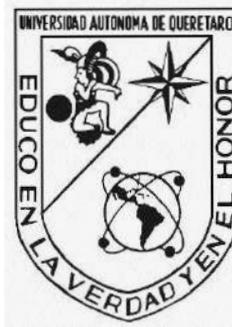


Universidad autónoma de Querétaro

Facultad de ingeniería



Sensor inteligente basado en fusión de señales y análisis espectral para  
detección de fallos electromecánicos en motores de inducción.

Tesis

que como parte de los requisitos para obtener el grado de

Maestro en ciencias

presenta:

Ing. Ricardo Robledo Castillo

Dirigido por:

Dr. Israel Zamudio Ramírez

**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](#).

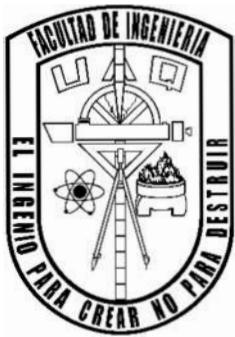
 **SinDerivadas** — Si [remezcla, transforma o crea a partir](#) del material, no podrá distribuir el material modificado.

**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:**

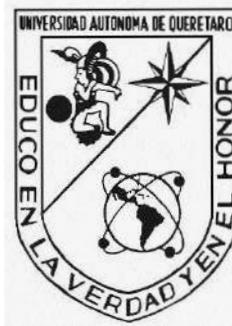
No tiene que cumplir con la licencia para elementos del material en el dominio público o cuando su uso esté permitido por una [excepción o limitación](#) aplicable.

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



Sensor inteligente basado en fusión de señales y análisis espectral para  
detección de fallos electromecánicos en motores de inducción.

## **Tesis**

que como parte de los requisitos para obtener el grado de

Maestro en ciencias (Mecatrónica)

presenta:

Ing. Ricardo Robledo Castillo

Dirigido por:

Dr. Israel Zamudio Ramírez

Sinodales:

Dr. Israel Zamudio Ramírez (Presidente)

Dr. Roque Alfredo Osornio Ríos (Secretario)

Dr. Arturo Yosimar Jaen Cuellar (Vocal)

Dr. Juan José Saucedo Dorantes (Suplente)

Dr. Juan Pablo Amézquita Sánchez (Suplente)

## **Agradecimientos**

Agradezco a mi madre, Gabriela Castillo Reyna por todo el apoyo, cariño y aliento que siempre me ha brindado.

A mi padre Ricardo Robledo Pérez por sus enseñanzas y motivarme a ser mejor.

A mi hermano Rodrigo Robledo Castillo y mi esposa Fernanda Maldonado De Jesus por su cariño compañía y apoyo durante todos estos años.

A mis amigos, que siempre han estado presentes para animarme y motivarme a seguir creciendo.

A mis asesores Dr. Israel Zamudio Ramírez y Dr. Roque Alfredo Osornio Ríos por su orientación y apoyo durante este periodo académico.

A mis profesores y miembros del sínodo por todo el apoyo y enseñanzas que hicieron posible la realización de este proyecto.

A la Universidad Autónoma de Querétaro por brindarme la oportunidad y el espacio adecuado para poder continuar con mi desarrollo académico.

## Dedicatorias

*A mis padres, A mi hermano, mi esposa, mi familia y amigos quienes siempre me han brindado su cariño y aliento.*

*A mis asesores y profesores, quienes han sido mi fuente constante de apoyo y orientación a lo largo de este camino académico.*

# Tabla de contenido

<b>1</b>	<b>INTRODUCCIÓN</b>	<b>10</b>
1.1	ANTECEDENTES	11
1.2	DESCRIPCIÓN DEL PROBLEMA	17
1.3	JUSTIFICACIÓN	18
1.3.1	<i>justificación científico-tecnológica</i>	18
1.3.2	<i>justificación social-económico-ambiental</i>	19
1.4	OBJETIVOS	19
1.4.1	<i>Objetivo general:</i>	19
1.4.2	<i>Objetivos específicos:</i>	19
1.5	HIPÓTESIS	20
1.6	PLANTEAMIENTO GENERAL	20
<b>2</b>	<b>FUNDAMENTACIÓN TEÓRICA</b>	<b>22</b>
2.1	MOTOR ELÉCTRICO DE INDUCCIÓN	22
2.2	FALLAS EN MOTORES Y MÉTODOS DE DETECCIÓN	23
2.2.1	<i>Descripción de fallas</i>	25
2.2.2	<i>Falla por ruptura barra</i>	26
2.2.3	<i>Desbalanceo en la masa del rotor</i>	27
2.2.4	<i>Fallo en los rodamientos</i>	29
2.2.5	<i>Cortocircuito en el estator</i>	31
2.2.6	<i>Falla en una fase</i>	33
2.2.7	<i>Falla por excentricidad</i>	33
2.3	SEÑALES EMPLEADAS PARA DIAGNÓSTICO DE FALLAS EN UN MOTOR DE INDUCCIÓN:	35
2.3.1	<i>Flujo magnético</i>	35
2.3.2	<i>Corriente</i>	37
2.3.3	<i>Vibración</i>	37
2.3.4	<i>Temperatura</i>	37
2.4	PROCESAMIENTO DE SEÑALES PARA DETECCIÓN DE FALLAS	38
2.4.1	<i>FFT</i>	38
2.4.2	<i>STFT</i>	40
2.4.3	<i>Indicadores estadísticos</i>	41
2.5	ALGORITMOS DE CLASIFICACIÓN	42
2.5.1	<i>Redes neuronales artificiales</i>	43
2.5.2	<i>Análisis de discriminante lineal (LDA)</i>	46

2.5.3	<i>Máquina de vectores de soporte</i>	48
2.5.4	<i>Algoritmo de aprendizaje lógico</i>	49
2.5.5	<i>Algoritmo basado en estadística</i>	50
2.6	SMART SENSOR	51
<b>3</b>	<b>METODOLOGÍA</b>	<b>53</b>
3.1	MATERIALES Y DISEÑO DE PCB	54
3.1.1	<i>Materiales</i>	54
3.1.2	<i>Diseño PCB</i>	56
3.1.3	<i>Procesamiento de señales</i>	60
3.2	BANCO DE PRUEBAS Y MATRIZ DE PRUEBAS	62
3.2.1	<i>Banco de pruebas</i>	62
3.2.2	<i>Matriz de pruebas</i>	64
<b>4</b>	<b>RESULTADOS</b>	<b>66</b>
4.1	HARDWARE	66
4.2	PROCESAMIENTO DE LAS SEÑALES Y DIAGNÓSTICO DE CONDICIÓN DEL MOTOR	67
4.2.1	<i>Procesamiento de señales en estado estable</i>	68
4.2.2	<i>Procesamiento de señales ante un pico de arranque</i>	85
4.3	INTERFACES DE COMUNICACIÓN Y DE USUARIO	88
<b>5</b>	<b>CONCLUSIONES Y PROSPECTIVAS</b>	<b>92</b>
5.1	CONCLUSIONES	92
5.1	PROSPECTIVAS	93
<b>REFERENCIAS</b>		<b>94</b>

# índice de figuras

<u>Figura 1.1 Diagrama general del funcionamiento del sensor</u>	21
<u>Figura 2.1 Esquema de partes principales que conforman un motor eléctrico de inducción (Traducido de Gangsar &amp; Tiwari, 2020).</u>	23
<u>Figura 2.2 Falla de ruptura de barra en el rotor.</u>	26
<u>Figura 2.3 Falla de ruptura de barra en el rotor.</u>	28
<u>Figura 2.4 Diferentes tipos de falla en rodamientos</u>	30
<u>Figura 2.5 Falla en el estator.</u>	32
<u>Figura 2.6 Diferentes tipos de falla por excentricidad: A) excentricidad estática B) excentricidad dinámica C) excentricidad combinada.</u>	34
<u>Figura 2.7 Ejes principales de flujo magnético disperso.</u>	36
<u>Figura 2.8 Ejemplo de una red neuronal</u>	44
<u>Figura 2.9 Ejemplo de una neurona.</u>	45
<u>Figura 2.10 Clasificación por máquina de vectores de soporte</u>	49
<u>Figura 2.11 Diagrama general de un Smart sensor</u>	52
<u>Figura 3.1 Diagrama general del funcionamiento del sensor inteligente</u>	53
<u>Figura 3.2 Diagrama de flujo de componentes del Smart sensor</u>	55
<u>Figura 3.3 Circuito integrado MCP2515</u>	56
<u>Figura 3.4 Diagrama de conexión de los componentes del Smart sensor</u>	57
<u>Figura 3.5 Diseño PCB de la tarjeta para montaje de componentes.</u>	58
<u>Figura 3.6 Diseño tridimensional de la tarjeta con componentes acoplados</u>	58
<u>Figura 3.7 Construcción en físico de la tarjeta</u>	59
<u>Figura 3.8 Banco de pruebas empleado</u>	62
<u>Figura 3.9 Montaje del sensor inteligente en el banco de pruebas</u>	63
<u>Figura 4.1 Diseño 3D del armazón del sensor inteligente</u>	66
<u>Figura 4.2 Armazón del sensor inteligente impreso en 3D con los componentes acoplados</u>	67
<u>Figura 4.3 Señal de flujo magnético disperso radial en la condición de motor sano .</u>	68
<u>Figura 4.4 Señal de flujo magnético disperso radial en la condición de motor sano eliminando los primeros 10 segundos de arranque</u>	69
<u>Figura 4.5 Procesamiento por FFT de la señal de flujo magnético radial en un motor sano</u>	70
<u>Figura 4.6Amplitud de frecuencia de falla por desalineación</u>	71
<u>Figura 4.7Amplitud de frecuencia de falla en el rotor.</u>	72
<u>Figura 4.8 Distribución de los resultados obtenidos tras el procesamiento de la señal en el dominio del tiempo empleando la varianza</u>	73
<u>Figura 4.9 LDA obtenido tras el procesamiento de la señal de corriente</u>	75
<u>Figura 4.10 red neuronal obtenida tras el procesamiento de la señal de corriente</u>	76
<u>Figura 4.11 LDA obtenido tras el procesamiento de la señal de flujo disperso en el eje radial</u>	77
<u>Figura 4.12 red neuronal obtenida tras el procesamiento de la señal de flujo disperso en el eje radial</u>	78
<u>Figura 4.13 LDA obtenido tras el procesamiento de la señal de flujo disperso en el eje axial</u>	79
<u>Figura 4.14 red neuronal obtenida tras el procesamiento de la señal de flujo disperso en el eje axial</u>	80

<u>Figura 4.15 LDA obtenido tras el procesamiento de la señal de flujo disperso en el eje combinado</u>	81
<u>Figura 4.16 red neuronal obtenida tras el procesamiento de la señal de flujo disperso en el eje combinado</u>	82
<u>Figura 4.17 LDA obtenido tras el procesamiento de las señales de flujo disperso y corriente</u>	83
<u>Figura 4.18 red neuronal obtenida tras el procesamiento de las señales de flujo disperso y corriente</u>	84
<u>Figura 4.19 STFT obtenida del procesamiento de las señales</u>	85
<u>Figura 4.20 STFT obtenida dividida en cuadrantes</u>	86
<u>Figura 4.21 LDA obtenido tras el procesamiento de las señales de flujo disperso y corriente ante un pico de arranque</u>	87
<u>Figura 4.22 red neuronal obtenida tras el procesamiento de las de flujo disperso y corriente ante un pico de arranque</u>	88
<u>Figura 4.23 interfaz de usuario del sensor inteligente</u>	90
<u>Figura 4.24 ejemplo de un reporte emitido por el sensor Ability Smart Sensor ABB</u>	91

## índice de tablas

<u>Tabla 2.1 Ecuaciones para identificación de frecuencias de falla en motores de inducción</u>	34
<u>Tabla 2.2 Indicadores estadísticos</u>	41
<u>Tabla 2.3 Funciones de activación</u>	46
<u>Tabla 3.1 Matriz de pruebas</u>	65

# Resumen

Este trabajo de tesis presenta el desarrollo de un sensor inteligente para la detección de fallos electromecánicos en motores de inducción, basado en la medición de corriente y flujo magnético disperso, y el posterior análisis de señales y clasificación de la información para lograr un diagnóstico de la condición del motor. Este proyecto surge de la necesidad de mejorar las herramientas de detección de fallos y la identificación específica de condiciones de fallo en motores, con el objetivo de evitar pérdidas de eficiencia y daños en los equipos y proveer al usuario de una herramienta valiosa para la toma de decisiones y programación de mantenimiento en los sistemas que funcionan mediante motores. Los objetivos específicos incluyen el análisis de las fallas electromecánicas comunes, la exploración y simulación de modelos de procesamiento de señales, el diseño y construcción del sensor, la programación de algoritmos de clasificación de fallos, y el desarrollo de una interfaz de usuario para diagnósticos simplificados. El sensor inteligente propuesto consta de tres etapas principales: siendo la primera la adquisición de señales mediante el uso de un sensor de corriente y un sensor de flujo disperso triaxial, para posteriormente pasar a la etapa de procesamiento de señales donde se emplean técnicas de Fourier y cálculo de indicadores estadísticos de la señal en el dominio del tiempo, para pasar a la etapa de clasificación de fallos por medio de LDA y redes neuronales y finalmente en la tercera etapa y se obtiene un diagnóstico simplificado mediante una interfaz de usuario y la opción de salida de información mediante protocolos de comunicación de ethernet y CAN. finalmente se exponen los resultados obtenidos al emplear el procesamiento de la fusión de señales, estos resultados se contrastan con los resultados obtenidos mediante el procesamiento individual de los diferentes tipos de señales, observando que existe una mejora significativa al emplear la información obtenida por ambos sensores y emplear información obtenida tanto en el dominio del tiempo como en el dominio de la frecuencia y tiempo-frecuencia.

palabras clave: sensor inteligente, técnicas de Fourier, red neuronal, motores de inducción, análisis de fallas.

# Abstract

This thesis work presents the development of a smart sensor for detecting electromechanical faults in induction motors, based on the measurement of current and magnetic stray flux, and the subsequent signal analysis and information classification to achieve a diagnosis of the motor's condition. This project arises from the need to improve fault detection tools and specifically identify fault conditions in motors, aiming to prevent efficiency losses and equipment damage, and to provide users with a valuable tool for decision-making and maintenance scheduling in motor-driven systems. Specific objectives include analyzing common electromechanical faults, exploring and simulating signal processing models, designing and constructing the sensor, programming fault classification algorithms, and developing a user interface for simplified diagnostics. The proposed intelligent sensor consists of three main stages: first, signal acquisition using a current sensor and a triaxial scattered flux sensor, followed by signal processing using Fourier techniques and calculation of signal statistical features in the time domain, then fault classification using LDA and neural networks, and finally, obtaining a simplified diagnosis through a user interface and information output options via ethernet and CAN communication protocols. Finally, the results obtained from signal fusion processing are presented, contrasting them with results obtained through individual signal processing, demonstrating a significant improvement when using information from both sensors and employing data from both the time and frequency domains, as well as time-frequency domain.

Keywords: smart sensor, Fourier techniques, neural network, induction motors, fault analysis.

# Capítulo 1

## 1 Introducción

En este proyecto se realizó el diseño y construcción de un sensor inteligente (smart sensor) cuyo objetivo es la detección de diferentes tipos de fallos en motores de inducción de forma no invasiva, evitando así detener procesos o maquinaria para poder realizar el diagnóstico de condición. Esta es una opción viable para su aplicación en la industria y con el potencial de reducir los tiempos de intervención y costos relacionados al mantenimiento en motores, así como de reducir el impacto ambiental relacionado con el incremento de consumo energético ocasionado por que estos equipos trabajen con fallas que produzcan perdidas de eficiencia por periodos prolongados de tiempo al no ser detectadas de forma oportuna. Tomando como punto de partida la adquisición de señales obtenidas de dos sensores primarios: un sensor de corriente y un sensor de flujo magnético, respectivamente, se realizó el acondicionamiento y procesamiento de estas señales mediante el uso de la transformada rápida de Fourier (fast Fourier transform, FFT), y la transformada de Fourier de tiempo corto (short-time Fourier transform, STFT) para el análisis y clasificación de componentes frecuenciales presentes en las señales que puedan ser relacionadas con la presencia de una falla específica en el motor, para finalmente ser entregado al usuario como un diagnóstico de la condición del motor de forma clara y entendible a través de una interfaz de usuario.

El contenido de este trabajo está organizado en 5 capítulos: en el capítulo 1 se abordan los antecedentes de trabajos relacionados, se describe el planteamiento del problema y la justificación del proyecto, y se presentan los objetivos de este trabajo; en el capítulo 2 se recopila la información que sirve como fundamentación teórica de este trabajo; en el capítulo 3 se describe la metodología utilizada para lograr el desarrollo del sensor inteligente; en el capítulo 4 se presenta la experimentación realizada, descripción de los casos de estudio y resultados obtenidos en las pruebas; y, finalmente, en el capítulo 5 se discuten los resultados y se presentan los comentarios finales de este proyecto.

## 1.1 Antecedentes

Actualmente, los motores de inducción son dispositivos ampliamente utilizados en la industria, llegando a tener diversas variaciones en cuanto a sus características de diseño con la finalidad de satisfacer diferentes necesidades para aplicaciones específicas. Es importante mencionar que los motores son aparatos capaces de funcionar aun teniendo diversos fallos presentes, lo cual afecta de manera negativa su eficiencia y provoca una mayor demanda de consumo energético para su funcionamiento y generando condiciones que podrían potencialmente causar mayores daños al mismo motor o a las instalaciones eléctricas. De acuerdo con un estudio de la agencia internacional de energía realizado por Waide & Brunner (2011), los sistemas de motores eléctricos representan aproximadamente el 53% del consumo eléctrico global. Se estima que, actualmente esto representa un costo de 565 billones de dólares anualmente y que esta cifra se incrementará hasta aproximarse a los 900 billones de dólares para el 2030. Según lo expuesto en la publicación de Tong (2022) alrededor de un 95% del costo económico total durante la vida útil de un motor eléctrico es su costo en consumo energético, por lo que mejorar la eficiencia de los motores eléctricos a nivel global tan solo un 1% reduciría el consumo de energía en aproximadamente 94.5 TWh y la huella de emisión de dióxido de carbono que representa la producción de esta energía en 60 millones de toneladas por año, de esta forma reduciendo en gran medida la necesidad de crear nuevas plantas eléctricas y disminuyendo el impacto ambiental por generación de energía. Debido a lo mencionado anteriormente, es de gran importancia poder contar con un método confiable, económico y eficaz para el monitoreo de la condición de los motores, ya que muchas de las posibles fallas que se pueden presentar en estos equipos no son evidentes y se requiere de realizar un diagnóstico por personal especializado para poder detectarlas.

De acuerdo con la revisión del diagnóstico de fallas en los motores de inducción de Tian et al. (2018) los problemas de funcionamiento más comunes en motores de inducción se pueden clasificar como fallas de estator, rotor y rodamientos, donde aproximadamente un 40-50% son relacionadas a los rodamientos, un 30-40% son relacionadas al estator y un 5-10% son

relacionadas al rotor, otro tipo de averías que también se pueden presentar en menor frecuencia, son aquellas debidas a condiciones externas, como por ejemplo errores de la línea de alimentación. Las principales averías en motores de inducción son las siguientes:

1. Daños en el estator debido a daño en una o varias fases del embobinado
2. Conexiones inapropiadas en el embobinado del estator
3. Embobinado del rotor en cortocircuito
4. Barra quebrada en el rotor
5. Excentricidad
6. Eje doblado
7. Fallas en los rodamientos o caja de engranes acoplada al motor.

Con el objetivo de mejorar continuamente los diagnósticos en los motores, se han desarrollado diversas metodologías que buscan alcanzar un equilibrio entre costo, confiabilidad y eficacia. Gaeid et al. (2010) en su revisión de las técnicas de diagnóstico de detección de fallas destacan, por ejemplo, el desarrollo de la técnica de corriente virtual (Virtual Current Technique, VCT) para el diagnóstico de fallas en el rotor, la cual ha demostrado ser una de las técnicas de diagnóstico más económicas y menos invasivas. Además, el análisis de la corriente característica del motor (Motor Current Signature Analysis, MCSA) que es relevante debido a su facilidad de uso y su carácter no invasivo. Sin embargo, estas metodologías presentan algunos problemas, ya que la amplitud de las componentes de corriente analizadas depende de las cargas conectadas al motor, lo que hace que su aplicación sea limitada en condiciones de variación de carga en el sistema. Asimismo, existe el riesgo de que una frecuencia relacionada con alguna falla se confunda con frecuencias generadas por las condiciones normales de funcionamiento del equipo.

En un análisis comparativo de técnicas de procesamiento de señales para la detección de fallos en motores de inducción trifásicos realizado por Amanuel et al. (2021), se hace una revisión de las características que diferencian varios métodos de detección de fallas en motores basadas en el procesamiento de las señales haciendo uso de las técnicas como la FFT, STFT y DWT. En este análisis se concluye que al incorporar los algoritmos FFT en combinación con métodos basados en DWT se obtiene una mayor precisión en la detección de fallos comparada con otras

metodologías existentes. Se ha utilizado bastante el método de la transformada rápida de Fourier (FFT) en diferentes señales obtenidas del motor. Esta es una de las técnicas de procesamiento de señales con mayor interés para la investigación ya que es un método rápido, útil en el análisis de señales que mantienen un comportamiento estacionario. De acuerdo con Karmakar et al. (2016), la mayoría de los métodos de análisis de señales para diagnóstico de fallas que han sido utilizados desde hace aproximadamente tres décadas se basan en la transformada rápida de Fourier (FFT), por ejemplo Garfias (2020) realizó un trabajo en el que señales de vibración son obtenidas de un motor a partir de acelerómetros, estas señales son posteriormente procesadas mediante la FFT y los datos obtenidos son analizados mediante la comparación de los espectros obtenidos para la detección de la falla de cortocircuito en diferentes severidades respecto a un motor sano. Otro trabajo que se puede mencionar es el análisis de la condición de fallos en los rodamientos de un motor presentado por Cureño (2020) en el que a partir del monitoreo de flujo magnético y el procesamiento de estos datos haciendo uso de técnicas como la transformada rápida de Fourier (FFT) y la transformada wavelet discreta (discrete wavelet transform, DWT) se analizan diferentes severidades de daño en los rodamientos (sano, 1mm, 2mm, 3mm, 4mm, 5mm) logrando diferenciarlas mediante esta metodología.

A pesar de las ventajas que presenta la FFT implementada en el procesamiento de señales, también existen ciertas limitaciones, por ejemplo, que algunas frecuencias que indican fallas pueden ser enmascaradas por frecuencias de alimentación o que no es apto para ser usado en señales que puedan presentar cambios abruptos en su comportamiento a través del tiempo como parte de su operación normal. Para poder superar estas limitaciones se han ido desarrollando otras técnicas de procesamiento de señales, como lo es la transformada de Fourier de tiempo corto (short time Fourier transform, STFT), un ejemplo de esto es mencionado en la revisión de la aplicación de técnicas de procesamiento de señales para el diagnóstico de fallas de motores de inducción de Faiz et al. (2017). En este trabajo se concluye que actualmente no es posible emplear un solo método de procesamiento con la finalidad de identificar y diferenciar todas las fallas que se pueden presentar en un motor, en este contexto el procesamiento por técnicas de Fourier resulta ser uno de los más aplicables para identificar entre múltiples fallas distintas; sin embargo, su principal punto débil se encuentra relacionado en el procesamiento de señales

transitorias, esto se debe a que la transformada de Fourier convierte una señal del dominio del tiempo al dominio de la frecuencia y cuando la señal transformada exhibe un comportamiento temporal inestable, pueden surgir múltiples componentes frecuenciales que dificultan el análisis y una correcta interpretación de los resultados obtenidos. Para hacer frente a este problema se sugiere aplicar un procesamiento por wavelet o STFT. También podemos mencionar el trabajo de Ortiz et al. (2019) quienes realizaron un trabajo para la detección de desalineación en el rotor de un motor, en el que se presenta una metodología basada en el análisis de la corriente característica del motor y el procesamiento de estas señales mediante la FFT y STFT en el dominio del tiempo-frecuencia, en este caso particular la falla solo pudo ser detectada mediante el procesamiento de las señales haciendo uso de la STFT.

