial revolucionaron el ámbito de la detección de fallos ya que son capaces de analizar datos complejos y resultan más efectivas como se menciona anteriormente. Sin embargo, ante el avance de nuevas tecnologías, resulta útil encontrar algoritmos inteligentes capaces de optimizar, mejorar o incrementar la capacidad que presentan métodos convencionales. Kumar et al. (2021) reportó que los algoritmos de aprendizaje de máquinas e inteligencia artificial más recurrentes y que a su vez, entregan excelentes resultados son las redes neuronales, máquinas de soporte vectorial (SVM del

inglés *Support Vector Machine*), árboles de decisión, etc. En este contexto, Esakimuthu et al. (2019) estudiaron una comparativa entre los algoritmos de aprendizaje automático y las redes neuronales artificiales pertenecientes a la inteligencia artificial en la detección de fallos en los rodamientos por agujero y rayado de motores de inducción, y, con la ayuda de este trabajó se logró comprender la diferencia entre el enfoque de diagnóstico y su efectividad para detectar fallos en los rodamientos, comparando la precisión entre los enfoques de SVM, clasificador Bayesiano, K-vecinos más cercanos (KNN del inglés *K-Nearest Neighbor*), Árbol de decisión y bosque aleatorio. Utilizan como señal de entrada la corriente de carga, a la cual le aplican la transformada de Fourier y concluyen que las máquinas de soporte vectorial y KNN son los algoritmos de aprendizaje de máquinas con mayores tasas de precisión. Por otro lado, el uso de las redes neuronales en el caso de los algoritmos de inteligencia artificial, entregaron resultados aceptables y prometedores. Desde esta perspectiva, se destacan los clasificadores SVM y ANN como dos de los métodos más eficientes en el ámbito de la detección de fallos.

Dentro de los trabajos que se han revisado en literatura, se puede encontrar que se centran en el uso de un solo clasificador en la detección de fallos en los rodamientos de los motores de inducción; tal es el caso de Tao et al. (2016) quienes buscaron detectar fallos en rodamientos ante condiciones de pista interna y pista externa dañada, además de fallo de bolas y el rodamiento sano. Utilizaron una red de creencia profunda (DBN del inglés *Deep Belief Network*) como clasificador y usando señales multi vibración lograron una identificación de cerca del 96%. Safizadeh y Latifi (2014) utilizaron la fusión de dos sensores, un acelerómetro y una celda de carga y se basaron en una metodología que consta de 6 pasos clave; obtuvieron los datos, obtuvieron algunos parámetros en el dominio del tiempo y la frecuencia, utilizan el Análisis de Componentes Principales (PCA del inglés *Principal Component Analysis*) para reducir dimensionalidad, se extraen las características principales y se usa un algoritmo clasificador basado en el K-vecino más cercano en función de la señal de vibraciones y de carga y obtuvieron buenos resultados para discriminar el rodamiento sano de los fallos por erosión por chispa, fallo de bolas y fallo en pista exterior. Lin (2021) propuso una máquina de soporte vectorial gaussiano medio aplicada a la señal de vibraciones para la detección y clasificación de fallos en los motores de inducción con 4 condiciones en el rodamiento, fallo en pista interna y externa, fallo de bolas y sano. Concluyó que se obtuvo un excelente resultado, mejorando la confiabilidad y precisión de la estimación, detección e identificación de los fallos ante otras técnicas similares. Dados los trabajos mencionados anteriormente, se distinguen áreas de oportunidad como la utilización de otro tipo de clasificadores para investigaciones futuras.

Algunos trabajos analizan múltiples algoritmos de aprendizaje de máquinas en la detección de fallos en rodamientos de los motores de inducción, comparan y finalmente reportan el algoritmo que mejores eficiencias brinda. Por ejemplo, Aldeoes et al. (2021) en su trabajo analizaron las vibraciones provocadas por fallos en rodamientos de motores de inducción ante 3 condiciones; condición saludable, fallo en pista interior, fallo en pista exterior y falla de bola descubierta. Compararon distintos métodos de clasificación basados en algoritmos de aprendizaje automático obteniendo un 100% de precisión en el caso de las máquinas de soporte vectorial para la detección de falla de bolas, donde, KNN obtuvo excelentes resultados y rendimiento en la predicción de las tres fallas de rodamientos. También, Mehta et al. (2021) analizaron 3 condiciones en los rodamientos de motores de inducción, fallo en pista interna, fallo en pista externa y finalmente la condición de rodamiento sano. Tomaron imágenes con termografía infrarroja, aplicando posteriormente la transformada Wavelet discreta bidimensional para su descomposición y posteriormente aplicando el Análisis de Componentes Principales para reducir la dimensionalidad y obtener las características más importantes. Aplicaron métodos de aprendizaje de máquina para obtener una clasificación; los algoritmos utilizados fueron máquina de soporte vectorial, el K-vecino más cercano y el análisis discriminante lineal (LDA del inglés *Linear Discriminant Analysis*). Concluyeron que la máquina de soporte vectorial tiende a ser el método más efectivo por encima del LDA y KNN. Kankar et al. (2012) analizaron la señal de vibraciones en rodamientos de motores de inducción ante las condiciones de combinaciones de falla como rotor sano y agrietado apoyados sobre rodamientos con defectos; estos fueron grieta en la pista exterior, pista interior con desconchados y picaduras de corrosión en las bolas. Utilizaron dos métodos de clasificación de fallos basados en algoritmos de aprendizaje de máquinas; por un lado, se usa una red neuronal artificial, además de una máquina de soporte vectorial. Finalmente, obtuvieron excelentes resultados de clasificación para ambos métodos, sin embargo, las redes neuronales artificiales presentaron una mejor clasificación en porcentaje que la máquina de soporte vectorial. De igual manera, Samanta et al. (2003) compararon 2 métodos de clasificación basados en algoritmos de aprendizaje automático e inteligencia artificial, tal es el caso de las redes neuronales artificiales y las máquinas de soporte vectorial. Todo esto lo lograron midiendo la señal de vibración ante fallo en pista exterior y condición normal de rodamientos en los motores de inducción. Los datos de entrada de los clasificadores, como es el caso del número de nodos en la capa oculta en el caso de la red neuronal artificial y el parámetro del núcleo de la función de base radial o mejor conocido como ancho en la máquina de soporte vectorial, son obtenidos mediante el uso de un algoritmo genético para optimizar y obtener los mejores parámetros. Finalmente, concluyeron que el uso y rendimiento de las máquinas de soporte

vectorial obtuvieron mejores resultados que las redes neuronales, aunque ambos obtuvieron resultados aceptables. Kankar et al. (2011) analizaron condiciones en rodamientos de motores de inducción tanto de grietas en la pista exterior, pista interior con superficie rugosa y picadura de corrosión en las bolas mediante el uso de la señal de vibraciones. Utilizaron métodos estadísticos para extraer características principales y posteriormente reducir dimensionalidad. Luego, hicieron una clasificación para obtener una comparativa entre dos métodos distintos; las redes neuronales artificiales y las máquinas de soporte vectorial. Finalmente, concluyeron que ambos métodos son efectivos en el diagnóstico de fallos en los rodamientos y que las vibraciones severas ocurren en gran medida por los rodamientos que presentaba picadura de corrosión en las bolas y la pista interior rugosa. Bhavsar et al. (2022) analizaron la degradación normal y rápida de la señal de vibraciones en rodamientos de máquinas rotatorias usando en primera escala la transformada Wavelet discreta para clasificar una Wavelet base, y, posteriormente se usan dos clasificadores distintos; árbol de ensamble en bolas y regresión del proceso gaussiano, y, ambos mostraron una correcta clasificación y bastante precisa. De los trabajos antes abordados se destacan áreas clave para futuras investigaciones, por ejemplo, el uso de métodos de ensamblaje de modelos de aprendizaje de máquinas con el fin de hacer un análisis más preciso, maximizando la precisión de estos modelos.

Con los antecedentes antes abordados se pueden observar las técnicas utilizadas en la detección de fallo en los rodamientos de los motores de inducción, las cuales se basan en algoritmos de aprendizaje de máquinas y el uso de la señal de vibraciones. Por otro lado, existen otro tipo de metodologías utilizadas y que se basan principalmente en la obtención de indicadores estadísticos y no estadísticos; este tipo de técnicas pueden entregar buenos resultados como un método alternativo. También se reporta el uso de transformadas como la transformada Wavelet y otras técnicas en el dominio de la frecuencia y tiempo-frecuencia. Este tipo de técnicas en que se analizan frecuencias específicas generalmente obtiene buenos resultados para fallos que tienen un patrón repetitivo, sin embargo, para otro tipo de problemas que no siguen un patrón cíclico será complicado realizar la detección. Por ejemplo, Li y Yan (2013) analizaron por medio de múltiples sensores el estado de rodamientos de motores de inducción ante parámetros de análisis de aceite, desechos microscópicos y vibraciones; después, utilizaron la transformada Wavelet y la descomposición de modo empírico para obtener características distintivas de los fallos por medio de la vibración. Por su parte, Saha et al. (2022) realizaron un análisis de vibraciones en los rodamientos de un motor de inducción y posteriormente aplicaron una transformada rápida de Fourier para encontrar características que sean capaces de mostrar y detectar rodamientos defectuosos; dentro de los fallos analizados o condiciones previstas se encuentran fallo en pista interna, externa, en la jaula y la condición

de rodamiento sano (fallas puntuales en las pistas). Sharma et al. (2016) detectaron 4 condiciones, fallo en pista exterior e interior, fallo de bolas y condición sana en rodamientos de motores de inducción mediante el uso de características estadísticas como asimetría, curtosis, desviación estándar y medidas de incertidumbre como la entropía de Shannon, la entropía de energía logarítmica, la entropía segura y otros parámetros. Concluyeron que tanto las características estadísticas y las medidas de incertidumbre son buenos indicadores para detectar la variación de la gravedad de los fallos. De igual manera, Castellino et al. (2007) analizaron los fallos más comunes en los rodamientos y realizan un estudio para realizar un mantenimiento predictivo mediante la obtención de la corriente del estator de los motores de inducción y lograron discriminar las condiciones de rodamiento sano, orificio a 2, 4 y 6 mm y desgaste. Finalmente, determinaron que el método aplicado obtuvo resultados positivos, sin embargo, aquellos fallos que son relativamente pequeños pueden presentar errores debido al ruido que puede ingresar al sistema. Yani et al. (2018) detectaron por medio del análisis de grabaciones de sonido de las vibraciones el fallo por rodamiento liso. Yoshioka y Shimizu (2009) por su parte, analizaron por medio de su metodología basada en un sensor compuesto, procesador de señales y software de procesamiento las señales de vibración y de emisión acústica para detectar el proceso de fatiga por contacto rodante de un rodamiento de bolas, el cual fue lubricado con grasa; dicho esto, el sistema fue capaz de generar información de la señal de vibración como, RMS, la media, variación, asimetría y curtosis. Se concluye que el valor cuadrático medio fue el más efectivo en la detección del proceso.

Dentro de la literatura revisada se encontró que el principal problema que se da en la industria es atribuido a los rodamientos, y, a su vez, la corrosión es uno de los fallos más comunes en estos elementos. Este tipo de problemas se presenta debido a sellos ineficaces y a los ambientes en que operan los motores de inducción como condiciones altas de temperatura y humedad. Como se mencionó anteriormente, los métodos de detección de fallos por corrosión en rodamientos han utilizado técnicas en frecuencia, sin embargo, generalmente el rodamiento se corroen en distintas zonas, por lo que el uso de transformadas en frecuencia no sería una correcta alternativa para la detección y evaluación de este fallo en específico. Dada la complejidad de análisis de este tipo de fallos, se encontró que existen pocos trabajos enfocados en la detección de la corrosión en los rodamientos de motores de inducción; además de que algunos de los artículos que analizan este fallo en rodamientos se centran en otro tipo de máquinas giratorias como turbinas. Esta literatura encontrada analiza principalmente técnicas tradicionales o algún algoritmo inteligente, sin embargo, se podría mejorar el diagnóstico y la eficacia aplicando otros métodos de aprendizaje automático que sean capaces de mejorar el rendimiento. Sharman et al. (2015) realizaron un

análisis en los rodamientos de los motores de inducción añadiendo el fallo por corrosión. Aplicaron la transformada Wavelet discreta para extraer características y posteriormente un análisis discriminativo de vecindad difusa ortogonal para reducción de dimensionalidad, y, estos valores se ingresan a una red neuronal dinámica para la clasificación de las severidades de fallo en los rodamientos y el estado sano; con los resultados, concluyeron que su método es exacto y efectivo en la clasificación. Chen et al. (2019) por su parte, realizaron un análisis de corrosión en rodamientos de turbinas eólicas (por su alto nivel de corrosión eléctrica) usando la señal de modulación biespectro y concluyeron que es posible realizar la detección con esta metodología mediante la identificación de la componente espectral de la frecuencia característica, además de que puede ser útil en aplicaciones industriales. Zamudio et al. (2022) realizaron un análisis de gradualidades de corrosión en rodamientos de motores de inducción haciendo un análisis de corriente y flujo parásito, aplicando una serie de indicadores estadísticos y concluyeron que es posible realizar no solo la detección, sino discriminarla frente a otro tipo de fallos. Por su parte, Sathujoda (2021) de igual manera realizaron un análisis de vibraciones en un sistema de rotor funcionalmente graduado para detectar la corrosión en los rodamientos. El método utilizado se basa en el análisis modal transformado por ondas y una variación espacial de una transformada Wavelet para identificar y localizar el fallo. Navarro et al. (2023) presentaron una metodología para determinar fallos por corrosión en motores síncronos de reluctancia usando indicadores estadísticos obtenidos de parámetros de tiempo-frecuencia. Concluyen finalmente que su método fue capaz de detectar el fallo, además de que se puede determinar la gravedad de este. Zhang et al. (2015) lograron detectar fallo por corrosión tanto en bolas del rodamiento como en las pistas de rodadura; analizaron 224 registros en el dominio del tiempo y utilizaron máquinas de soporte vectorial con PCA para reducir la dimensionalidad y mejorar el diagnóstico. Finalmente concluyeron que los resultados lograron una buena exactitud que logra ascender al 92% al combinar los efectos de ambos algoritmos (reductor de dimensionalidad y clasificador). Por su parte, Zhang et al. (2020) realizaron un análisis de corrosión por picadura simple en rodamientos de máquinas giratorias y realizaron una metodología basada en transformadas Wavelet para eliminar el ruido de la señal, posteriormente usa la descomposición en modo empírico para extracción de características y se propone una red neuronal artificial para la clasificación de la corrosión logrando una precisión y eficiencia alta. Finalmente, resulta bastante importante realizar el análisis de fallos por corrosión debido a su gran relevancia y recurrencia en los procesos de producción de los motores de inducción.

Cabe resaltar que dentro de la literatura no se encontró algún algoritmo de optimización o de selección de los mejores parámetros en la detección de fallos por corrosión ante el comportamiento

dinámico de la señal en el tiempo (vibraciones, flujo magnético de dispersión, corriente, etc.). Entonces, este tipo de algoritmos que utilizan parámetros estadísticos y no estadísticos o aquellos que analizan el comportamiento dinámico de las señales son buenos indicadores de fallos, sin embargo, existen otros algoritmos más robustos como los métodos de aprendizaje de máquinas, los cuales son capaces de discriminar fallos de manera eficiente y con grandes volúmenes de datos si se combinan sus efectos. En la literatura revisada, se observa que la mayoría de los estudios abordan este tipo de fallo de manera puntual, como es el caso de la corrosión por picaduras. Además, los métodos empleados en la mayoría de los trabajos se centran en el análisis en el dominio de la frecuencia o tiempo-frecuencia, lo cual es adecuado para fallos puntuales donde se puede asociar una frecuencia específica al defecto. Sin embargo, pocos estudios exploran el uso de algoritmos de ensamblaje en aprendizaje automático para mejorar la precisión de la detección. La mayoría de los enfoques utilizan un único método o combinan varios, pero de manera separada, sin buscar optimizar las técnicas existentes a través de enfoques como el Bagging. Este trabajo, por lo tanto, se destaca al aplicar modelos de ensamblaje de aprendizaje automático, lo que permite una mejora en la precisión de la detección de corrosión en motores de inducción, este fallo es muy frecuente, pero poco estudiado, lo cual, a su vez, contribuirá a mantener la eficiencia operativa de los motores y evitar costos adicionales debido a fallos no detectados a tiempo.

1.2 DESCRIPCIÓN DEL PROBLEMA

Con la literatura revisada, se logra encontrar una serie de problemáticas que deben ser atacadas por su importancia, éstas se encuentran relacionadas con la generación de energía eléctrica por medio de contaminantes, la necesidad de optimizar y mejorar los métodos de detección de fallos por medio de algoritmos de aprendizaje automático, la combinación de métodos que ya han sido probados mediante algoritmos inteligentes y finalmente, contribuir en el desarrollo de nuevos métodos para uno de los principales fallos que se da en los motores de inducción, como lo es el fallo en rodamientos por corrosión. Por un lado, la corrosión en los rodamientos de los motores de inducción ha sido muy poco investigado debido a su complejidad para detectarlo con los métodos existentes. Dentro de la literatura y de los pocos trabajos reportados, se encuentra que se analiza la corrosión, pero en otro tipo de máquinas giratorias como turbinas, además de que algunos otros analizan picaduras de corrosión en ciertas zonas, sin embargo, en un ambiente industrial, los rodamientos se encuentran expuestos a niveles altos de humedad y temperatura, lo que hace que los rodamientos comiencen a corroerse de distintas áreas sin seguir necesariamente algún

patrón. Por esta razón, resulta ser difícil analizar parámetros en frecuencia como la transformada rápida de Fourier y se opta por utilizar algoritmos en el tiempo. A partir de la literatura técnica consultada, se puede encontrar que los motores de inducción son las máquinas eléctricas que más consumen energía a nivel mundial. Además, es bien sabido que los motores de inducción al presentar fallos comienzan a consumir mayor cantidad de energía eléctrica, y, por lo tanto, comienzan a reducir su eficiencia e incluso su tiempo de vida, por lo que detectar sus fallos y programar mantenimientos es una técnica importante en el ámbito de reducción de energía y al evitar costos extras en el consumo de energía eléctrica.

En los últimos años se resalta el gran valor que los algoritmos inteligentes basados en aprendizaje de máquinas e inteligencia artificial han ganado por su gran impacto debido a su alta eficiencia para discriminar ciertos fallos. Se logra observar que, los autores de investigaciones consiguen la detección de fallos en los rodamientos de los motores de inducción, sin embargo, se analizan los efectos de dichos algoritmos clasificadores por separado y finalmente escogen el mejor. Por ello, se ha reportado que existen otras metodologías poco o nada exploradas que son capaces de incrementar la eficiencia y precisión de detección y discriminación de los fallos. Antes de que se comenzarán a usar las técnicas modernas de discriminación de los fallos en los motores de inducción, se han utilizado metodologías convencionales como el análisis del comportamiento dinámico de señales en el tiempo como vibraciones, corriente, voltaje, flujo magnético de dispersión, etc., y que han sido de gran importancia por su gran eficiencia en la detección de ciertos fallos, pero limitación en otro tipo, por ejemplo, el hecho de que la corrosión no se presenta de una manera cíclica.

Por otra parte, se logra observar que en la previsión hacia el 2030 revisada anteriormente, el uso de combustibles fósiles para la generación de energía va a incrementar, y, por lo tanto, será necesario realizar un esfuerzo para lograr mantener la eficiencia de los equipos, ya que tan solo el incremento o decremento del 1% de la eficiencia de las máquinas eléctricas puede significar una cantidad muy considerable de petróleo. De hecho, diarios a nivel nacional como Expansión por medio de Nava y Pardo (2023) mencionan lejana la posibilidad de que México reduzca el uso de combustibles fósiles, y, por el contrario, se muestra un incremento en el consumo de estos para la generación de energía eléctrica.

1.3 JUSTIFICACIÓN

Impacto tecnológico-económico

La detección de los fallos en rodamientos de motores de inducción es un tema bastante amplio y muy estudiado debido a que es el principal fallo que se presenta en estas máquinas. Se sabe que los motores eléctricos regularmente están expuestos a amplias temperaturas y a una alta humedad por las condiciones del entorno industrial, por ello, se ha demostrado que la corrosión en los rodamientos es un fallo muy común y a pesar de ello, ha sido muy poco explorado y se han utilizado métodos tradicionales que pueden presentar problemas en la detección. Entonces, con el desarrollo de este trabajo, se logra desarrollar una metodología para discriminar diversos niveles de corrosión en un rodamiento perteneciente a un motor de inducción. Es bien sabido que los motores de inducción presentan aumentos en el consumo de corriente, lo que se traduce a aumentos en el coste de electricidad, por ello, es importante analizar y detectar problemas en estas máquinas para posteriormente generar mantenimientos constantes.

Impacto científico

El presente trabajo presenta un aporte en el ámbito científico debido a la necesidad de optimizar y hacer más eficientes los métodos de detección de fallos, por lo tanto, se va a estudiar el uso del clasificador Bagging (del inglés *Bootstrap Aggregation*) el cual es un algoritmo capaz de mejorar la clasificación de los métodos de aprendizaje de máquinas como la máquina de soporte vectorial y finalmente desplegar resultados más robustos y confiables. Por ello, se logran obtener las señales de flujo magnético de dispersión, corriente y vibraciones para posteriormente usar un algoritmo de reducción de dimensionalidad como el análisis discriminante lineal. Luego, se hace uso de una máquina de soporte vectorial como modelo base para que el método Bagging, finalmente, brinde una clasificación más precisa. Por otro lado, el análisis de la dinámica del sistema tanto de vibración como de flujo magnético de dispersión son métodos muy utilizados y que muestran resultados confiables, por ello, se hace uso de indicadores estadísticos y no estadísticos y se utiliza un algoritmo genético para encontrar el mejor parámetro que sea capaz de discriminar y detectar la corrosión en los rodamientos. Por ello, combinar este tipo de metodologías con el uso de algoritmos inteligentes puede tomar gran importancia y mejorar de manera sustancial la precisión de los algoritmos de detección debido a que dentro de la literatura no se ha reportado el uso de algoritmos inteligentes en combinación con estadísticos y no estadísticos para la detección de fallos por corrosión en rodamientos de motores de inducción.

Impacto social-ambiental

El desarrollo de este trabajo se encuentra vinculado directamente con los Programas Nacionales Estratégicos (PRONACES) establecidos por la Secretaría de Ciencia, Humanidades, Tecnología e Innovación (SECIHTI) en la sección “ENERGÍA Y CAMBIO CLIMÁTICO”. Este impacto social se atribuye al desarrollar un sistema de detección del fallo de corrosión en motores de inducción a sabiendas de que estos motores son los más comunes en la industria y que su consumo total de energía es muy elevado, ocupando un amplio porcentaje de la energía mundial consumida. El desarrollo de este trabajo permite a los encargados de los motores eléctricos, el poder detectar corrosión en los rodamientos para programar mantenimientos que permitan que la eficiencia se mantenga, y, por lo tanto, no representen un consumo de energía mayor al que realmente necesitan. Acorde a los antecedentes revisados, un solo punto porcentual en la eficiencia de los motores puede significar el uso de millones de litros de elementos contaminantes como el petróleo, de allí la necesidad de mantener la eficiencia de los equipos.

1.4 HIPÓTESIS

Mediante la fusión de señales de corriente, flujo magnético de dispersión y vibraciones de un motor de inducción empleando técnicas de reducción de dimensionalidad y ensamblaje de modelos de aprendizaje automático, será posible detectar 3 niveles de corrosión en rodamientos con una precisión mayor al 95%.

1.5 OBJETIVOS

1.5.1 Objetivo general

- Desarrollar una metodología para la detección de fallos por corrosión en rodamientos de motores de inducción mediante la fusión de datos de corriente, flujo magnético de dispersión y vibraciones empleando algoritmos de aprendizaje de máquinas y parámetros estadísticos y no estadísticos.

1.5.2 Objetivos específicos

- Inducir niveles de corrosión en rodamientos mediante la generación de muestras controladas para establecer una referencia en la clasificación de fallos.

- Implementar un sistema de adquisición de datos empleando sensores de corriente, flujo magnético y vibraciones para capturar el comportamiento dinámico de los rodamientos y generar una base de datos.
- Desarrollar un modelo de clasificación de fallos mediante algoritmos de ensamblaje de aprendizaje automático y reducción de dimensionalidad para mejorar la detección de corrosión.
- Optimizar la selección de características mediante algoritmos genéticos para diferenciar los niveles de corrosión en los rodamientos.
- Evaluar el método propuesto mediante un análisis comparativo para validar su efectividad en la detección de fallas.

CAPÍTULO 2 FUNDAMENTACIÓN TEÓRICA

A lo largo del presente documento se han presentado los antecedentes y las bases que existen en literatura, además de las problemáticas por las que surge la necesidad de realizar este estudio. Por ello, es necesario estudiar las bases teóricas que serán necesarias para comprender los fenómenos que se presentarán partiendo de la definición básica de los motores de inducción y sus partes, hasta los algoritmos que se utilizarán tanto de aprendizaje de máquinas como los estadísticos y no estadísticos.