Dentro de las diferentes técnicas y metodologías que se han ido implementando para el diagnóstico de fallas en motores, se ha ido adoptando el uso de sistemas autónomos como los Smart sensor, que es un dispositivo que puede ser implementado en la industria con múltiples objetivos y funcionalidades dependiendo de las necesidades específicas de cada proceso, e incorpora diferentes funciones como lo son la adquisición de señales, procesamiento, clasificación y diagnóstico, alarmas, entre otros. De acuerdo con Van Der Horn & Huijsing (1997) un Smart sensor puede considerarse como un dispositivo que integra diferentes funciones, basándose inicialmente en un sensor para simplificar su uso y aplicación, las funciones que integra generalmente son las siguientes:

1. La lectura de salida de señal de un sensor y el acondicionamiento, filtrado y amplificación en caso de ser requerido para su procesamiento.
2. Conversión analógica a digital de la señal para interpretación de los datos si el sensor empleado es analógico.
3. Una interfaz para simplificar la comunicación a microcontroladores, computadoras, interfaces de usuario u otros dispositivos.
4. Calibración de la función de transferencia del sensor, preferiblemente mediante una calibración programable de forma digital.

Un ejemplo de una metodología basada en el funcionamiento de los Smart sensor fue propuesta por Luong & Wang (2020) para el diagnóstico de barras rotas en el rotor de un motor de inducción, por medio de la interpretación de señales de vibración, análisis de frecuencias y harmónicos de corriente. Sin embargo, en este trabajo solo se evalúa un único tipo de falla. Otra técnica desarrollada con el objetivo de implementarse en un Smart sensor es el procesamiento de señales termográficas para diagnóstico de fallos en motores de inducción propuesta por Alvarado (2021), este trabajo se basa en la obtención de imágenes termográficas a partir de un sensor infrarrojo y el procesamiento de estas imágenes haciendo uso de indicadores estadísticos y redes neuronales, el estudio considera 14 posibles condiciones del motor, estos son el motor sano, desalineación, desbalanceo, 2 severidades de barras rotas, 5 severidades de falla en balero, y 4 severidades de falla en caja de engranes, finalmente pudiendo obtener un procesamiento que fue capaz de diferenciar entre los distintos estados de condición del motor con una efectividad del 90.5%. Por otra parte, está el trabajo enfocado en el desarrollo de un smart sensor por Antonino et al. (2022), quienes hacen uso de señales de corriente, flujo magnético e información termográfica para el análisis mediante técnicas como corriente característica (MCSA), FFT y redes neuronales es posible la detección y clasificación de diferentes fallas en motores de inducción, logrando diagnosticar de forma automática fallas relacionadas a barras rotas del rotor, errores de alineación, fallos de excentricidad, daño en los rodamientos y problemas en el sistema de transmisión, no obstante, a pesar de las grandes ventajas que ofrece por el método MCSA, existen algunos inconvenientes que deben tenerse en cuenta al realizar un diagnóstico final. En este sentido, se sabe que la sensibilidad relativamente baja debido a la atenuación de la firma de la falla a frecuencias altas dificulta la detección de excentricidad o fallas en los rodamientos, especialmente en entornos de campo ruidosos, por otro lado, dado que esta técnica se basa en la comparación de amplitud de un número limitado de componentes de frecuencia, los fenómenos no relacionados con fallas, como las características del equipo o las condiciones de funcionamiento de la máquina, a veces pueden enmascarar o amplificar componentes de frecuencia similares y generar posibles indicaciones de fallo falsas. Garcia et al. (2012) propone un sensor inteligente de corriente que implementa FFT, cálculo de raíz media cuadrada y redes neuronales que son procesados en línea a través de la implementación del procesamiento con una

tarjeta FPGA (field programmable gate array, Arreglo de Puertas Programables en Campo) para la detección de fallas de barras rotas, desbalanceo, desalineación y condición de motor sano, pudiendo detectar y diferenciar estas fallas de forma efectiva; sin embargo, el rango de fallas consideradas en este trabajo es limitado. Ramírez (2019) realizó un trabajo para la detección de fallas en rodamientos instalados en motores de inducción mediante el análisis de señales de vibración y corriente, además de la obtención de indicadores estadísticos a partir de estas señales y análisis de componentes principales (Principal component Analysis, PCA) y la clasificación de la información relacionada a las fallas mediante k vecinos más próximos (k-nearest neighbors, KNN) usando datos de señales de falla tanto experimentales como obtenidos de una base de datos en línea y finalmente logrando diferenciar exitosamente la condición de fallo del motor sano al emplear la información obtenida en combinación de ambas señales, pero aun con algunos errores para diferenciar entre distintas severidades de esta falla.

Tras la revisión del estado del arte relacionado con la detección de fallas en motores haciendo uso de metodologías enfocadas en la implementación de un Smart sensor y la búsqueda de opciones comerciales actualmente disponibles en el mercado, se ha identificado que existe una importante área de oportunidad y necesidad de desarrollo de este tipo de soluciones, ya que muchos trabajos se enfocan únicamente en el diagnóstico de un tipo de falla, y aún existe la necesidad de mejorar la detección entre diferentes tipos de fallo y diferentes severidades de estas. En las opciones comerciales disponibles actualmente, no se encontró una herramienta ampliamente extendida que sea capaz de realizar la adquisición de los datos, procesarlos, interpretarlos y proporcionar un diagnóstico de falla simplificado sin la intervención de personal, la mayoría de los resultados comerciales para dispositivos de detección de fallas requieren personal que ejecute e interprete las mediciones. Como ejemplo de esto es el equipo modelo MDA-550 de la marca Fluke (Fluke, 2022), que integra las opciones de emitir reportes de medición de parámetros eléctricos en los motores, mediciones de armónicos y funciones de osciloscopio, pero la medición siempre debe ser realizada por una persona y se requiere que posteriormente esta información sea interpretada para concluir un diagnóstico de la condición del motor. Existen también varias opciones de sensores que pueden ser montados directamente en los motores para que algunos parámetros importantes puedan ser monitoreados sin necesidad de

que alguna persona realice la medición en sitio. Un ejemplo de estos son los sensores térmicos, de vibración y de corriente de la marca NCD (NCD, 2019), que integran opciones de transferencia de datos por vía remota; sin embargo, también presentan diferentes desventajas, por ejemplo, que los datos aun necesitan ser analizados e interpretados por alguien para detectar fallas y es necesario el uso de software especializado que implica el costo de la licencia.

## 1.2 Descripción del problema

A partir de lo expuesto en los antecedentes, se detectaron diversos problemas que constituyen un área de oportunidad para el desarrollo del proyecto propuesto, entre los que destacan los siguientes puntos:

- El impacto energético, económico y ambiental que conlleva el uso extendido de los motores eléctricos de inducción, y por lo tanto la importancia de lograr evitar pérdidas de eficiencia relacionadas con fallas en los equipos.
- La detección de fallas específicas en motores y la identificación de la gravedad que presentan es complicada, ya que las variaciones en una señal pueden deberse a diferentes causas y los métodos para diferenciarlas suelen requerir agregar diversas variables medibles, un alto costo o una carga de procesamiento elevada. Se observó que al emplear sistemas basados en únicamente una metodología y/o variable es posible que las señales lleguen a enmascararse por ruido o aparezcan falsos positivos. Esto debido a la presencia de una falla diferente que produzca un efecto similar en los parámetros medidos o condiciones de operación, por lo cual se detectó que aún existe una necesidad de desarrollar algoritmos y equipos que permitan diferenciar las fallas a partir del procesamiento adecuado de las señales.
- Otro pendiente de gran relevancia en el área, es la necesidad de desarrollar sistemas autónomos para la detección de fallas en motores que sean capaces de llevar la clasificación y procesamiento de las señales de forma que sean capaces de discriminar correctamente entre diferentes tipos de fallas y grados de deterioro en los motores eléctricos y puedan brindar información simplificada y útil a través de una interfaz de usuario.

-Tras la revisión de antecedentes y dispositivos comerciales actuales en el mercado, se detectó que aunque ya hay trabajos de investigación y dispositivos comerciales creados para su aplicación en la industria en el ámbito de la detección de fallas en motores eléctricos, estos presentan limitaciones en la detección, altos costos y requieren de interpretación por personal especializado, por lo tanto, aún existe necesidad de desarrollar equipos de bajo costo y con capacidad de detectar múltiples fallas, pues varios de los trabajos se limitan a la detección de un solo tipo de falla, prueba de esto es este mismo proyecto que surge como parte de un convenio con la Universidad Politécnica de Valencia para satisfacer las necesidades de una empresa europea (con convenio de confidencialidad).

## **1.3 Justificación**

### **1.3.1 justificación científico-tecnológica**

Este trabajo propone el desarrollo de un sensor inteligente que sea capaz de llevar a cabo el monitoreo y análisis de señales de corriente y flujo magnético de dispersión con el fin de proveer un diagnóstico temprano de fallas electromecánicas en motores de inducción de manera no invasiva. Otro punto que se busca lograr es que el sensor sea capaz de discernir entre diferentes tipos de fallas con la metodología empleada para lograr ofrecer información suficiente y así planificar un mantenimiento enfocado a la falla, de forma que se reduzca el tiempo de mantenimiento necesario. El desarrollo del sistema mediante la aplicación de STFT y FFT tiene como objetivo incrementar el espectro de fallas detectables, mejorar la confiabilidad de los diagnósticos y descartar falsos positivos que ocurren al emplear únicamente una de las dos técnicas. El smart sensor integra las funciones de acondicionamiento de señales obtenidas de los sensores primarios, clasificación, procesamiento e interpretación para finalmente obtener información relevante para el usuario mediante la implementación de una interfaz. Se pretende que este dispositivo sea capaz de realizar todos los procesos necesarios para brindar un diagnóstico de fallas confiable al técnico o usuario sin la necesidad de un especialista que interprete los valores obtenidos, dependencia de un software comercial especializado o el uso de herramientas o sistemas adicionales.

### **1.3.2 justificación social-económico-ambiental**

El desarrollo de un smart sensor que sea capaz de llevar a cabo la detección temprana de fallas en motores tendría un impacto positivo directo en los costes energéticos, ya que un diagnóstico oportuno reducirá el tiempo que los motores trabajan con fallas que provocan una disminución en su eficiencia y un incremento en la demanda de energía. Contando con este sistema algunas empresas podrían programar los mantenimientos al momento de percibir que existe algún deterioro y mucho antes de que se presente una falla crítica, de esta manera se evitarían costos de reparaciones por daños mayores a los motores, así como la disminución de la huella de emisión de dióxido de carbono como consecuencia de evitar mayores consumos energéticos al operar un motor en condición de fallo por tiempos prolongados. Otro aspecto importante al que puede contribuir como impacto ecológico este trabajo es la reducción de residuos derivados de daños mayores en los motores, además, al no requerir de personal para realizar mediciones o la interpretación de las señales ya que se busca lograr un diagnóstico simplificado, sería posible que este tipo de dispositivos se usen en una gran cantidad de motores sin la necesidad de detenerlos o exponer al personal a condiciones de riesgo por realizar mediciones en motores que se encuentran en funcionamiento o en ambientes peligrosos.

## **1.4 Objetivos**

### **1.4.1 Objetivo general:**

Desarrollar un sensor inteligente basado en la medición de corriente y flujo magnético de dispersión, y el análisis de las lecturas mediante el procesamiento de las señales haciendo uso de técnicas de Fourier para la detección de fallos electromecánicos en motores de inducción.

### **1.4.2 Objetivos específicos:**

1. Analizar las fallas electromecánicas más comunes de acuerdo con lo expuesto en la sección de fundamentación teórica en los motores de inducción y estudiarlas mediante

una revisión del estado del arte para determinar las características que debe tener el smart sensor.

2. Estudiar y simular los modelos de la FFT, STFT y métodos de clasificación mediante la teoría y el software Matlab, para seleccionar la utilización de cada técnica en base a la detección requerida para los fallos.
3. Definir la estructura del smart sensor para la selección de los componentes que lo integrarán basado en las fallas, mediciones y el tipo de procesamiento a realizar.
4. Elaborar la tarjeta del Smart-Sensor mediante el diseño de esquemáticos y PCB para la integración de los elementos requeridos.
5. Programar los algoritmos FFT, STFT y de clasificación de fallas en el procesador del smart sensor para la detección y clasificación de fallos electromecánicos en un motor de inducción.
6. Desarrollar una interfaz de usuario para el smart sensor mediante lenguaje de programación adecuado para ello que muestre la detección de fallos detectados en los motores como: excentricidad, desbalance, desalineamiento angular y paralelo, barras rotas.
7. Validar el funcionamiento del smart sensor mediante datos reales de fallos en motores de inducción para determinar su efectividad.
8. Analizar el desempeño del smart sensor, visualizar y evaluar los resultados obtenidos con el fin de compararlos con las opciones comerciales actuales.

## **1.5 Hipótesis**

Mediante el desarrollo de un sistema basado en la fusión de señales de corriente y flujo magnético de dispersión, las cuales serán procesadas mediante técnicas de Fourier, será posible la detección de al menos 5 tipos de condición en motores de inducción y permitirá mejorar la detección en comparación con sistemas comerciales y/o el procesamiento individual de las señales.

## **1.6 Planteamiento general**

Para el desarrollo del proyecto se siguieron los pasos descritos en la Figura 1.1, se seleccionaron dos sensores, uno para la medición de flujo magnético y otro para medición de corriente, mismas que al ser adquiridas serán acondicionadas para ser introducidas a una etapa de procesamiento por FFT y STFT, donde se obtendrán los datos característicos que dan indicios de falla para cada caso, con el objetivo de lograr desarrollar un método capaz de identificar y diferenciar las fallas más comunes de acuerdo con lo abordado en la sección de antecedentes, posteriormente estos datos son llevados a una etapa de clasificación con el fin de identificar una palla específica del resto de condiciones, para finalmente poder emitir un diagnóstico simplificado que indique el resultado actual de la condición del motor que será entregada mediante una interfaz de usuario, los componentes empleados y etapas se explicaran a mayor detalle más adelante en la sección de metodología.

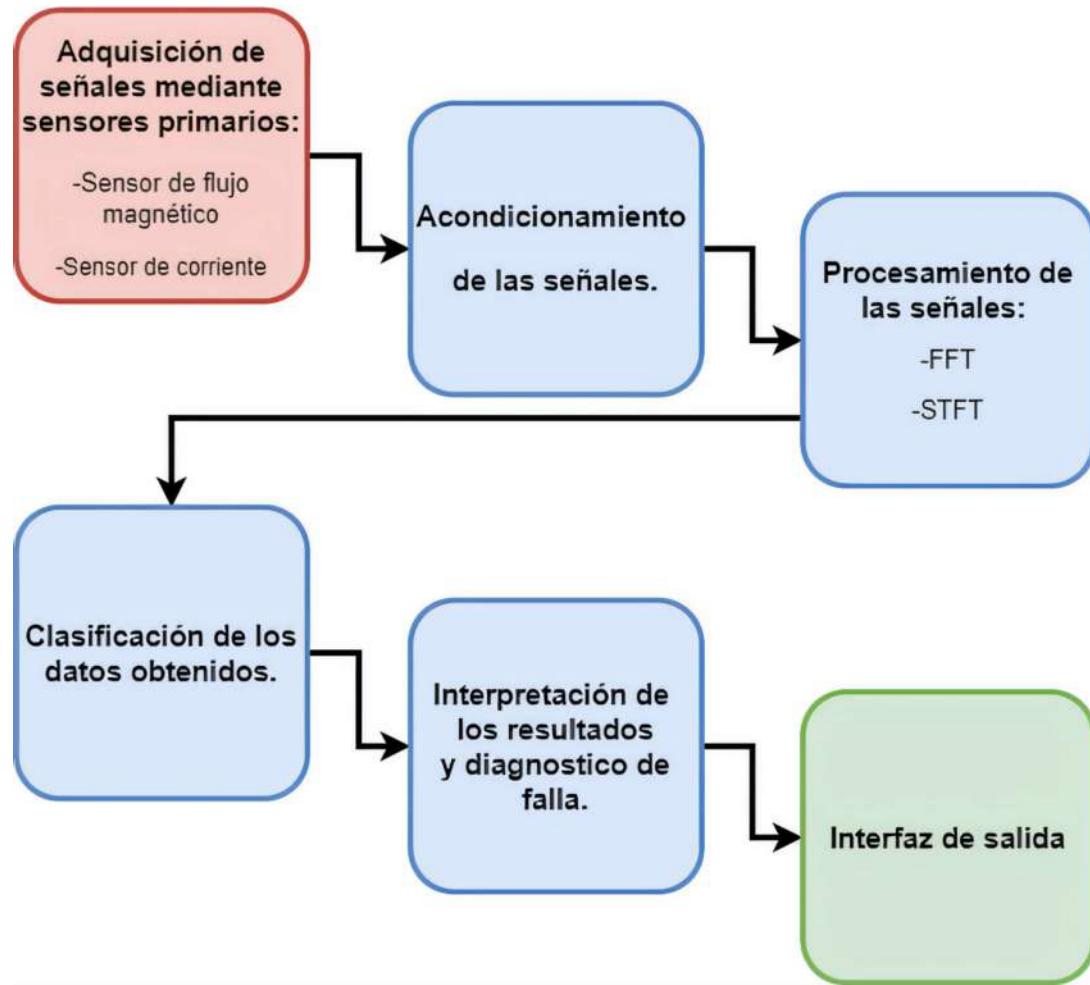


Figura 1.1 Diagrama general del funcionamiento del sensor (autoría propia).

# Capítulo 2

## 2 Fundamentación teórica

En esta sección se abordarán cuatro temas para sustentar la fundamentación teórica del proyecto, en la primera sección se dará una descripción del motor eléctrico de inducción, sus partes y principio de funcionamiento; en la segunda sección se hará una revisión de diversas fallas de los motores y los métodos de detección para dichas fallas; en la tercera sección se abordarán métodos de detección de fallas por medio del procesamiento de señales haciendo uso de la FFT y STFT; por último, en la cuarta sección se describe qué es un smart sensor y su aplicación en motores de inducción.

### 2.1 Motor eléctrico de inducción

Los motores eléctricos se utilizan para convertir la energía eléctrica en energía mecánica y se manufacturan en una gran variedad de tipos y configuraciones, típicamente un motor eléctrico está formado por un conjunto de partes que incluyen el estator, embobinados, rotor, anillos, ejes o acoplamientos, rodamientos y carcasa, además de estos componentes principales, algunos motores incluyen componentes electrónicos adicionales empleados para modificar sus características de operación para aplicaciones particulares, de acuerdo con la publicación de Tong (2022), un motor de inducción consta de un circuito magnético que interconecta dos circuitos eléctricos que se encuentran en las dos partes principales de la máquina: la parte estacionaria llamada estator, que consta del marco cilíndrico exterior, la trayectoria magnética y un conjunto de devanados eléctricos aislados; y la parte giratoria llamada rotor. La energía se transfiere de una parte a la otra por inducción electromagnética, a esta máquina de inducción se le conoce como un dispositivo electromecánico de conversión de energía que convierte la energía eléctrica en energía mecánica. En la Figura 2.1 se pueden observar las partes principales de un motor.

El rotor se apoya sobre rodamientos en cada extremo. En general, tanto el estator como el rotor constan de dos circuitos: un circuito eléctrico para transportar corriente normalmente hecho de cobre o aluminio aislados; y un circuito magnético para transportar el flujo magnético hecho de un material magnético laminado, normalmente acero (Muhammad et al., 2021).

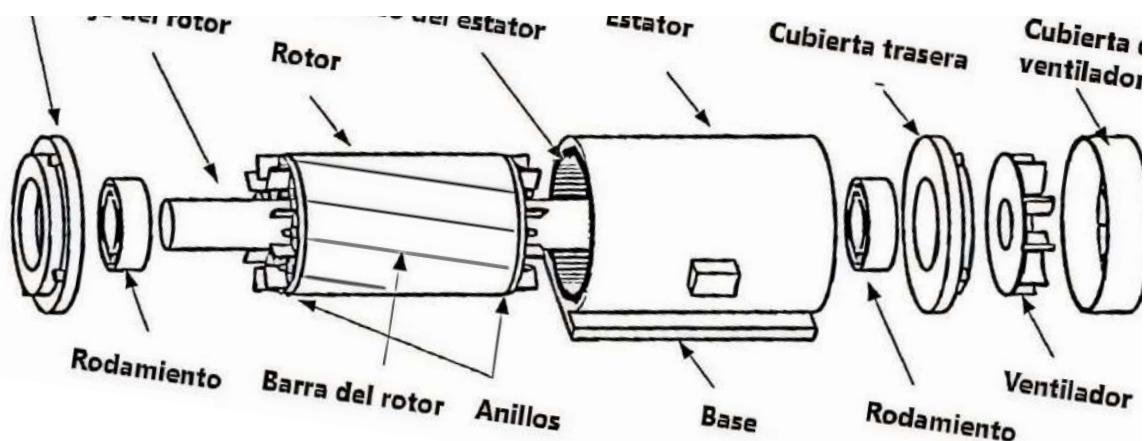


Figura 2.1 Esquema de partes principales que conforman un motor eléctrico de inducción  
(Traducido de Gangsar & Tiwari, 2020).

## 2.2 Fallas en motores y métodos de detección

El mantenimiento de los motores eléctricos se puede realizar principalmente de tres formas: por avería, tiempo fijo y basado en la condición del motor. En el mantenimiento por averías, se toman medidas de mantenimiento solo cuando el motor se descompone, en este caso, aunque el motor puede funcionar durante mucho tiempo antes de que se realice el mantenimiento, cuando se produce una avería es necesario realizar un mantenimiento mucho más costoso y también provoca pérdida de productividad; en el mantenimiento de tiempo fijo, se requiere que el motor se detenga para realizar el mantenimiento y reemplazo de las piezas de desgaste, lo que provoca un tiempo de inactividad prolongado, con los correspondientes inconvenientes económicos y de producción; finalmente, el mantenimiento basado en la condición del motor permite que el motor

funcione normalmente cuando se ha identificado una falla, se obtienen los datos necesarios para que el operador tome la mejor decisión posible sobre el curso de acción correcto. Si los datos son insuficientes existe la posibilidad de un diagnóstico erróneo de la condición del motor, que conduce a la sustitución inadecuada de los componentes. En el monitoreo de condición, se puede implementar un sistema en el que las señales del motor en cuestión se envían continuamente a un sistema de adquisición de datos y la salud del motor se evalúa continuamente durante su funcionamiento, esto se conoce como monitoreo de condición en línea y, por lo tanto, es posible identificar las fallas incluso cuando apenas se están desarrollando. El operador/técnico puede prepararse para el mantenimiento y puede organizar las piezas de repuesto necesarias, por adelantado para la reparación, por lo tanto, el monitoreo de la condición puede optimizar el programa de mantenimiento y minimizar el tiempo de inactividad de los motores y, de esta forma, aumentar la confiabilidad del motor (Karmakar et al., 2016).