2.1 MOTORES DE INDUCCIÓN

A nivel general, los motores eléctricos son máquinas que se encargan de convertir la potencia eléctrica en potencia de tipo mecánica rotativa y existen dos tipos, uno de ellos son los motores síncronos y por otro lado se encuentran los motores asíncronos. Los motores síncronos son aquellos en donde se aplica un voltaje directamente al estator de la máquina, y, posteriormente, se produce un flujo magnético en los devanados. Este flujo, a su vez, produce un campo magnético uniforme B_s como se muestra en la Figura 2a. Como se puede observar, se generan dos campos magnéticos; el campo del rotor tiende a alinearse con el campo magnético del estator, por lo tanto, se deduce que la característica principal de estos motores es que el rotor estará constantemente persiguiendo al campo magnético del estator, pero no podrá alcanzarlo. Por su parte, los motores de inducción son aquellas máquinas que, por medio de un voltaje introducido al rotor, generan un campo magnético y una corriente; dicho voltaje se induce en los devanados del rotor, sin tener que estar necesariamente conectados físicamente por medio de cables de corriente eléctrica. Estos motores tienen básicamente el mismo estator que una máquina síncrona, pero el rotor es diferente ya que puede ser de dos tipos: rotor jaula de ardilla o rotor devanado. Los rotores de tipo jaula de ardilla tal como muestra la Figura 2b tienen como principal característica que los conductores se encuentran dispuestos en barras dentro de ranuras en el rotor y estos se encuentran cortocircuitados en los extremos, se le llama jaula de ardilla debido a su similitud con las jaulas giratorias de estos roedores. El rotor devanado posee devanados que son muy parecidos a los devanados del estator y se encuentran en conexión estrella cortocircuitados por escobillas en los anillos rozantes para poder ajustar el par velocidad del motor mediante el uso de resistencias adicionales en el circuito del rotor. Sin embargo, por su simpleza y periodos de mantenimiento, los rotores jaula de ardilla son los más utilizados (Chapman, 2012).

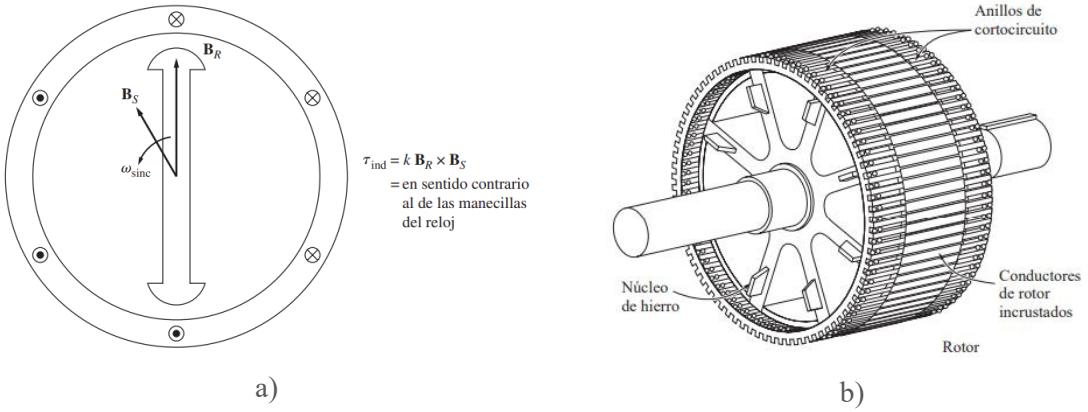
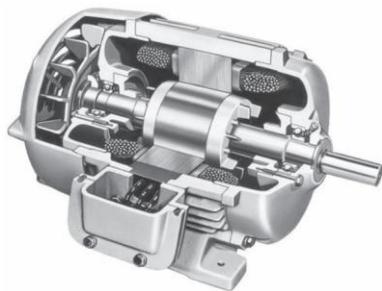


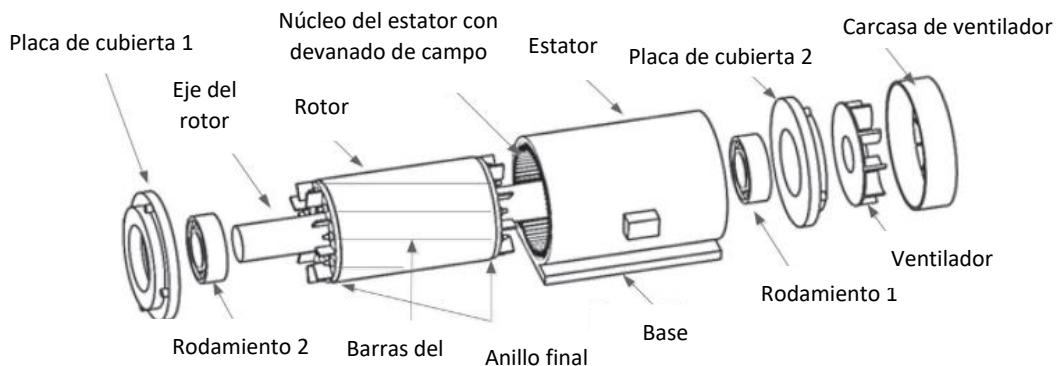
Figura 2 Características básicas de un motor tipo: a) síncrono, se muestra el campo magnético generado y b) inducción, se muestra un rotor de tipo jaula de ardilla (Chapman, 2012).

2.1.1 Partes de un motor de inducción

Los motores de inducción están constituidos por eje, ventilador, cubierta de ventilador, carcasa, rodamientos, estator, caja de terminales y rotor como se muestra en la Figura 3a. A nivel general, el eje es la parte que gira debido a los efectos físicos que ocurren internamente dentro del motor y este será la parte donde se conectan las diversas terminales para infinidad de aplicaciones. Por su parte, el ventilador se encarga de girar a la par del giro del eje para evitar sobrecalentamientos y con ello, la pérdida de la eficiencia del motor, la carcasa sirve como protector del ventilador y para proteger la parte interna, además de que también se encarga de una parte de la disipación del calor producido. La caja de terminales es aquella donde se conectan las líneas eléctricas; dichas líneas se conectan a las bobinas del estator y éstas generan un campo magnético giratorio sobre el rotor. El eje del motor se apoya sobre dos rodamientos (uno en la parte delantera y otro en la parte trasera) y con ello, se logra mantener en la posición correcta. Todos los elementos mencionados se pueden encontrar en la Figura 3b.



a)



b)

Figura 3 a) Representación gráfica de un motor de inducción de tipo jaula de ardilla (Chapman, 2012) y b) Partes internas de un motor de inducción (Gangsar y Tiwari, 2020).

2.2 PRINCIPALES FALLOS EN MOTORES DE INDUCCIÓN

Debido a los efectos que sufren los motores de inducción como aumentos en la tasa de facturación en el coste de la electricidad, los equipos comienzan a requerir mantenimientos y revisiones periódicas para evitar que ciertos fallos generen otros más graves. Aunque regularmente, los fallos ocurren de manera aleatoria e instantánea, por lo que el motor comienza a presentar un impacto en el par de operación aumentos en temperatura, pérdidas, vibraciones mecánicas, etc., lo que contribuye a una reducción en la eficiencia del motor. Bazurto et al. (2016) en su trabajo realizaron una revisión tanto de los orígenes, como clasificación y recuento de los fallos más comunes en los motores de inducción. Mencionan que los fallos pueden ser considerados y clasificados por la naturaleza de la falla (eléctrica y mecánica) además de la localización (rotor y estator). También definen fallo como aquella condición donde existe un cambio en

cualquier componente, lo que produce que la máquina no pueda operar con normalidad e impide su correcto funcionamiento. Es importante mencionar que se pueden representar los fallos en dos categorías, los dados por fuentes externas o los dados por fuentes internas. Por otro lado, los fallos siguen un patrón de progresión donde primero se da la insipiecia, posteriormente se da la fatiga del material y finalmente se presenta el fallo mismo. En dicho artículo se discuten las causas principales del porque se presentan los fallos y se concluye que es debido a 3 razones:

- Debilidad del material, diseño y fabricación.
- La aplicación de los esfuerzos se hace en dirección equivocada o mal uso.
- Un deterioro paulatino a causa del desgaste, fatiga por tensión o corrosión de los materiales.

En el mismo estudio, se realiza una clasificación de los fallos en rotor y estator como combinación de diversas fuerzas que actúan sobre estos componentes. Dentro de las fuerzas aplicadas en el estator, se encuentran el estrés térmico (causado por sobrecarga, los ciclos de trabajo y el deterioro), el estrés eléctrico (causado por transitorio, el efecto corona y aislamientos), estrés mecánico (causado por rozamientos mecánicos y desplazamientos de bobina) y estrés ambiental (provocado por humedad en gran medida, contaminación, abrasión y objetos extraños). En el rotor se aplican diversas fuerzas, como el estrés térmico, electromagnético, residual, dinámico, mecánico y ambiental. De igual manera, dentro de los fallos provocados por las fuentes internas del motor se encuentran dos clasificaciones; por un lado, los fallos mecánicos provocados por desplazamiento de láminas y bobinas, fallo en los rodamientos y excentricidad dinámica y estática. La otra clasificación es la eléctrica, donde principalmente se provoca por fallo en barras rotas del rotor, fallo en circuito magnético y por aislamiento. Los fallos provocados por fuentes externas del motor se clasifican en tres; las fallas mecánicas (provocadas por cargas oscilantes, sobrecarga e incorrecto montaje), las fallas eléctricas (provocadas por transitorios y fluctuaciones de voltaje, conexión e instalación deficiente y desbalance de voltaje) y del ambiente (provocadas por humedad, temperatura y contaminación). Finalmente, se hace una clasificación de los fallos en cuanto al porcentaje de recurrencia, donde determinan que el principal fallo con cerca del 50% de recurrencia es en los rodamientos. La distribución completa se muestra en la Figura 4.

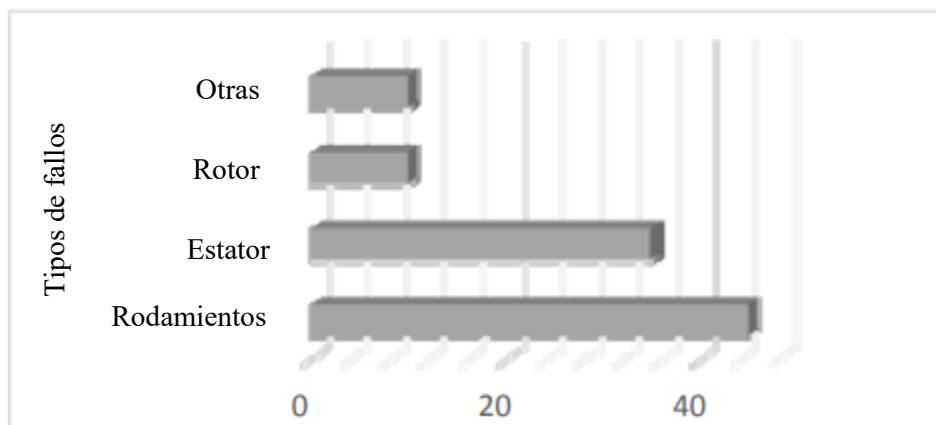


Figura 4 Porcentaje de ocurrencia de los fallos en motores de inducción (Bazurto et al., 2016).

2.3 FALLO POR CORROSIÓN EN MOTORES DE INDUCCIÓN

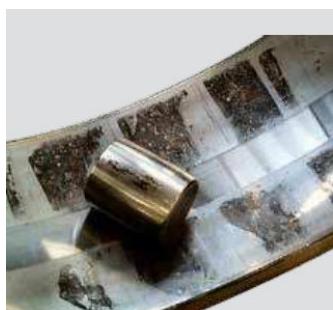
Los rodamientos se pueden definir como aquellos elementos capaces de transmitir las cargas y reducir fricción entre los componentes. Ahora bien, los motores de inducción se componen de tres partes principales, el rotor, estator y los rodamientos, además de otros elementos como se muestra en la Figura 3b, estas partes tienen a fallar debido al sobreuso, desgaste natural o bien, otro tipo de fallos pudo haber ocasionado más problemas; el más común es la falla en los rodamientos (Bazurto et al., 2016). Sus principales causas son la alta vibración del rotor a causa de un elevado par de salida, instalación inadecuada, deterioro de la lubricación, calor, fricción y contaminación. Además, el fallo en los rodamientos genera que el rotor sea de tipo excéntrico y esto a su vez, produce una atracción magnética desequilibrada y genera una carga adicional que actúa sobre los rodamientos; además, se sabe que este fallo es el principal causante de las vibraciones excesivas por el cambio en la rigidez del rodamiento. También, se puede generar otro tipo de problemas cuando hay fallos en los rodamientos, el más común es el fallo en las barras del rotor y una posible ruptura si no se corrige el problema (Gangsar y Tiwari, 2020).

SKF (2017) menciona en su manual sobre los fallos en los rodamientos una estimación sobre la importancia de detectar este tipo de problemas, y es que, se fabrican alrededor de 10000 millones de rodamientos anualmente en todo el mundo, de estos, un gran porcentaje tiende a fallar y se deben remplazar cerca de 50 millones de rodamientos a causa de los diversos problemas que tienden a tener. Dentro de los problemas más comunes por los que se cambian son debido a fatigas (1/3), problemas de lubricación (1/3), contaminación (1/6) y otro tipo de fallos como manipulación incorrecta, montaje mal realizado,

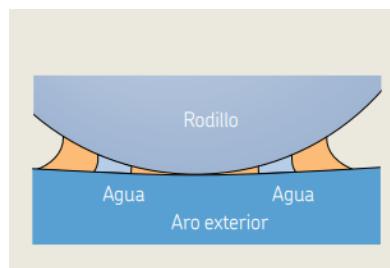
sobrecargas, etc. La corrosión, por su parte, puede ser provocada por una combinación de una o más de las fallas mencionadas, por lo que es una de las principales razones por las que se tienen que cambiar los rodamientos en los motores de inducción. Si uno de estos fallos no es detectado a tiempo, se puede producir un problema catastrófico, lo cual puede dañar otros componentes del motor y conducir a que sea bastante difícil determinar la causa raíz del problema.

2.3.1 Corrosión por humedad

Según el manual de SKF, la corrosión puede darse de dos formas, por humedad y por fricción. Dentro de las características que se destacan y que vienen a consecuencia de este tipo de fallos es la creación de oxidación y herrumbre debido a una reacción química, además de que también se pueden dar picaduras o escamado y decapado (esta es la mezcla de aceite o agua con los químicos). Entonces, es bastante común que, debido a sellos ineficaces, se ingrese humedad, agua o algún líquido agresivo con los rodamientos y provoque su corrosión, además de que se puede crear herrumbre si el líquido excede la lubricación del rodamiento y su capacidad de protección a las superficies de acero. De igual manera, es bastante importante destacar que tanto la oxidación, como la corrosión son dos procesos distintos, pero que van de la mano. La oxidación es una capa de protección de óxido que se impregna al acero del rodamiento que está expuesto al aire, si el agua o humedad entra en contacto con el acero, se produce la oxidación. La corrosión, según este manual, es bastante común y es la principal causa de fallo prematuro en rodamientos de motores de la industria alimenticia y de bebidas (dos de los sectores más demandados a nivel mundial) y viene de la mano de la oxidación, ya que a partir de ese proceso inicial se produce la corrosión, la cual es una pérdida en las propiedades de este. El decapado es la corrosión profunda a causa de que entran partículas de agua (Figura 5b), humedad o algún líquido agresivo como ácidos, entre el elemento rodante del rodamiento y el camino de rodadura como se muestra en la Figura 5c. La Figura 5a por su parte, muestra como se ve la corrosión en el aro exterior.



a)



b)



c)

Figura 5 Algunos casos de corrosión provocadas por: a) corrosión en aro exterior y rodillo de rodamiento, b) agua entra en contacto con lubricante y se acumula en parte inferior, c) decapado inicial en elementos rodantes y caminos de rodadura (SKF, 2017).

2.3.2 Corrosión por fricción provocada por contacto

Según lo que menciona el manual de SKF abordado anteriormente, menciona que la corrosión por contacto se da cuando hay un movimiento entre el aro de rodamiento y su asiento en un eje o soporte debido a irregularidades en su forma como se muestra en la Figura 6. Este movimiento tiende a desprender partículas pequeñas de material, dichas partículas presentan una rápida oxidación al estar expuestas al aire, formando óxido de hierro. Este proceso puede ser el causante de alteraciones en la distribución de carga del rodamiento y culminar con fracturas. Las áreas que presentan corrosión son puntos donde se concentran esfuerzos y se presentan como zonas de herrumbre en superficie exterior. La corrosión puede presentarse de manera rojiza (por hematita) o tonalidades negras (por magnetita).



a)



b)

Figura 6 Corrosión por contacto provocada por: a) asiento de eje inadecuado y b) carga pesada (SKF, 2017).

2.3.3 Corrosión por fricción debida a la vibro corrosión

La vibro corrosión ocurre en el área de contacto debido a micro movimientos y/o la elasticidad del contacto bajo vibraciones repetitivas. La combinación de corrosión y desgaste se forma en el camino de rodadura, dependiendo de la intensidad de las vibraciones, la lubricación y la carga. Las depresiones en el camino de rodadura varían según el tipo de rodamiento. En aplicaciones con grasa, la vibro corrosión tiende a mostrar un tono rojizo-marrón, mientras que, en aquellas con aceite, las depresiones son muy reflectantes. La herrumbre se nota a menudo en la parte inferior de las depresiones debido a la oxidación

de las partículas sueltas. La gravedad del daño está influenciada por el nivel y la frecuencia de la vibración, así como por la duración de la inactividad. Ejemplo de la vibro corrosión se muestra en la Figura 7.



Figura 7 Vibro corrosión severa en camino de rodadura en un rodamiento de bolas (SKF, 2017).

Ante todos estos tipos de fallos, se presenta el fenómeno de las vibraciones debido al desgaste irregular y a que puede haber picaduras de corrosión en la superficie de contacto, por lo que se espera ver un gran efecto de la corrosión ante esta señal. Las vibraciones producidas pueden llevar a otro tipo de problemas, como un desgaste mayor y problemas en otros componentes mecánicos, recordando que las fallas incipientes pueden provocar fallos catastróficos. La señal de corriente puede verse afectada debida a la corrosión en los rodamientos, ya que, al haber picaduras u otras formas de fallo, y al aumentar las vibraciones, y fricción entre los elementos, la eficiencia del motor tiende a bajar debida al aumento de corriente eléctrica.

2.4 MÉTODOS DE DETECCIÓN DE FALLOS

A lo largo de la historia se han desarrollado diversos métodos de detección de fallos en motores de inducción, debido a su amplia gama de aplicaciones y a que son los motores más usados a nivel mundial. Por otro lado, estas máquinas deben tener mantenimientos constantes para evitar pérdidas o paros en el proceso de producción debido a algún fallo grave que pueda presentar a causa de algún problema menor. Gangsar y Tiwari (2020) mencionan en su artículo científico y reúnen diversas técnicas que se han desarrollado para detectar los fallos en los motores de inducción mediante la señal en el tiempo y espectros

de dos de las señales que tienden a tener mejores resultados como lo es la corriente y la vibración. Por lo tanto, este apartado sobre métodos de detección se centrará en dicha revisión y toda la información se obtendrá de dicho artículo. Se debate que existen dos métodos distintos, las técnicas convencionales, las cuales se centran en el análisis de la dinámica del sistema mediante parámetros estadísticos como el RMS, varianza, etc. De igual manera, se utilizan técnicas modernas, las cuales analizan transformadas en el tiempo-frecuencia como la descomposición de modo empírico, la transformada wavelet y otras. En los últimos años, se han comenzado a desarrollar metodologías basadas en el aprendizaje de máquinas e inteligencia artificial, las cuales son capaces de mejorar los resultados de la detección y tienen un alto nivel de precisión. Cuando fallan los motores de inducción comienzan a presentar diversos problemas como lo es el desequilibrio de brecha de aire, flujo, aumento par velocidad, disminución del par promedio, calentamientos excesivos, vibraciones mecánicas excesivas, disminución de la eficiencia y un aumento en las perdidas como la corriente, además de la desviación y asimetría de corrientes y voltajes. Por otro lado, dentro de los métodos de detección principales, se encuentran:

- Monitoreo de flujo magnético o flujo de fuga axial.
- Monitoreo de par de brecha de aire.
- Medición de ruido acústico.
- Monitoreo térmico.
- Potencia instantánea.
- Análisis químico.
- Monitoreo de vibraciones.
- Monitoreo de corriente.

El monitoreo del flujo magnético generalmente se usa para detectar fallos como el de barras rotas, excentricidad, giro a giro, etc. Por su parte, las vibraciones se utilizan para detectar fallas mecánicas como las barras rotas, rotores desequilibrados, desalineados, fallas en los rodamientos, etc. Sin embargo, también puede ser usado para encontrar fallos eléctricos. El método de las vibraciones es muy común y ha sido muy estudiado a lo largo de los años por su simpleza, ya que puede instalarse un sensor como lo es el acelerómetro en el motor y monitorear. Finalmente, el monitoreo de la corriente por medio del análisis de la firma de corriente de máquina es muy utilizado para detectar fallos eléctricos, aunque también puede detectar fallos mecánicos. Para realizar la obtención de la señal, se instalan sensores como sondas en los cables de alimentación, por lo que es no es un método invasivo con el motor. Finalmente, se menciona el

artículo que el monitoreo basado en el análisis de corriente, y vibraciones es el método preferido ya que son técnicas no invasivas, económicas y muy confiables, presentan una alta precisión, además de que son fáciles de obtener, son capaces de detectar y distinguir la mayoría de los fallos. Para detectar las señales se realiza generalmente el uso de tres técnicas distintas, las cuales se basan en el dominio del tiempo, el dominio de la frecuencia y el dominio del tiempo frecuencia.

2.4.1 Algoritmos basados en el dominio del tiempo y uso de indicadores estadísticos y no estadísticos

Cuando ocurren fallos en los elementos de los motores de inducción pueden provocar cambios en las señales tanto de vibración como corriente en el dominio del tiempo, por lo que las amplitudes de las señales pueden incrementarse de cierta manera específica dependiendo el tipo de falla. Entonces, estas señales pueden presentar otras características como demasiado ruido, lo que genera que a simple vista no puedan ser detectados problemas, optando por utilizar algunas metodologías de procesamiento de señales, con lo que ahora se podrá detectar y discriminar el fallo de manera segura y eficiente. Entonces para poder realizar el análisis y el diagnóstico de fallos en los motores de inducción, se hace uso de algunos indicadores estadísticos y no estadísticos que ayudan al modelo a conocer de mejor manera el comportamiento dinámico de las señales medidas en el tiempo. Dichos indicadores utilizados se clasifican en dos tipos, los indicadores estadísticos y los indicadores no estadísticos; cada uno de estos proporciona información para obtener un mejor panorama del estado del motor de inducción y ayuda a obtener patrones que generalmente se asocian a fallos, como se pudo observar en la literatura anteriormente.

Los indicadores estadísticos buscan describir el comportamiento de una señal en términos de valores promedio, dispersión o incluso de variabilidad, es decir, se basan en parámetros matemáticos que analizan los datos y como varían entre ellos y se basa principalmente en el análisis de la distribución de los datos, permitiendo detectar cambios en la tendencia o en la magnitud de las variaciones de una señal medida, por ejemplo en el tiempo, como las que se abordan en esta metodología, corriente, flujo magnético de dispersión y corriente; esto ayuda a determinar más fácilmente a determinar si un motor presenta un fallo. Este tipo de indicadores estadísticos son de gran utilidad para identificar patrones muy generales en las señales y para evaluar cuánto ha variado el comportamiento dinámico del sistema analizado, en este caso, el motor de inducción. Por ejemplo, un aumento en la varianza o en la curtosis puede significar la que el motor presenta una condición de fallo, como un desbalance, desalineamiento, barras rotas de rotor,

entre otras, o una irregularidades en el funcionamiento del motor, por ejemplo, una carga que presenta problemáticas o condiciones como cargas oscilantes.

Por otro lado, los indicadores no estadísticos, no se basan en la distribución de los datos, sino en la estructura interna de la señal, efectos un poco más físicos. Estos indicadores se obtienen mediante transformaciones matemáticas que permiten analizar propiedades físicas como la energía, la complejidad o la dinámica de las señales, un ejemplo puede ser cuando a una señal en el tiempo como la corriente, se le aplica la transformada de Fourier, y de la cual se obtiene un cambio, de analizar parámetros en el tiempo, se analizan parámetros en frecuencia. El propósito de este tipo de estadísticos es extraer características que no son evidentes mediante métodos estadísticos convencionales a simple vista, pero que reflejan directamente el comportamiento físico del sistema, usando el mismo ejemplo de la señal en frecuencia, por ejemplo, no es posible ver mediante la señal en el tiempo de la corriente fallas que son cíclicas, sin embargo, en frecuencia, es más fácil ver este tipo de fallos, ya que representan un incremento de magnitud en ciertas frecuencias características de fallo. El uso combinado tanto de indicadores estadísticos como de indicadores no estadísticos permite construir un mejor modelo, con la característica de ser más robusto para la detección de fallos y su combinación mejora la precisión de las metodologías de diagnóstico conocidas en literatura y lo cual permitiendo encontrar fallos tempranos y así, reducir el riesgo de daños más graves en el sistema, por ejemplo paros inesperados en el motor, lo cual significaría una pérdida económica importante.

Algunos de los indicadores estadísticos comunes pueden ser el valor RMS, asimetría, curtosis, desviación estándar, los momentos estadísticos superiores, entre otros; los cuales son utilizados en diversos artículos de investigación y metodologías para la detección de fallos en los motores de inducción. De todos estos parámetros estadísticos y en combinación con otros parámetros no estadísticos como lo son el factor de impulso, entropía de muestreo, análisis de la envolvente, dimensión fractal, entre otras, es posible encontrar los parámetros más eficientes y que logren discriminar la falla de la condición sana. Finalmente, estos parámetros pueden entrar a un sistema basado en aprendizaje de máquinas para aumentar la eficiencia.

A continuación, en la Tabla 1 se enlistan las ecuaciones de los parámetros estadísticos y no estadísticos más comunes, donde X_i es la señal en el dominio del tiempo, M es la media de la señal, N el número de puntos de los datos, σ es la desviación estándar en el caso de los parámetros estadísticos. Para los parámetros no estadísticos se tiene que $N(e)$ representa el número de "cajas" o "celdas" de tamaño e

necesarias para cubrir completamente un objeto fractal. Un objeto fractal es una estructura que muestra una complejidad similar a diferentes escalas, es decir, su patrón o forma se repite a medida que se observa a menor escala. Para calcular la dimensión fractal de este objeto, se cubre con un número de cajas de tamaños cada vez menores (reduciendo el valor de e), y se cuenta cuántas cajas son necesarias para cubrir toda la forma. Al estudiar cómo cambia $N(e)$ cuando el tamaño de las cajas se reduce, se puede obtener un valor que describe la "complejidad" del objeto fractal, conocido como su dimensión fractal. Esta dimensión es una medida de cuán irregular o detallado es el objeto en comparación con figuras geométricas clásicas como líneas o superficies planas. Es el número mínimo de cuadrados necesarios para cubrir la serie temporal con cuadrados de tamaño e . Por otro lado, $x(t)$ representa la señal en el tiempo.

Tabla 1 Parámetros estadísticos y no estadísticos, además de sus ecuaciones.

Nombre del parámetro	Característica	Ecuación	Número de ecuación
Desviación estándar	Estadístico	$\sigma = \sqrt{\frac{1}{N} * \sum_{i=1}^N (X_i - M)^2}$	(1)
Curtosis		$K = \frac{\sum(X_i - M)^4}{\sigma^4}$	(2)
Quinto momento		$FM = \frac{\sum(X_i - M)^5}{\sigma^6}$	(3)
Sexto momento		$SM = \frac{\sum(X_i - M)^6}{\sigma^6}$	(4)
Asimetría		$A = \frac{\frac{1}{n} \sum_{i=1}^n (X_i - M)^3}{\sigma^3}$	(5)
RMS		$RMS = \sqrt{\frac{1}{N} * \sum_{i=1}^N (x_i)^2}$	(6)
Energía de Teager-Kaiser	No estadístico	$\gamma[x(t)] = [x'(t)]^2 - x(t)x''(t)$	(7)
Entropía de muestreo		$ES = - \sum_{i=0}^N p(x_i) * \log_2(p(x_i))$	(8)

Dimensión fractal	$DF = \frac{\log(N(e))}{\log\left(\frac{1}{e}\right)}$	(9)
Exponente de Hurst	$H = 2 - DF$	(10)
Entropía aproximada	$EA = \sum_{i=1}^N p(x_i) * \log_2\left(\frac{1}{p(x_i)}\right)$	(11)
Análisis de la envolvente	$E(t) = x(t) $	(12)

2.4.2 Algoritmos basados en el dominio de la frecuencia

Cuando ocurren fallos, como alguna barra en el rotor rota, problema en una de las bolas del rodamiento, o en general, fallas que tienden a tener un comportamiento cíclico, se opta por analizar los algoritmos que se basan en el dominio de la frecuencia, ya que a ciertas frecuencias características comienzan a producirse los efectos no esperados como aumentos en amplitudes, etc. A nivel general y de manera ideal, un motor de inducción saludable, sin defectos ni fallos, presenta una simetría física, como un rotor equilibrado y otras características, por lo que idealmente no debería producir vibraciones, sin embargo, físicamente esto es imposible, por lo que se producen algunas vibraciones en frecuencias bajas debidas a los errores y asimetrías físicas de la construcción del motor. Entonces, diversos fallos producen problemas a ciertas componentes de frecuencia, por ejemplo, las barras rotas producen componentes de frecuencia adicional en las bandas laterales, las cuales se pueden calcular mediante la Ecuación 13, donde f_b son las bandas laterales de falla por barras rotas, k es una constante que puede tomar valores de 1, 2, 3, ..., n , s es el deslizamiento del motor y f_s la frecuencia de operación o suministro. Por su parte, los fallos en el devanado del estator que suelen ser debido a daños en el aislamiento y aparecen componentes de frecuencia adicionales, que pueden ser calculados gracias a la Ecuación 14 donde f_{st} son las frecuencias adicionales provocadas por la falla, f_s es la frecuencia de operación del motor, p es el número de pares de polos, k y n son dos constantes que pueden tomar valores de 1, 3, 5, ... y de 1, 2, ... respectivamente. Por otro lado, las fallas en los rodamientos son como se mencionó anteriormente, las más comunes en los motores de inducción, este tipo de fallas producen componentes de frecuencia dependiendo del tipo de problema presente. Por ejemplo, ante el rodamiento con fallo de bolas se presentan componentes de frecuencia adicionales y que se pueden calcular por medio de la Ecuación 15. La falla en la pista exterior

presenta componentes de frecuencia que se pueden calcular por medio de la ecuación 16. La falla en pista interior presenta componentes de frecuencia que se pueden calcular usando la ecuación 17. La ecuación 18 por su parte, presenta los componentes de frecuencia que surgen a causa del fallo en el conjunto. De las ecuaciones, se sabe que Z es el número de bolas o rodillos, d es el diámetro del elemento rodante y D el diámetro del círculo de paso del rodamiento, a denota el ángulo de contacto en radianes y fr la frecuencia de rotación. El fallo de excentricidad de espacio de aire se da cuando hay un espacio desigual entre el estator y el rotor, lo que causa una frecuencia característica en el espectro de corriente, la cual puede ser calculada mediante la ecuación 19, donde fs es la frecuencia de suministro, p el número de pares de polos, m puede tomar valores positivos enteros y s el deslizamiento. Con ayuda de la Figura 8 se puede determinar gráficamente lo que representan estas variables.

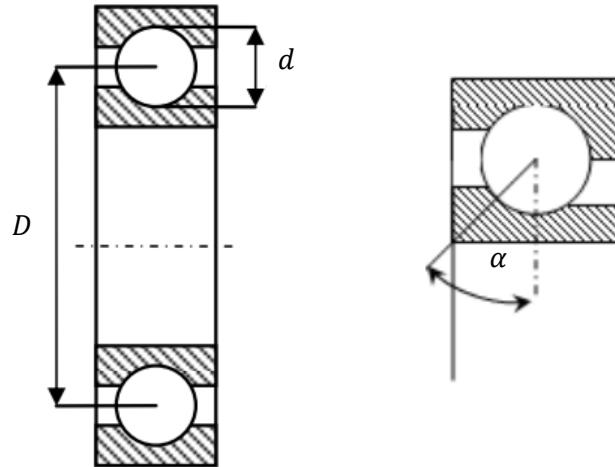


Figura 8 Representación gráfica de algunos parámetros de las ecuaciones de fallo características (Castellino et al., (2007)).

$$fb = (1 \pm 2 * k * s) * fs \quad (13)$$

$$f_{st} = \left\{ k \pm \frac{n(1-s)}{p} \right\} fs \quad (14)$$

$$fb = Z * \frac{fr}{d} \left(1 - \frac{d^2}{D^2} \cos(a) \right) \quad (15)$$

$$fo = Z * \frac{fr}{2} \left(1 - \frac{d}{D} \cos(a) \right) \quad (16)$$

$$fi = Z * \frac{fr}{2} \left(1 + \frac{d}{D} \cos(a) \right) \quad (17)$$

$$ft = \frac{fr^2}{2} \left(1 - \frac{d}{D} \cos(a) \right) \quad (18)$$

$$f_{ect} = \left\{ 1 \pm \frac{m(1-s)}{p} \right\} fs \quad (19)$$

2.4.3 Algoritmos basados en el uso de transformadas en el tiempo-frecuencia

Ahora bien, se sabe que el uso de las transformadas de Fourier y en general, las transformadas en frecuencia pueden tener ciertas limitaciones debido a que analizan exclusivamente señales estacionarias y puede generar que la detección de los fallos presente dificultad para discriminar las múltiples fallas, por ello se analizan las transformadas en el tiempo frecuencia como la transformada de Fourier en tiempo corto, transformadas Wavelet, de Hilbert-Huang, etc. Las cuales mejoran el rendimiento en la detección. Sin embargo, como se mencionó anteriormente, este tipo de análisis solo son posibles cuando la falla presente tiene una característica de ser cíclica; es por ello por lo que se prefiere el uso de parámetros en el tiempo y su mejora mediante obtención de estadísticos y no estadísticos para la detección de corrosión en rodamientos de motores de inducción, ya que no se presenta de manera cíclica o de manera puntual en una parte del rodamiento.

2.5 ALGORITMOS DE APRENDIZAJE AUTOMÁTICO

El uso de algoritmos de aprendizaje automático para la detección y discriminación de fallos representa una herramienta de gran valor, ya que puede contribuir a reducir los costos de mantenimiento y evitar operaciones innecesarias, como el reemplazo prematuro de un rodamiento en buen estado. Ahora bien, en la Figura 9 se presenta un diagrama que permite realizar la implementación de un algoritmo de aprendizaje automático.

El proceso comienza con la adquisición de los datos (pueden ser de corriente, flujo magnético de dispersión, vibraciones, de sonido), para, posteriormente, realizar la extracción de características, cuyo principal objetivo es reducir la dimensionalidad de los datos y resaltar las características más relevantes, ya que en ocasiones, al tener múltiples señales en el tiempo y aplicar los diferentes indicadores estadísticos y no estadísticos se comienzan a tener diversas dimensiones, sin embargo, es más sencillo analizar datos en solo 2 dimensiones o incluso 3, pudiendo incluso graficar los datos. Para lograr lo anterior, se pueden

emplear técnicas como el análisis discriminante lineal o métodos en el dominio del tiempo, dominio de la frecuencia o la combinación de ambos dominios, tiempo-frecuencia, como trabajan las transformadas Wavelet, entre otras. Para la detección de corrosión en rodamientos de los motores de inducción, es muy recomendado hacer uso de parámetros en el tiempo, junto con características estadísticas y no estadísticas, ya que como se mencionó anteriormente, este tipo de fallos no presenta un patrón repetitivo o cíclico, que pudiera generar frecuencias características de fallo. Luego, se lleva a cabo la selección de características principales., la cual se basa en identificarlas mediante algoritmos de optimización, como pueden ser los algoritmos heurísticos, por ejemplo, los algoritmos genéticos. Una vez seleccionadas las características principales, se procede a realizar el entrenamiento y validación del modelo, donde se usan algunos clasificadores como redes neuronales, máquinas de soporte vectorial o métodos de ensamblaje, como Bagging y Boosting, en general, métodos de inteligencia artificial y de aprendizaje automático. Los métodos basados en la combinación de métodos de aprendizaje automático, como el nombre lo indica, combinan diversos clasificadores para mejorar la robustez y la precisión final del modelo en cuanto a diagnóstico de fallos. Finalmente, el modelo se implementa realizando el diagnóstico de fallos en entornos reales, como los que se presentan en la industria y su desempeño debe ser evaluado continuamente, permitiendo en un futuro realizar mejoras para garantizar su eficacia en la identificación de fallos. Además, por medio de los algoritmos de optimización como los algoritmos genéticos se puede realizar un análisis más preciso con la selección de las mejores características (Gangsar y Tiwari, 2020).

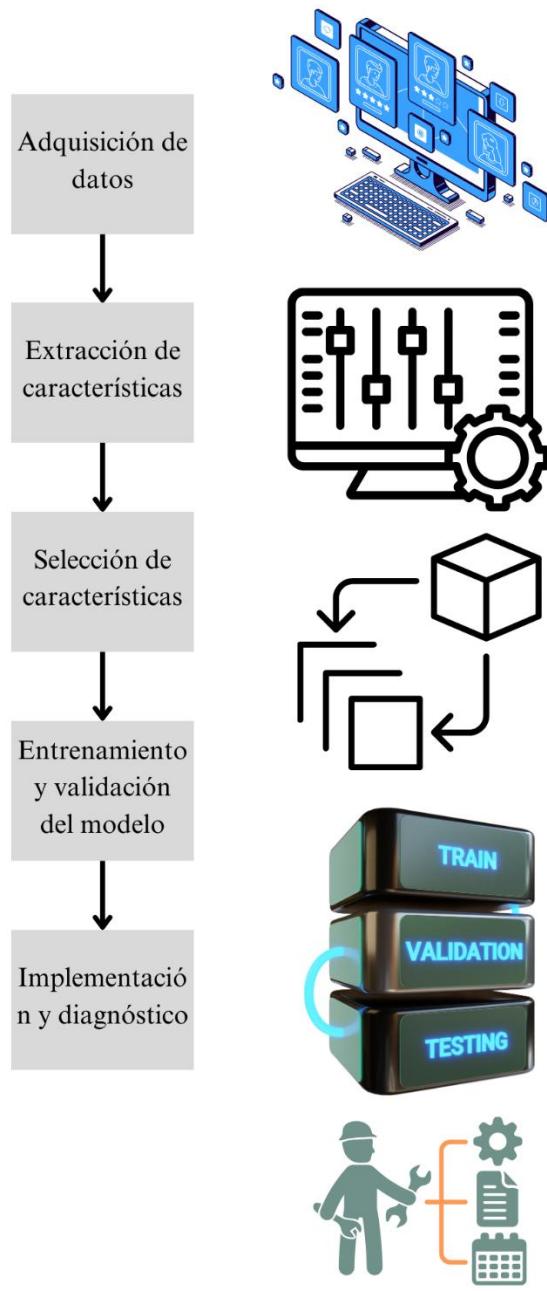


Figura 9 Diagrama de pasos para realizar un algoritmo de aprendizaje de máquinas (autoría propia).

2.5.1 Máquina de soporte vectorial

Las Máquinas Soporte Vectorial son herramientas de aprendizaje automático utilizadas para la clasificación y su objetivo principal es encontrar un hiperplano de separación en un espacio de características de alta dimensión que maximice el margen entre las clases y minimice el error de clasificación, tal y como se muestra en la Figura 10. Para lograrlo las SVM realizan un mapeo de los datos de entrada a un espacio que debe tener mayor dimensión y donde pueden ser separados por un hiperplano, donde generalmente se hace la comparación clase a clase. Si los datos a analizar son separables de manera lineal, la SVM se encarga de realizar una optimización para la distancia entre los dos hiperplanos paralelos que contienen los puntos más cercanos de cada clase, conocidos como vectores de soporte, de ahí el nombre del clasificador. Estos vectores son fundamentales ya que ayudan a definir la posición y orientación del hiperplano para la toma de la decisión, ya que el resto de los datos no influye directamente en su cálculo; Por otro lado, cuando las clases no son linealmente separables, las SVM utilizan funciones de núcleo (también conocidas como Kernel) para transformar los datos en un espacio de mayor dimensión donde es más probable encontrar un hiperplano que los separe de mejor manera. Entre los hiperparámetros más utilizados se encuentra los núcleos, los cuales permiten crear límites que no sean lineales, pero de otro tipo de aproximación para lograr una mejor precisión. Dentro de los núcleos más utilizados se encuentran el lineal, polinómico, gaussiano (RBF) y sigmoide; estos permiten adaptar la SVM a distintos tipos de problemas de clasificación, dependiendo del tipo de problema que se esté analizando, para este caso en particular, la detección de daño por corrosión en motores de inducción, donde se tienen datos no lineales. Este enfoque permite que la SVM sea una técnica que brinde un mayor robustez y efectividad para problemas de detección y diagnóstico de fallos ya que permite manejar grandes volúmenes de datos y adaptarse a diversas configuraciones sin requerir un ajuste en la selección de hiperparámetros (Bhavsar y Panchal, 2012).

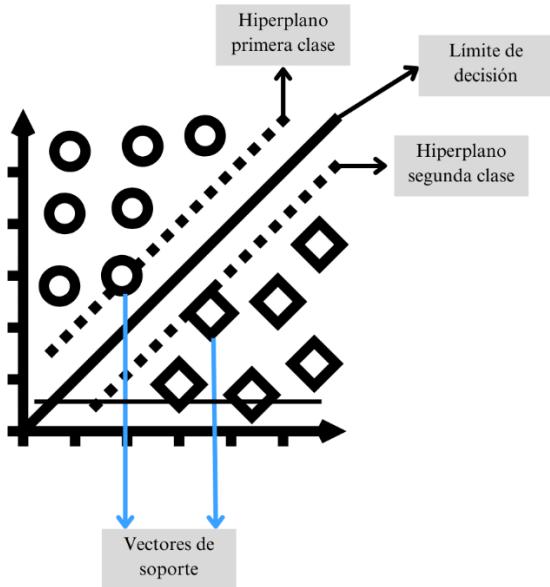


Figura 10 Representación de parámetros de una Máquina de Soporte Vectorial.

2.5.2 Bootstrap Aggregation

Los métodos de detección que se han analizado en la literatura, como se planteó anteriormente, tienen algunas desventajas, entre las cuales se encuentra que dentro de sus estructuras internas no permiten una mejora en la clasificación, a diferencia del Bootstrap Aggregation o Bagging, el cual es capaz de combinar distintos tipos de clasificadores para mejorar la precisión en la clasificación y predicción en los datos. Esta técnica se usa para extraer características muy particulares cuando se manejan grandes cantidades de datos, y, ha sido efectiva en varias aplicaciones como la toma de decisiones y el reconocimiento de patrones. Bagging es una forma de promediar modelos para mejorar la precisión, y, utiliza métodos como el bootstrap 0.632 para seleccionar muestras de datos de manera efectiva; en pocas palabras, el Bagging toma una serie de datos, estos datos los divide en subconjuntos más pequeños y luego a cada subconjunto se le entrena con un clasificador y luego se pasa el conjunto de prueba a cada conjunto entrenado para dar una clasificación más certera. Se ha demostrado que los clasificadores bagging tienen una precisión superior a los clasificadores que se usan de forma individual, lo que genera una mayor utilidad cuando hay grandes cantidades de datos o de información (Farid et al., 2011). El proceso de Bagging mostrado en la Figura 11 comienza con la generación de múltiples subconjuntos del conjunto de datos original, como se menciona anteriormente, a dichos subconjuntos se crean mediante un muestreo aleatorio con reemplazo, lo que significa que algunos datos pueden repetirse dentro de un subconjunto,

mientras que otros pueden no aparecer en ciertos subconjuntos, entonces, cada modelo base, se entrena de manera independiente utilizando uno de los subconjuntos generados. Posteriormente, se hacen las predicciones individuales de estos modelos y se combinan para obtener una predicción final. En el caso de problemas de clasificación, como el abordado en este trabajo, esta combinación suele realizarse mediante el uso de lo que se conoce como votación mayoritaria, donde la clase más predicha o repetida entre todos los modelos se toma como la salida definitiva. El uso del Bagging ofrece múltiples ventajas, las cuales se enlistan a continuación:

- Reducción de la varianza: Al combinar modelos entrenados con diferentes subconjuntos, el método disminuye la sensibilidad a pequeñas variaciones en los datos de entrenamiento.
- Mayor estabilidad: La predicción final es más robusta frente a errores individuales de los modelos base.
- Escalabilidad: Permite trabajar eficientemente con grandes volúmenes de datos al dividirlos entre varios modelos.

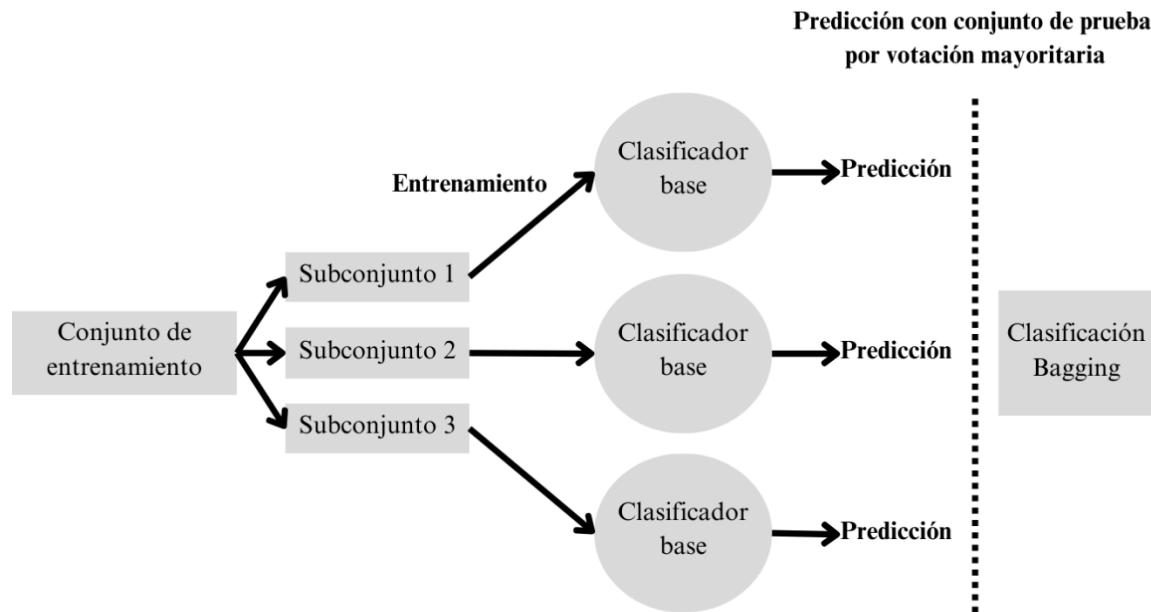


Figura 11 Proceso Bagging (Kalirane, 2023).

2.6 ANÁLISIS DISCRIMINANTE LINEAL

El análisis discriminante lineal, es conocido por ser un método de reducción de dimensionalidad, pero también suele funcionar como un clasificador lineal. Mediante el algoritmo LDA se busca encontrar un nuevo conjunto de características que maximicen la separación entre las diferentes clases de los datos, donde en lugar de seleccionar todos los datos de cada clase, se selecciona un subconjunto de características que mejor distingan y será de menos datos. LDA utiliza dos matrices para lograr esto, una matriz entre clases que calcula la distancia entre las medias de cada clase y otra matriz dentro de clases que calcula la distancia entre las medias de cada clase y los datos dentro de esa clase. Para lograr que el método sea efectivo se deben seguir una serie de pasos que se describen a continuación.

- Construir dos matrices de dispersión para la matriz de datos X, una entre clases y una dentro de clases.
- Calcular los valores y vectores propios de la matriz de dispersión.
- Clasificar los vectores propios según sus valores propios en orden descendente.
- Construir una matriz W utilizando los k vectores propios principales.
- Transformar la matriz de datos X utilizando la matriz W para obtener un nuevo subespacio (Anowar et al., 2021).