De acuerdo con la publicación de prácticas recomendadas para el diseño de sistemas de energía industriales y comerciales confiables de la IEEE (1997), cerca de un 44% de las fallas en los motores de inducción se deben a los rodamientos, alrededor de un 26% están relacionadas a los devanados, un 8% están relacionadas al rotor, carcasa o acoplamientos, mientras que el porcentaje restante se debe a diversas fallas que no fueron especificadas en el estudio. Al transformar la energía eléctrica a mecánica, un motor de inducción presenta pérdidas de energía, que se estiman de la siguiente forma:

- Pérdidas por fricción 5-15%
- Pérdidas en el núcleo de hierro 15-25%
- Pérdidas en el estator 25-40%
- Pérdidas en el rotor 15-25%

Un motor puede presentar diferentes fallas simultáneamente. Además, cuando se presentan múltiples fallas, determinar cuál fue el problema inicial es difícil, produciendo múltiples efectos, tales como consumos elevados de corriente o voltaje, reducción de la eficiencia y torque,

sobrecalentamiento, vibración, oscilaciones en el torque y ocasionar que se incrementen componentes harmónicos en corrientes y voltajes. en la mayoría de las fallas el motor podrá continuar trabajando con un rendimiento reducido, pero presentará un deterioro gradual cuando la falla no es atendida. Una forma de realizar el diagnóstico de fallas del motor es mediante el análisis de corriente característica (MCSA) o análisis de vibraciones (motor vibration análisis, MVA). Actualmente se han propuesto varios enfoques basados en MCSA para detectar diferentes tipos de fallas mecánicas internas como falla de barra de rotor rota, falla de rodamientos, falla mecánica de rotor desequilibrado, detección de desequilibrios de tensión del estator y efectos monofásicos utilizando técnicas avanzadas de procesamiento de señales. La mayor parte del análisis utilizado para el diagnóstico de fallas que se inició hace unas tres décadas se había realizado utilizando herramientas basadas en la FFT, en la firma de vibración o corriente del motor. Sin embargo, la FFT tiene algunas limitaciones, como el enmascaramiento de frecuencias características (generalmente frecuencias de baja amplitud) por la frecuencia de alimentación, señales transitorias, etc. Para superar estas limitaciones actualmente se están utilizando diferentes técnicas de procesamiento nuevas, tales como: STFT, WT (wavelet transform, transformada wavelet), DWT y CWT (continuous wavelet transform, transformada wavelet continua), WVD (Wigner-Ville distribution, distribución de Wigner Ville), PSD (power spectral density, densidad espectral de potencia), transformada de Park, SVM (support vector machine, máquinas de vectores de soporte), análisis de Prony, lógica fractal y lógica difusa, ya que la mayoría de estas técnicas son aplicables a señales no estacionarias (Karmakar et al., 2016).

### **2.2.1 Descripción de fallas**

Como ya se mencionó, pueden existir una gran diversidad de fallas que pueden presentarse en los motores de inducción, en esta subsección se describirán las principales fallas, en qué consisten, qué condiciones puede ocasionarlas, los efectos que producen y los métodos de detección más comúnmente utilizados.

### **2.2.2 Falla por ruptura barra**

Según la descripción proporcionada por Karmakar et al., (2016), esta falla ocurre cuando una o más barras de la jaula de ardilla se encuentran parcial o totalmente quebradas, dichas barras pueden romperse debido a defectos de fabricación, arranques frecuentes a voltaje nominal, tensiones térmicas y / o estrés mecánico causado por fallas en los rodamientos y fatiga del metal, un ejemplo de esta falla se muestra en la Figura 2.2. Una barra rota causa varios efectos en los motores de inducción. Un efecto es la aparición de los llamados componentes de banda lateral. Estas bandas laterales se encuentran en el espectro de potencia de la corriente del estator en los lados izquierdo y derecho del componente de frecuencia fundamental (Silva, 2014) La corriente que fluye en cada barra contribuye al torque del motor, el flujo de corriente casi se detiene cuando una barra se agrieta o se rompe, esto ocasiona que transporte muy poca corriente por lo que las barras de rotor rotas disminuyen la potencia de un motor (Hand, 2011) es posible identificar componentes frecuenciales características de esta falla en las señales de corriente y flujo magnético disperso mediante la Ecuación 1 (Antonino et al., 2022).

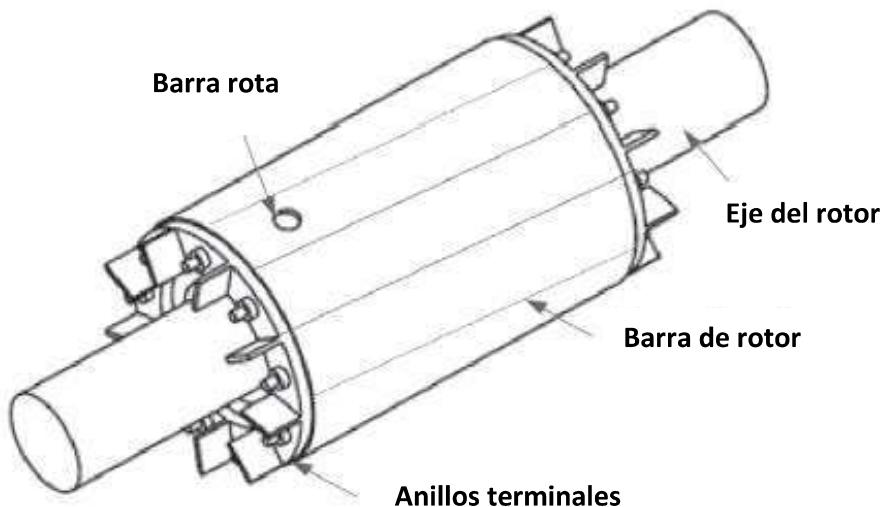


Figura 2.2 Falla de ruptura de barra en el rotor. (Traducido de Gangsar & Tiwari, 2020).

Ecuación 1

Donde  $f$  es la frecuencia fundamental  $s$  es el deslizamiento y

### 2.2.3 Desbalanceo en la masa del rotor

Es una distribución desigual de la masa alrededor del centro de rotación del rotor, como se muestra en la Figura 2.3, hay tres tipos de desbalanceo: A) el desbalanceo estático, que ocurre cuando el eje principal de inercia de un rotor está desplazado de forma paralela al eje de rotación y solo se corrige en un plano axial; B) el desbalanceo de par ocurre cuando el eje principal de inercia interseca el eje de rotación en el centro de gravedad; y C) el desequilibrio dinámico es la combinación del desequilibrio estático y el desequilibrio acoplado. Aunque un motor se diseña, fabrica, ensambla para garantizar un equilibrio adecuado en condiciones de funcionamiento, siempre existe cierto grado de desequilibrio de masas en el motor, sin embargo, si la desviación en la simetría de masas alrededor del eje de rotación se vuelve significativa o si la velocidad de rotación del motor es considerablemente alta (Tong, 2022), es la causa principal de fuerzas centrífugas y vibraciones extremas durante el funcionamiento que degradan la vida útil del rotor, los cojinetes, el acoplamiento, los sellos y los engranajes, un pequeño desbalanceo puede causar problemas graves en los motores de inducción de alta velocidad y en los peores casos, puede hacer que el rotor y el estator entren en contacto y se rocen entre sí, lo que resulta en una falla grave del motor (Gangsar & Tiwari, 2020).

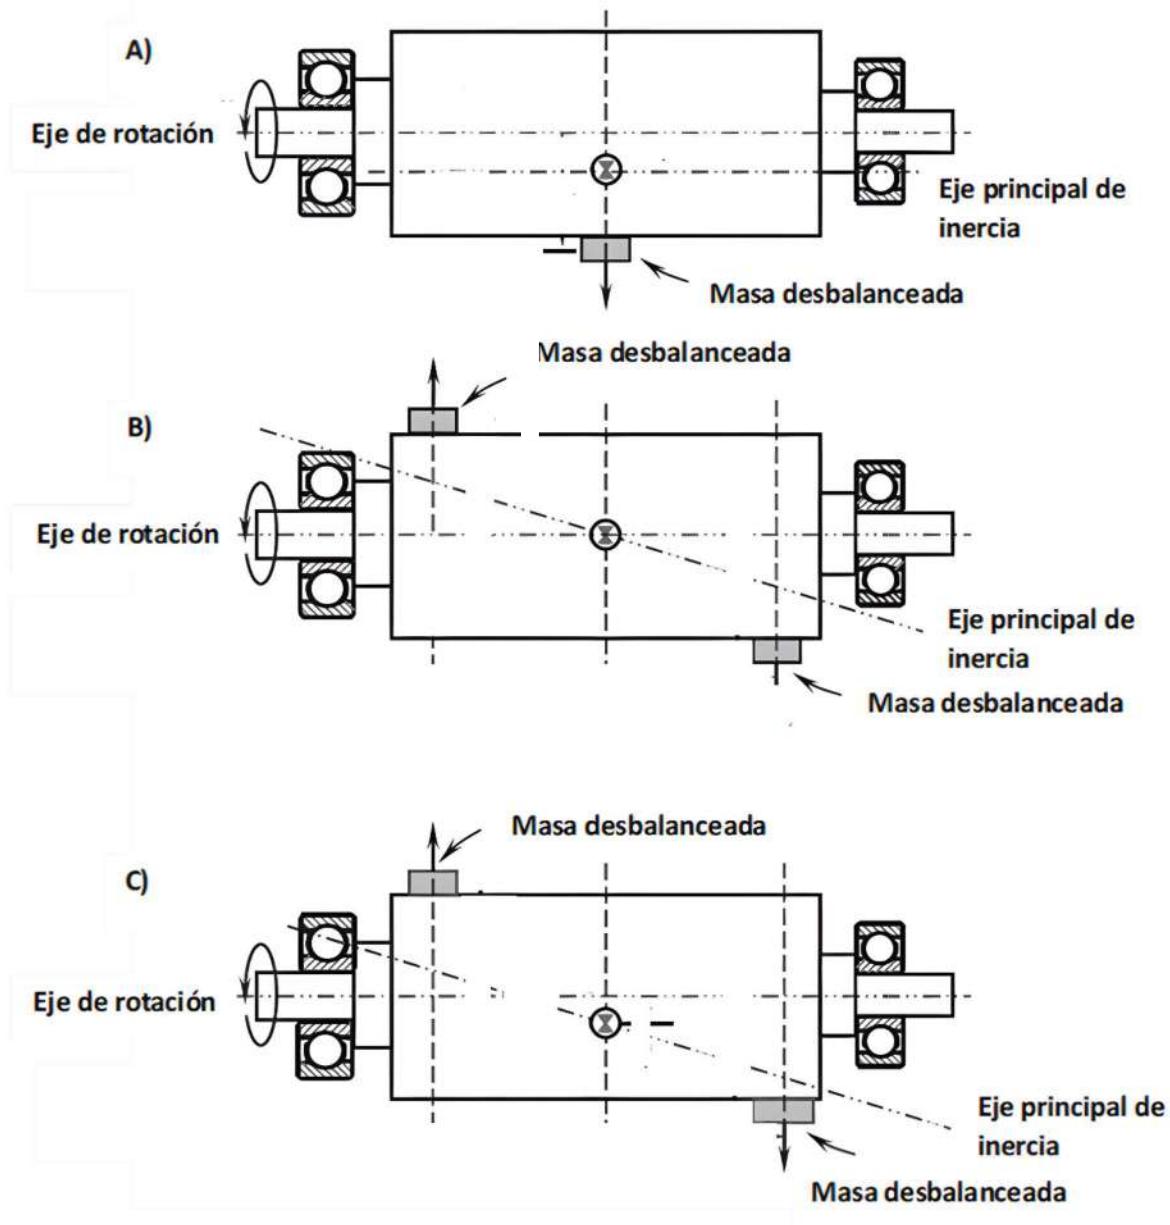


Figura 2.3 Falla de ruptura de barra en el rotor. (Traducido de Tong, 2022).

## 2.2.4 Fallo en los rodamientos

Las fallas relacionadas con los rodamientos de esferas se pueden categorizar como defecto en la pista externa del rodamiento, defecto en la pista interna y defecto en las esferas. La Figura 2.4 muestra un ejemplo de estos tipos de fallas. De acuerdo con la información proporcionada por la IEEE, las fallas en los rodamientos conforman el grupo de fallas más común en los motores de inducción, pues incluso en condiciones normales de funcionamiento con carga equilibrada y buena alineación, pueden producirse fallos por fatiga, que puede ocasionar que las piezas pequeñas se desprendan del rodamiento (Nandi et al., 2005). Según un estudio de fallas en motores de inducción de Thorsen & Dalva, (1995) las causas más frecuentes de fallas en los rodamientos se deben a ruptura, vibraciones, sobrecargas o sobrecalentamiento, ocasionados por una mala operación del equipo, componentes defectuosos o un mantenimiento inadecuado o mal realizado. La falla de rodamientos puede producir una vibración excesiva en el motor ya que la dinámica del eje está influenciada por el cambio en la rigidez del rodamiento, los efectos finales son fallas de las barras del rotor (Gangsar & Tiwari, 2020). Tian et al. (2018) mencionan que este grupo de fallas es identificado principalmente mediante análisis de vibraciones, pero también puede identificarse por medio del monitoreo de temperatura, flujo magnético, ruido y corriente. La falla de un rodamiento puede resultar en una gran cantidad de daños a otros componentes del motor, debido a que el rotor está totalmente soportado por los rodamientos, cualquier defecto puede conducir directamente a la variación de la posición radial del rotor (Tong, 2019) es posible identificar componentes frecuenciales características de esta falla en las señales de flujo magnético disperso y corriente mediante la Ecuación 2 para fallas relacionadas a la pista exterior, la Ecuación 3 para fallas relacionadas a la pista interior y la Ecuación 4 para fallas relacionadas a las esferas del rodamiento (Antonino et al., 2022).

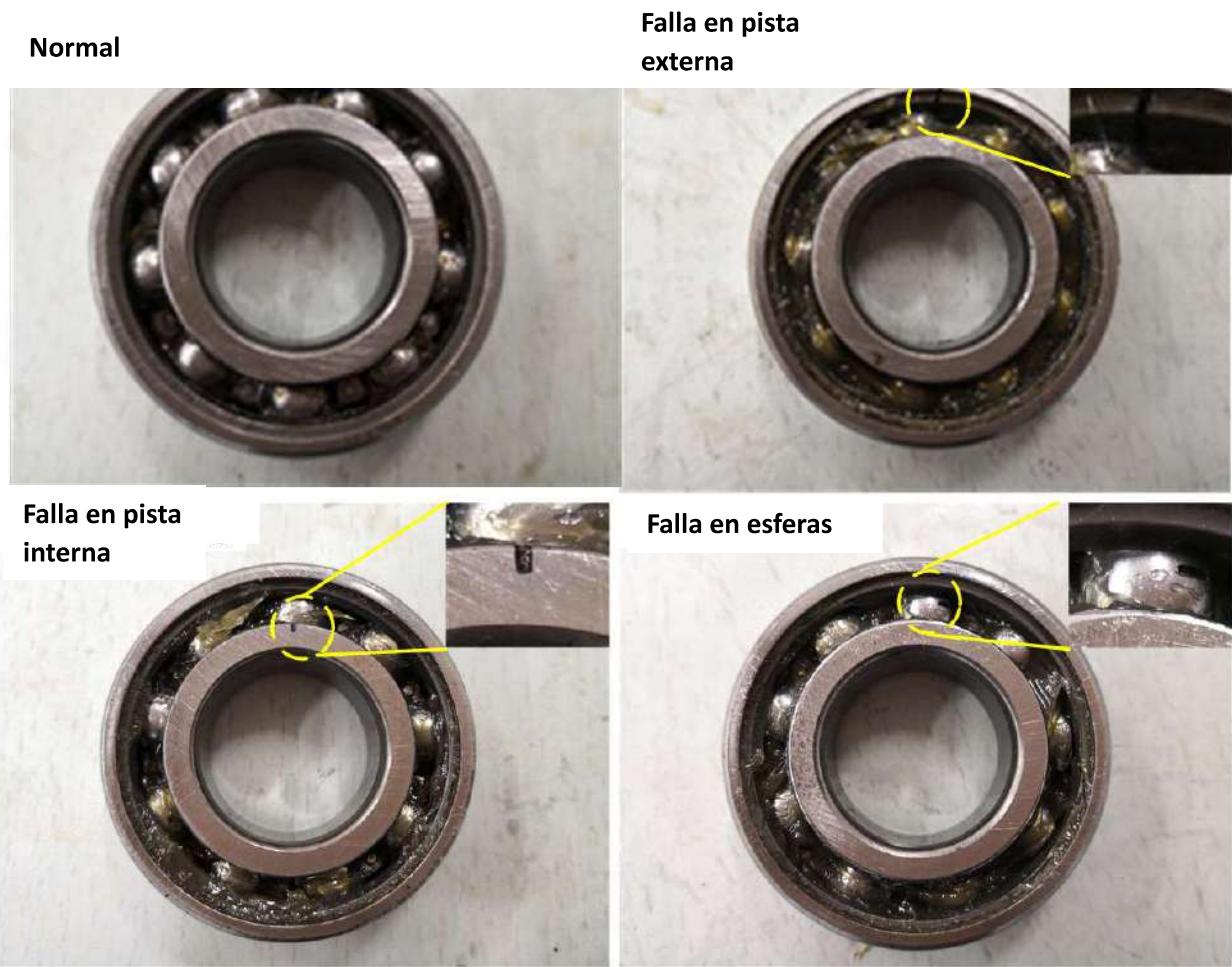


Figura 2.4 Diferentes tipos de falla en rodamientos (traducido de Liu et al. (2020)).

Ecuación 2

Ecuación 3

Ecuación 4

donde  $\omega$  es la frecuencia de rotación,  $f_0$  es la frecuencia fundamental,  $N$  es el número de esferas,  $D$  es el diámetro de las esferas y  $\alpha$  es el ángulo de contacto

## 2.2.5 Cortocircuito en el estator

El estator de un motor de inducción está expuesto a muchos esfuerzos, tanto mecánicos, eléctricos, térmicos y ambientales, dependiendo de la severidad de estos esfuerzos, como se observa en la Figura 2.5, pueden ocurrir cortocircuitos en el embobinado del estator, que se deben a una falla en el aislamiento del devanado del estator lo cual puede ocurrir debido al calentamiento excesivo (estrés térmico), fuente de alimentación desequilibrada (estrés eléctrico), golpes por barra del rotor rota, desequilibrada o desalineada (estrés mecánico), la vibración, falla durante la instalación y la contaminación por aceite. Esta falla puede dar lugar a la apertura, cortocircuito o puesta a tierra de uno o más circuitos de embobinado, calentamiento excesivo y daño total de las máquinas. Estas fallas producen campo magnético no uniforme en los motores de inducción que provocan alta vibración mecánica y aumento de la ondulación del par (Gangsar & Tiwari, 2020). Componentes frecuenciales características de esta falla pueden ser identificadas en las señales de flujo magnético disperso y corriente mediante la Ecuación 5 (Antonino et al., 2022).

Ecuación 5

Donde  $\omega$  es la frecuencia de rotación,  $f$  es la frecuencia de alimentación,  $p$  es un entero impar y  $m$  es un entero de tal forma que  $\omega = mf$ , donde  $m$  es un entero

**Falla de estator**  
(corto circuito entre espiras en la fase b)

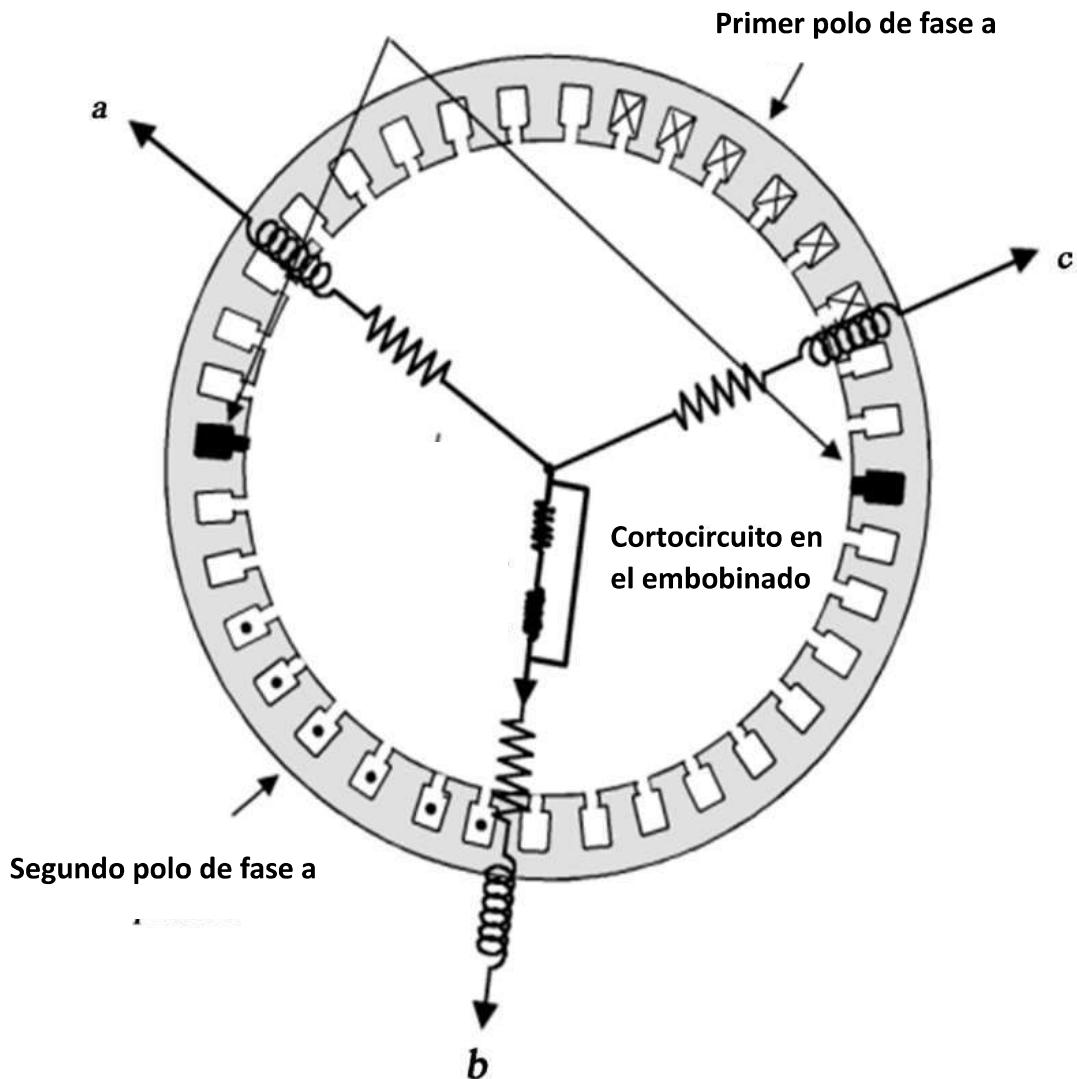


Figura 2.5 Falla en el estator. (traducido de Teguia et al, 2020).