2.7 SOBREAJUSTE Y LA TASA DE SOBREAJUSTE RELATIVO

El sobreajuste ocurre cuando un modelo se adapta demasiado a los datos de entrenamiento, capturando patrones específicos e incluso ruido en lugar de identificar las tendencias generales. Esto hace que el modelo tenga un desempeño muy alto en el conjunto de entrenamiento, pero un rendimiento deficiente en datos nuevos, ya que las regularidades que aprendió durante el entrenamiento no son aplicables a datos no vistos. La tasa de sobreajuste relativo mide el grado de sobreajuste comparando la diferencia entre la precisión en entrenamiento y la precisión en prueba de manera relativa a la precisión en entrenamiento, se obtiene como indica la ecuación 20.

$$TSR = \frac{Precisión_{entrenamiento} - Precisión_{prueba}}{Precisión_{entrenamiento}} \quad (20)$$

Si el valor de TSR es cercano a cero, el modelo está generalizando bien (la precisión en entrenamiento y prueba son similares). Si TSR es alto, el modelo está sobre ajustado, lo que indica que la

diferencia entre la precisión en entrenamiento y prueba es significativa. En este trabajo, la tasa de sobreajuste relativo (TSR) se utiliza para evaluar la capacidad de generalización de los modelos de detección de fallos en rodamientos de motores de inducción, implementados mediante técnicas como Bagging, LDA y SVM. La TSR es una herramienta que permite medir el sobreajuste al obtener la diferencia relativa entre la precisión en entrenamiento y en prueba, normalizada por la precisión en entrenamiento, similar al cálculo de errores relativos; se sabe que un valor alto de TSR indica que el modelo está capturando patrones demasiado específicos de los datos de entrenamiento, lo que reduce su desempeño en aquellos datos nuevos que se ingresen en la etapa de prueba y finalmente puede reducir la capacidad de la detección de corrosión en condiciones reales, como las condiciones que se presentan naturalmente en la industria, por ejemplo, alta humedad, ruido eléctrico, otros tipos de vibraciones, etc. Entonces, el análisis de la TSR ayuda a facilitar la comparación entre los modelos y el ajuste de hiperparámetros y esto ayuda a mejorar la capacidad de generalización del sistema de detección de fallos, por lo que, para este trabajo, se hace uso de este tipo de herramientas para comprender cómo funciona la metodología propuesta contra otras existentes.

CAPÍTULO 3. METODOLOGÍA

Esta sección está destinada para comprender la estrategia seguida para lograr realizar la detección de corrosión en rodamientos de motores de inducción, y, se logra resumir en el diagrama presentado en la Figura 12, el cual consta de dos partes principales, el banco de pruebas y la metodología propuesta. Por un lado, el banco de pruebas incluye un variador de velocidad o frecuencia, el cual es usado para modificar la frecuencia de operación del motor de inducción, logrando variar entre las dos frecuencias más usadas a nivel mundial, las cuales son a 50 y 60 Hz. Este motor está siendo monitoreado con la ayuda de tres sensores principales; Un sensor de flujo magnético de dispersión, un sensor de vibraciones y un sensor de corriente eléctrica para posteriormente, las señales generadas sean capturadas mediante un sistema de adquisición de datos propietario.

Estas señales en el tiempo, las cuales representan el comportamiento del motor bajo distintas condiciones (sano y niveles de corrosión), son posteriormente utilizadas como entrada para la siguiente etapa del procedimiento, la cual corresponde a la metodología y consiste en el procesamiento y análisis de las señales obtenidas. Estas señales de corriente, flujo magnético de dispersión y vibraciones son analizadas en una pc mediante algoritmos, diseñados en el entorno de desarrollo de PyCharm, donde, inicialmente, se calculan indicadores y parámetros estadísticos y no estadísticos, como se detalla en la Tabla 1, los cuales se utilizan para caracterizar las señales en función de las condiciones del motor. Estos indicadores son procesados a través del método de reducción de dimensionalidad Análisis Discriminante Lineal (LDA), optimizando la representación de los datos para su clasificación.

Posteriormente, se emplea un clasificador basado en SVM, y, su salida se utiliza como entrada para un modelo de aprendizaje por conjuntos, con el objetivo de mejorar la precisión en la identificación de las condiciones del rodamiento, sano, con corrosión en nivel 1 y con corrosión nivel 2. Esto permite retroalimentar la selección de indicadores, mejorando demasiado el conjunto final y, con ello, garantizar que los mejores indicadores sean utilizados en la clasificación, donde el resultado final es un sistema robusto y confiable para la detección de fallas en rodamientos de motores de inducción.

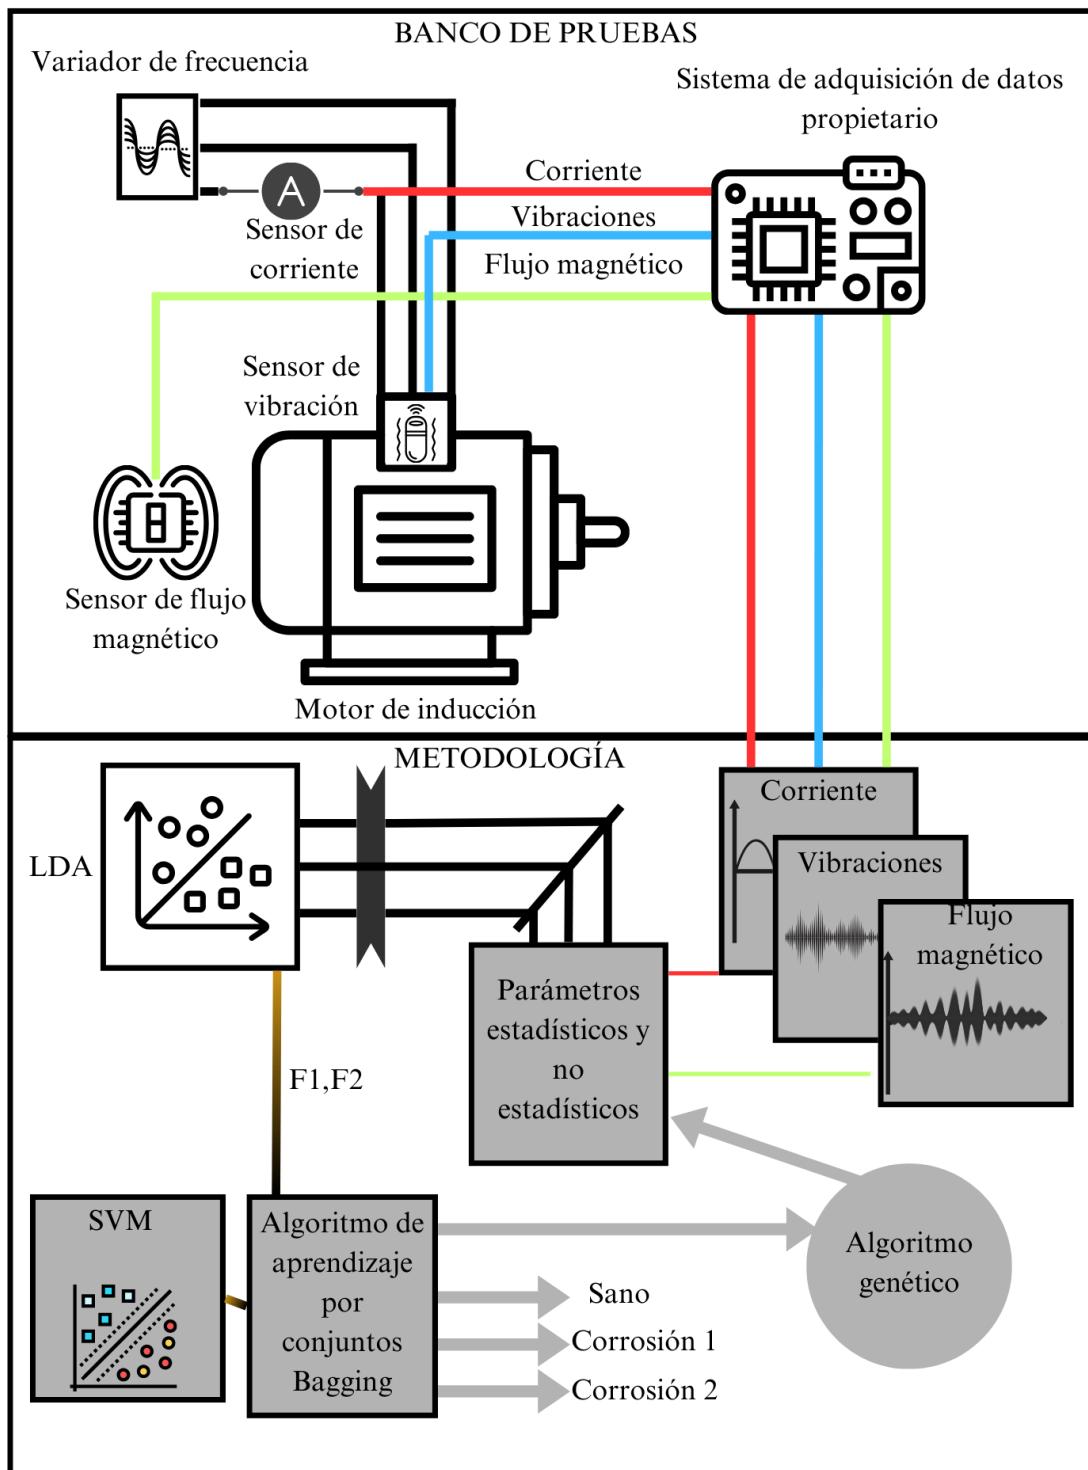


Figura 12 Diagrama metodológico a realizar (autoría propia).

3.1 RODAMIENTO SELECCIONADO

Los rodamientos utilizados en este estudio son del tipo 6203 2RS/C3, los cuales, son bastante reconocidos en la industria por su confiabilidad, versatilidad y buen funcionamiento; estos rodamientos son de tipo metálicos y se encuentran comúnmente en aplicaciones que requieren soporte para cargas radiales y axiales en motores eléctricos, en bombas y maquinaria industrial. Entre sus principales características físicas se destacan un diámetro exterior de 40 mm, un diámetro interior de 17 mm, además de contar con 8 bolas internas. También están equipados con sellos de hule en ambos lados lo que los ayuda a tener protección contra contaminantes como polvo y humedad, mejorando su desempeño y prolongando su vida útil, sin embargo, muchas veces estos sellos terminan siendo defectuosos, generando problemáticas como la entrada de agua y posteriormente, la corrosión. A continuación, la Figura 13 muestra el rodamiento utilizado para este trabajo.



Figura 13 Rodamiento metálico 6203 RS/C3 (autoría propia).

3.2 MATRIZ DE DATOS REALIZADA

La Tabla 2 presenta la matriz de datos utilizada en este trabajo, la cual cuenta con diferentes condiciones de operación en el motor de inducción, donde se realizaron experimentos bajo dos frecuencias de operación distintas, (50 y 60 Hz) lo cual ayuda a demostrar que los efectos de la corrosión se presentan a pesar de que se presente una condición de operación distinta sobre las señales del motor. Además, para cada condición de corrosión (sano, nivel 1 y nivel 2) se llevaron a cabo 10 pruebas, esto ayuda a garantizar

que se tengan los suficientes datos para observar el fenómeno, dando posteriormente a la clasificación una mejor respuesta.

Tabla 2 Matriz de pruebas.

<i>Estado del rodamiento</i>	<i>Frecuencias que se utilizarán (Hz)</i>	<i>Número de pruebas a realizar por estado del rodamiento</i>
<i>Sano</i>		
<i>Corrosión nivel 1</i>	50 y 60	15
<i>Corrosión nivel 2</i>		

Cada muestra registrada tuvo una duración de 48 segundos, donde 10 segundos que se le atribuyen al estado de arranque del motor y el resto al estado estacionario, permitiendo capturar la dinámica del motor tanto en su estado inicial como en su estado estacionario, generando una buena cantidad de datos y con gran detalle para el análisis posterior. Las señales capturadas incluyen corrientes, flujo magnético de dispersión y vibraciones las cuales fueron utilizadas para alimentar los modelos de clasificación descritos en la metodología.

3.3 CONFIGURACIÓN DE LA BANCADA CON ELEMENTOS MECÁNICOS, ELÉCTRICOS Y SENSORES

La Figura 14 ilustra la configuración de la bancada experimental y la disposición de los sensores utilizados en este estudio. En la imagen se puede observar la línea de alimentación que conecta al variador de frecuencia marca WEG SFW 08, el cual controla las condiciones de operación del motor de inducción

al modificar la frecuencia de entrada. Posterior al variador, se encuentra un sensor de corriente que mide la señal en la línea de alimentación antes de llegar al motor.

Adicionalmente, se muestra cómo el sensor de flujo magnético realiza las lecturas de manera perpendicular al motor, mientras que el sensor de vibraciones se coloca directamente sobre la carcasa para captar las señales mecánicas generadas. Estas señales, junto con las de flujo magnético, son adquiridas por una tarjeta de adquisición de datos específica, puesta en el motor. Es importante señalar que la tarjeta de adquisición utilizada para las señales de corriente es diferente y se describirá en detalle más adelante.

La imagen también ilustra que el motor está acoplado a una banda dentada que transmite movimiento a un alternador, simulando aproximadamente un 30% de carga. Esta configuración experimental asegura que las condiciones de operación del motor reflejen un escenario realista, lo que contribuye a la validez de los datos recolectados y al análisis posterior.

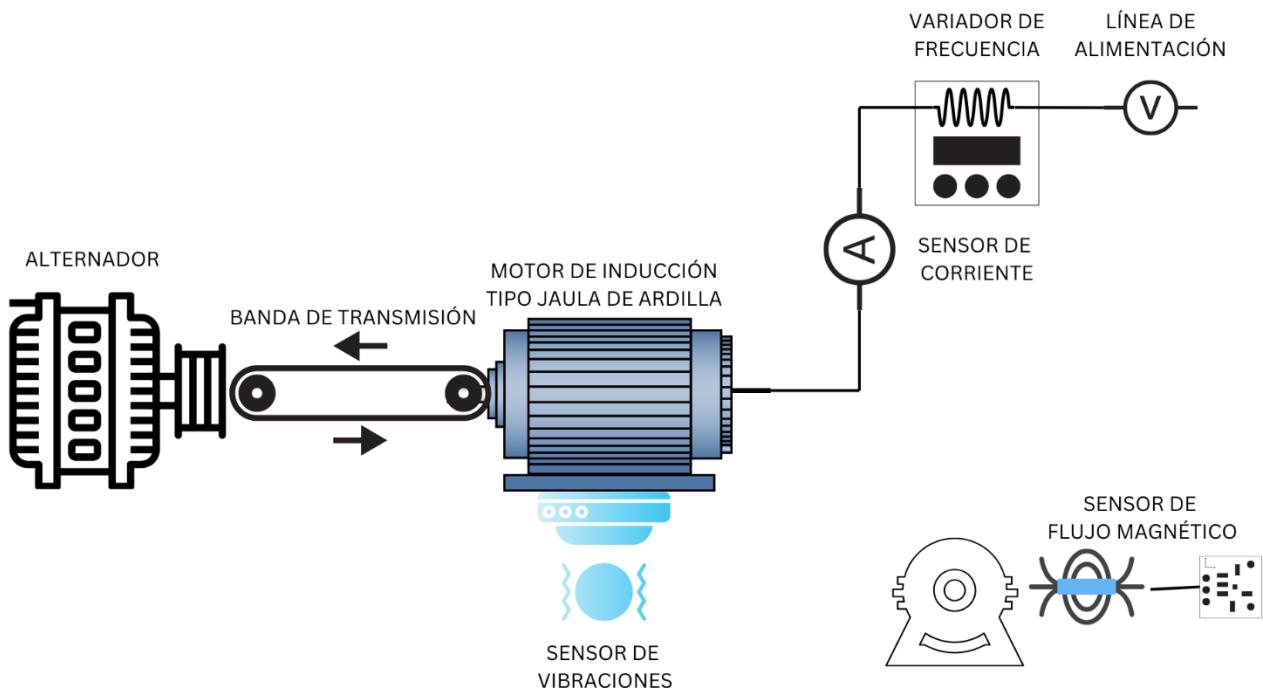


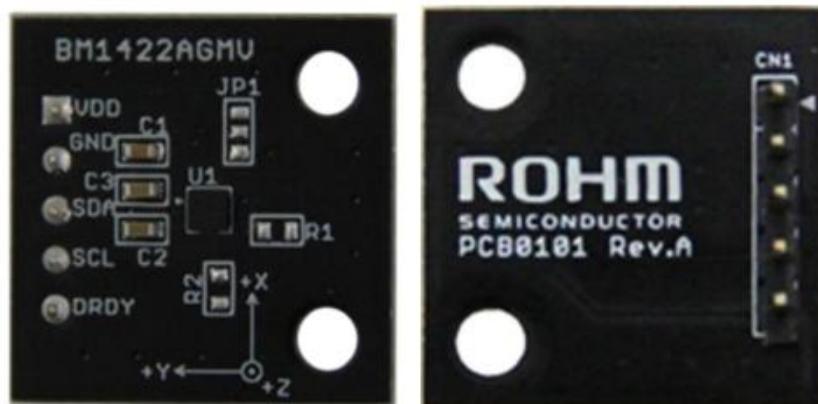
Figura 14 Configuración de bancada y sensores (autoría propia).

Por otro lado, se muestra el motor de inducción, el cual es marca WEG y tiene como especificaciones una tensión de alimentación de 208-230/460 V, una velocidad nominal de 60 Hz (3355

rpm), una potencia de 1 Hp, una corriente nominal de 2.83 A bajo una eficiencia nominal de 75.5%, finalmente, presenta un factor de potencia de 0.87.

3.4 INSTRUMENTACIÓN DE SENSORES

En este estudio se emplearon diversos sensores para la adquisición de las señales necesarias para el análisis. Para la medición de corriente, se utilizó una pinza ampermétrica Fluke i200s, reconocida por su precisión y confiabilidad. Por su parte, las lecturas de flujo magnético de dispersión se realizaron con un magnetómetro de tres ejes, modelo BM1422AGMV, el cual, permitió obtener mediciones detalladas en las tres direcciones o ejes. Por un lado se encuentra el sensor de vibraciones, el cual viene incluido en la tarjeta de adquisición de datos que se usó para adquirir de igual manera el flujo magnético, esta tarjeta, basada en tecnología FPGA permite realizar lecturas a una frecuencia de 1 kHz tanto para las señales de vibraciones como para las de flujo magnético de dispersión, lo cual es útil para encontrar aspectos muy detallados en cuanto a la detección de fallos en motores de inducción. La Figura 15 muestra los sensores principales utilizados, donde a muestra el magnetómetro de tres ejes BM1422AGMV y en b la pinza ampermétrica Fluke i200s para la lectura de la corriente eléctrica en una de las fases del motor de inducción.



a)



b)

Figura 15 Sensores utilizados: a) Sensor de flujo magnético de dispersión BM1422AGMV y b) Pinza amperimétrica Fluke i200s.

Además, también se utilizó un sistema de adquisición de datos basado en un microcontrolador STM el cual adquiere las señales de corriente, al igual que sucede con flujo magnético y vibraciones, a una frecuencia de 1 kHz. La Figura 16 muestra ambas tarjetas de adquisición utilizadas, a presenta la tarjeta basada en FPGA y b muestra la tarjeta basada en STM para la adquisición de corriente.

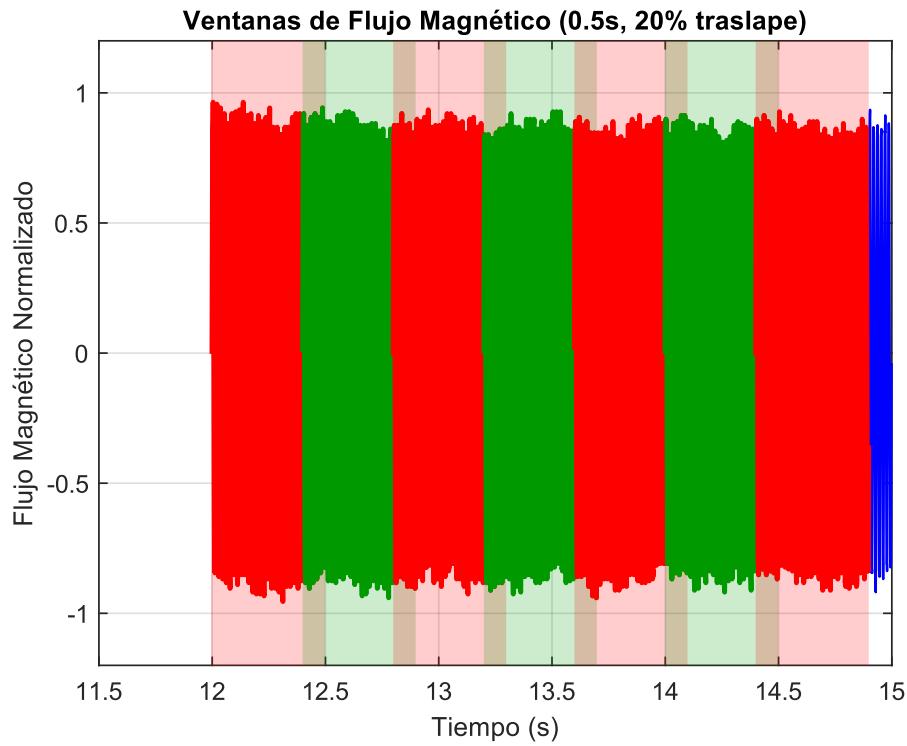


Figura 16 Tarjetas de adquisición de datos usadas para a) flujo magnético de dispersión y vibraciones y b) corriente.

La Tabla 3 muestra algunos datos importantes sobre las especificaciones de la tarjeta de adquisición y el sensor que se usaron para recolectar los datos del sistema, esta tabla muestra la frecuencia

de muestreo de la tarjeta, que básicamente indica cuántas veces por segundo se registran las señales o bien, cuantas veces por segundo se realiza una lectura. Es bastante importante tener una frecuencia de muestreo correcta, ya que de eso depende que la señal conserve su comportamiento real y que no se pierdan detalles importantes durante el proceso, por ejemplo, si un fallo en un motor de inducción es periódico, es decir, tiene una frecuencia característica, si la frecuencia de muestreo no se selecciona correctamente, se puede perder esta información y posteriormente, dar falsos resultados de que el motor se encuentra sano, cuando realmente no lo está.

También se muestra la resolución del convertidor, el cual indica con cuántos bits se convierte la señal analógica a digital, lo que se refiere a cuantos más bits se usen, más preciso será ese proceso ya que se tienen más niveles posibles para representar la amplitud de la señal. Este detalle es muy importante cuando se necesita captar pequeñas variaciones en las señales del motor de inducción, mejorando la capacidad de detección de fallos o daños. Finalmente, se incluye la resolución del sensor, que en términos simples es la menor diferencia que puede detectar, por ejemplo, si el sensor tiene una buena resolución, puede registrar cambios muy pequeños, algo que resulta muy útil para detectar posibles fallas en los rodamientos desde etapas muy tempranas. La resolución del sensor se relaciona con la resolución del convertidor mediante la ecuación 21, donde R_s es la resolución del sensor, la *Referencia* es el rango de medición del sensor y n es el número de bits del convertidor.

$$R_s = \frac{\text{Referencia}}{2^n} \quad (21)$$

Tabla 3 Datos de sensores y tarjetas de adquisición.

Parámetro	Sensor Corriente (pinza)	Sensor de Flujo magnético de dispersión	Sensor Vibraciones
Frecuencia de muestreo de tarjeta de adquisición		1000	
Resolución del convertidor	24 bits	14 bits	16 bits

Resolución obtenida del sensor	23 nA/LSB	0.042 μ T/LSB	0.00479 $\frac{m}{s^2}$ /LSB
--------------------------------	-----------	-------------------	------------------------------

3.5 PUESTA EN EXPERIMENTACIÓN

Para la ejecución de los experimentos, se implementó la configuración descrita en la Sección 3.3, asegurando la correcta integración y operación de cada elemento como se muestra en la Figura 17. Se estableció la bancada experimental con el motor de inducción acoplado a la banda dentada, replicando una carga aproximada del 30%. Se utilizó un variador de frecuencia WEG SFW 08 para poder modificar la frecuencia de entrada al motor y, así, poder controlar sus condiciones de funcionamiento, además, los sensores de corriente, vibración y flujo magnético se colocaron como se explicó anteriormente, de manera que permitieran obtener señales para el posterior procesamiento de estas. Para obtener los datos, se usaron tarjetas de adquisición propietarias, que fueron diseñadas específicamente para este tipo de tareas por investigadores de la Universidad Autónoma de Querétaro, lo que ayudó a capturar y guardar la información de forma adecuada.

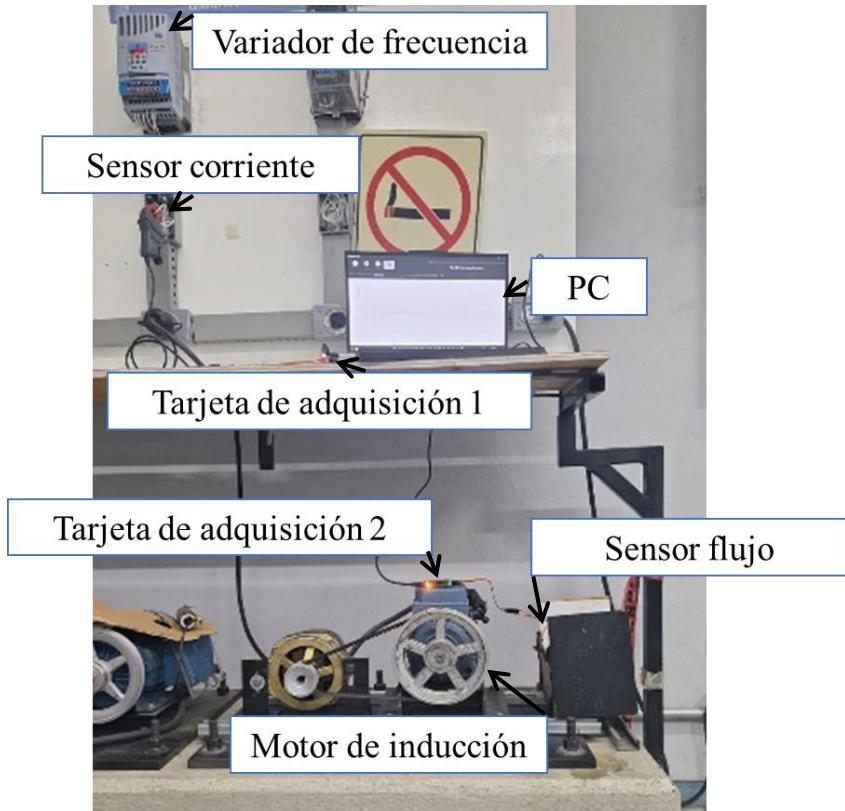


Figura 17 Puesta en experimentación.

3.6 PROCESAMIENTO DE LAS SEÑALES

El procesamiento inicial de las señales de corriente, del flujo magnético de dispersión, y de corriente se hicieron en una computadora usando el entorno de desarrollo de PyCharm, el cual se programa con Python, este es un entorno bastante usado sobre todo en áreas como ciencia de datos y análisis de señales, ya que cuenta con opciones para descargar directamente librerías de inteligencia artificial y de aprendizaje automático. A dichas señales se les aplicó una normalización a un rango de -1 a 1 para que todas las amplitudes estén en el mismo nivel y así sea más fácil compararlas y procesarlas después, normalizando primero el estado sano, y luego, tomando esta como base para realizar la normalización de las demás señales pero con fallos.

Cada señal capturada tiene una duración de 48 segundos, de los cuales, los primeros 10 segundos corresponden al estado transitorio del motor, y los otros 38 segundos restantes el estado estable como se mencionó anteriormente, dicho estado estable es el más importante para su posterior análisis.

Para analizar las señales cuando el motor ya está en estado estable, se aplicó una técnica conocida como ventaneo, la cual, consiste en dividir las señales en pequeñas ventanas o segmentos de 0.5 segundos, aplicando además, un 20% de traslape entre cada una de estas ventanas. Esto es bastante útil ya que ayuda a mejorar la resolución en la detección del fallo, permitiendo detectar cambios pequeños en las tendencias de las señales, cuando se aplican justamente los indicadores estadísticos y los no estadísticos, además, es útil para no perder información importante y para mejorar la precisión cuando se llega a las etapas finales de clasificación.

3.7 INDICADORES ESTADÍSTICOS Y NO ESTADÍSTICOS

Durante el procesamiento de las señales adquiridas, se aplican ciertos indicadores importantes que se usan como base para analizar y clasificar las condiciones de los rodamientos a las diferentes señales utilizadas, por ejemplo, el parámetro no estadístico de la energía de Teager-Kaiser, que, según varios trabajos en la literatura está relacionado con procesos mecánicos que generan señales oscilantes. Este indicador ayuda a entender cómo se comporta en cuánto a niveles de energía una señal considerando tanto su frecuencia como su dinámica a lo largo del tiempo. La ecuación que se usa aparece como la ecuación 12 en la Tabla 1, donde $X(n)$ representa la señal (ya sea de corriente o flujo magnético) y n es el número de muestra. Existen otros parámetros bastante importantes y que pueden ayudar a mejorar la detección de fallos, pero también existen algunos que pueden empeorarla, por ello, resalta la importancia de crear algoritmos que permitan seleccionar los mejores indicadores estadísticos que se pueden utilizar, para posteriormente, hacer un estudio para determinar que tanto un indicador puede estar relacionado físicamente con el fallo en sí. Ejemplo de estos algoritmos pueden ser los de selección heurística, como los algoritmos genéticos, salto de rana barajadas, entre otros.

Además, estos parámetros son muy importantes y útiles porque permiten detectar cambios muy sutiles en las oscilaciones de la señal, lo que lo hace adecuado para encontrar señales de desgaste o fallas como, por ejemplo, la corrosión en los rodamientos. La razón por la que funciona bien en este tipo de casos es porque puede identificar alteraciones en patrones que pueden ir relacionados con aspectos físicos como la energía o puramente matemáticos de las señales, como la media, varianza y, que suelen ocurrir cuando hay interacciones mecánicas anormales como en el caso de cuando se presentan fallos o daños. Por ejemplo, si un rodamiento tiene corrosión, las imperfecciones en su superficie afectan las vibraciones

por óxido que se genera, por el mismo decapado que suele presentarse cuando existe la corrosión, todo esto a final de cuentas puede generar un cambio de igual manera en la corriente, ya que será necesario un gasto mayor de energía eléctrica a causa de los fallos, por la misma perdida de eficiencia como se mencionó anteriormente en la literatura.

3.8 ANÁLISIS DE VARIANZA

Una vez aplicados los indicadores estadísticos y no estadísticos, se lleva a cabo un análisis de varianza (ANOVA, por sus siglas en inglés, *Analysis of Variance*) a las señales de corriente, vibraciones y flujo magnético de dispersión, considerando las tres condiciones de los rodamientos, los cuales son sano, con corrosión nivel 1 y con corrosión nivel 2 y cuyo propósito principal es comparar cuánta variación hay dentro de cada grupo (por ejemplo, las muestras de rodamientos sanos) frente a la variación que existe entre grupos diferentes. Esto ayuda particularmente a generar una pequeña discriminación del daño, sin embargo, si el resultado que se genera en este análisis no muestra una tendencia de separación entre los datos, realza la importancia de usar técnicas avanzadas para poder hacer la detección de daños y separación de las clases.

El ANOVA sirve para saber si las señales obtenidas para cada tipo de rodamiento muestran diferencias significativas desde el punto de vista estadístico, es decir, mediante métodos matemáticos, sin embargo, en este caso se utilizó más como una herramienta que permite determinar que no es posible separar los datos solo utilizando métodos tradicionales que se usan en literatura. Los resultados muestran que, aunque hay ciertas diferencias, no siempre son tan claras como para poder identificar el tipo de daño usando solo estas pruebas estadísticas aplicadas directamente a las señales en el tiempo, y, como se menciona anteriormente, se realza la importancia de usar técnicas avanzadas, no solo para el ámbito de la detección y diagnóstico de máquinas, sino para cualquier aplicación. Ejemplo de estas técnicas avanzadas pueden ser los modelos de clasificación basados en técnicas de aprendizaje automático, de inteligencia artificial o de aprendizaje profundo, ya que pueden identificar patrones más complejos (no necesariamente lineales), lo que les da una clara ventaja frente a análisis como el ANOVA u otras técnicas convencionales.

3.9 USO DE ANÁLISIS DISCRIMINANTE LÍNEAL

Después de ver que el análisis ANOVA no fue suficiente para diferenciar claramente entre las distintas condiciones de los rodamientos, se decidió aplicar una técnica más avanzada como el Análisis Discriminante Lineal, el cual permite mejorar la separación entre las clases (rodamiento sano, con corrosión nivel 1 y con corrosión nivel 2) debido a que esta técnica busca maximizar la diferencia entre clases mientras reduce la variabilidad dentro de cada una, además, de ser una herramienta capaz de reducir la dimensionalidad; esto es específicamente útil debido a que se cuenta con una gran cantidad de datos, teniendo señales de corriente, 3 ejes del flujo magnético y 3 ejes de las vibraciones, además, a cada una de estas señales se le aplican parámetros estadísticos y no estadísticos, teniendo un gran número de dimensiones, por lo que realza la importancia de usar la técnica para optimizar aún más la metodología seguida para este trabajo. Como características principales para este análisis, se combinaron los datos de corriente y del flujo magnético de dispersión y vibraciones junto con los indicadores estadísticos, generando un espacio de características bidimensional, a partir de las señales, que contienen un total de 38,000 muestras para cada una de las pruebas (10), se aplicó un ventaneo de 500 muestras por segmento con un solapamiento del 20%. Es importante resaltar que todas las pruebas realizadas para cada condición se unieron, es decir, se analizaron en combinación para obtener una mayor cantidad de datos y que la muestra pueda ser correctamente representativa.

Para llevar a cabo el LDA se calcularon las matrices de medias y dispersión, lo que a su vez permiten encontrar la transformación más efectiva, para posteriormente obtener los valores y vectores propios que son capaces de definir las nuevas dimensiones o la selección de las dos mejores características. Los datos fueron proyectados en un espacio bidimensional, lo que facilita su visualización e interpretación, y permite observar mejor la separación entre las clases.

La forma en que se aplica el LDA, está estrechamente relacionado con el algoritmo genético (AG), ya que este inicialmente da un conjunto de datos en forma de un vector, lo cual significa que indicadores de cada señal serán usados, para posteriormente, evaluar estos indicadores de las señales usando LDA, y los métodos de aprendizaje automático, devolviendo al final la mejor combinación, que ofrece la mejor precisión. Este paso es bastante fundamental para saber qué características aportan más información relevante y, en conjunto, los resultados del análisis discriminante ofrecen una base sólida para el desarrollo de un modelo de clasificación más robusto y resalta la importancia de combinar distintos indicadores con

técnicas avanzadas para mejorar la detección de fallas y ayuda a mejorar las técnicas convencionales que existen de detección.

3.10 USO DE MÁQUINA DE SOPORTE VECTORIAL

En esta etapa del análisis, se utilizó la Máquina de Soporte Vectorial como algoritmo base para el enfoque de clasificación que se explica más adelante, el cual se basa en la metodología Bagging, este clasificador es un algoritmo que se basa en una técnica supervisada, y, que es ampliamente reconocida por su eficiencia en tareas de clasificación y regresión (como generalmente funcionan la mayoría de algoritmos de aprendizaje automático), especialmente cuando se trabaja con conjuntos de datos complejos o que pueden llegar a ser no lineales como es el caso de las señales en los motores de inducción.

El objetivo principal de este método es encontrar un hiperplano que logre separar las clases de forma óptima en un espacio multidimensional, sabiendo que este hiperplano se construye de tal manera que se maximice el margen, es decir, la distancia entre el hiperplano y los puntos más cercanos de cada clase y que se conocen como vectores de soporte, como se mencionó anteriormente. Al aumentar este margen, la SVM mejora su capacidad para generalizar lo que se traduce en un mejor desempeño cuando se enfrenta a nuevos datos, lo que es especialmente útil para evitar que el modelo presente sobreajustes, aunque en ocasiones es complicado evitar esta problemática por la naturaleza de los datos y la capacidad que tienen los modelos para generalizarse.

Una de las grandes ventajas de la SVM es su flexibilidad para resolver problemas no lineales mediante el uso de funciones kernel y que pueden ser de diversos tipos, estas funciones permiten transformar los datos originales a un espacio de mayor dimensionalidad donde es posible separar clases que en el espacio original no eran separables linealmente, lo que ayuda a su capacidad de adaptación a diferentes tipos de patrones en los datos, desde los más simples hasta los más complejos. Para este trabajo, la SVM es el algoritmo base para la construcción de un modelo más avanzado y su implementación representa una buena elección, tanto por su capacidad para evitar el sobreajuste como por su desempeño comprobado en tareas de clasificación con conjuntos de datos relativamente pequeños, además como se describió anteriormente, muchos artículos han determinado que la SVM es de los algoritmos de aprendizaje automático que mejores resultados entregan en tareas de clasificación.

3.11 USO DE ALGORITMO DE APRENDIZAJE POR CONJUNTOS BAGGING

En este trabajo, el método Bagging se integró al proceso del algoritmo genético como parte de la evaluación de cada individuo generado, ya que, cada vez que el algoritmo propone una nueva combinación de características, estas son evaluada mediante una función de aptitud que incluye tres etapas clave como lo son la selección de características, la reducción de dimensionalidad mediante Análisis Discriminante Lineal y la clasificación con un modelo Bagging con una SVM de algoritmo base. Ahora bien, para entrenar y validar los modelos, los datos se dividieron en un 70% para entrenamiento y un 30% para validación, esto se hace con el único fin de asegurar una evaluación confiable del desempeño del clasificador y cuyos porcentajes se obtuvieron de manera a prueba y error, cuyo porcentaje posterior ya no hacía mejorar la precisión del modelo de clasificación.

En cuanto al modelo Bagging, se utilizó la Máquinas de Soporte Vectorial con kernel RBF (función de base radial, la cual presentó una buena generalización) como clasificadores base, después, se entrenaron 11 modelos de SVM de forma independiente, cuyas predicciones se combinaron para generar una decisión final más robusta y precisa (sabiendo que a cada uno de esos 11 modelos se les añade una serie de datos del conjunto de entrenamiento que contiene el 70 por ciento de los datos). Este enfoque mejora la capacidad del sistema para detectar fallas en los rodamientos, ya que reduce el riesgo de sobreajuste teniendo múltiples modelos y generando una clasificación final tomando en cuenta todos los modelos generados y aprovechando la diversidad de los subconjuntos de datos empleados en cada iteración.

El desempeño del modelo ensamblado se evaluó en términos de precisión de clasificación sobre los datos de prueba, de esta forma, cada combinación de características generada por el algoritmo genético se validó bajo este esquema, asegurando no solo una selección eficiente de características, sino, también una alta capacidad de generalización para identificar correctamente los diferentes tipos de fallas. También, es importante señalar que cada uno de los datos de prueba son evaluados por los 11 modelos, y, finalmente, se hace una clasificación usando la votación mayoritaria, esto permite obtener la clasificación dependiendo cada uno de los modelos de SVM. De igual manera, se utilizó un número impar de modelos, para que en caso de que exista un empate, se obligue a determinar una clasificación ya que no podría existir un empate.

Los parámetros utilizados en este modelo se muestran en la Tabla 4 y fueron definidos mediante prueba y error y, una vez que el algoritmo alcanzó un punto en el que la precisión ya no mejoraba significativamente, se optó por mantener dichos valores.

Tabla 4 Selección de hiperparámetros del Bagging.

Hiperparámetros del Bagging	Valor
Clasificador base	Máquina de soporte vectorial
Kernel	Rbf
Número de estimadores	11
Estado aleatorio	42
Tamaño del conjunto de prueba	30%

3.12 ALGORITMO GENÉTICO IMPLEMENTADO

El algoritmo genético implementado en este trabajo tiene como finalidad optimizar la selección de características con el objetivo de mejorar el rendimiento del sistema de clasificación, el cual combina Análisis Discriminante Lineal y un clasificador Bagging con una SVM como base. Como entrada, el algoritmo recibe una matriz de datos X , que contiene las características extraídas a partir de las señales obtenidas de los rodamientos (por ejemplo, la señal de corriente con todos los indicadores estadísticos y no estadísticos y así, para cada una de las señales de flujo magnético de dispersión y de vibraciones en sus respectivos ejes), y un vector y , que representa las etiquetas correspondientes a cada muestra. Además, se definen parámetros fundamentales para el funcionamiento del algoritmo, tales como el tamaño de la población, el número de generaciones y la tasa de mutación, donde estos parámetros son parte importante

del proceso evolutivo del algoritmo, permitiendo explorar diferentes combinaciones de características y seleccionar aquellas que maximicen el desempeño del clasificador en la tarea de detección de fallas, seleccionando finalmente la mejor combinación que entrega la precisión más alta, logrando así resultados que pueden ser fácilmente comparados con el desarrollo que existe en literatura.

El algoritmo comienza con la inicialización de una población de individuos, donde cada individuo es representado por un vector binario cuya longitud es igual al número total de características en la matriz X. En este vector, un valor de "1" indica que la característica correspondiente es seleccionada, mientras que un "0" indica que la característica es descartada. Cada individuo es evaluado mediante una función de aptitud (fitness), en la cual se seleccionan las características activas en el individuo y se dividen los datos en conjuntos de entrenamiento y prueba en una proporción del 80 % y 20 %, respectivamente. Posteriormente, se aplica Análisis Discriminante Lineal (LDA) para reducir la dimensionalidad y proyectar los datos en un nuevo espacio de menor dimensión. Los datos transformados se utilizan para entrenar un modelo Bagging-SVM, compuesto por 10 clasificadores SVM con kernel RBF. Finalmente, la precisión de clasificación obtenida sobre el conjunto de prueba es utilizada como métrica de aptitud del individuo.

Para la selección de la siguiente generación, se ordenan los individuos de acuerdo con su precisión de clasificación y se conserva la mitad superior de la población. A continuación, se realiza la recombinación de los individuos seleccionados mediante un operador de cruce de un solo punto, donde se elige un punto de corte aleatorio y se intercambian las partes subsecuentes entre dos padres para generar dos nuevos descendientes. Posteriormente, cada descendiente es sometido a un proceso de mutación con una probabilidad determinada, en la cual algunos bits pueden cambiar de estado para introducir variabilidad en la población.

Este proceso iterativo de selección, cruzamiento y mutación se repite durante un número definido de generaciones. Al finalizar, el algoritmo devuelve las 10 mejores combinaciones de características junto con sus respectivas precisiones de clasificación. De esta manera, se obtiene un subconjunto óptimo de características que maximiza la capacidad predictiva del clasificador, reduciendo la dimensionalidad del problema sin comprometer el rendimiento del modelo. La integración de Bagging-SVM mejora la estabilidad y generalización del sistema, mientras que LDA permite optimizar el espacio de representación sin perder información relevante. La tabla 5 muestra los hiperparámetros necesarios para el correcto funcionamiento del algoritmo genético, al igual que en el caso del algoritmo Bagging, se obtuvieron los

parámetros mediante prueba y error, manteniendo finalmente los datos a partir de los cuales el sistema no presentó cambios en la precisión final.

Tabla 5 Hiperparámetros del algoritmo genético.

Hiperparámetros del Algoritmo Genético	Valor
Tamaño de la población	50
Generaciones	30
Tasa de mutación	0.1
Tipo de selección	Selección por torneo
Cruza	Aleatorio a la mitad del individuo

3.13 DIAGRAMA DE FLUJO DEL SISTEMA IMPLEMENTADO

El código representado en el diagrama de flujo de la Figura 18 implementa un sistema para la detección de corrosión en rodamientos de motores de inducción mediante un modelo de clasificación basado en una combinación de Análisis Discriminante Lineal (LDA), Bagging y Máquinas de Vectores de Soporte (SVM), optimizado mediante un algoritmo genético para la selección de características. El proceso inicia con la carga de los datos capturados mediante archivos de texto, donde las señales obtenidas mediante los sensores de corriente, flujo magnético de dispersión y vibraciones se organizan en tres clases: condiciones de rodamientos sano, con corrosión leve y con corrosión severa. Posteriormente, los datos son normalizados mediante un MinMaxScaler para ajustarlos a un rango entre -1 y 1, lo que facilita el procesamiento y mejora el rendimiento del modelo al eliminar efectos de escalas diferentes entre las señales. Una vez normalizados los datos, el código aplica un proceso de segmentación mediante ventanas con solapamiento de tamaño fijo, con un traslape del 20%, para extraer las características de las señales en cada ventana. Para cada segmento, se extraen indicadores específicos como curtosis, quinto y sexto momento, asimetría y entropía de muestreo, que proporcionan información detallada sobre la forma y

complejidad de la señal. Las características extraídas se almacenan en una matriz de características que será utilizada para el entrenamiento y prueba del modelo, para, posteriormente, crear las etiquetas correspondientes para cada clase (sano, corrosión leve y corrosión severa) para permitir la clasificación supervisada.

El algoritmo genético inicia con la generación de una población inicial de combinaciones aleatorias de características donde un valor de 1 indica que la característica está seleccionada y un valor de 0 indica que está descartada; cada una de las combinaciones de características es evaluada mediante un proceso de entrenamiento y validación como se mencionó en las etapas anteriores. Básicamente, para esto los datos seleccionados se dividen en conjuntos de entrenamiento y prueba mediante `train_test_split` (una de las herramientas que brinda el software de PyCharm), manteniendo la proporción de clases, es decir, el mismo número de elementos. Luego, se aplica LDA para reducir la dimensionalidad y proyectar los datos en un espacio donde las clases sean más separables. Y, el modelo resultante se entrena mediante Bagging, utilizando SVM como clasificador base. Bagging permite reducir la varianza mediante el entrenamiento de múltiples modelos sobre subconjuntos de datos y promediando sus resultados, lo que mejora la capacidad de generalización del modelo. La precisión obtenida en el conjunto de prueba se considera como el valor de aptitud de la combinación de características. Una vez evaluadas todas las combinaciones, el algoritmo genético selecciona las mejores mediante un proceso de ordenación, donde las combinaciones con mayor precisión son retenidas para formar la siguiente generación. El proceso de selección dentro del algoritmo genético utiliza una selección que se conoce como selección por torneo, mediante la cual se eligen las combinaciones de características que participarán en el proceso de cruzamiento y, durante esta etapa, dos de los individuos seleccionados intercambian segmentos de sus estructuras binarias (es decir, de sus valores de 0 y 1) para generar nuevas combinaciones, lo cual es bastante útil para evitar que el modelo tienda a obtener una solución bastante rápida y, que probablemente pueda no ser la solución más optima. después, estas combinaciones son sometidas a una fase de mutación, en la que con una probabilidad definida se invierten ciertos bits y cuyo principal objetivo es el incrementar la diversidad poblacional y prevenir la convergencia rápida a soluciones optimas iniciales o poco efectivas, por ejemplo, que en la detección de fallos en los motores de inducción entregue un valor de precisión bajo para la combinación seleccionada, cuando tal vez haya una combinación que entregue el 100%. Al concluir el proceso el algoritmo retorna las diez mejores combinaciones de características junto con sus respectivas precisiones, lo que permite identificar los indicadores más relevantes para la detección de corrosión en rodamientos.

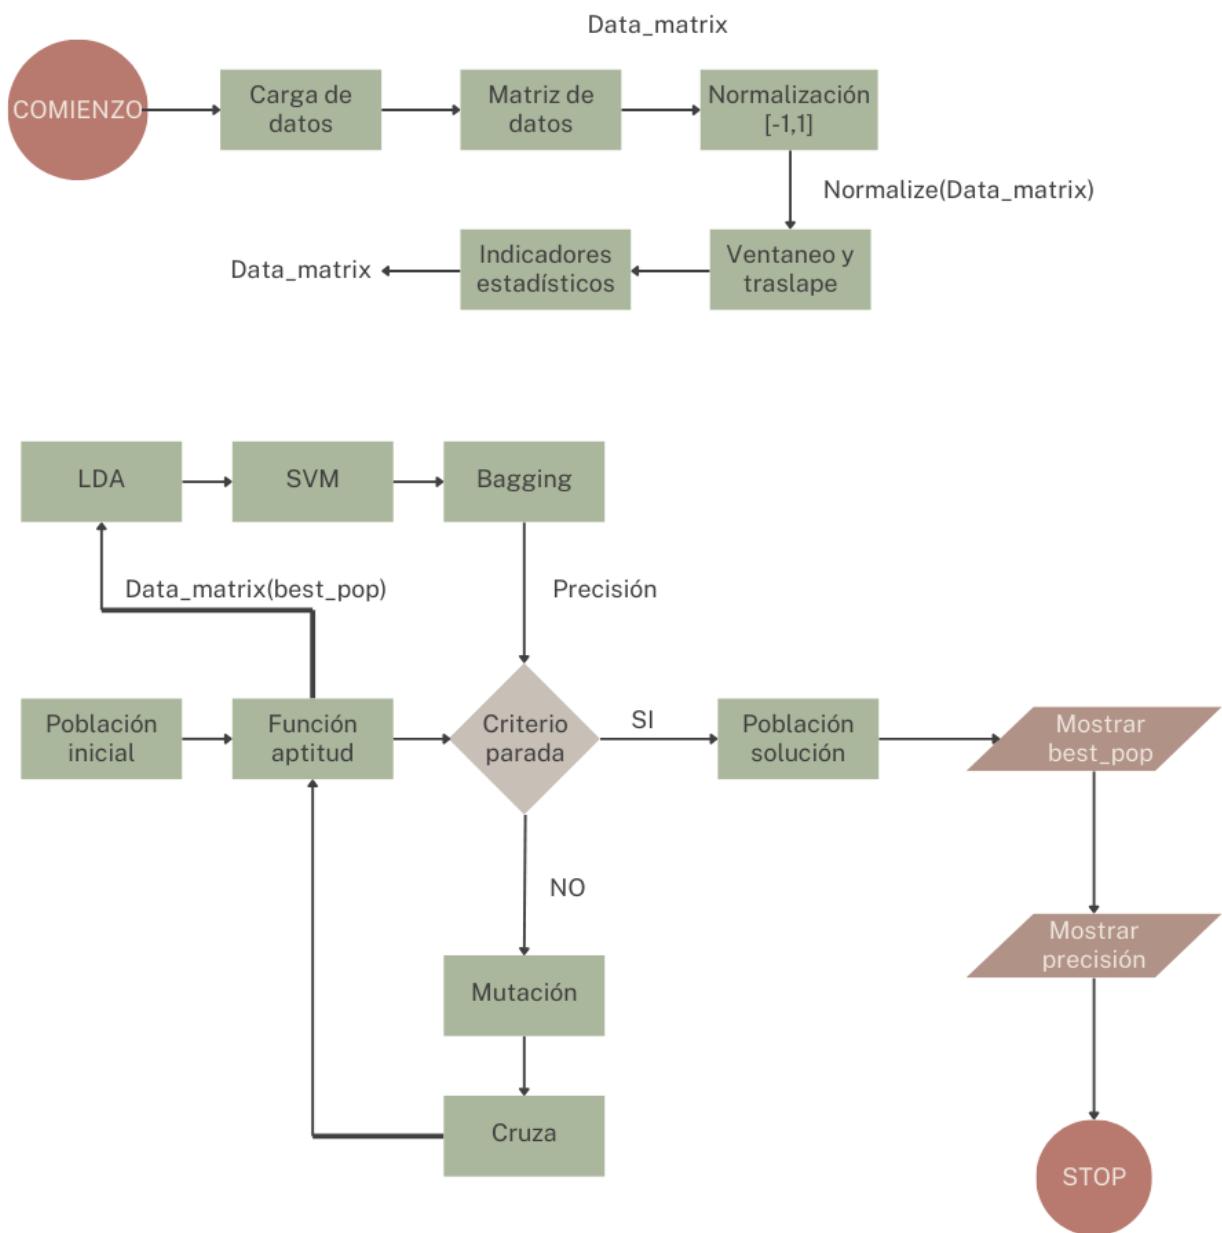


Figura 18 Diagrama de flujo del sistema implementado.