## 2.2.6 Falla en una fase

Es cuando en un motor eléctrico de inducción de dos o tres fases, una fase deja de suministrar energía, usualmente se debe a que el fusible de la línea se quemó. Otro tipo de fallas pueden deberse al sistema de alimentación o corto circuito en un motor, lo que provoca sobrecalentamiento, ruido de vibración del eje y en última instancia, daños en el aislamiento y fallas en el devanado del estator (Gansar & Tiwari, 2020).

## 2.2.7 Falla por excentricidad

La excentricidad de la máquina es la condición de espacio desigual que existe entre el estator y el rotor. Cuando la excentricidad es grande, las fuerzas desequilibradas resultantes pueden hacer que el estator y el rotor se rocen entre sí, y esto puede resultar en graves daños tanto en el estator como en el rotor. Como se puede observar en la Figura 2.6, hay dos tipos de excentricidad: la estática y la dinámica. La excentricidad estática puede ser causada porque el núcleo del estator se ha deformado o por el posicionamiento incorrecto del rotor o estator. En caso de excentricidad dinámica, el centro del rotor no está en el centro de rotación. Esta desalineación puede deberse a varios factores, como un eje de rotor doblado, desgaste o desalineación del rodamiento, resonancia mecánica, etc. Tanto las excentricidades estáticas como las dinámicas tienden a coexistir, existe un nivel inherente de excentricidad estática incluso en motores nuevos debido al método de fabricación y montaje (Nandi et al., 2005). Esta falla produce picos de frecuencia adicionales en el espectro de corriente y vibración (Tong, 2022). Las frecuencias que indican una falla por excentricidad pueden ser determinadas mediante la Ecuación 6 para señales de corriente y la Ecuación 6 y Ecuación 7 para señales de flujo magnético (Antonino et al., 2022).

Ecuación 6

Ecuación 7

Donde  $s$  es el deslizamiento,  $f_r$  es la frecuencia de rotación y  $f_a$  es la frecuencia de alimentación

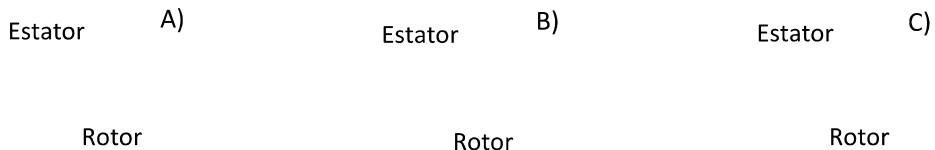


Figura 2.6 Diferentes tipos de falla por excentricidad: A) excentricidad estática B) excentricidad dinámica C) excentricidad combinada. (traducido de Faiz & Ojaghi, 2009).

Las frecuencias de falla obtenidas a partir de la investigación de las fallas son recapituladas en la Tabla 2.1.

Tabla 2.1 Ecuaciones para identificación de frecuencias de falla en motores de inducción (autoría propia).

	Ecuación 1
	Ecuación 2
	Ecuación 3
	Ecuación 4
	Ecuación 5
	Ecuación 7

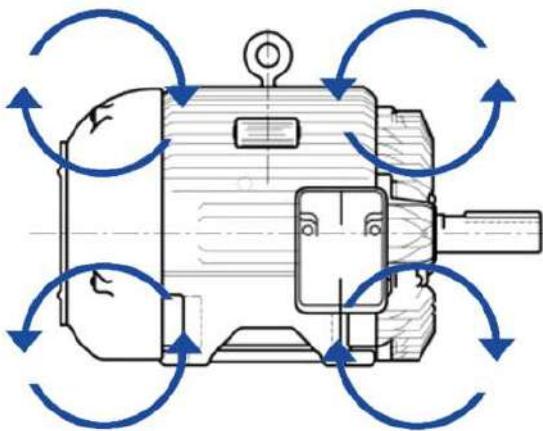
Donde  $f$  es la frecuencia fundamental,  $s$  es el deslizamiento y  $\omega$  es la frecuencia de rotación,  $N$  es el número de esferas,  $D$  es el diámetro de las esferas y  $\alpha$  es el ángulo de contacto,  $p$  es un entero impar y  $q$  es un entero de tal forma que  $p/q$  es un entero y  $\alpha = 180^\circ$ .

## 2.3 Señales empleadas para diagnóstico de fallas en un motor de inducción:

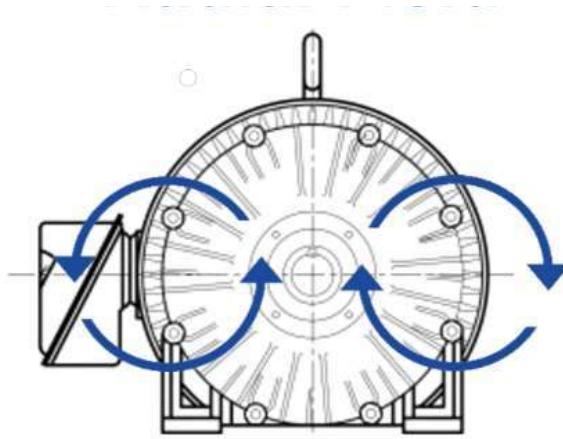
Como ya se ha mencionado previamente, existen múltiples mediciones de señales obtenidas a partir de un motor que pueden ser empleadas con el objetivo de detectar indicios de que un motor se encuentra en fallo y permiten conocer aproximadamente la condición de uno de estos equipos sin tener interrumpir su funcionamiento, en esta sección se hablara un poco más a detalle de los principales tipos señales empleadas con este objetivo, siendo estas el flujo magnético, la corriente, vibración, y temperatura.

### **2.3.1 Flujo magnético**

En el caso del flujo magnético, dado que un motor de inducción presenta simetría respecto a su eje, la existencia de fallas o daños que alteren esta simetría provoca cambios en la distribución del flujo magnético o en la magnitud de algunas frecuencias específicas asociadas a fallas conocidas (Gangar & Tiwari, 2020). Las metodologías basadas en el monitoreo del flujo magnético se basan principalmente en el monitoreo del flujo disperso o del flujo magnético en el entrehierro. El flujo magnético disperso, que se refiere a aquel que irradia desde la máquina hacia el exterior del armazón, esto es un efecto residual indeseable, ya que no contribuye a la generación de torque del motor. En un motor trifásico ideal en condiciones de operación normales, el flujo disperso prácticamente no debería existir, sin embargo, incluso en motores nuevos, siempre hay un grado de asimetría en la fabricación y siempre es posible detectarlo, el análisis del espectro de frecuencia del flujo disperso puede proporcionar información sobre las fallas que ocurren en un motor de inducción, las técnicas basadas en esta metodología tienen la ventaja de ser no invasivas, ya que el monitoreo se realiza desde el exterior del motor y la medición de la señal se realiza con el motor en funcionamiento (Ceban et al., 2012). El flujo magnético disperso tiene dos componentes principales, que son el flujo disperso axial y radial. La Figura 2.7 muestra la circulación de las líneas de campo para los flujos magnéticos axiales y radiales. También es posible capturar una combinación de estos dos flujos, dependiendo de la posición en la que se coloque el sensor.



**Flujo disperso axial**



**Flujo disperso radial**

Figura 2.7 Ejes principales de flujo magnético disperso. (Autoría propia).

De acuerdo con la revisión del análisis de flujo magnético para el monitoreo de condición de máquinas eléctricas de Zamudio et al. (2022), el uso de sensores de flujo magnético y el análisis de las señales obtenidas para fines de monitoreo de condición tiene muchas ventajas, las cuales son que esta técnica ha demostrado ser eficiente y confiable en los casos en que las técnicas convencionales producen indicaciones falsas, su naturaleza es no invasiva y su implementación es simple; además, se requieren sensores de muy bajo costo; por último estos sensores tienen una gran flexibilidad y simplicidad de instalación. En el caso de las técnicas basadas en monitorear el flujo magnético en el entrehierro, es posible obtener señales que contienen información valiosa para el diagnóstico del estado del motor. Este tipo de monitoreo se realiza dentro del motor y tiene la desventaja de que se debe intervenir el motor previamente para instalar un sensor de flujo magnético en su interior. El monitoreo del flujo magnético del entrehierro puede ofrecer una mayor sensibilidad a varios tipos de fallas en comparación con las técnicas de monitoreo de señales magnéticas externas. Sin embargo, no es un método seguro para la operación de mayoría de los motores de inducción, ya que la instalación de componentes dentro del motor podría interferir en su funcionamiento. Por lo tanto, este tipo de monitoreo es más adecuado para motores que fueron diseñados desde el principio para este tipo de monitoreo Mazaheri & Faiz, (2022).

### **2.3.2 Corriente**

El método de análisis de la firma de corriente del motor (MCSA) opera midiendo las corrientes del estator del motor de inducción. Es más simple que otras técnicas, ya que este método no invasivo solo requiere una entrada. El MCSA detecta armónicos de corriente no deseados asociados con la corriente del estator que son producidos por el flujo rotativo. El análisis espectral del MCSA permite detectar varias fallas eléctricas y mecánicas, la técnica se basa en la información de frecuencia que tiene dos bandas laterales alrededor de los componentes de frecuencia fundamental, cualquier anomalía provoca variaciones en las bandas laterales del espectro de frecuencia de la corriente (soother & Duadpoto, 2019).

### **2.3.3 Vibración**

Todos los motores producen ruido y vibración durante su funcionamiento, la salud del motor puede ser estimada mediante el análisis de estos ruidos y vibraciones. Un alto nivel de ruido puede ser generado por una pequeña amplitud de vibración en la estructura de una máquina, las fuerzas magnetomotrices y mecánicas son la causa de ruido y vibraciones en los motores, las fuerzas radiales resultantes del campo del entrehierro son las mayores fuentes de vibraciones en los motores. Es posible detectar diferentes tipos de defectos y asimetrías cuando se analiza la señal de vibración de los motores, las situaciones más adecuadas para realizar diagnósticos basados en el análisis de vibraciones son aquellas en las que se busca diagnosticar fallas en rodamientos y engranajes (Muhammad et al., 2021).

### **2.3.4 Temperatura**

El monitoreo térmico de señales en motores de inducción se basa en que se produce una cantidad excesiva de calor en motor en diferentes puntos del motor debido a diferentes fallas, ya que muchas de estas producen fricción o rozamiento entre los componentes mecánicos del motor, la magnitud del calentamiento puede indicar la gravedad de la falla, en consecuencia, muchos investigadores han desarrollado modelos térmicos de los motores eléctricos. De acuerdo con Muhammad et al., (2021).existen principalmente dos categorías para la clasificación de los diversos modelos térmicos del motor:

1.- Modelos basados en análisis de elementos finitos (FEA).

2.- Modelos térmicos de parámetros concentrados.

Aunque los modelos basados en FEA funcionan con mayor precisión, requieren una gran capacidad computacional. Por otro lado, los modelos térmicos de parámetros concentrados son un modelo que consta de capacitancias y resistencias térmicas, así como sus pérdidas de potencia asociadas. La precisión de un modelo generalmente depende de cuántos cuerpos térmicamente homogéneos componen el modelo.

## **2.4 Procesamiento de señales para detección de fallas**

El procesamiento de señales una técnica eficiente en la detección de problemas en los motores de inducción, la transformada rápida de Fourier y la transformada de Fourier de tiempo corto son técnicas ampliamente utilizadas para analizar la condición de un motor basándose en las características de las señales obtenidas y en las que se basará el desarrollo del smart sensor propuesto en este trabajo por lo que enseguida se describen sus fundamentos teóricos.

### **2.4.1 FFT**

La transformada de Fourier convierte una señal del dominio del tiempo al dominio de la frecuencia, para hacer esto se requiere un número de cálculos igual a  $N$  donde  $N$  es el número de datos, la transformada rápida de Fourier ejecuta la misma acción de convertir una señal del dominio del tiempo al dominio de la frecuencia y viceversa, pero en este caso el número de cálculos es  $\log N$ . La diferencia entre el número de cálculos es inmensa, el número de cálculos requeridos para la FFT es pequeño en comparación con la transformada de Fourier, para grandes sets de datos (1000 o más) la diferencia en velocidad para realizar la transformada se vuelve enorme, por lo que la FFT se convierte en una herramienta práctica, conveniente y fundamental para los sistemas digitales de procesamiento de señales, por lo que esta técnica es ampliamente usada en campos como la ingeniería, comunicaciones, aplicaciones mecánicas y muchos otros. De acuerdo con un comparativo de técnicas de análisis de procesamiento para detección de fallas en motores de inducción trifásicos de Amanuel (2021), la FFT es un método más rápido que la

DWT, por lo que el procesamiento de señales es más rápido. La FFT descompone un conjunto de valores en el espectro de la señal de un dominio a otro, la FFT de una señal se define en la Ecuación 8.

Ecuación 8

Donde  $N$  es el número de muestras,  $k=0,1,2,\dots,N-1$  y  $x(n)$  es la señal discreta en el dominio del tiempo.

La FFT aplicada en el diagnostico de motores el análisis se realiza cuando el motor se encuentra en estado estacionario y permite obtener diferentes componentes de frecuencia presentes en la señal, en los últimos años ha existido una gran cantidad de trabajos de investigación que se basan en la FFT bajo este contexto, sin embargo, existen limitaciones en la aplicación de la FFT, por ejemplo, que la frecuencia de muestreo debe ser al menos el doble que la frecuencia de la señal analizada, se observa que en algunos casos las frecuencias generadas son muy cercanas a la frecuencia fundamental con pequeña amplitud. Por lo tanto, las frecuencias características para el motor en falla están muy cerca del componente fundamental y su amplitud es pequeña en comparación con la fundamental, la detección de la falla y la determinación de la gravedad de la falla bajo una carga ligera no es posible, especialmente en motores pequeños. Además, la longitud de ventana de datos debe ser un múltiplo entero de la frecuencia de la fuente de alimentación, ya que si no se cumplen estos requerimientos, se obtendrán resultados inexactos, ya que la frecuencia de la fuente puede enmascarar totalmente las componentes de frecuencia características del motor estudiado especialmente si el motor es pequeño y se encuentra operando sin cargas o cargas muy pequeñas, debido a esto la detección de fallas o la determinación de su severidad no es posible en este tipo de casos. Otra limitación importante de la FFT es que no es apropiada para señales cuyas características pueden cambiar con el tiempo debido a que al transformar los componentes al dominio de la frecuencia la información del tiempo se pierde, por esta razón es un método inapropiado en casos como el análisis de la corriente al arrancar un

motor; también debido a que en este ejemplo la variación de carga en el motor, inercia, torque, voltaje de alimentación u oscilación en la velocidad del motor puede dar origen a armónicos que sean similares a frecuencias características de un motor en falla, este problema se soluciona con el uso de otra herramienta de procesamiento de señales digitales llamada la transformada de Fourier de tiempo corto (STFT) (Karmakar et al., 2016).

## 2.4.2 STFT

La STFT es normalmente usada para el mapeo de una señal en dos variables, el tiempo y la frecuencia, en los cuales el tiempo es discreto y la variable de frecuencia es continua, de esta forma, es capaz de analizar una señal transitoria que varía en el tiempo.

Si en una secuencia el índice de tiempo es fijo, la STFT se convierte en una transformada de Fourier normal, al mantener un valor específico de frecuencia la interpretación lleva a considerarla como un filtrado lineal, esto es útil cuando solo se requiere identificar un número de frecuencias particulares, este enfoque se puede utilizar para determinar la frecuencia fundamental y su múltiplo entero. Otro enfoque es la aplicación de la función de ventana a la señal de entrada. La ventaja de esta aplicación es que la señal periódica se puede analizar sin determinar el múltiplo entero de sus períodos. Hay diferentes tipos de funciones de ventana. Entre ellas, las funciones de ventana hamming y ventana hanning son adecuadas para la estimación armónica e interarmónica. La STFT utiliza una ventana de tamaño constante para analizar todas las frecuencias, esta es la limitación de este método, esta ventana limitada puede tener dificultades para igualar el contenido de frecuencia de la señal, que generalmente no se conoce antes del análisis. Para superarla, se requiere que esta ventana de tamaño limitado sea reemplazada por una ventana de tamaño variable, en estos casos se utiliza la transformada wavelet (WT) una ventana de tamaño variable adecuada. La STFT de una señal  $X(m,w)$  se muestra en la Ecuación 9 (Karmakar et al., 2016).

Ecuación 9

Donde  $x(n)$  es la señal,  $w(n)$  es la ventana y  $y$  es la frecuencia.

### 2.4.3 Indicadores estadísticos

Las técnicas basadas en indicadores estadísticos generalizan problemas con la ayuda de  $y$  examinan la estructura de la distribución de la señal para continuar con la tarea de predicción (Sen et al., 2020). El emplear indicadores estadísticos para procesamiento y posterior análisis de las señales presenta diversas ventajas, por ejemplo es posible modelar tendencias y cambios en señales que se encuentran en el dominio del tiempo, mientras que cambios en las componentes de principales pueden ser modelados al analizar señales en el dominio de frecuencia, además de que estos cálculos son sencillos y ofrecen una ventaja a nivel de carga computacional respecto a muchas otras técnicas actualmente empleadas (Saucedo et al., 2021). Algunos ejemplos de indicadores estadísticos se muestran a continuación en la Tabla 2.2.

Tabla 2.2 Indicadores estadísticos (autoría propia).

Función:	Formula:
Media	Ecuación 10
Valor máximo	Ecuación 11
Raíz media cuadrada (RMS)	Ecuación 12
Raíz cuadrada media (SRM)	Ecuación 13
Desviación estándar	Ecuación 14
Varianza	Ecuación 15
Factor de forma RMS	Ecuación 16

Factor de forma SRM	Ecuación 17
Factor de cresta	Ecuación 18
Factor de latitud	Ecuación 19
Factor de impulso	Ecuación 20
Skewness	Ecuación 21
Kurtosis	Ecuación 22
Quinto momento	Ecuación 23
Sexto momento	Ecuación 24

Donde  $\bar{x}$  es una muestra para  $x$ , donde  $n$  es el numero de datos de una señal adquirida.

## 2.5 Algoritmos de clasificación

Un algoritmo de clasificación es aquel que cuenta con una basa de reglas o es entrenado con diferentes técnicas de aprendizaje automático para asignar datos a una clase en particular de acuerdo con las características que presenta. De acuerdo con una revisión de los algoritmos de clasificación supervisados en el aprendizaje automático de Sen et al. (2020) en el que se resumen las principales características y ventajas de diferentes algoritmos de aprendizaje usados en tareas de clasificación, existe la clasificación binaria y multi etiqueta. La clasificación binaria es aquella en la que uno de dos resultados es posible; la clasificación multi etiqueta es aquella en la que dos o más condiciones pueden ser posibles simultáneamente. En esta subsección se mencionan algunos de los principales métodos de clasificación saucedo et al. (2021).

### 2.5.1 Redes neuronales artificiales

Las redes neuronales artificiales (Artificial neural network, ANN) son programas informáticos inspirados en la biología diseñados para simular la forma en que el cerebro humano procesa la información, adquieren su conocimiento detectando los patrones y relaciones en los datos y aprenden, o son entrenadas a través de la experiencia. Una red neuronal está formada por múltiples unidades individuales, neuronas artificiales o elementos de procesamiento, conectados con coeficientes o ‘pesos sinápticos’, que constituyen la estructura neuronal y están organizados en capas. El poder de los cálculos neuronales proviene de la conexión de las neuronas en una red. Cada neurona tiene entradas ponderadas, una función de transferencia y una salida. El comportamiento de una red neuronal está determinado por las funciones de transferencia de sus neuronas, por la regla de aprendizaje y por la arquitectura misma. Los pesos son los parámetros ajustables y, en ese sentido, una red neuronal es un sistema parametrizado. La suma ponderada de las entradas constituye la activación de la neurona. La señal de activación se pasa a través de la función de transferencia para producir una única salida de la neurona, la función de transferencia introduce no linealidad en la red. Durante el entrenamiento, las conexiones entre unidades se optimizan hasta que se minimiza el error en las predicciones y la red alcanza el nivel especificado de precisión. Una vez que la red está entrenada y probada, se le puede proporcionar nueva información de entrada para predecir la salida Agatonovic & Beresford, (2000). En la Figura 2.8 se muestra una estructura básica de una red neuronal. La red consta de tres capas: una capa de entrada, una o más capas ocultas y una capa de salida.

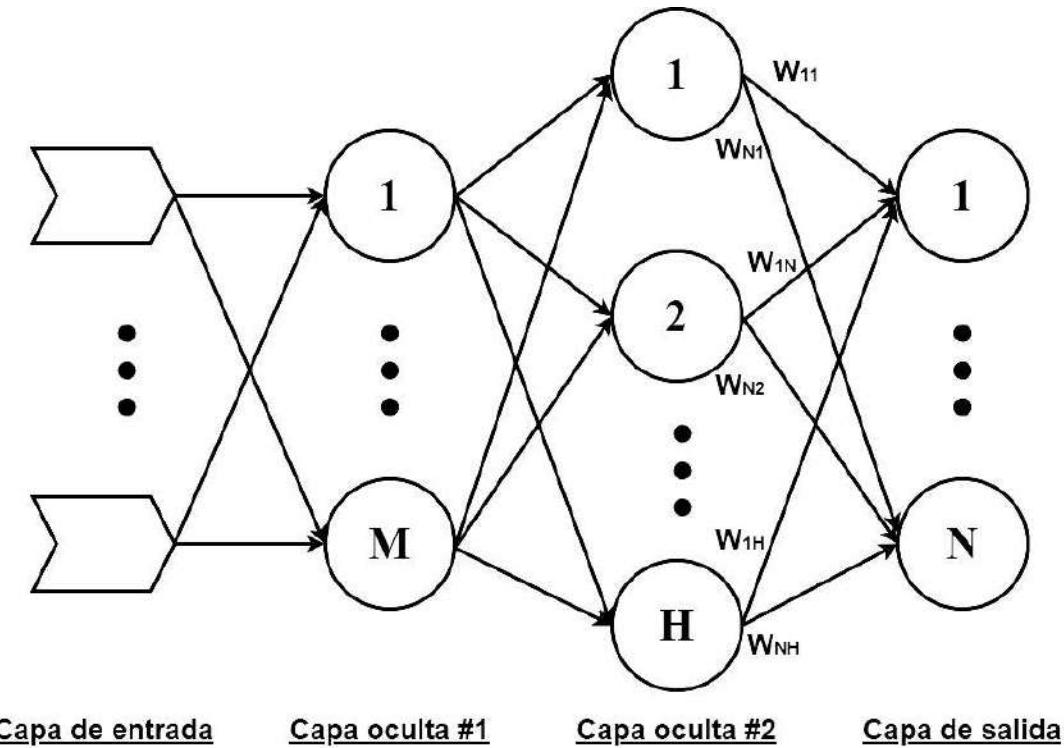


Figura 2.8 Ejemplo de una red neuronal (autoría propia).

De acuerdo con Zupan (1994) una neurona artificial busca imitar la acción de una neurona biológica, es decir, que acepta diferentes señales de neuronas vecinas y las procesa de una manera predefinida y simple, un ejemplo de una neurona se puede apreciar en la Figura 2.9. Dependiendo del resultado de este procesamiento, la neurona decide si emitir una señal de salida o no. La señal de salida (si se activa) por lo general es un valor 0 o 1, se considera que la función que calcula la salida a partir del vector de entrada de dimensiones. Según Hu & Hwang (2001) cada neurona consiste en dos partes, la función neta, que se describe en la Ecuación 25 y la función de activación. La función neta determina como las entradas se combinan dentro de la neurona, los coeficientes son conocidos como ‘pesos sinápticos’, es llamado ‘bias’ y se emplea para representar el sesgo, permite que la función de activación de cada neurona tenga cierta flexibilidad en su comportamiento y ayuda a que la red neuronal aprenda y represente mejor las

funciones. Como puede observarse en la Ecuación 26, la salida de la neurona esta relacionada a la entrada de la red a partir de una transformación lineal o no lineal por medio de una función llamada función de activación. En la Tabla 2.3 se puede observar una recopilación de algunas de las funciones de activación comúnmente usadas.