CAPÍTULO 4. RESULTADOS

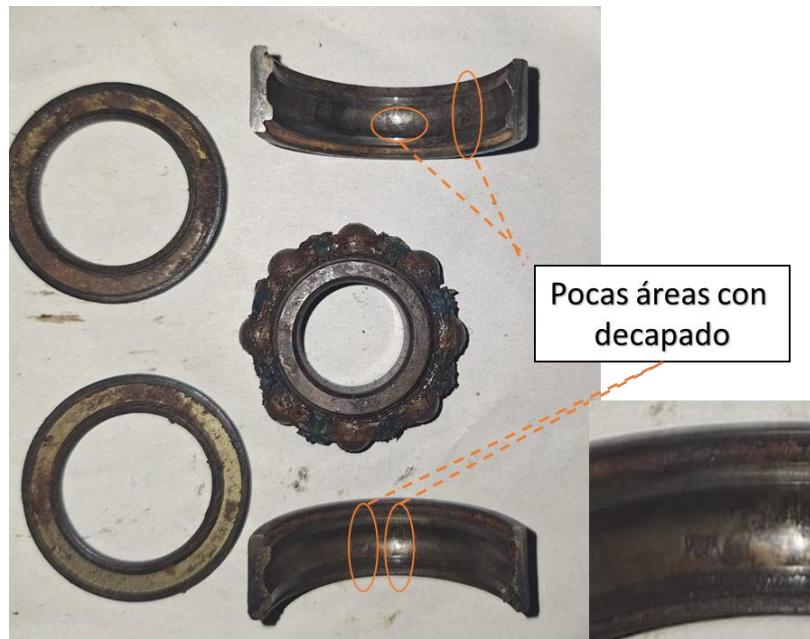
En la presente sección se presentan los resultados obtenidos a partir del análisis de las señales de flujo magnético de dispersión, vibraciones y corriente obtenidas por el motor de inducción bajo las tres condiciones analizadas, las cuales son el motor sano, la corrosión nivel 1 y la corrosión nivel 2, donde a manera de resumen, se realizó la detección de daño aplicando a las señales un procesamiento que incluye la aplicación de parámetros estadísticos y no estadísticos a estas señales ventaneadas y con el solapamiento, para posteriormente usar un algoritmo genético que entregue la mejor combinación de indicadores estadísticos de cada una de las señales analizadas de manera conjunta y que ofrezcan la precisión más alta, basada en el modelo de clasificación Bagging con SVM de clasificador base y reducción de dimensionalidad con LDA.

4.1 RODAMIENTOS BAJO FALLOS OBTENIDOS

En la Figura 19 se muestra el estado de los rodamientos sometidos a diferentes niveles de corrosión, donde la Figura 19a presenta un rodamiento con corrosión nivel 1, en el cual pueden identificarse áreas con signos iniciales de deterioro. El daño en este caso es bastante leve, caracterizado por la presencia de zonas con decapado y pérdida del material como lo muestran los manuales de rodamientos del SKF, analizados en la sección de literatura, pero sin afectar de manera significativa la estructura general del rodamiento, aún así, al presentar este tipo de corrosión significa que ya existe un daño estructural, tal vez no tan marcado o en un estado no tan grave, pero existente. Las áreas afectadas son limitadas y el patrón de daño es irregular, lo que indica que el proceso de corrosión ha comenzado, pero aún no ha progresado de manera crítica.

Por otro lado, en la Figura 19b se observa un rodamiento con corrosión nivel 2 donde el grado de daño es considerablemente mayor y donde las áreas afectadas muestran un decapado profundo y extenso, con una pérdida significativa de material en varias zonas de contacto. Este patrón de daño sugiere un estado bastante avanzado de corrosión en la que el desgaste y la pérdida del material han comprometido de manera notable el estado del rodamiento, lo que a corto plazo podría generar otro tipo de problemáticas más graves como paros inesperados o comprometer la vida del motor.

La comparación entre ambas figuras permite evidenciar la progresión del daño por corrosión, destacando la importancia de una detección temprana para evitar el deterioro severo de los componentes y garantizar un funcionamiento óptimo del motor de inducción, además, al presentar demasiadas zonas con daño, y en zonas no puntuales, realza la importancia de utilizar técnicas avanzadas, diferentes a las transformadas en frecuencia que son bastante útiles para detectar patrones de fallo.



a)



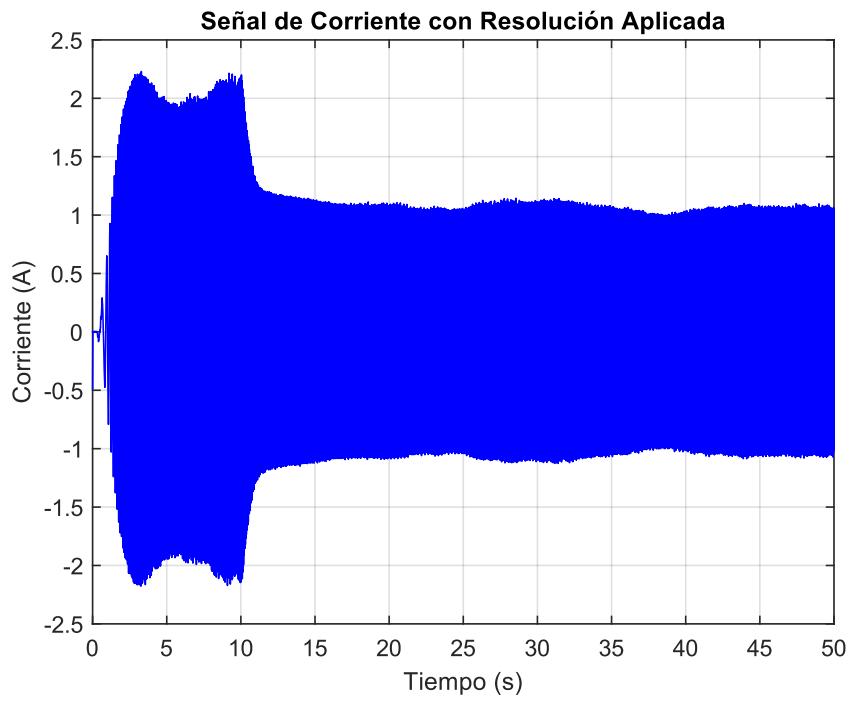
Figura 19 Rodamientos bajo a) corrosión nivel 1 y b) corrosión nivel 2.

4.2 SEÑALES EN EL TIEMPO OBTENIDAS

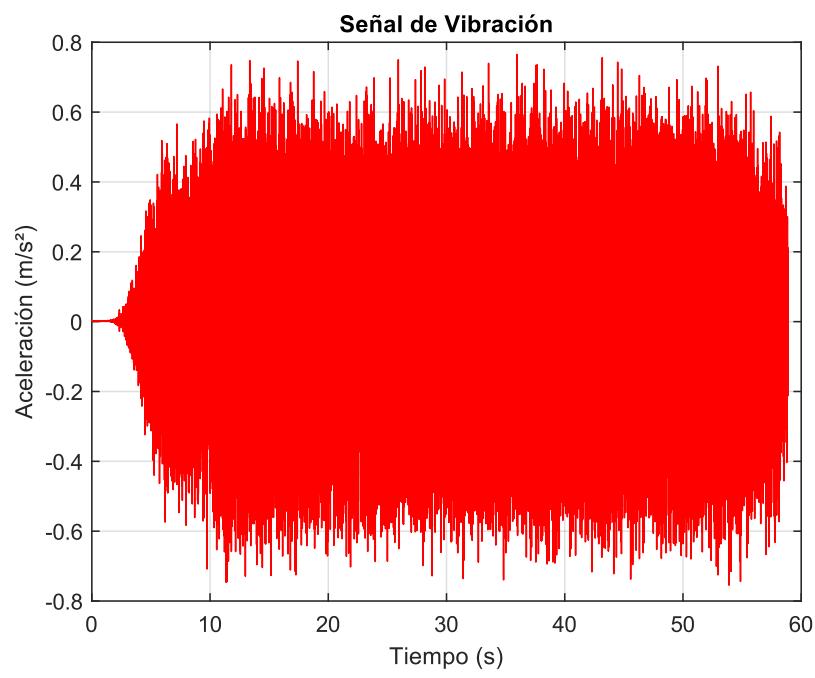
Ahora bien, la Figura 20 presenta las señales obtenidas de un motor de inducción bajo diferentes condiciones de operación, donde se muestra la respuesta en términos de corriente, vibraciones y flujo magnético de dispersión. En la Figura 20^a la cual es correspondiente a la señal de corriente, se puede observar un comportamiento estable y la presencia del estado estacionario tras el periodo transitorio inicial (todos estos datos son definidos en el variador de velocidad y cuyas especificaciones se mencionan anteriormente). Se puede observar que se alcanza el estado estable a los 10 segundos, donde las oscilaciones iniciales tienden a desaparecer y la señal de corriente mantiene una frecuencia y amplitud constantes reflejando un funcionamiento controlado y sin perturbaciones significativas.

En la Figura 20b se muestra la señal de vibraciones y se observa el comportamiento es notablemente más irregular y que, a diferencia de la señal de corriente, no se alcanza un estado estacionario claro, ya que las vibraciones presentan una dinámica compleja y fluctuaciones continuas en la amplitud. Finalmente, en la Figura 20c, correspondiente al flujo magnético de dispersión, se observa un comportamiento similar al de la corriente, con una fase inicial transitoria seguida de un estado estacionario

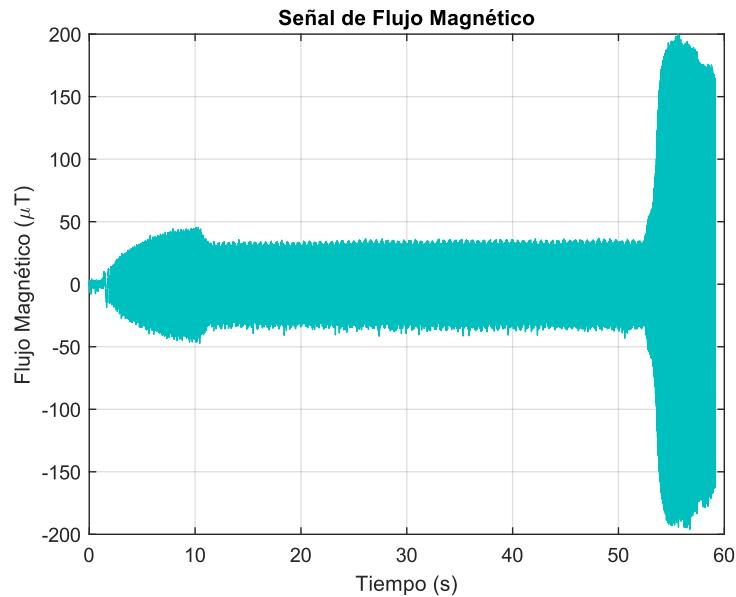
bien definido a los 10 segundos de iniciar las oscilaciones iniciales. La señal muestra una frecuencia estable y una amplitud constante, lo que indica que el campo magnético generado por el motor mantiene una configuración estable después del periodo inicial de ajuste. Esto refleja un adecuado comportamiento del sistema electromagnético, en el cual las pérdidas por dispersión magnética se mantienen controladas tras alcanzar el estado estable.



a)



b)

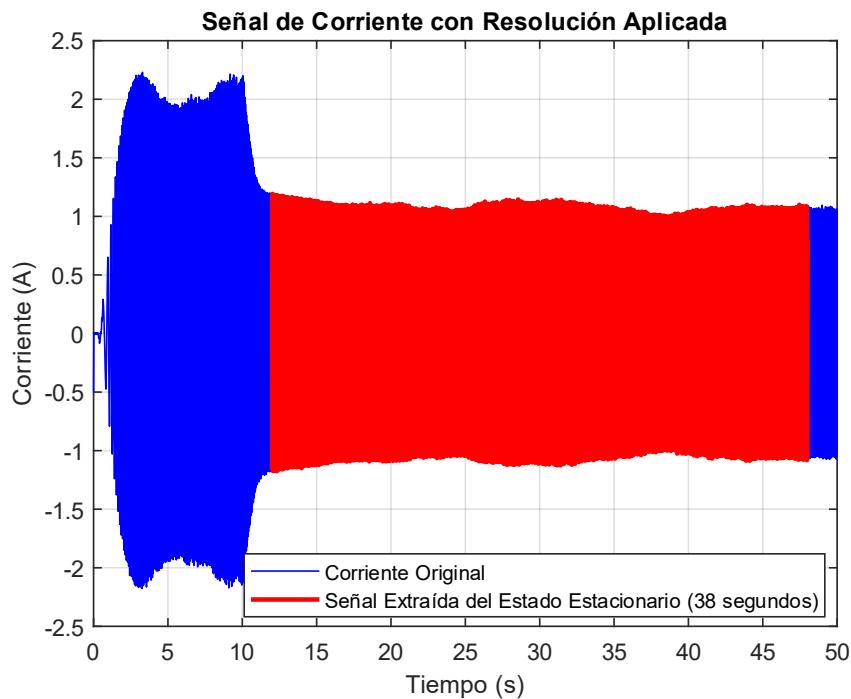


c)

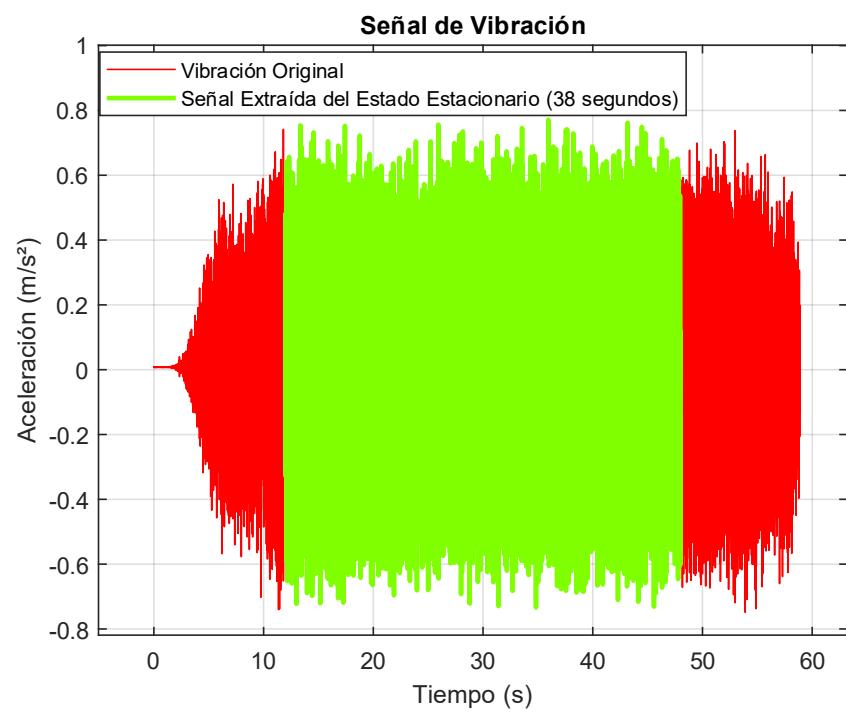
Figura 20 Señales en el tiempo de a) corriente, b) vibraciones y c) flujo magnético de dispersión.

4.3 MUESTRAS REPRESENTATIVAS DE LAS SEÑALES EN EL TIEMPO OBTENIDAS

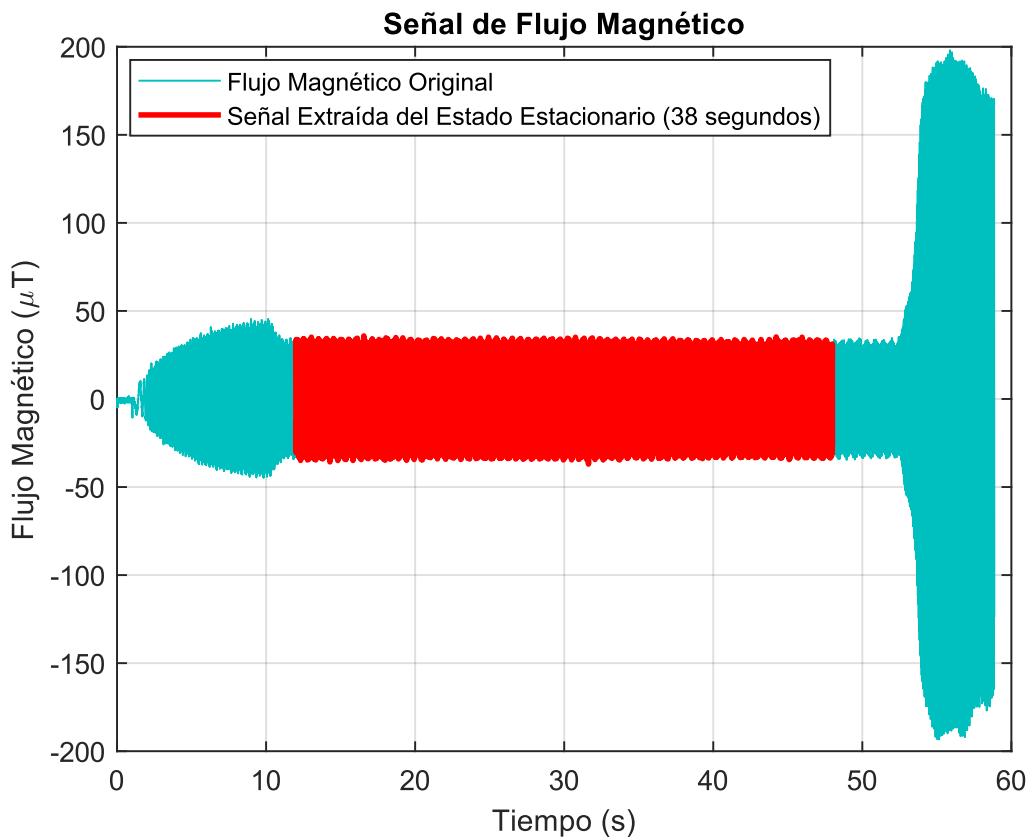
La Figura 21 muestra un segmento de 38 segundos del estado estable de las señales obtenidas del motor de inducción. Para este caso, es posible realizar un análisis tanto en el estado transitorio como en el estado estable para la detección de fallos; sin embargo, se optó por utilizar el estado estable debido a que en esta fase las señales presentan un comportamiento más uniforme y menos influenciado por efectos transitorios, lo que facilita la identificación de patrones asociados a condiciones de fallo. En la Figura 21a se presenta el segmento utilizado de la señal de corriente, en la Figura 21b el segmento de la señal de vibraciones, y en la Figura 21c el segmento de la señal de flujo magnético de dispersión, todas ellas corresponden al estado estable y seleccionadas específicamente para garantizar una evaluación representativa y confiable del comportamiento del motor.



a)



b)



c)

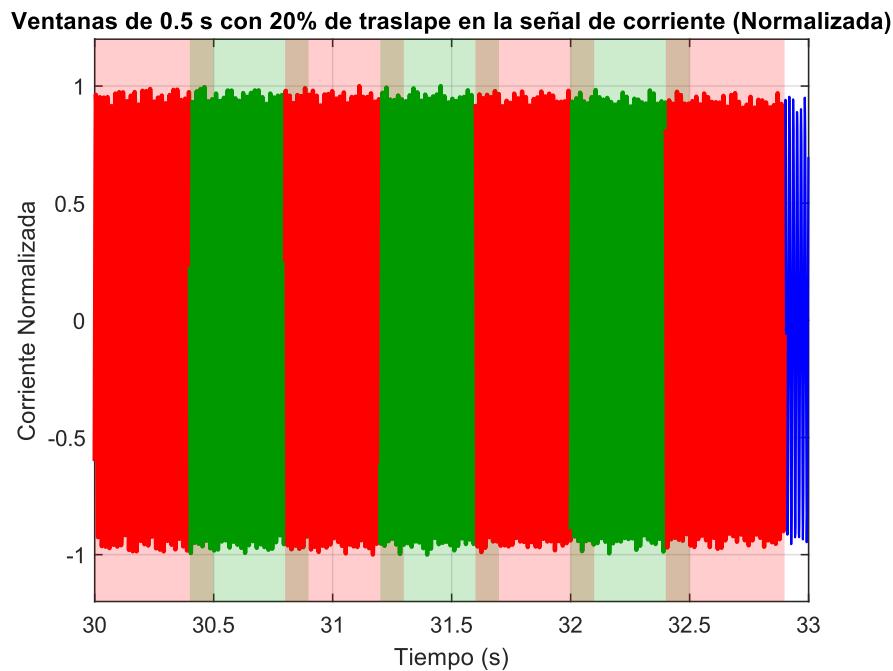
Figura 21 Segmentos analizados para señales de a) corriente, b) vibraciones y c) flujo magnético.

4.4 VENTANEO DE LAS SEÑALES ACOTADAS

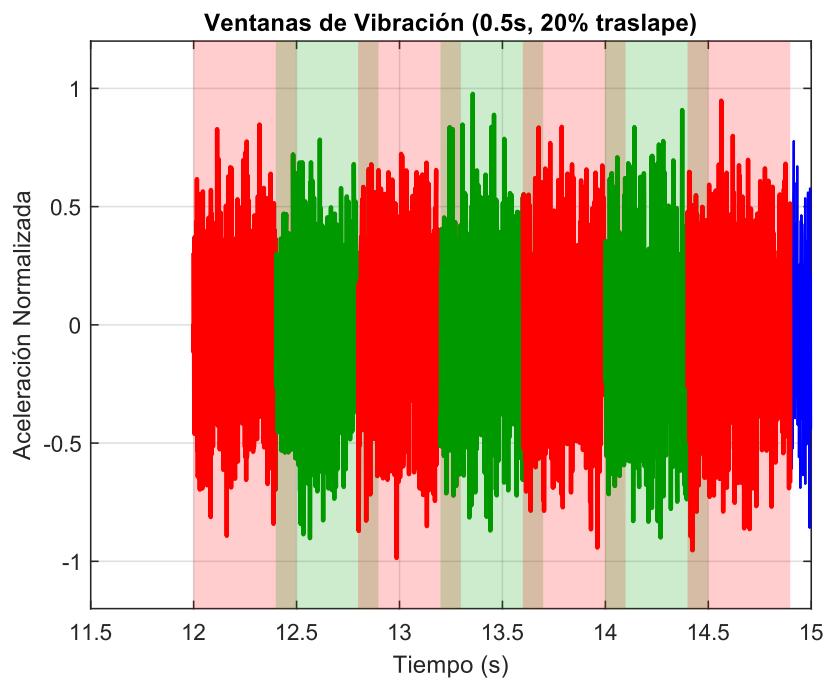
Para el análisis de las señales obtenidas, se aplicó un ventaneo sobre las muestras de datos, utilizando ventanas de 0.5 segundos con un solapamiento del 20% entre ellas, donde la frecuencia de muestreo de todas las señales fue de 1 kHz, lo que implica que cada ventana contiene 500 muestras realizando el cálculo. Dado que se realizaron un total de 10 pruebas, las señales correspondientes a estas pruebas fueron combinadas en una sola señal, lo que permitió un análisis más representativo de las condiciones del motor, teniendo múltiples datos y múltiples ventanas para analizar mediante todo el procesamiento con los indicadores estadísticos y finalmente, entregando una mejor confiabilidad en la precisión en la detección de daño.

El proceso de ventaneo es también bastante fundamental para analizar señales no estacionarias ya que permite observar las variaciones de la señal en intervalos más pequeños, permitiendo una mayor facilidad en la identificación de patrones o anomalías que podrían pasar desapercibidos bajo otras condiciones. Además al combinar todas las señales estacionarias en una sola, se logra capturar una mayor cantidad de información y se reduce el riesgo de perder detalles importantes, lo que resulta en un análisis más completo y fiable.

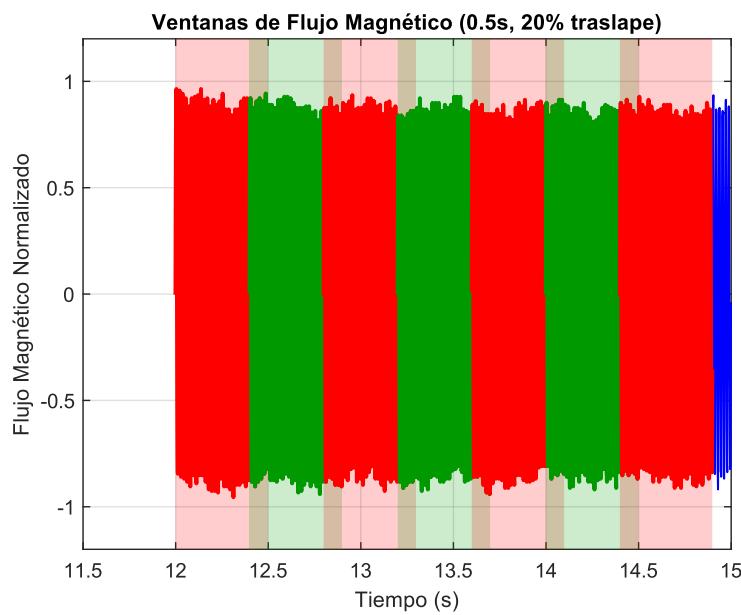
A cada ventana obtenida se le aplicaron los indicadores estadísticos y no estadísticos mostrados en la Tabla 1, los cuales incluyen parámetros como la media, desviación estándar como parámetros estadísticos y energía, complejidad, entre otros, como parámetros no estadísticos. Estos indicadores permiten extraer características clave de la señal que facilitarán la clasificación del estado del motor y la detección de posibles fallos en los rodamientos y otros componentes. Por otro lado, el ventaneo, junto con la aplicación de estos indicadores optimiza el proceso de diagnóstico mejorando la precisión en la identificación de anomalías. La Figura 22 muestra una representación de cómo se obtienen las ventanas con su respectivo solapamiento del 20%, a cada una de esas ventanas se le calculan todos los indicadores estadísticos para 21a corriente, 21b vibraciones y 21c flujo magnético de dispersión.



a)



b)



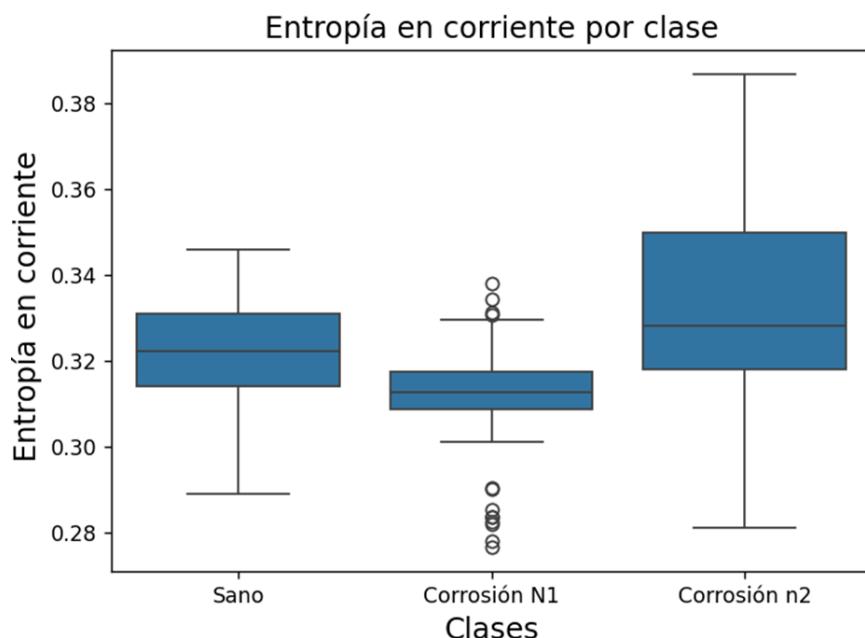
c)

Figura 22 Ventaneo y solapamiento de las señales de a) corriente, b) vibraciones y c) flujo magnético de dispersión.

4.5 APLICACIÓN DE ANÁLISIS ANOVA DE PARÁMETROS ESTADÍSTICOS Y NO ESTADÍSTICOS

La Figura 23 muestra el análisis ANOVA aplicado a dos indicadores, la entropía Figura 23a y la curtosis Figura 23b. Este análisis se realizó con el propósito de ilustrar la dificultad para la separación y detección de fallos únicamente utilizando indicadores estadísticos y no estadísticos. Como se puede observar en las gráficas de cajas, las distribuciones de los valores correspondientes a las diferentes condiciones de operación (rodamientos sanos, corrosión nivel 1 y corrosión nivel 2) están muy próximas entre sí, lo que dificulta la identificación clara de las diferencias entre los estados del motor utilizando exclusivamente estos parámetros.

Este resultado muestra la limitación de basarse únicamente en estadísticas básicas para la detección de fallos, ya que, aunque la entropía y la curtosis ofrecen información relevante sobre el comportamiento de la señal, no son suficientes por sí solas para distinguir de manera eficaz entre las diferentes condiciones de funcionamiento del motor. Para los demás parámetros estadísticos y no estadísticos, se obtuvo un comportamiento similar al presentado en la Figura 23, por lo tanto, es fundamental recurrir a técnicas más avanzadas y utilizar un conjunto más amplio de datos para mejorar la precisión del diagnóstico.



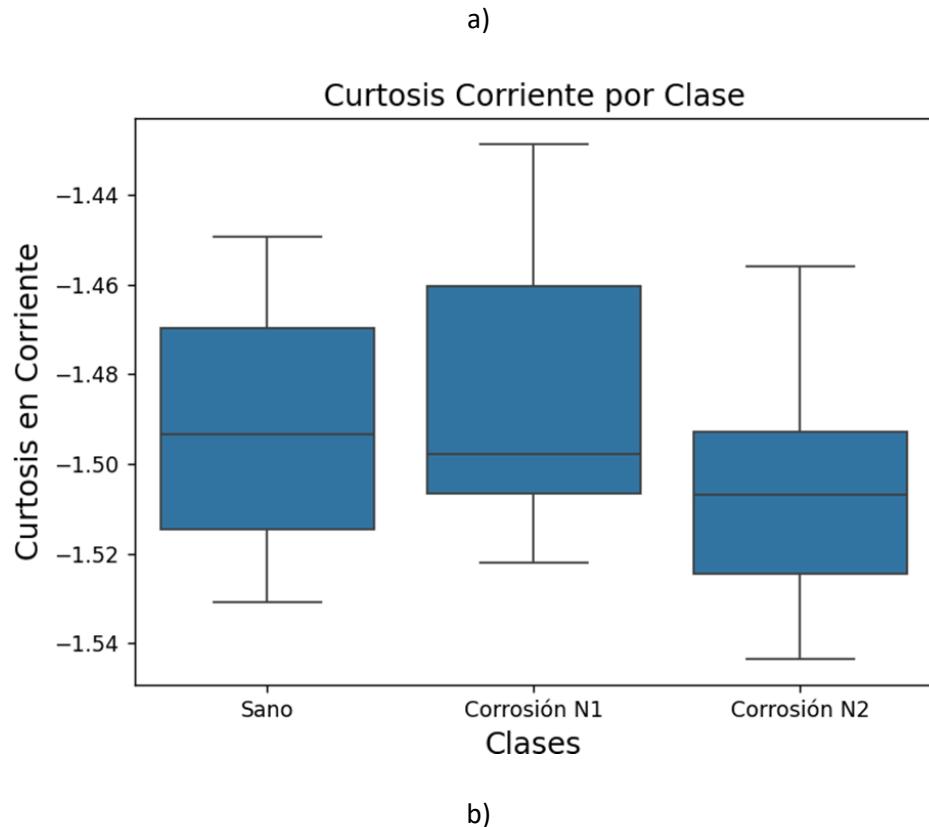


Figura 23 Análisis de varianza para señal de corriente con a) entropía de muestreo y b) curtosis.

4.6 MEJOR COMBINACIÓN DE INDICADORES OBTENIDA Y ANÁLISIS DISCRIMINANTE LINEAL

Del algoritmo genético se obtuvo como mejor combinación un vector donde cada '0' indica que el indicador no se usa y el '1' indica que si debe ser usado. Los indicadores estadísticos obtenidos en la mejor combinación son los siguientes:

- Corriente: entropía.
- Vibraciones x: Curtosis, RMS, Teager-Kaiser.
- Vibraciones y: Curtosis, desviación estándar, RMS, Teager-Kaiser y entropía.
- Vibraciones z: Curtosis, RMS y entropía.

- Flujo magnético x: RMS y entropía.
- Flujo magnético y: No utilizó.
- Flujo magnético en z: Desviación estándar y RMS.

Dada esta mejor combinación de indicadores estadísticos y no estadísticos que resultó del proceso de optimización mediante el algoritmo genético, se procedió a realizar la gráfica de Análisis Discriminante Lineal (LDA) utilizando las dos características más relevantes identificadas durante el proceso de selección, se muestra en la Figura 24. El LDA es una técnica estadística que busca proyectar las características de una señal en un espacio de menor dimensión, con el objetivo de maximizar la separación entre las diferentes clases, en este caso, entre los rodamientos sanos y los dañados (con corrosión de nivel 1 y nivel 2).

Es importante señalar que este análisis se llevó a cabo sobre el conjunto de entrenamiento, el cual se obtuvo a partir de la división de los datos en un 70% para entrenamiento y un 30% para prueba. Esta división es crucial, ya que permite evaluar el modelo de clasificación de manera objetiva y evitar el sobreajuste a los datos. El LDA, aplicado sobre las características seleccionadas del conjunto de entrenamiento, mostró una separación más clara entre las diferentes condiciones del motor. La selección de las dos mejores características fue fundamental, ya que el algoritmo genético permitió identificar aquellos indicadores que ofrecían la mayor capacidad discriminativa. Al aplicar el LDA sobre estas características seleccionadas, se generó una visualización que permite observar cómo las diferentes condiciones del motor (sano, corrosión nivel 1, corrosión nivel 2) se agrupan en un espacio de características reducido. Este análisis de LDA resalta la efectividad del proceso de selección de características ya que muestra una mayor distinción entre los estados del motor en comparación con los análisis previos, donde los indicadores estadísticos y no estadísticos por sí solos no lograban una separación clara.

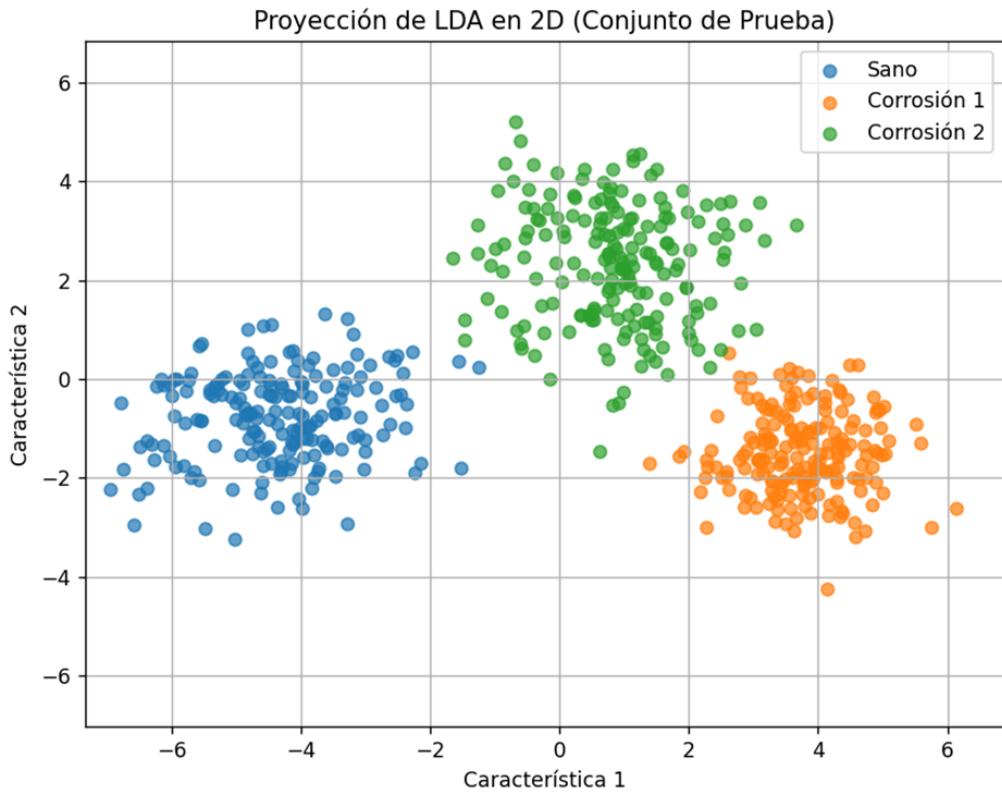


Figura 24 Análisis Discriminante Lineal con el mejor conjunto obtenido en el algoritmo genético.

4.7 RESULTADOS TRAS ANÁLISIS BAGGING

Al someter el conjunto de prueba al análisis del Análisis Discriminante Lineal junto con el análisis de Bagging utilizando una Máquina de Soporte Vectorial y el mejor conjunto de características encontrado mediante el algoritmo genético, se obtuvo la matriz de confusión mostrada en la Figura 25. Este análisis resultó en una precisión superior al 99%, lo que refleja la efectividad del enfoque utilizado en este trabajo.

De igual manera, la combinación de LDA y Bagging con SVM permitió maximizar la capacidad discriminativa entre las distintas condiciones de los rodamientos, demostrando la robustez del modelo ante datos previamente no vistos y el uso del algoritmo genético para seleccionar el mejor conjunto de

características jugó un papel fundamental en esta alta precisión, ya que eliminó redundancias y optimizó el rendimiento del clasificador, enfocándose únicamente en las características más relevantes.

El hecho de alcanzar una precisión superior al 99% resalta la capacidad del modelo para realizar una clasificación precisa y confiable, incluso en condiciones complejas de fallos de los rodamientos y, demuestra que el enfoque combinado, que integra técnicas avanzadas de análisis y aprendizaje automático, ofrece una solución eficiente y efectiva para la detección de fallos en motores de inducción, siendo así, una herramienta valiosa para la detección de condiciones de máquinas en entornos industriales.

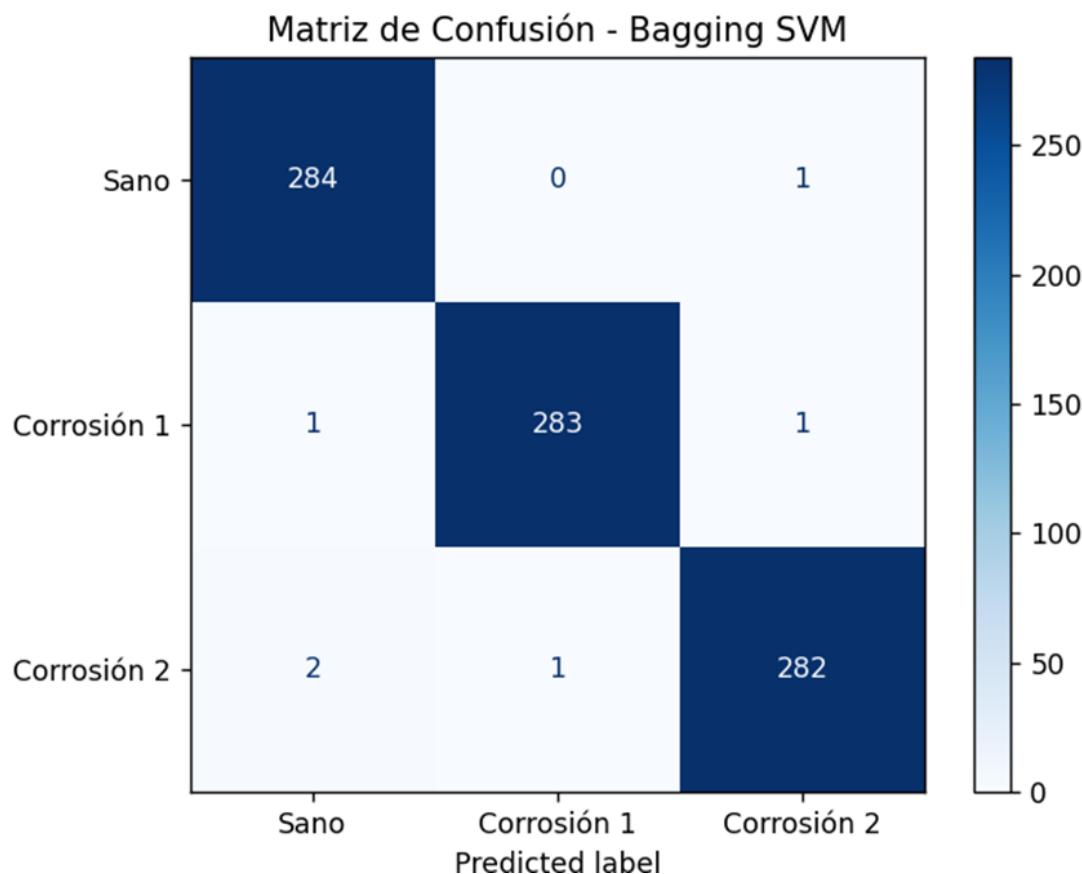


Figura 25 Matriz de confusión obtenida tras análisis del conjunto de prueba con los datos de entrenamiento para la metodología propuesta.

4.8 ANÁLISIS COMPARATIVO DE LA METODOLOGÍA PROPUESTA

La Tabla 6 muestra los resultados de cuatro configuraciones principales, etiquetadas desde E1 hasta E4, las cuales fueron realizadas con base en los parámetros estadísticos y el algoritmo genético para seleccionar la mejor combinación de parámetros. A continuación, se describen los resultados de cada configuración:

- E1: En este caso, se utilizó Análisis Discriminante Lineal (LDA) junto con SVM alimentando al Bagging. Esta combinación logró una precisión de 99.4% y una tasa de sobreajuste relativo de 0.0832%, lo que refleja una excelente capacidad de generalización del modelo y un rendimiento superior en la clasificación de fallos en rodamientos.
- E2: En esta configuración, solo se empleó SVM, pero sin la técnica de Bagging. Se obtuvo una precisión de 99.3% y una tasa de sobreajuste relativa de 0.251%. Aunque la precisión es ligeramente inferior a la de E1, la tasa de sobreajuste es más alta, lo que indica un mayor riesgo de que el modelo se ajuste demasiado a los datos de entrenamiento, comprometiendo su capacidad de generalización.
- E3: Aquí no se utilizó LDA, pero sí SVM y Bagging, obteniendo una precisión de 85.55% y una tasa de sobreajuste relativa de 1.198%. Aunque la precisión es considerablemente menor que en las configuraciones anteriores, el modelo sigue mostrando cierto rendimiento, pero con una tasa de sobreajuste ligeramente más alta.
- E4: En esta configuración, tampoco se utilizó LDA ni Bagging, y solo se empleó SVM. Esta combinación resultó en una precisión de 44.84% y una tasa de sobreajuste relativa de 0.845%, lo que indica un rendimiento muy bajo.

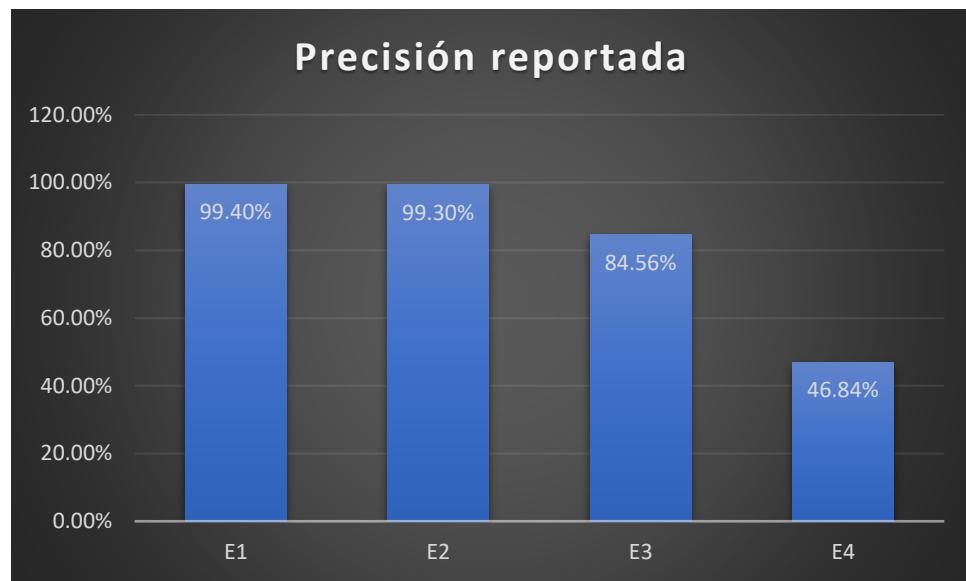
La configuración E1, que es la propuesta para este trabajo, y que combina LDA, SVM y Bagging, ofrece la mejor precisión y la menor tasa de sobreajuste, lo que la convierte en el enfoque más efectivo para la detección de fallos en los rodamientos. Además, el uso del enfoque Bagging resalta su importancia, ya que mejora significativamente la precisión del modelo, además, se resalta la importancia del modelo Bagging, ya que cuando no se usa ni LDA ni esta técnica, la precisión reportada obtenida fue la menor de todas las combinaciones realizadas.

Tabla 6 Comparativa entre bloques de la metodología propuesta.

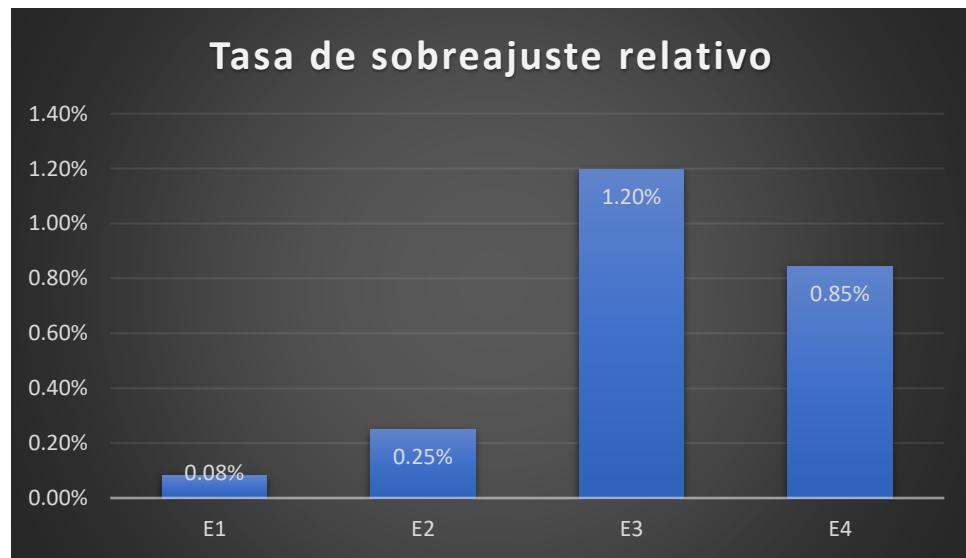
Etiqueta	Análisis Discriminante lineal	Máquina de soporte vectorial	Bagging	Precisión reportada (%)	Tasa de sobreajuste relativo (%)
E1	1	1	1	99.4	0.0832
E2	1	1	0	99.3	0.251
E3	0	1	1	84.56	1.198
E4	0	1	0	46.84	0.845

La Figura 26 muestra una gráfica que ilustra los resultados previamente mencionados dada la Tabla 6. En esta se puede observar claramente una mejor tendencia en la configuración E1, que corresponde a la metodología propuesta. Esta tendencia refleja un rendimiento superior, con una precisión más alta y una menor tasa de sobreajuste, lo que confirma la efectividad de la combinación de LDA, SVM y Bagging en la detección de fallos en los rodamientos. La diferencia en la tendencia se destaca en comparación con las otras configuraciones, evidenciando que la metodología propuesta proporciona los mejores resultados en términos de clasificación y generalización. Por otro lado, las configuraciones E2, E3 y E4 presentan una mayor tendencia al sobreajuste, lo que puede indicar que el modelo se ajusta excesivamente a los datos de entrenamiento y pierde capacidad de generalización. En particular, el caso E4, muestra una precisión baja acompañada de un sobreajuste considerable. Esto sugiere que el modelo tiene dificultades para clasificar correctamente nuevas muestras, lo que podría derivar en errores significativos durante el uso del algoritmo en condiciones reales.