Ecuación 25

Ecuación 26

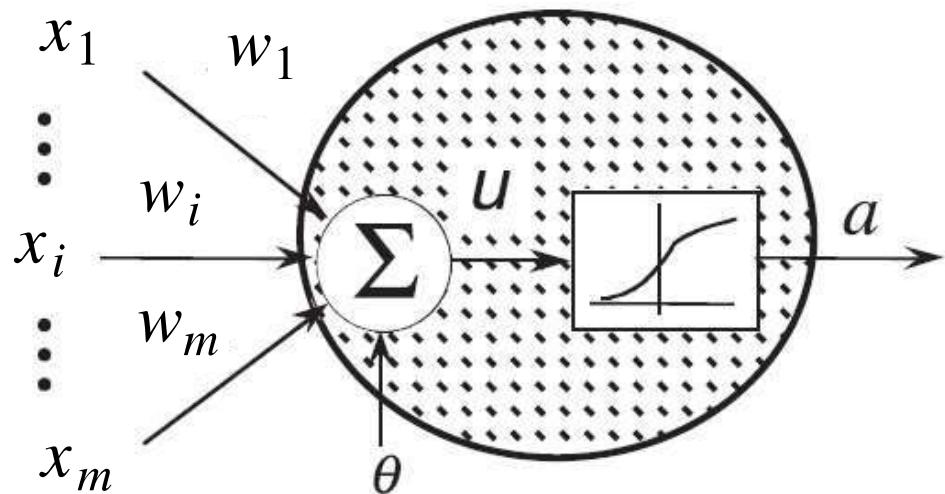


Figura 2.9 Ejemplo de una neurona (traducido de Hu & Hwang 2001).

Tabla 2.3 Funciones de activación (autoría propia).

Nombre de la función de activación:	Formula:
Sigmoide	Ecuación 27
Escalón	Ecuación 28
Escalón simétrico	Ecuación 29
Lineal	Ecuación 30
Lineal positiva	Ecuación 31
Tangente hiperbólica	Ecuación 32

### 2.5.2 Análisis de discriminante lineal (LDA)

LDA es un algoritmo supervisado que encuentra una transformación lineal utilizada para realizar una reducción de dimensionalidad de un conjunto de datos original mediante la maximización de la separabilidad entre diferentes clases, generalmente empleada para la clasificación. De forma general, el procedimiento para realizar LDA es el siguiente:

1. Calcular los vectores medios d-dimensionales de la matriz de entrada.
2. Calcular la matriz entre clases y la matriz de dispersión dentro de las clases.
3. Calcular los eigenvectores y eigenvalores.
4. Seleccionar los discriminantes lineales para el nuevo subespacio y formar una matriz de eigenvectores.
5. Utilizar la matriz de eigenvectores para transformar los vectores al nuevo espacio de menor dimensión. Maximizar la matriz entre clases y minimizar la matriz de dispersión dentro de las clases.

El objetivo de este clasificador es proyectar un conjunto de vectores de datos de dimensión en un subespacio más pequeño de dimensión dónde (Zamudio et al., 2022).

Para llevar a cabo esta tarea, LDA utiliza dos informaciones estadísticas: la matriz dispersa entre clases  $S_b$  obtenida mediante la ecuación (37) y la matriz dispersa dentro de las clases  $S_w$ , definidas a partir de la ecuación (38) como:

(37)

(38)

Donde  $C$  es el número de clases,  $X$  son los datos de entrenamiento compuestos por variables y números de muestras,  $\mathbf{x}_i$  denota los datos pertenecientes a la  $i$ -ésima clase,  $n_i$  es el número de mediciones de la  $i$ -ésima,  $\bar{x}_i$  es el número de todas las mediciones de entrenamiento,  $\bar{x}$  es el valor esperado para cada clase de entrenamiento y  $\mathbf{x}_i^*$  son los valores esperados para todos los conjuntos de datos. A partir de estas ecuaciones se tiene que la matriz de dispersión total de clases se obtiene de la ecuación (39) (Ciabattoni et al., 2015)

.

(39)

### 2.5.3 Máquina de vectores de soporte

Las máquinas de vectores de soporte fueron desarrolladas por Cortes & Vapnik en 1995 para la clasificación binaria. Como se muestra en la Figura 2.10, se busca el hiperplano de separación

óptimo entre dos clases maximizando el margen entre los puntos más cercanos de las clases, los puntos que se encuentran en los límites se llaman vectores de soporte, y el centro del margen es el hiperplano de separación óptimo (Meyer, 2009). Sus ventajas son muestra un aumento notable en el rendimiento cuando la "n" del espacio n-dimensional es mayor que el tamaño total del conjunto de muestras; es una buena opción elegir este algoritmo cuando se trata de datos con muchas dimensiones y si el hiperplano está bien construido, muestra un alto rendimiento. Sus principales desventajas son que el tiempo de entrenamiento es bastante elevado en comparación con otros algoritmos. Si el conjunto de datos es muy grande la tarea de predicción resulta ser notablemente lenta y cuando las clases se superponen su rendimiento también disminuye (Sen et al., 2020).

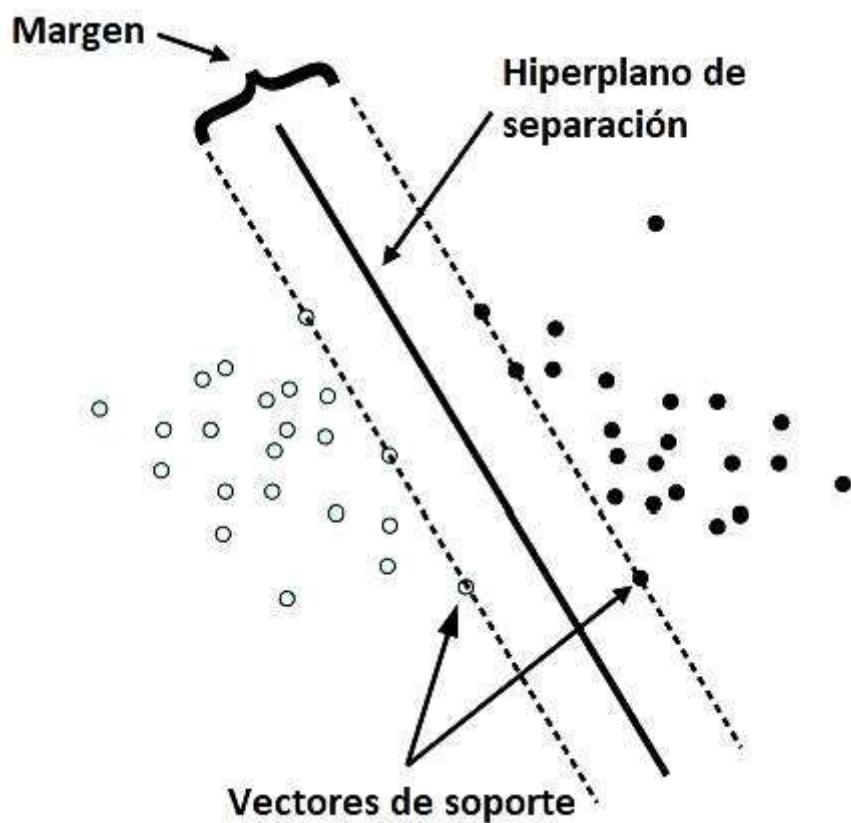


Figura 2.10 Clasificación por máquina de vectores de soporte (traducido de Meyer, 2009).

#### **2.5.4 Algoritmo de aprendizaje lógico**

Es una técnica estadística utilizada en regresión y clasificación, los algoritmos basados en la lógica se ocupan del procesamiento con la transmisión de datos paso a paso con una lógica funcional en cada paso, un ejemplo clásico de algoritmo basado en la lógica es un árbol de decisiones. Sus principales ventajas son que el método es fácil de entender y visualizar, es rápido y requiere poco procesamiento de datos y puede trabajar con datos numéricos o de propiedades. Sus principales desventajas son que este tipo de procesamiento puede dar origen a árboles de decisión demasiado grandes y complejos si no son suficientemente optimizados y llegan a ser sistemas inestables (Sen et al., 2020).

#### **2.5.5 Algoritmo basado en estadística**

Los algoritmos basados en estadísticas generalizan los problemas con la ayuda de estadísticas distributivas y analizan la estructura de distribución para continuar la tarea de predicción. El algoritmo de Naive Bayes es un ejemplo popular de este tipo de algoritmo ya que es simple pero muy poderoso para el modelado predictivo. Naïve Bayes proporciona un mecanismo para usar la información en los datos de la muestra para estimar la probabilidad posterior de cada clase , dado un elemento . Una vez que se tienen las estimaciones, se pueden usar para la clasificación u otras aplicaciones de apoyo para tomar una decisión. Sus ventajas son que este método tiene poca varianza, requiere pocos datos para entrenamiento del algoritmo, es rápido y puede resolver problemas diagnósticos de forma eficiente, también es robusto ante la presencia de ruido en los datos o ausencia de algunos valores. Sus desventajas son que este método puede ser muy poco preciso (Webb, 2020).

##### **1. Algoritmo de aprendizaje vago**

Este método retraza el proceso de generalización hasta que se realiza la tarea de clasificación dando como resultado el nombre de este como algoritmo de aprendizaje vago o algoritmo de aprendizaje perezoso. Un ejemplo es el llamado vecino más cercano k, que almacena todos los registros disponibles y predice la clase de una nueva instancia prestando atención a las mediciones de similitud de los vecinos más cercanos en probabilidad. Esta técnica de

clasificación es un método de aprendizaje perezoso que mantiene los miembros de los datos almacenados simplemente en estructuras de datos eficientes, por lo cual el costo de cálculo se vuelve menor para verificar y aplicar la función de distancia adecuada entre la nueva observación y todos los  $k$  puntos de datos diferentes almacenados, para luego llegar a cualquier conclusión sobre la etiqueta del nuevo punto de datos, sin construir una función de mapeo o modelo interno como otros algoritmos de clasificación. Sus ventajas son que es una técnica poderosa cuando los datos de entrenamiento presentan ruido; funciona de forma efectiva con datos de entrenamiento muy grandes y su implementación es simple. Sus desventajas son que tiene una elevada carga computacional y el valor de  $k$  debe ser correctamente determinado para tener un bajo porcentaje de error (Sen et al., 2020).

## **2.6 Smart sensor**

Los sensores convencionales son dispositivos funcionalmente simples que convierten magnitudes físicas en señales eléctricas. A diferencia de estos sensores, los sensores inteligentes, también conocidos como smart sensor, suelen estar equipados con uno o más sensores y un procesador con los circuitos de acondicionamiento de señales necesarios, para algunas aplicaciones específicas, la memoria y la fuente de alimentación también se pueden integrar en la placa. Las capacidades para operar sin fuente de alimentación a bordo y el bajo consumo de energía los hacen ideales para sistemas de control remoto. los sensores inteligentes se han desarrollado en los últimos años para responder a las necesidades de la sociedad moderna, especialmente para aplicaciones de Internet de las cosas y tienen un amplio campo de aplicaciones en la actualidad (Popović & Kejik, 2008). De acuerdo con Luong & Wang (2020) un smart sensor se caracteriza por estar compuesto por un módulo de adquisición de señales, un módulo de acondicionamiento de las señales, un módulo de conversión analógico-digital si es requerido, una unidad de microcontrolador y una interfaz de comunicación, todo integrado en un mismo dispositivo. En los sistemas de sensores inteligentes, las funciones de los sensores y sus interfaces se combinan en un diseño general. Estas funciones incluyen detección, acondicionamiento de señales, conversión de analógico a digital, Interfaz de bus y procesamiento de datos, en la Figura 2.11 se muestra un diagrama de la estructura general de un smart sensor.

Además, las funciones en un nivel jerárquico más alto pueden incluirse, tales como autocomprobación, auto calibración, evaluación e identificación de datos (Meijer, 2008) los sensores inteligentes pueden llegar a tener capacidades avanzadas como la comunicación inalámbrica y toma de decisiones.. Un sensor inteligente puede convertir la entrada del entorno físico en flujos de datos digitales y usar una unidad de microprocesador integrada para realizar funciones predefinidas al detectar una entrada específica y luego procesar los datos antes de transmitirlos. Además, la inteligencia que posee se puede utilizar para ejecutar muchas otras funciones. Por ejemplo, en la industria, las unidades de microprocesador pueden detectar cualquier parámetro de producción que comience a desviarse más allá de las normas aceptables y generar automáticamente alertas tempranas para evitar grandes desastres. Hoy en día, la tecnología de sensores se está convirtiendo en una parte integral de las modernas máquinas eléctricas energéticamente eficientes. Los sensores inteligentes realizan un autodiagnóstico al monitorear las señales internas en busca de evidencia de fallas, además que tienen otras ventajas sobre los sistemas basados en sensores convencionales, como un tamaño más pequeño y un consumo de energía mínimo y a menudo están equipados con una fuente de energía incorporada. Los sensores inteligentes son especialmente adecuados para monitorear y controlar mecanismos en una amplia variedad de entornos, incluido el control de tráfico, diagnóstico de fallas de equipos, sistemas de riego automático, sistemas de diagnóstico médico, redes inteligentes, sistemas de iluminación, telecomunicaciones, control de procesos de fabricación, monitoreo de sistemas remotos y muchas otras aplicaciones industriales (Tong, 2022).

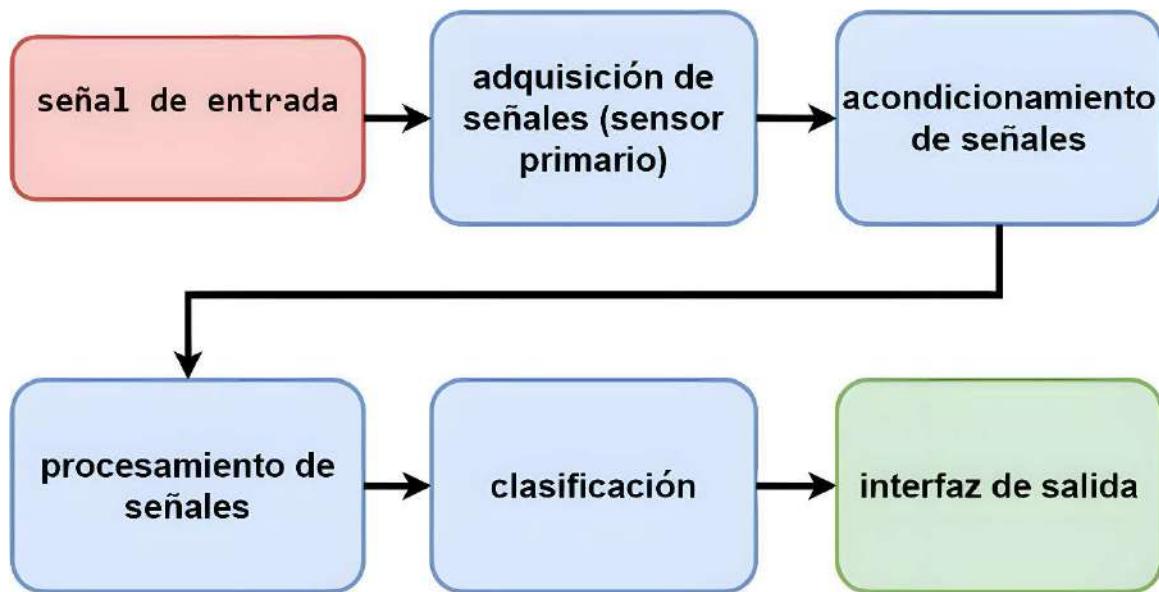


Figura 2.11 Diagrama general de un Smart sensor (autoría propia).

# Capítulo 3

## 3 Metodología

El sensor inteligente que se propone en este trabajo está compuesto de tres principales etapas, como se puede observar en la Figura 3.1.

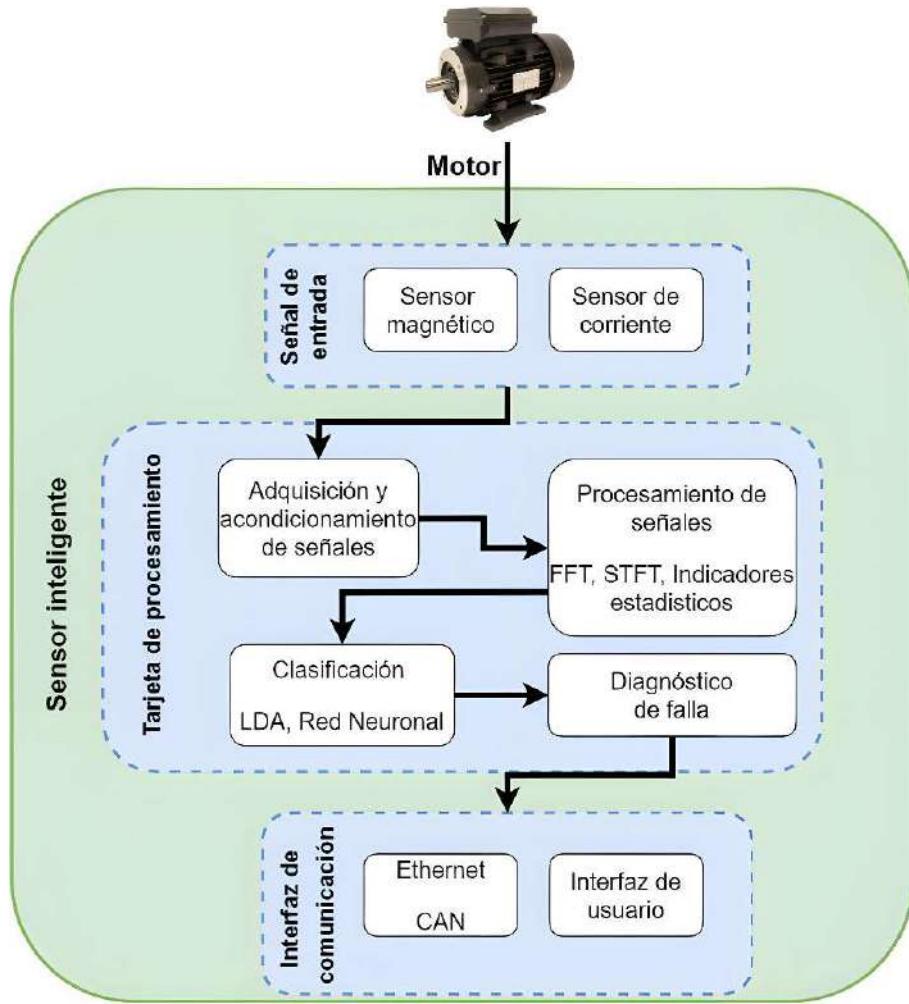


Figura 3.1 Diagrama general del funcionamiento del sensor inteligente (autoría propia).

La primera etapa que es la adquisición de las señales de entrada mediante los sensores primarios de flujo magnético y de corriente que se encuentran colocados en el motor, y que se describen en la subsección de materiales. La segunda etapa que es la etapa de procesamiento de las señales mediante indicadores estadísticos, las técnicas de Fourier y la clasificación de fallas por medio de LDA y redes neuronales. Finalmente, la tercera etapa es la salida de la información obtenida mediante las interfaces propuestas. El sensor inteligente cuenta con dos tipos de procesamiento y clasificación de fallas, el primero se emplea cuando la señal se encuentra estable, el segundo caso es cuando se detecta que existe un pico de arranque.

En este capítulo se abordan tres subtemas principales, en la sección 3.1 se abordan los materiales seleccionados para la construcción del sensor inteligente y el diseño y construcción del modelo de la tarjeta PCB, en la sección 3.2 se describe el banco y la matriz de pruebas a partir del cual se obtuvieron las señales. finalmente en la sección 3.3 se describe el funcionamiento del sensor inteligente abordando los procesamientos e interfaces de salida.

## 3.1 Materiales y diseño de PCB

### 3.1.1 Materiales

En esta sección se mencionarán los componentes seleccionados para la construcción del Smart sensor, los cuales se muestran en la Figura 3.2.

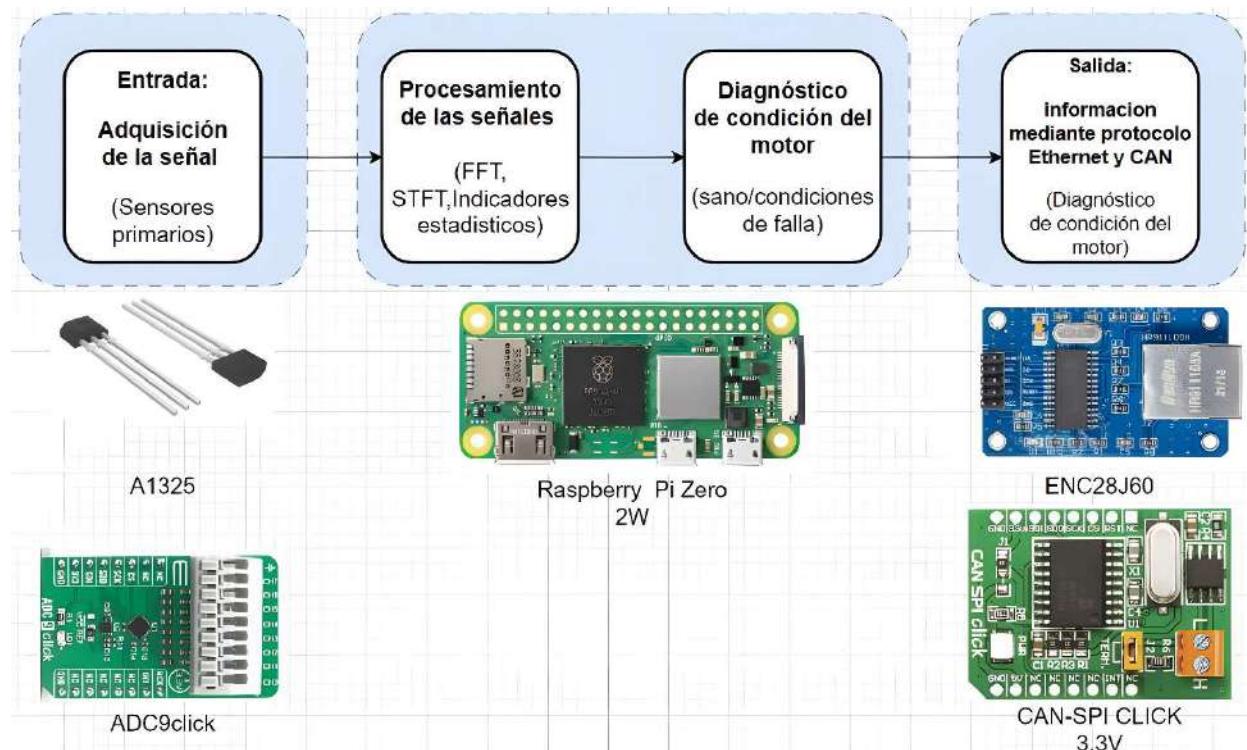


Figura 3.2 Diagrama de flujo de componentes del Smart sensor (autoría propia).