El sobreajuste observado en E2, E3 y E4 puede ser consecuencia de una selección inadecuada de características o de una complejidad excesiva en el modelo, lo que impide que este generalice correctamente los patrones en los datos. Finalmente, la metodología propuesta en E1 demuestra una mejor relación entre precisión y generalización, asegurando una clasificación más confiable y robusta en la detección de fallos.



a)



b)

Figura 26 Gráficos representativos para comparar la metodología propuesta en a) precisión y b) tasa de sobreajuste relativo..

4.9 COMPARATIVA CON OTRAS METODOLOGÍAS

La Tabla 7 presenta una comparativa entre la metodología propuesta y otras metodologías existentes en la literatura para la detección de fallos en rodamientos de motores de inducción. Como se observa en la tabla, la metodología propuesta alcanza una precisión superior, lo que la posiciona como la opción más eficaz para este tipo de tareas. Además, las otras metodologías que se comparan en la tabla se enfocan en el análisis de fallos puntuales, lo cual las hace menos efectivas para detectar patrones generales de fallo, ya que no logran abarcar la complejidad de los comportamientos de las señales en su totalidad. En cambio, la metodología propuesta tiene en cuenta una combinación más robusta de indicadores estadísticos y no estadísticos, y emplea técnicas avanzadas como el LDA, SVM y Bagging, lo que le permite detectar fallos de manera más precisa y con mayor capacidad de generalización. Esta ventaja se refleja no solo en los resultados numéricos obtenidos, sino también en la menor tasa de sobreajuste, lo que demuestra que el enfoque propuesto tiene una mayor capacidad predictiva y es más confiable en diferentes condiciones.

Tabla 7 Comparativa con otras metodologías.

Metodología usada	Precisión obtenida (%)	Tipo de fallo	Observaciones
Metodología propuesta (Bagging, LDA, SVM)	99.4	Corrosión por humedad	Corrosión respecto a manual SKF
Zhang et al. (2015)	92	Puntual	Corrosión por picadura en bolas
Sharma et al. (2015)	88-98	Puntual	Corrosión por picadura en bolas
Navarro et al. (2023)	>90	Corrosión por humedad	Motor de reluctancia síncrona.
F.G.M Herrera et al. (2023)	78.9	Puntual	Corrosión por picadura en bolas
Aldeoes et al. (2021)	91-96	Puntual	Daño en pista interna
Nakamura et al. (2022)	<96	Puntual	Daño en pista interna

CAPÍTULO 5. CONCLUSIONES Y PROSPECTIVAS

En esta sección se presentan las conclusiones derivadas de los resultados obtenidos, así como las posibles líneas de trabajo futuro. El análisis de las señales de flujo magnético de dispersión, vibraciones y corriente mediante técnicas de reducción de dimensionalidad y clasificación permitió detectar con alta precisión las condiciones de operación del motor de inducción. La combinación de Análisis Discriminante Lineal (LDA), Máquinas de Soporte Vectorial (SVM) y el algoritmo de ensamblaje Bagging demostró ser una estrategia eficaz para la detección de fallos en rodamientos, alcanzando una precisión de más del 99%. Además, el uso de indicadores estadísticos y no estadísticos, optimizados mediante un algoritmo genético, permitió identificar las características más relevantes para el diagnóstico de fallos. Las prospectivas de este trabajo incluyen la implementación de estos métodos en tiempo real y la evaluación de su desempeño en condiciones de operación variables, lo que abriría la posibilidad de desarrollar sistemas de monitoreo y mantenimiento predictivo más robustos y eficientes.

5.1 CONCLUSIONES

El presente trabajo abordó el problema de detección de corrosión en rodamientos de motores de inducción mediante la implementación de técnicas avanzadas de clasificación y optimización. A partir de los resultados obtenidos, se pueden extraer las siguientes conclusiones.

Se evidenció que el análisis directo de los datos mediante técnicas estadísticas tradicionales, como ANOVA, resulta insuficiente para la correcta separación de las clases en el problema abordado. Al evaluar las características extraídas, tanto estadísticas como no estadísticas, se observó que no presentan una diferenciación clara con respecto a sus clases cuando se aplican métodos convencionales de análisis de varianza. Esto sugiere que la relación entre las características y las clases no es fácilmente distinguible mediante enfoques tradicionales, lo que dificulta la interpretación de los datos y la construcción de modelos de clasificación precisos.

Dada esta problemática, se concluye que es necesario recurrir a técnicas avanzadas de procesamiento y clasificación. En este estudio, se desarrolló un modelo basado en la combinación de Análisis Discriminante Lineal (LDA), Bagging y Máquinas de Vectores de Soporte (SVM), optimizado

mediante Algoritmos Genéticos. LDA permitió una mejor proyección de los datos en un espacio donde las clases son más separables, mientras que Bagging y SVM contribuyeron a reducir la varianza y mejorar la capacidad de clasificación del modelo. La aplicación de Algoritmos Genéticos optimizó la selección de características, mejorando la precisión del modelo y reduciendo su complejidad.

El análisis comparativo mostró que el modelo propuesto supera en precisión a enfoques convencionales reportados en la literatura. En particular, se observó que el uso exclusivo de SVM, tanto con como sin LDA, presentó menores precisiones en comparación con la estrategia combinada con Bagging, lo que confirma que la integración de técnicas de reducción de dimensionalidad y ensamble mejora significativamente el desempeño del modelo.

Asimismo, la implementación de Bagging contribuyó a reducir la tasa de sobreajuste relativo (TSR), lo que mejoró la capacidad de generalización del modelo. Al entrenar múltiples clasificadores sobre subconjuntos de datos y combinar sus predicciones, Bagging disminuyó la varianza y redujo el impacto de patrones específicos del conjunto de entrenamiento, logrando un rendimiento más estable en datos de prueba.

Finalmente, los resultados obtenidos validan la efectividad del modelo implementado para la detección de corrosión en rodamientos de motores de inducción bajo condiciones reales de operación. La combinación de técnicas de reducción de dimensionalidad, ensamble y clasificación permitió desarrollar un sistema robusto, con alta capacidad de generalización, adecuado para aplicaciones industriales y de mantenimiento predictivo.

5.2 PROSPECTIVAS

- Optimización de hiperparámetros: Ajustar parámetros en Bagging y SVM para mejorar la precisión en la detección de corrosión en motores de inducción.
- Validación en entornos reales: Probar el modelo en una planta industrial para evaluar su robustez ante ruido, vibraciones y variaciones de operación.
- Integración de nuevas técnicas: Aplicar filtros digitales avanzados y explorar redes neuronales para mejorar la extracción de características y la clasificación.

REFERENCIAS BIBLIOGRAFICAS

- Abiodun, O. I., Jantan, A., Omolara, A. E., Dada, K. V., Mohamed, N. A., & Arshad, H. (2018). State-of-the-art in artificial neural network applications: A survey. *Heliyon*, 4(11).
- Aldeoes, Y. N., Ghockle, P., & Sondkar, S. Y. (2021). Comparison of Machine Learning Algorithms for Bearing Failures Classification and Prediction. In *International Conference on Advances in Electrical and Computer Technologies* (pp. 269-282). Singapore: Springer Nature Singapore.
- Anowar, F., Sadaoui, S., & Selim, B. (2021). Conceptual and empirical comparison of dimensionality reduction algorithms (pca, kpca, lda, mds, svd, lle, isomap, le, ica, t-sne). *Computer Science Review*, 40, 100378.
- Bazurto, A. J., Quispe, E. C., & Mendoza, R. C. (2016). Causes and failures classification of industrial electric motor. In *2016 IEEE ANDESCON* (pp. 1-4). IEEE.
- Bhavsar, K., Vakharia, V., Chaudhari, R., Vora, J., Pimenov, D. Y., & Giasin, K. (2022). A comparative study to predict bearing degradation using discrete wavelet transform (DWT), tabular generative adversarial networks (TGAN) and machine learning models. *Machines*, 10(3), 176.
- Castellino, A. M., Donolo, P. D., Bossio, G. R., De Angelo, C. H., & García, G. (2007). Diagnóstico de fallas en los rodamientos de motores eléctricos empleando variables eléctricas. *XII Reunión de Trabajo en Procesamiento de la Información y Control*, 6.
- Chapman, S. (2012). *Máquinas eléctricas*. Mc Graw Hill.
- Chen, X., Xu, W., Liu, Y., & Islam, M. R. (2019). Bearing corrosion failure diagnosis of doubly fed induction generator in wind turbines based on stator current analysis. *IEEE Transactions on Industrial Electronics*, 67(5), 3419-3430.
- Esakimuthu Pandarakone, S., Mizuno, Y., & Nakamura, H. (2019). A comparative study between machine learning algorithm and artificial intelligence neural network in detecting minor bearing fault of induction motors. *Energies*, 12(11), 2105.
- Farid, D. M., Rahman, M. Z., & Rahman, C. M. (2011). An ensemble approach to classifier construction based on bootstrap aggregation. *International Journal of Computer Applications*, 25(5), 30-34.
- Gangsar, P., & Tiwari, R. (2020). Signal based condition monitoring techniques for fault detection and diagnosis of induction motors: A state-of-the-art review. *Mechanical systems and signal processing*, 144, 106908.
- Garcia, M., Panagiotou, P. A., Antonino-Daviu, J. A., & Gyftakis, K. N. (2018). Efficiency assessment of induction motors operating under different faulty conditions. *IEEE Transactions on Industrial Electronics*, 66(10), 8072-8081.

Gavrila, H., Manescu, V., Paltanea, G., Scutaru, G., & Peter, I. (2017). New trends in energy efficient electrical machines. *Procedia Engineering*, 181, 568-574.

Kalirane, M. (2023, enero 20). *Ensemble learning in Machine learning: Bagging, boosting and stacking*. Analytics Vidhya. <https://www.analyticsvidhya.com/blog/2023/01/ensemble-learning-methods-bagging-boosting-and-stacking/>.

Kankar, P. K., Sharma, S. C., & Harsha, S. P. (2011). Fault diagnosis of ball bearings using machine learning methods. *Expert Systems with applications*, 38(3), 1876-1886.

Kankar, P. K., Sharma, S. C., & Harsha, S. P. (2012). Vibration-based fault diagnosis of a rotor bearing system using artificial neural network and support vector machine. *International Journal of Modelling, Identification and Control*, 15(3), 185-198.

Kumar, P., & Hati, A. S. (2021). Review on machine learning algorithm-based fault detection in induction motors. *Archives of Computational Methods in Engineering*, 28(3), 1929-1940.

Lin, S. L. (2021). Application of machine learning to a medium Gaussian support vector machine in the diagnosis of motor bearing faults. *Electronics*, 10(18), 2266.

Li, Z., & Yan, X. (2013). Study on data fusion of multi-dimensional sensors for health monitoring of rolling bearings. *Insight-Non-Destructive Testing and Condition Monitoring*, 55(3), 147-151.

Mehta, A., Goyal, D., Choudhary, A., Pabla, B. S., & Belghith, S. (2021). Machine learning-based fault diagnosis of self-aligning bearings for rotating machinery using infrared thermography. *Mathematical Problems in Engineering*, 2021, 1-15.

Nakamura, H.; Mizuno, Y. Diagnosis for Slight Bearing Fault in Induction Motor Based on Combination of Selective Features and Machine Learning. *Energies* 2022, 15, 453.

Navarro-Navarro, A., Biot-Monterde, V., Ruiz-Sarrió, J. E., Antonino-Daviu, J., Osornio-Rios, R. A., & Zamudio-Ramirez, I. (2023). Detection of Corrosion in Ball Bearings in Synchronous Reluctance Motors through the Computation of Statistical Indicators of Current Signals. In *2023 IEEE 14th International Symposium on Diagnostics for Electrical Machines, Power Electronics and Drives (SDEMPED)* (pp. 530-534). IEEE.

Nava, D., & Pardo, P. (Eds.). (2023). *La generación eléctrica se dirige hacia un aumento en el uso de fuentes fósiles*. Expansión. <https://expansion.mx/empresas/2023/10/12/generacion-electrica-dirige-fuentes-fosiles>.

Safizadeh, M. S., & Latifi, S. K. (2014). Using multi-sensor data fusion for vibration fault diagnosis of rolling element bearings by accelerometer and load cell. *Information fusion*, 18, 1-8.

Saha, D. K., Hoque, M. E., & Badihi, H. (2022). Development of intelligent fault diagnosis technique of rotary machine element bearing: a machine learning approach. *Sensors*, 22(3), 1073.

- Samanta, B. I. S. W. A. J. I. T., Al-Balushi, K. R., & Al-Araimi, S. A. (2003). Artificial neural networks and support vector machines with genetic algorithm for bearing fault detection. *Engineering applications of artificial intelligence*, 16(7-8), 657-665.
- Sathujoda, P. (2021). A novel corrosion detection method using wavelet transformed mode shapes of a functionally graded rotor-bearing system. *Composites Part C: Open Access*, 5, 100134.
- Sharma, A., Amarnath, M., & Kankar, P. K. (2016). Feature extraction and fault severity classification in ball bearings. *Journal of Vibration and Control*, 22(1), 176-192.
- Sharma, S., Abed, W., Sutton, R., & Subudhi, B. (2015). Corrosion fault diagnosis of rolling element bearing under constant and variable load and speed conditions. *IFAC-PapersOnLine*, 48(30), 49-54.
- SKF. (2017). Skf.com. Recuperado el 15 de abril de 2024, de <https://www.skf.com/mx/products/rolling-bearings/bearing-failure-and-how-to-prevent-it>.
- Szabó, L. (2019). A survey on the efficiency improves of electrical machines. In *2019 26th International Workshop on Electric Drives: Improvement in Efficiency of Electric Drives (IWED)* (pp. 1-6). IEEE.
- Tao, J., Liu, Y., & Yang, D. (2016). Bearing fault diagnosis based on deep belief network and multisensor information fusion. *Shock and vibration*, 2016.
- Varela-Arregoces, E., & Campbells, E. (2011). Redes Neuronales Artificiales: una revisión del estado del arte, aplicaciones y tendencias futuras. *Investigación y Desarrollo en TIC*, 2(1), 18-27.
- Yadav, E., & Chawla, V. K. (2022). An explicit literature review on bearing materials and their defect detection techniques. *Materials Today: Proceedings*, 50, 1637-1643.
- Yani, I., Resti, Y., & Burlan, F. (2018). Identification of bearing failure using signal vibrations. In *Journal of Physics: Conference Series* (Vol. 1007, No. 1, p. 012067). IOP Publishing.
- Yoshioka, T., & Shimizu, S. (2009). Monitoring of ball bearing operation under grease lubrication using a new compound diagnostic system detecting vibration and acoustic emission. *Tribology Transactions*, 52(6), 725-730.
- Zamudio-Ramírez, I., Biot-Monterde, V., Navarro-Navarro, A., Antonino-Daviu, J., Osornio-Rios, R. A., Mäki-Ontto, P., ... & Fajt, T. (2022). Detection of corrosion in ball bearings through the computation of statistical indicators of stray-flux signals. In *IECON 2022–48th Annual Conference of the IEEE Industrial Electronics Society* (pp. 1-6). IEEE.
- Zhang, B., Xu, L. J., & Sun, H. (2020). A Fault Diagnosis Method for Single Pitting Corrosion of Rotating Machinery Bearing Based on Wavelet Analysis. In *2020 International Conference on Robots & Intelligent System (ICRIS)* (pp. 55-59). IEEE.

Zhang, Y., Shi, H., Zhou, X., & Zheng, Z. (2015). Vibration analysis approach for corrosion pitting detection based on SVDD and PCA. In *2015 IEEE International Conference on Cyber Technology in Automation, Control, and Intelligent Systems (CYBER)* (pp. 1534-1538). IEEE.

ANEXOS

ANEXO 1: Trabajo publicado en el XVIII Coloquio de Posgrado en el libro Innovación Sustentable: IA al Servicio del Planeta

Se realizó la publicación del trabajo de investigación en el XVIII Coloquio de Posgrado celebrado en la Universidad Autónoma de Querétaro, se muestra la portada de dicho artículo y la hoja de aceptación.



UNIVERSIDAD AUTÓNOMA DE QUERÉTARO
FACULTAD DE INGENIERÍA

Detección de corrosión en rodamientos de motores de inducción usando aprendizaje automático y fusión de datos

Detection of corrosion damage in induction motors bearing using machine learning algorithms and data fusion

Pacheco-Guerrero, J Pablo^{1*}, Zamudio-Ramírez, Israel¹, Osornio-Rios, Roque Alfredo¹, Antonino Daviu, Jose²

¹Maestría en Ciencias (Mecatrónica), DIPFI, UAQ, Facultad de Ingeniería, San Juan del Río, Querétaro, México

²Dpto. de Ingeniería Eléctrica, Universitat Politècnica de València, Camino de Vera, Valencia, España
jpacheco10@alumnos.uaq.mx

Palabras clave: MEC, Motores de Inducción, Corrosión, Algoritmo del Árbol de decisión, Indicadores no Estadísticos, Ensamblaje de Modelos de Aprendizaje.

Resumen- La detección de fallas en motores de inducción es crucial para prevenir problemas graves y paradas de producción, ya que estos motores son ampliamente utilizados y consumen una cantidad significativa de la energía eléctrica mundial. Los rodamientos representan más del 40% de las fallas en estos motores. Aunque los métodos de aprendizaje automático e inteligencia artificial son comunes, se proponen enfoques más efectivos que combinan múltiples modelos para mejorar la clasificación del nivel de daño. Este trabajo se centra en la obtención de señales de flujo magnético y corriente en motores de inducción bajo diferentes gradualidades de corrosión. Se utilizará el Análisis Discriminante Lineal (LDA del inglés *Linear Discriminant Analysis*) para la reducción de dimensionalidad y el Algoritmo de Árboles de Decisión con el algoritmo de aprendizaje por conjuntos Bagging para mejorar la precisión. Además, se aplicará un análisis dinámico de las señales mediante el uso de parámetros no estadísticos.



UNIVERSIDAD
AUTÓNOMA
DE QUERÉTARO



FACULTAD
DE INGENIERÍA



Estimados Autores del Artículo con título

**“Detección de corrosión en rodamientos de motores de inducción
usando aprendizaje automático y fusión de datos”**

enviado para su
participación en el XVIII Coloquio de Posgrado de la
Facultad de Ingeniería este ha sido:

ACEPTADO

Para su participación en el Coloquio a desarrollarse del
19 al 23 de Noviembre del 2024 en la Ciudad de
Querétaro, Querétaro

Le solicitamos
atentamente generar y enviar el archivo final del
trabajo con toda la información requerida.

Noviembre de 2024
Facultad de ingeniería

Msc. Luis Angel Iturralde Carrera
PRESIDENTE DEL XVIII COLOQUIO DE POSGRADO
Facultad de Ingeniería

ANEXO 2: Presentación XVIII Coloquio de Posgrado en el libro Innovación Sustentable: IA al Servicio del Planeta

Se realizó la presentación del trabajo de investigación en el XVIII Coloquio de Posgrado celebrado en la Universidad Autónoma de Querétaro del 19 al 23 de Noviembre del 2024.



Se otorga la presente
CONSTANCIA a:

**J Pablo Pacheco-Guerrero, Israel Zamudio-Ramírez,
Roque Alfredo Osornio-Ríos y José Antonino Daviu**

Por su participación en el
XVIII Coloquio de Posgrado de la Facultad de Ingeniería
de la Universidad Autónoma de Querétaro con el artículo:

**Detección de corrosión en rodamientos de motores de
inducción usando aprendizaje automático y fusión de
datos**

Noviembre de 2024
Facultad de Ingeniería

Dra. María de la Luz Pérez Rea
Directora
Facultad de Ingeniería

Dr. Juan Carlos Láuregui Correa
Jefe de la División de Investigación y Posgrado
Facultad de Ingeniería

ANEXO 3: Artículo desarrollado para el OPTIM-ACEMP 2025

Se realizó un artículo con doi: para el OPTIM – ACEMP 2025: 2025 International Aegean Conference on Electrical Machines and Power Electronics (ACEMP) & 2025 International Conference on Optimization of Electrical and Electronic Equipment (OPTIM).

Corrosion damage detection in induction motor bearings using ensemble learning algorithms and data fusion

José Pablo Pacheco-Guerrero
Engineering department
Autonomous University of Querétaro
San Juan del Rio, Querétaro, México
jpacheco10@alumnos.uaq.mx

Israel Zamudio Ramírez
Engineering department
Autonomous University of Querétaro
San Juan del Rio, Querétaro, México
israel.zamudio@uaq.edu.mx

Jose Antonino Daviu
Instituto tecnológico de la Energía
Universitat Politècnica de València
Camino de Vera, Valencia, España.
joanda@die.upv.es

Larisa Dunai
Dept. Graphical Engineering
Universitat Politècnica de València
Camino de Vera, Valencia, España.
ladu@upv.es

Abstract— Early fault detection in induction motors is essential to ensure operational continuity, improve energy efficiency, and reduce costs associated with unexpected repairs or downtime. These motors are critical in modern industry due to their reliability and versatility, but their natural wear, especially in components like bearings, can account for over 40% of recorded failures. This work proposes a comprehensive approach to analyzing magnetic flux, current, and vibration signals in motors subject to different levels of corrosion. Both statistical and non-statistical parameters are used to characterize the signals, combining advanced techniques such as Linear Discriminant Analysis for dimensionality reduction and the classification algorithm based on Gradient Boosting with the Bagging ensemble learning method to enhance model accuracy. Additionally, a genetic algorithm is employed to optimize parameter selection and achieve the best damage-level classification model, achieving an accuracy of 99%.

Keywords—Induction motors, Corrosion, Ensemble Learning Algorithm, Gradient Boosting, Fault detection.

I. INTRODUCTION

Induction motors are machines designed to convert electrical energy into rotational mechanical energy, playing a crucial role in modern industry due to their low cost, reliability, and versatility. Early fault detection in these motors is essential to ensure operational continuity and reduce costs associated with unexpected repairs or downtime. However, their natural wear can lead to unforeseen failures, with 40% attributed to bearing failures, 36% to the stator, 10% to the rotor, and 14% to other categories [1]. Moreover, studies have shown that mechanical issues, such as bearing failures, often significantly increase electrical current consumption [2], [3], [4]. This phenomenon becomes even more critical, considering that 42% of the world's energy is allocated to industrial applications, with 28% attributed explicitly to electric motors [5]. Therefore, minimizing factors contributing to increased energy consumption is crucial to optimize operational costs and mitigate environmental impact,

especially as projections indicate a significant rise in fossil fuel usage by 2030 to meet global energy demands.

One of the most common failures in the bearings of induction motors is due to corrosion [6]. This type of failure often occurs in industrial environments, especially under conditions of high temperature, high humidity, and poor lubrication or inefficient seals, which facilitate water entrance and cause corrosion [7]. Furthermore, several studies have shown that if incipient faults are not detected and addressed in time, they can lead to catastrophic failures or unexpected downtimes in production processes, highlighting the importance of early detection [8]. The literature presents several options regarding detection methods, mainly grouped into three approaches. First, traditional methods (based on time or frequency) typically rely on the Fast Fourier Transform (FFT) or statistical parameters. Although these approaches are effective in some situations, they may have limitations when dealing with complex or non-stationary signals. Second, advanced techniques based on time-frequency analysis, such as Short-Time Fourier Transform (STFT) and Wavelet Transform, offer higher time and frequency resolution, allowing for better characterization of fault signals. Finally, there are methods based on artificial intelligence and machine learning, which have proven to be the most effective in detecting faults in induction motors, as they can handle large volumes of data and adapt to varying operational conditions [9].

The literature reports frequency or time-frequency analysis methods to detect faults in induction motor bearings. These approaches are capable of identifying faults through characteristic frequencies. Bearings comprise two concentric rings, between which balls or rollers rotate on raceways. Bearing faults can be classified into two types: distributed defects, such as misaligned raceways or surface roughness, and localized defects, including spalls, corrosion pitting, and cracks. These defects tend to generate vibrations when the roller or ball passes over the defective surface, and these vibrations can be calculated based on the position of the anomaly, speed, and bearing dimensions [10]. However, corrosion in induction motors can affect multiple bearing areas, complicating calculations based on characteristic frequencies and reducing the effectiveness of frequency-based analysis techniques. Therefore, it is essential to employ other analytical methods focusing on time-domain parameters,

This research was funded by the Spanish 'Ministerio de Ciencia e Innovación', Agencia Estatal de Investigación and FEDER program in the framework of the "Proyectos de Generación de Conocimiento 2021" of the "Programa Estatal para Impulsar la Investigación Científico-Técnica y su Transferencia", belonging to the "Plan Estatal de Investigación Científica, Técnica y de Innovación 2021-2023". (ref. PID2021-122343OB-I00).