Para la adquisición de las señales se empleó el sensor modelo BM1422AGMV para la obtención de las señales de flujo magnético disperso en los ejes axial, radial y el eje combinado. Se empleó el sensor de corriente modelo SCT-013-030 30 como sensor de corriente. La tarjeta Raspberry Pi Zero 2 W fue el componente principal utilizado para el procesamiento y diagnóstico de las señales adquiridas, ya que cuenta con la potencia requerida para este proyecto y ofrece versatilidad, la Raspberry Pi Zero 2 W permite realizar la medición y procesamiento en tiempo real de las señales de los sensores, posibilitando una detección efectiva de posibles fallas.

Se seleccionó el módulo CAN SPI Click 3.3V para habilitar la conexión del dispositivo a través del protocolo de comunicación de red de área de control (control area network, CAN), el cual es ampliamente utilizado en el sector industrial automotriz para la transmisión de datos en redes de control distribuido. La tarjeta empleada para implementar este protocolo cuenta con el circuito integrado MCP2515, un diagrama de este componente es presentado en la Figura 3.3, es un controlador CAN que proporciona una interfaz entre un microcontrolador a través de comunicación mediante el protocolo SPI (Serial Peripheral Interface, Interfaz Periférica Serial).

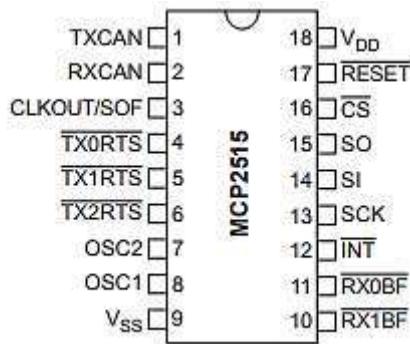


Figura 3.3 Circuito integrado MCP2515

También se utilizó el módulo ENC28J60, el cual proporciona conectividad al sensor inteligente a través del protocolo Ethernet. Este protocolo es ampliamente utilizado en la industria y permite que el dispositivo envíe información sobre la condición del motor bajo monitoreo a la red de trabajo de la empresa. Esto posibilita contar con un diagnóstico en tiempo real desde cualquier ordenador dentro del sitio de trabajo.

### 3.1.2 Diseño PCB

Una vez determinados los componentes que formarían parte del Smart sensor se realizó el diagrama de conexión de los componentes, el cual se muestra en la Figura 3.4.

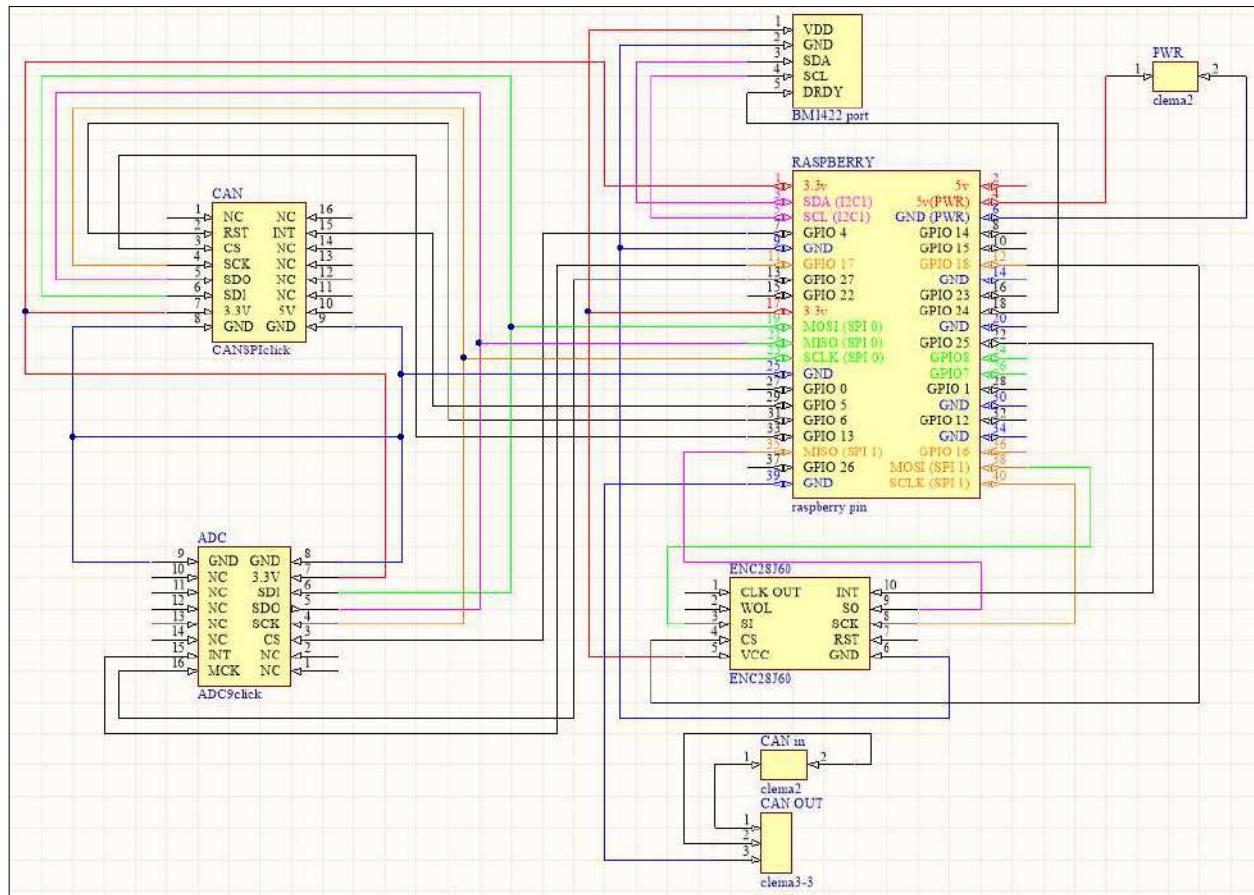


Figura 3.4 Diagrama de conexión de los componentes del Smart sensor (autoría propia).

Posteriormente se llevó a cabo el diseño del PCB en dos dimensiones como se muestra en la Figura 3.5 de forma que la tarjeta fuera lo más pequeña posible ya que se busca que el Smart sensor sea un dispositivo que no obstruya la operación normal de los motores en una línea de producción, se comprobó también las dimensiones de los componentes en un modelo tridimensional como se muestra en la Figura 3.6 para comprobar que el espacio entre los

componentes era suficiente y que los orificios para los tornillos de montaje no obstruyeran la colocación de los componentes.

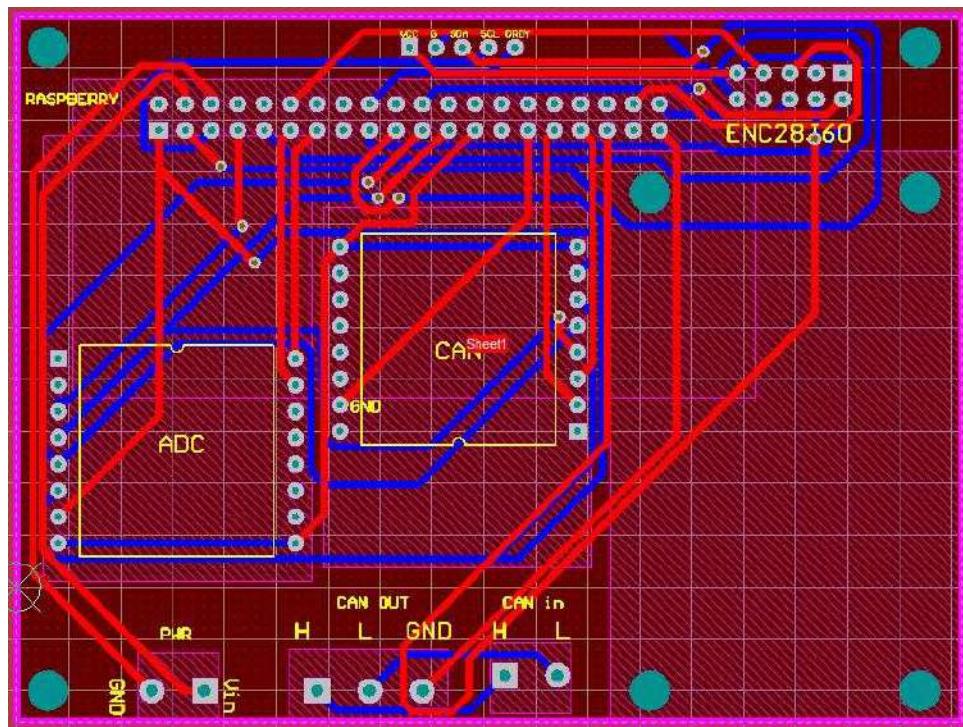


Figura 3.5 Diseño PCB de la tarjeta para montaje de componentes (autoría propia).

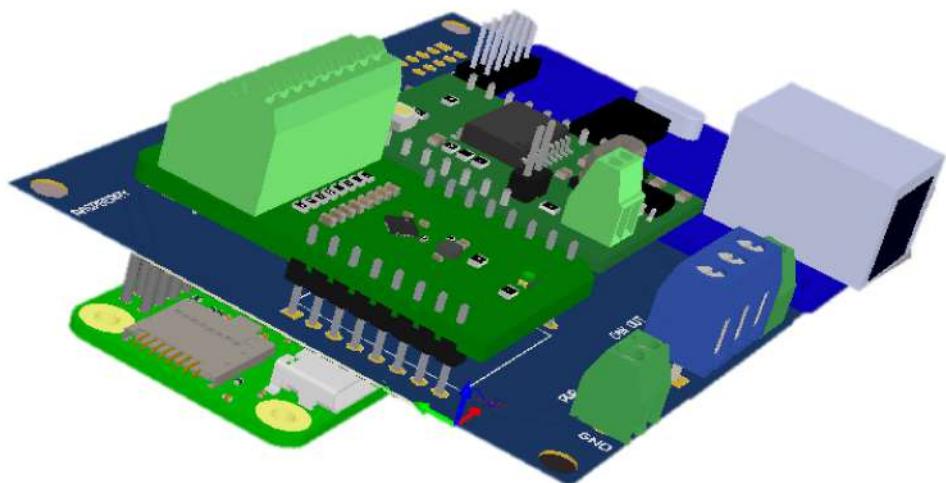


Figura 3.6 Diseño tridimensional de la tarjeta con componentes acoplados (autoría propia).

Una vez concluido el diseño en digital y se comprobó que las dimensiones y conexiones fueran correctas se procedió a la construcción en físico del PCB, el cual se muestra en la Figura 3.7.

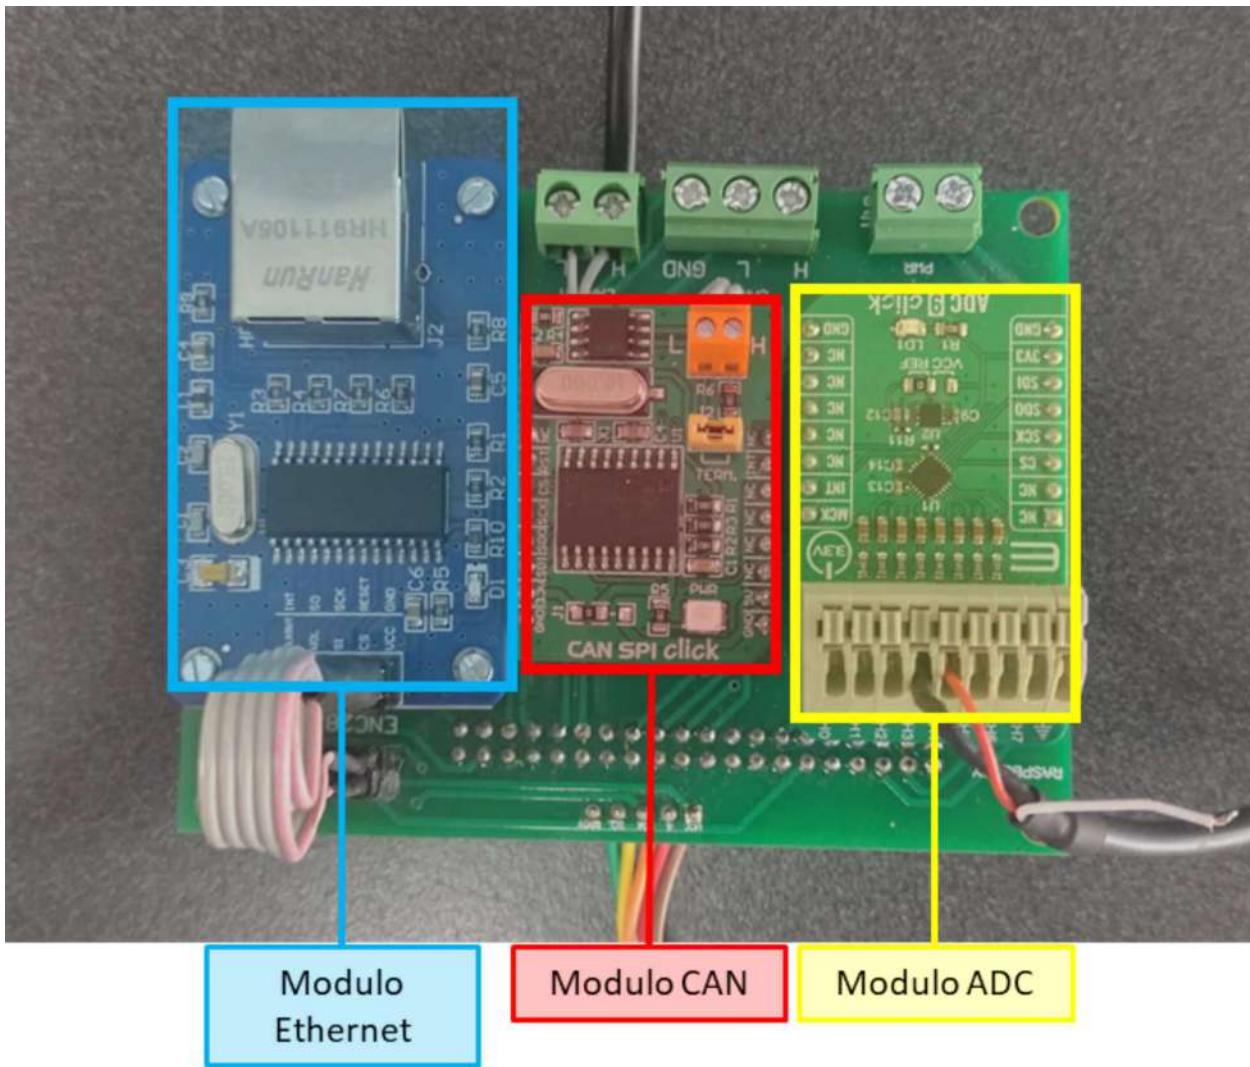


Figura 3.7 Construcción en físico de la tarjeta (autoría propia).

### 3.1.3 Procesamiento de señales

Las señales de entrada (corriente y flujo magnético disperso) fueron procesadas inicialmente haciendo uso del software MATLAB con la finalidad de observar los resultados del procesamiento mediante las técnicas de Fourier, clasificación y entrenamiento de una red neuronal y obtener los pesos asociados a las neuronas para introducirlos directamente en la tarjeta y de esta forma facilitar la etapa de entrenamiento.

Para lograr esto, primero se toma en cuenta que debe hacerse una distinción entre la señal cuando se encuentra en estado estable, y cuando se encuentra frente a un pico de arranque, ya que como fue expuesto en la sección de fundamentación teórica, la técnica de transformada rápida de Fourier (FFT) es eficaz al momento de realizar el análisis en estado estable, y la transformada de Fourier de tiempo corto nos ayudara a identificar las componentes frecuenciales de la señal cuando se encuentra ante el pico de arranque, por lo que el procesamiento será distinto dependiendo del caso en el que la señal se encuentre.

En un primer escenario, cuando la señal se encuentra en un estado estable, se emplea la Transformada Rápida de Fourier (FFT) para identificar las componentes frecuenciales de la señal. Una vez obtenidas estas frecuencias, se utilizan la Ecuación 1 y Ecuación 7 para calcular la frecuencia característica de la falla por excentricidad, así como el valor del deslizamiento de forma indirecta, resolviendo la ecuación correspondiente. Estos valores de frecuencia y deslizamiento se calculan en cada iteración para minimizar el rango de error ya que estos valores serán utilizados como referencia para encontrar las frecuencias características de otras fallas, definiendo un rango de búsqueda del pico de mayor amplitud alrededor de la frecuencia obtenida mediante la ecuación, con una tolerancia de  $\pm 1$  Hz. Esta información de la señal en el dominio de la frecuencia es complementada con información obtenida en el dominio del tiempo, ya que se lleva a cabo el cálculo de 7 indicadores estadísticos de la señal en el dominio del tiempo, siendo estos: la media, raíz media cuadrada, desviación estándar, skewness, kurtosis, quinto momento y sexto momento, ya que estos indicadores demostraron un mejor comportamiento para lograr la distinción de las fallas.

En el caso específico de las señales ante un pico de arranque, se implementa el siguiente procesamiento: se recurre al uso de la transformada de Fourier de tiempo corto para capturar con

precisión las características dinámicas de la señal durante este período transitorio. Mediante la STFT, la señal se descompone en segmentos temporales más pequeños, lo que permite una representación detallada de cómo evolucionan las frecuencias a lo largo del tiempo durante el arranque del motor. Una vez obtenida la representación tridimensional de tiempo, frecuencia y amplitud mediante la STFT, se procede a segmentar la gráfica resultante en diversos cuadrantes. Esta división en cuadrantes facilita el análisis y la extracción de información relevante, en cada cuadrante, se identifica el pico de frecuencia de mayor amplitud presente en la señal. Este enfoque permite una evaluación precisa de cómo las características espectrales de la señal varían en diferentes momentos durante el proceso de arranque del motor.

Una vez recopilada la información de las señales mediante indicadores estadísticos y técnicas de Fourier, se procede a emplear la técnica de Análisis Discriminante Lineal (LDA) para reducir la dimensionalidad de los datos. Esto simplificará su uso y permitirá llevar a cabo el entrenamiento de la red neuronal. Cabe destacar que el procesamiento por LDA y redes neuronales es idéntico, independientemente de si el motor se encuentra en estado estable o experimenta un pico de arranque, la única diferencia radica en la dimensionalidad de los valores de entrada, la cual será distinta entre estado estable y pico de arranque.

ya que la red neuronal ha sido entrenada de forma exitosa, la estructura y pesos asociados a la red neuronal será replicada directamente en el sensor inteligente, de forma que el procesamiento que el sensor lleva a cabo en físico será el mismo que el simulado mediante MATLAB, una vez obtenidos los resultados de la clasificación por parte de la red neuronal, estos se presentarán a través de una interfaz de usuario visual, esta interfaz proporcionará de manera simplificada la información sobre la condición detectada del motor. Además, las interfaces de comunicación podrán configurarse para transmitir la información relevante a una red o sistema conectado al sensor inteligente, según las preferencias y necesidades del usuario.

### **3.2 Banco de pruebas y matriz de pruebas**

### 3.2.1 Banco de pruebas

Las señales empleadas como base de datos y pruebas realizadas se obtuvieron haciendo uso de un motor trifásico de 1 HP de potencia modelo WEG 00136APE48T alimentado a 220 V CA, el cual es un motor de dos polos y se encuentra acoplado a un alternador ordinario que representa el 25% de la carga nominal del motor como se muestra en la Figura 3.8.

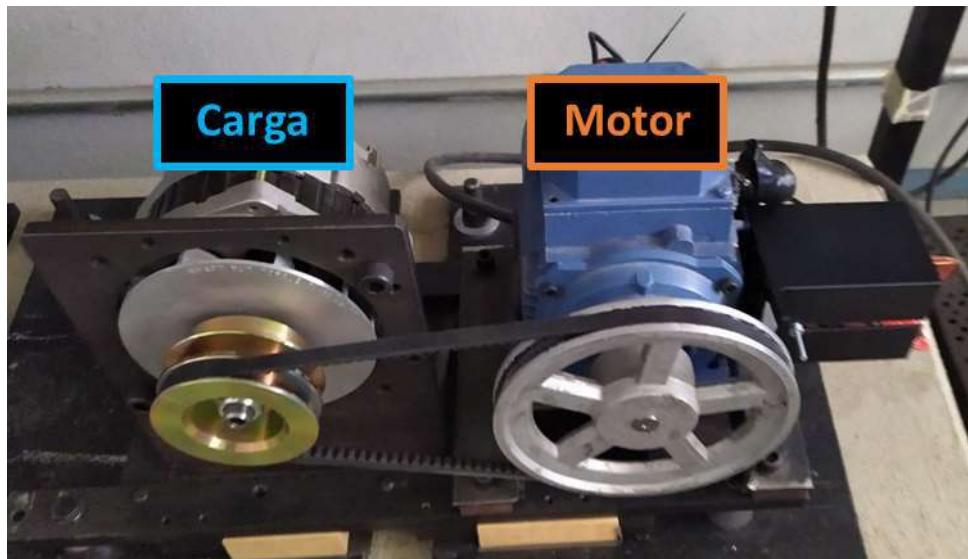


Figura 3.8 Banco de pruebas empleado (autoría propia).

En la figura Figura 3.9 se puede observar los sensores primarios colocados en el banco de pruebas y conectados al prototipo del sensor inteligente, cabe mencionar que la tarjeta realiza los mismos procesamientos explicados anteriormente y realizados mediante Matlab, con la excepción del entrenamiento de las redes neuronales, ya que la configuración de la clasificación se extrae de los datos obtenidos de Matlab y se carga directamente a la tarjeta.

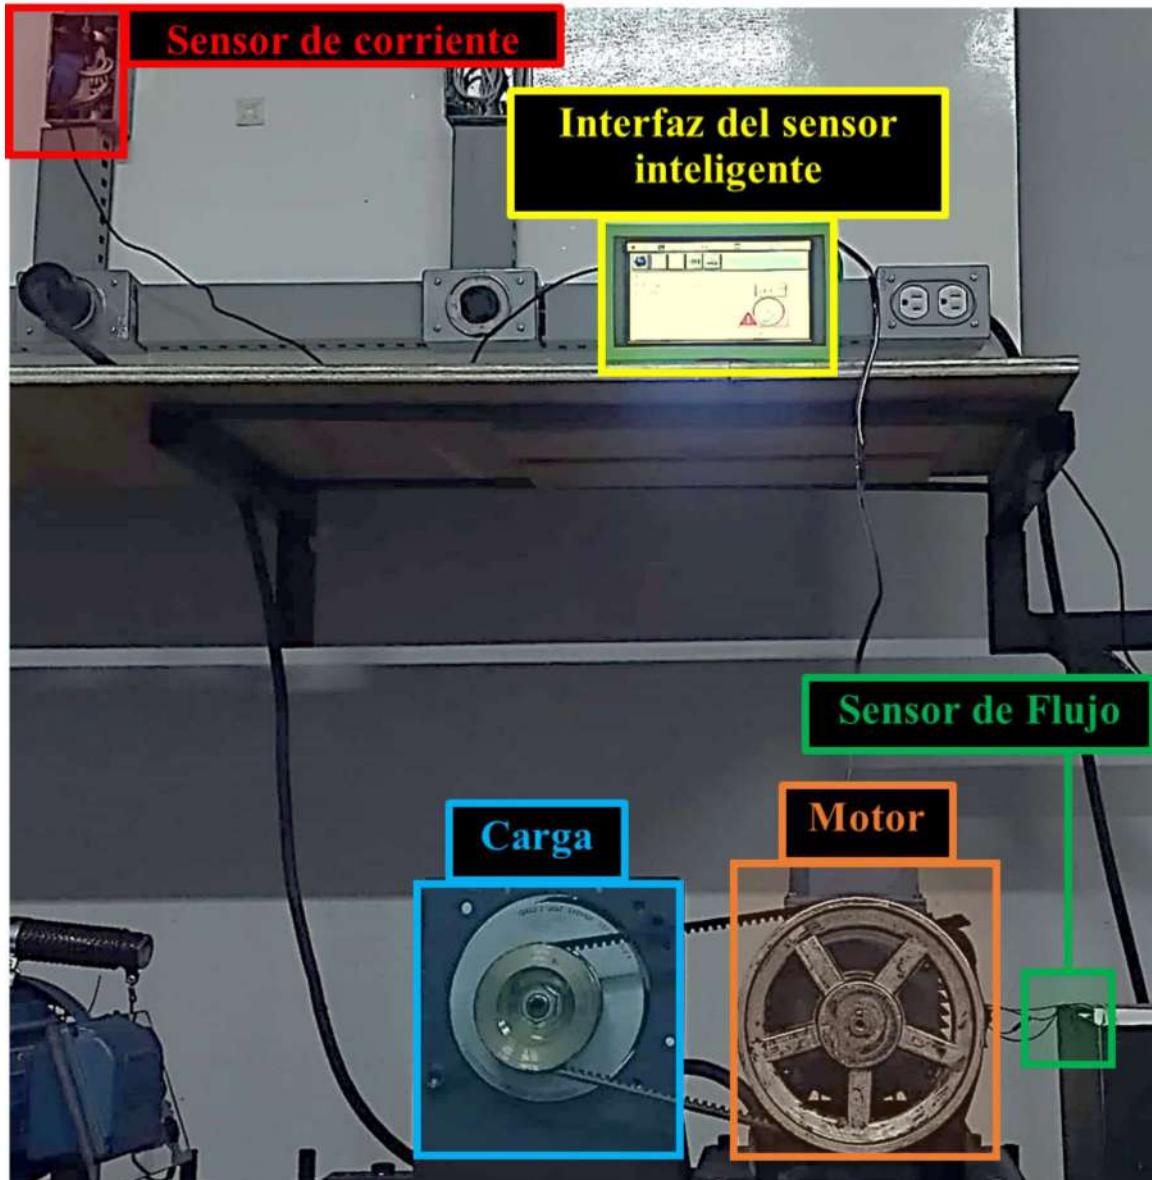


Figura 3.9 Montaje del sensor inteligente en el banco de pruebas (autoría propia)

### 3.2.2 Matriz de pruebas

Para el desarrollo del sensor inteligente se empleó como punto de partida una base de datos previamente adquirida en trabajos anteriores realizados en la universidad autónoma de Querétaro, empleando los mismos componentes electrónicos (sensores y tarjeta) para la adquisición de los datos, a una frecuencia de muestreo de 1000 Hz durante 30 segundos, estas señales fueron posteriormente procesadas y empleadas para el entrenamiento y validación de los algoritmos de clasificación, en la Tabla 3.1 se puede observar la descripción de esta base de datos.

Como se muestra en la matriz de pruebas mostrada en la Tabla 3.1, la base de datos consta de 5 condiciones de estado del motor: motor sano, falla por una barra rota, falla por dos barras rotas, desbalanceo y desalineación. Para cada una de estas condiciones se realizaron 20 mediciones con el motor acoplado al alternador y 20 mediciones con el motor sin carga, alimentado a una frecuencia de 60 Hz. Además, se realizaron 7 mediciones con el motor acoplado al alternador y 7 mediciones con el motor sin carga cuando la frecuencia de alimentación fue de 50 Hz. En cada una de estas mediciones, se adquirieron 4 señales: la corriente y el flujo magnético en los ejes axial, radial y combinado.

Tabla 3.1 Matriz de pruebas (autoría propia).

Condición del motor	Señal	Carga	Frecuencia de alimentación	Número de Muestras
Motor Sano	Flujo magnético (Axial)	25%	60 Hz	20 pruebas
		0%	60 Hz	20 pruebas
		25%	50Hz	7 pruebas
		0%	50Hz	7 pruebas
	Flujo magnético (Radial)	25%	60 Hz	20 pruebas
		0%	60 Hz	20 pruebas
		25%	50Hz	7 pruebas
		0%	50Hz	7 pruebas
	Flujo magnético (Combinado)	25%	60 Hz	20 pruebas
		0%	60 Hz	20 pruebas
		25%	50Hz	7 pruebas
		0%	50Hz	7 pruebas
1 Barra rota	Corriente	25%	60 Hz	20 pruebas
		0%	60 Hz	20 pruebas
		25%	50Hz	7 pruebas
		0%	50Hz	7 pruebas
	Flujo magnético (Axial)	25%	60 Hz	20 pruebas
		0%	60 Hz	20 pruebas
		25%	50Hz	7 pruebas
		0%	50Hz	7 pruebas
	Flujo magnético (Radial)	25%	60 Hz	20 pruebas
		0%	60 Hz	20 pruebas
		25%	50Hz	7 pruebas
		0%	50Hz	7 pruebas
2 Barras rotas	Flujo magnético (Combinado)	25%	60 Hz	20 pruebas
		0%	60 Hz	20 pruebas
		25%	50Hz	7 pruebas
		0%	50Hz	7 pruebas
	Corriente	25%	60 Hz	20 pruebas
		0%	60 Hz	20 pruebas
		25%	50Hz	7 pruebas
		0%	50Hz	7 pruebas
	Flujo magnético (Axial)	25%	60 Hz	20 pruebas
		0%	60 Hz	20 pruebas
		25%	50Hz	7 pruebas
		0%	50Hz	7 pruebas
Desalineación	Flujo magnético (Radial)	25%	60 Hz	20 pruebas
		0%	60 Hz	20 pruebas
		25%	50Hz	7 pruebas
		0%	50Hz	7 pruebas
	Flujo magnético (Combinado)	25%	60 Hz	20 pruebas
		0%	60 Hz	20 pruebas
		25%	50Hz	7 pruebas
		0%	50Hz	7 pruebas
	Corriente	25%	60 Hz	20 pruebas
		0%	60 Hz	20 pruebas
		25%	50Hz	7 pruebas
		0%	50Hz	7 pruebas
Desbalanceo	Flujo magnético (Axial)	25%	60 Hz	20 pruebas
		0%	60 Hz	20 pruebas
		25%	50Hz	7 pruebas
		0%	50Hz	7 pruebas
	Flujo magnético (Radial)	25%	60 Hz	20 pruebas
		0%	60 Hz	20 pruebas
		25%	50Hz	7 pruebas
		0%	50Hz	7 pruebas
	Flujo magnético (Combinado)	25%	60 Hz	20 pruebas
		0%	60 Hz	20 pruebas
		25%	50Hz	7 pruebas
		0%	50Hz	7 pruebas
	Corriente	25%	60 Hz	20 pruebas
		0%	60 Hz	20 pruebas
		25%	50Hz	7 pruebas
		0%	50Hz	7 pruebas

# Capítulo 4

## 4 Resultados

### 4.1 Hardware

Se realizo el diseño de PCB que posteriormente se construyó en físico y se realizó un modelo tridimensional de un armazón que contiene todos los componentes, mismo que se muestra en la Figura 4.1, que fue impreso con filamento. El armazón construido con todos los componentes integrados se observa en la Figura 4.2.

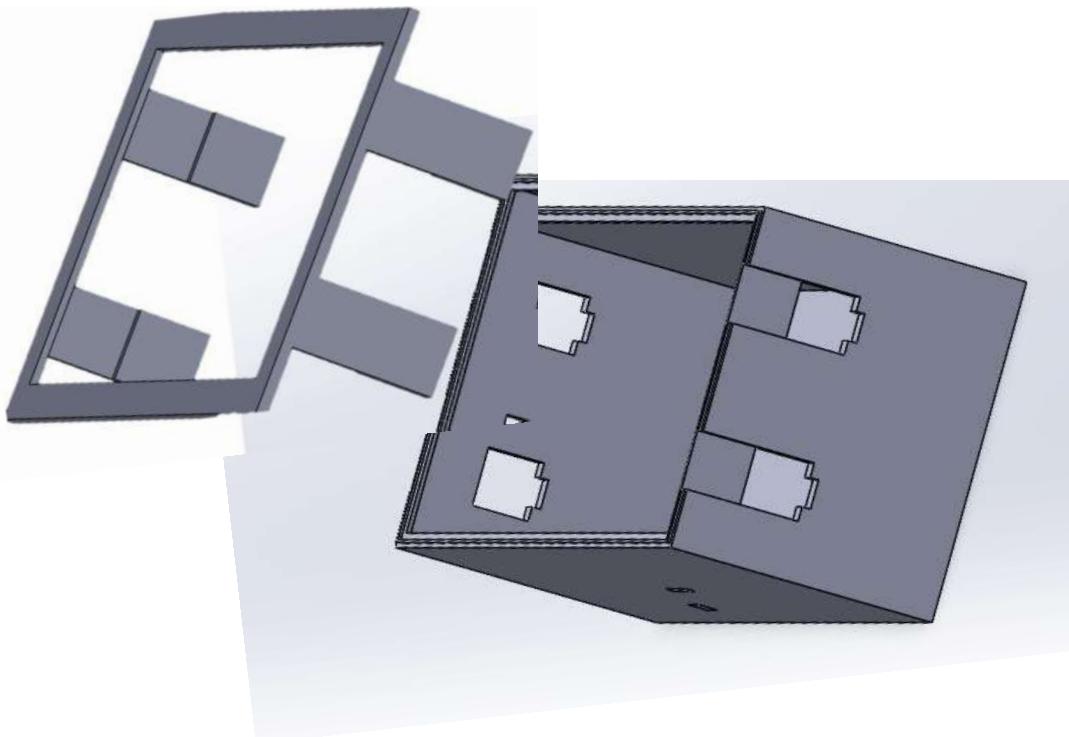


Figura 4.1 Diseño 3D del armazón del sensor inteligente (autoría propia)



Figura 4.2 Armazón del sensor inteligente impreso en 3D con los componentes acoplados  
(autoría propia)

## 4.2 Procesamiento de las señales y diagnóstico de condición del motor

Como se mencionó previamente en la sección de metodología, las señales fueron analizadas por separado para el caso de estado estable y cuando se presenta un pico de arranque. En la Figura 4.9 se muestra un ejemplo de una gráfica en el dominio del tiempo obtenida a partir de la medición de señales de flujo magnético disperso para un motor sano en el eje radial, donde se puede observar primero el comportamiento ante el pico de arranque, y como la señal empieza a estabilizarse gradualmente.

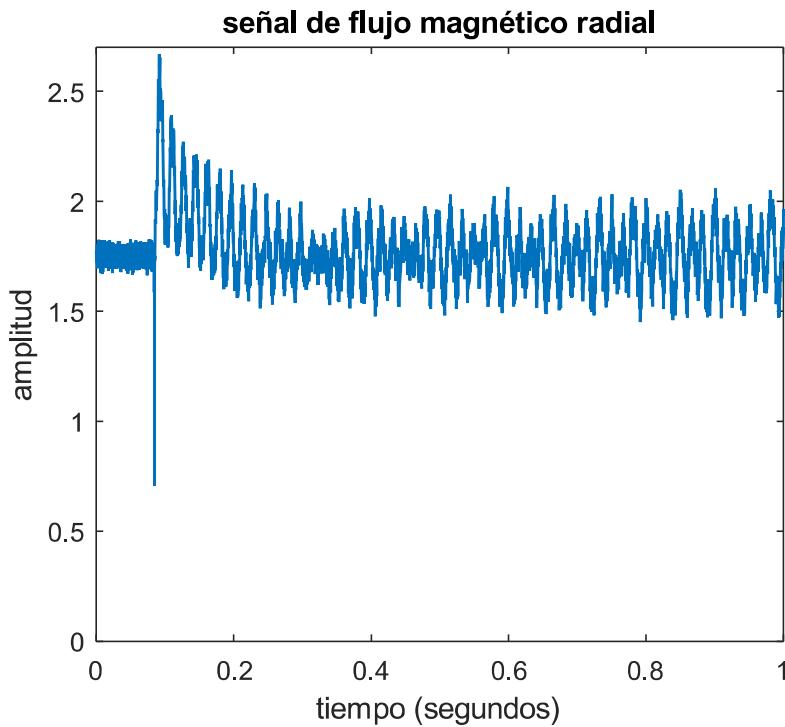


Figura 4.3 Señal de flujo magnético disperso radial en la condición de motor sano (autoría propia).

#### 4.2.1 Procesamiento de señales en estado estable

Como se ha detallado previamente en la sección de metodología, se llevó a cabo un proceso específico para el procesamiento de señales en estado estable. Este proceso implicó la extracción de amplitudes de frecuencias características asociadas con falla, así como la obtención de indicadores estadísticos en el dominio del tiempo.

En la Figura 4.4 se observa que para el procesamiento de las señales por medio de FFT, para cada señal se eliminaron los primeros 10 segundos de medición que corresponden al arranque del motor, puesto que como se expone en la sección de fundamentación teórica, el procesamiento por medio de FFT es más confiable en el caso de señales que son estables en el tiempo y el comportamiento inestable en el arranque aporta ruido al procesamiento, lo que podría llevar a diagnósticos erróneos.

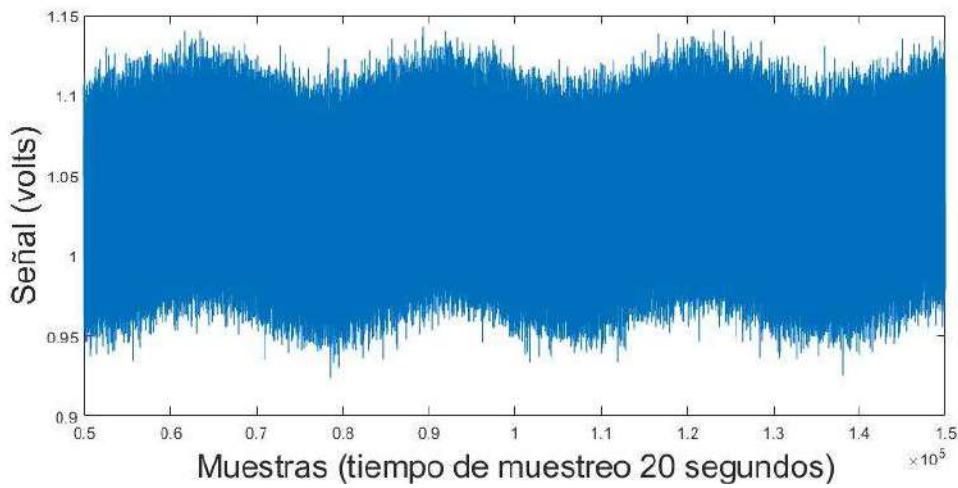


Figura 4.4 Señal de flujo magnético disperso radial en la condición de motor sano eliminando los primeros 10 segundos de arranque (autoría propia).

Una vez eliminados los primeros 10 segundos de la señal, los cuales se consideraron para eliminar las variaciones debido al arranque, se procedió a realizar el procesamiento mediante la Transformada Rápida de Fourier (FFT) del resto de la señal para descomponerla en sus componentes frecuenciales y así identificar patrones característicos que brinden indicio de la condición del motor. En la Figura 4.5 se muestra un ejemplo del procesamiento por FFT aplicado a la señal de flujo magnético radial de un motor en condición sana.

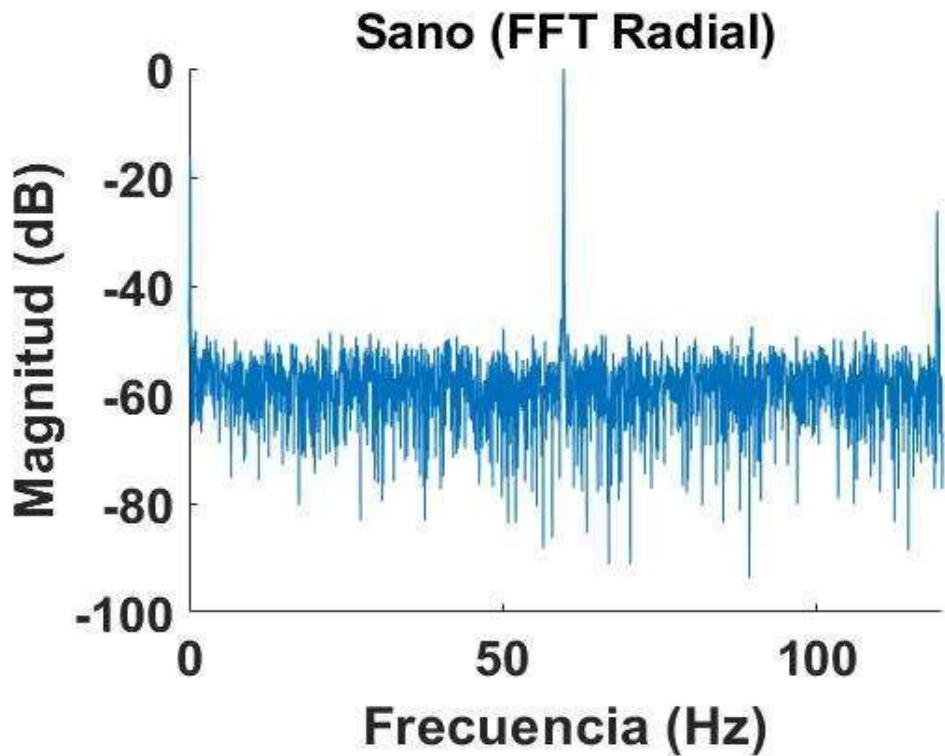


Figura 4.5 Procesamiento por FFT de la señal de flujo magnético radial en un motor sano (autoría propia).

Posteriormente, se procede a obtener las amplitudes de las frecuencias características de falla mediante la Ecuación 1 y Ecuación 7, las cuales se resumen en la Tabla 2.1. Para estimar el rango en el que debería aparecer la frecuencia característica de falla por excentricidad, se utiliza inicialmente la Ecuación 7, en la cual se sustituyen los valores del deslizamiento por 6% y 0%, considerando que los motores típicamente operan con un deslizamiento menor al 6%. Una vez obtenidas estas frecuencias, se busca la mayor amplitud en este rango, ya que se espera que esté relacionada con el pico de la frecuencia de falla por excentricidad medida. Una vez identificada esta frecuencia, es posible obtener el valor del deslizamiento de forma indirecta, un ejemplo de este proceso se ilustra en la Figura 4.12, una vez obtenido el valor de deslizamiento, es posible utilizar la Ecuación 1 para obtener la frecuencia de falla en el rotor.

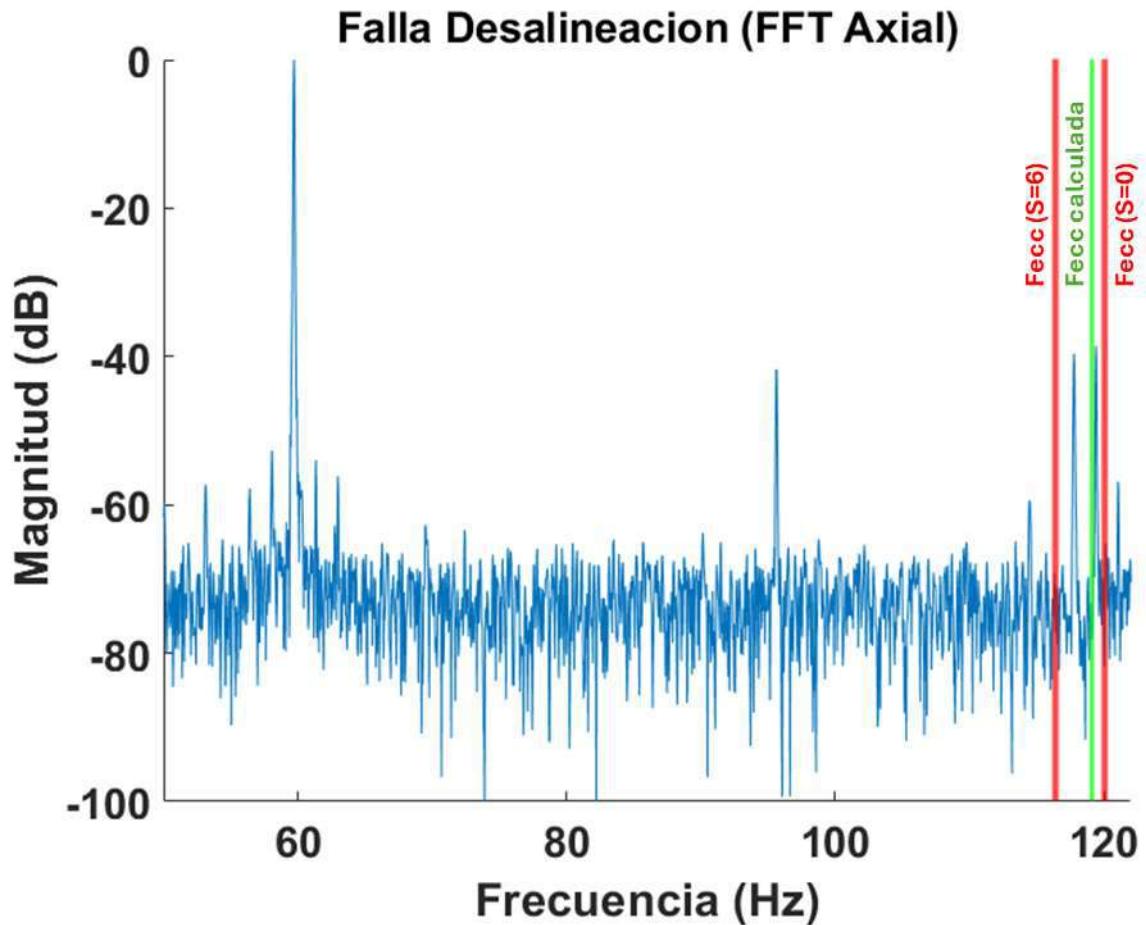


Figura 4.6 Amplitud de frecuencia de falla por desalineación (autoría propia).

Una vez obtenida esta frecuencia de falla calculada a partir del deslizamiento obtenido, se busca la mayor amplitud dentro de un rango de tolerancia de 1 Hz, un ejemplo de la obtención de la amplitud de frecuencia de falla en el rotor se puede observar en la Figura 4.7. Este valor de deslizamiento y cálculo de frecuencias se estima nuevamente por cada medición realizada y para cada señal durante la medición, de forma que, si ocurre algún cambio durante la operación del motor, estos datos se actualizarán constantemente.

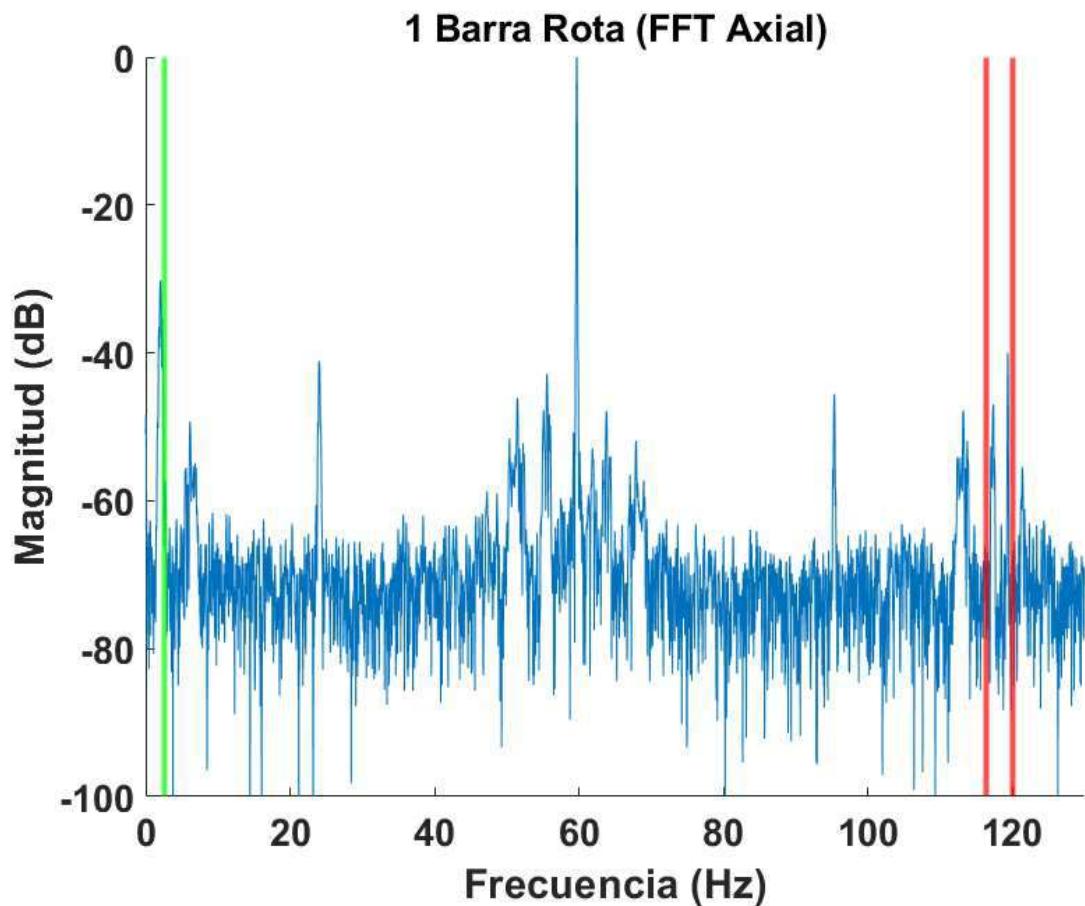


Figura 4.7 Amplitud de frecuencia de falla en el rotor (autoría propia).

Ya que han sido obtenidas las frecuencias de falla se almacenan los valores de las cuatro amplitudes obtenidas, esta información de la señal en el dominio de la frecuencia se complementa con el cálculo de siete indicadores estadísticos en la señal en el dominio del tiempo, siendo estos: la media, raíz media cuadrada, desviación estándar, skewness, kurtosis, quinto momento y sexto momento, estos indicadores se eligieron ya al graficar la distribución de los datos obtenidos agrupados por condición del motor, estos eran los que presentaban una mayor separación entre clases o una mejor definición del resto, un ejemplo de lo expuesto se puede observar en la Figura 4.8 en dónde se puede observar una buena definición de la condición de motor sano comparada con las condiciones de falla para el flujo disperso axial y combinado.

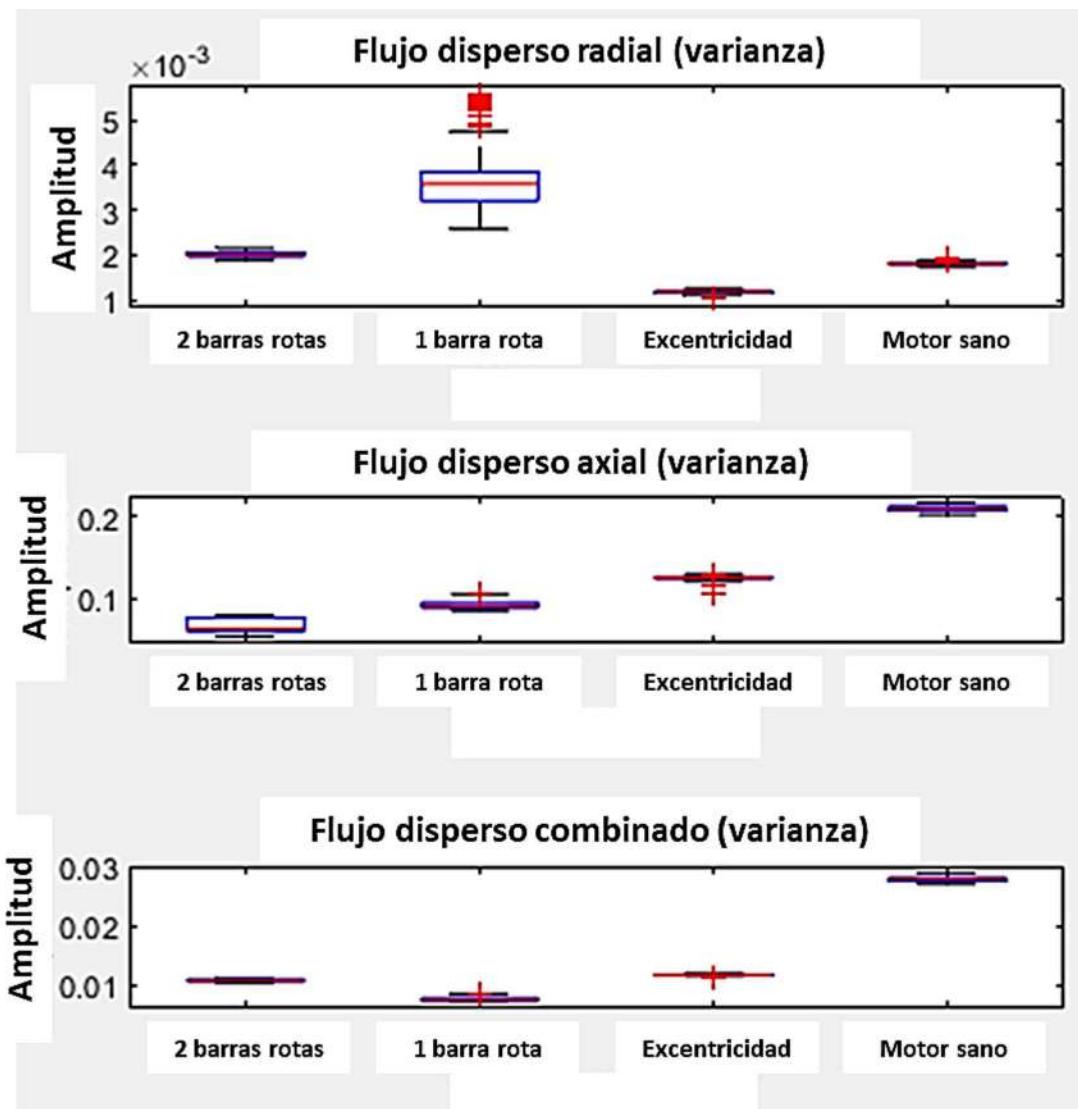


Figura 4.8 Distribución de los resultados obtenidos tras el procesamiento de la señal en el dominio del tiempo empleando la varianza (autoría propia).

Para evaluar y comparar los resultados derivados de estas señales procesadas, se realizó primero el análisis individual de las señales. Este paso inicial permitió comprender la capacidad de discriminación de cada señal por separado y su eficacia en la identificación de las diferentes condiciones de falla en el motor con el procesamiento propuesto. Posteriormente, se llevó a cabo el procesamiento de las señales en conjunto. Este paso final permitió observar cómo la combinación de todas estas señales impactaba en la capacidad de clasificación y distinguir las condiciones de falla del motor de una manera más clara.

En el primer análisis, se llevó a cabo el procesamiento de las señales de corriente obtenidas del motor obteniendo una matriz de tamaño  $11 \times n$ , donde  $n$  es el número de muestras y 11 es la dimensión obtenida al incluir las cuatro amplitudes de frecuencia de falla y los siete indicadores estadísticos previamente mencionados en esta sección. Se aplicó el procesamiento mediante el algoritmo de Análisis Discriminante Lineal (LDA) a una matriz bidimensional. Al examinar visualmente el resultado de esta transformación por LDA que se muestra en la Figura 4.9, se observa la ausencia de una clara separación entre las distintas clases de señales. Sin embargo, entre las condiciones evaluadas, se identificó que la señal correspondiente al estado de funcionamiento del motor en condiciones normales (motor sano) fue la que presentó la mejor capacidad de separación con respecto a las demás condiciones.

# LDA corriente

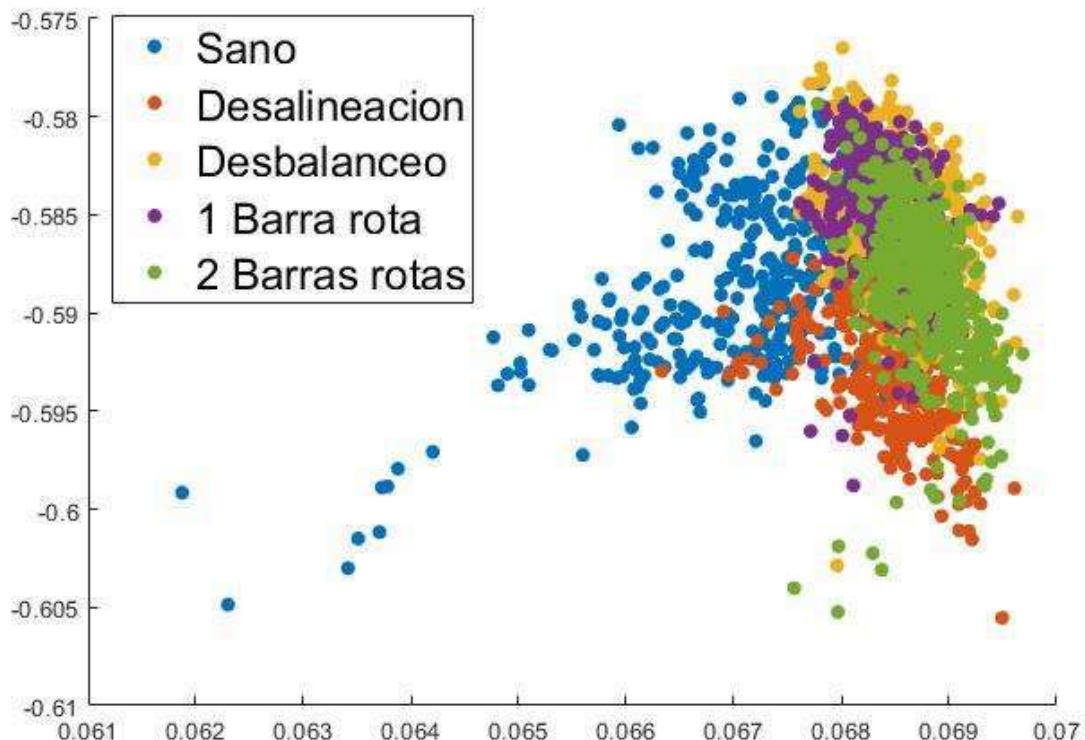


Figura 4.9 LDA obtenido tras el procesamiento de la señal de corriente (autoría propia)

Tras el procesamiento a través de la red neuronal, se constató que no se logró una separación precisa entre las clases, lo que se reflejó en una eficiencia global de clasificación del 55.4% para distinguir los distintos tipos de falla, como se muestra en la Figura 4.10.

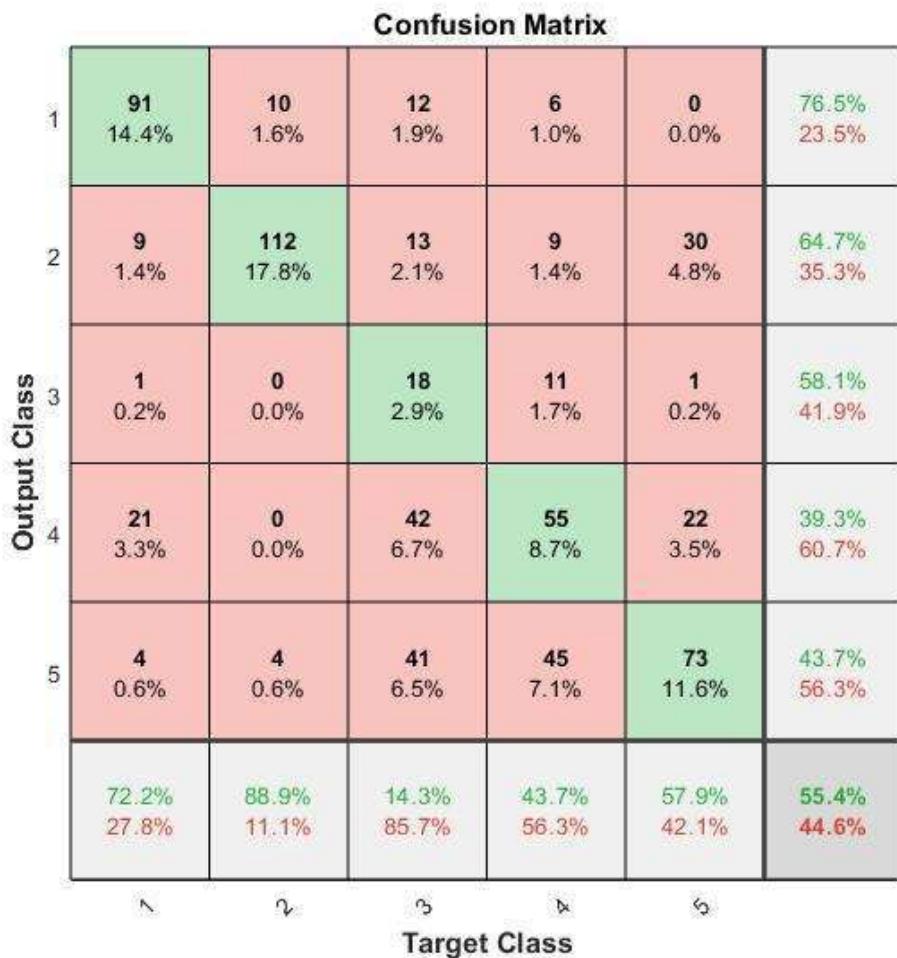


Figura 4.10 red neuronal obtenida tras el procesamiento de la señal de corriente (autoría propia)

En el segundo análisis, se empleó la señal de flujo magnético disperso en el eje radial. Tras someter esta señal al proceso de reducción por medio del Análisis Discriminante Lineal, como se observa en la Figura 4.11 se identificó una clara separación entre las clases asociadas a una y dos barras rotas en comparación con las demás condiciones del motor. Sin embargo, al analizar las

clases relacionadas con desalineación, desbalanceo y el estado de funcionamiento normal del motor, se observó una ligera diferenciación entre estas clases, pero se detectaron traslapes entre ellas lo que dificulta su clasificación precisa.

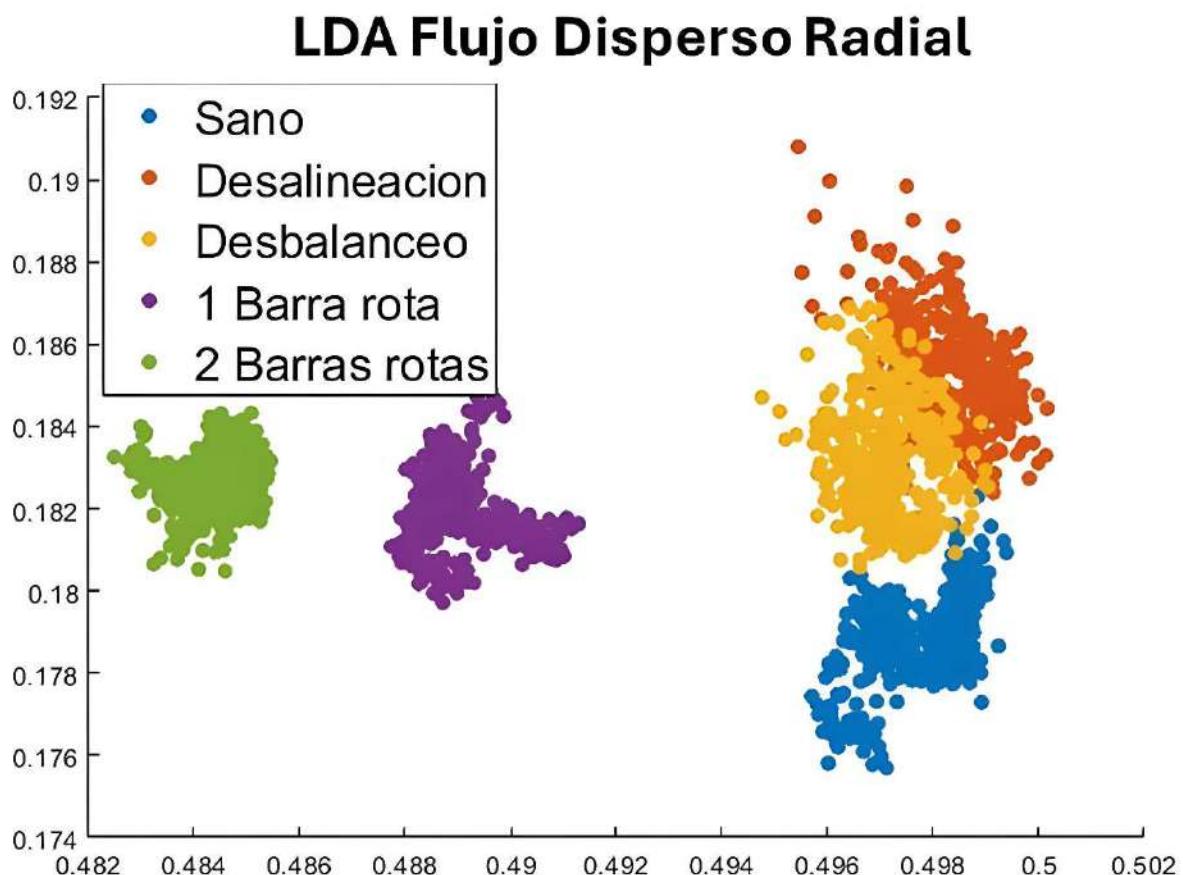


Figura 4.11 LDA obtenido tras el procesamiento de la señal de flujo disperso en el eje radial (autoría propia)

Tras el procesamiento de esta señal a través de la red neuronal se evidenció una notable mejora en la eficiencia para la separación de los distintos tipos de falla. En este análisis, la eficiencia general de clasificación alcanzó un 95.5%, Un aspecto a resaltar fue la precisión en la

clasificación de una y dos barras rotas (clasificaciones correspondientes a la clase 4 y 5), donde se logró un 100% de exactitud en la identificación de estas condiciones específicas, como se observa en la Figura 4.12.

		Confusion Matrix					
		1	2	3	4	5	
Output Class	1	123 19.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	2	0 0.0%	109 17.3%	6 1.0%	0 0.0%	0 0.0%	94.8% 5.2%
3	3	3 0.5%	17 2.7%	120 19.0%	0 0.0%	0 0.0%	85.7% 14.3%
	4	0 0.0%	0 0.0%	0 0.0%	126 20.0%	0 0.0%	100% 0.0%
5	5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	126 20.0%	100% 0.0%
		97.6% 2.4%	86.5% 13.5%	95.2% 4.8%	100% 0.0%	100% 0.0%	95.9% 4.1%
		1	2	3	4	5	

Figura 4.12 red neuronal obtenida tras el procesamiento de la señal de flujo disperso en el eje radial (autoría propia)

En el tercer análisis, se procedió a utilizar la señal de flujo magnético disperso en el eje axial. Al examinar la representación gráfica del LDA de esta señal en la Figura 4.13, se destacó una mejora significativa en la separación entre las cinco clases distintas en comparación con los análisis anteriores. Esta mejora se reflejó en una mayor distancia o separación visual entre las

diferentes clases. si bien se logró una separación más clara y definida entre las diferentes clases de falla, se observa que también existen traslapes entre las clases asociadas al estado de funcionamiento normal del motor (clase 1) y la condición de desbalanceo (clase 3).

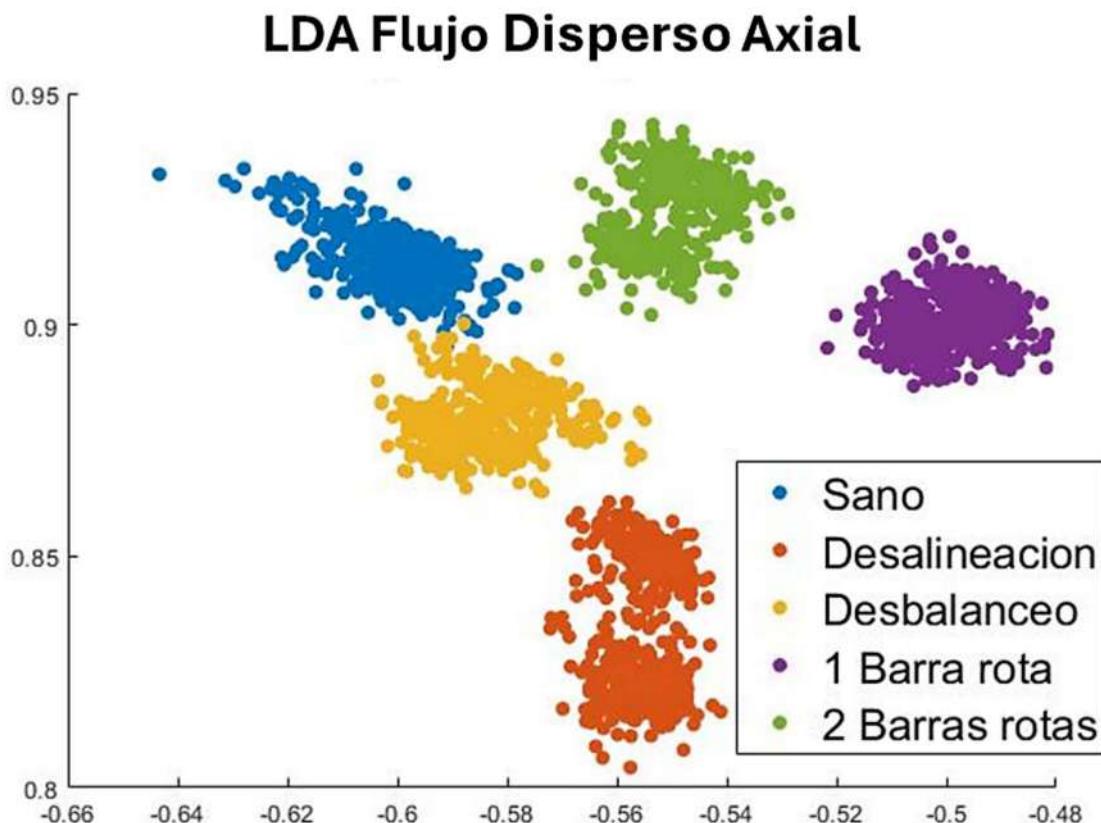


Figura 4.13 LDA obtenido tras el procesamiento de la señal de flujo disperso en el eje axial (autoría propia)

Tras el entrenamiento de la red neuronal se observó una elevada eficiencia de clasificación del 99.2%. Cómo es posible observar en la Figura 4.14 se presentaron problemas de clasificación, únicamente con los valores asociados a las clases del motor sano (clase 1) y la condición de desbalanceo (clase 3), mismas que son las que muestran un traslape en la representación gráfica de la LDA.

		Confusion Matrix					
		1	2	3	4	5	
Output Class	1	123 19.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	2	0 0.0%	126 20.0%	2 0.3%	0 0.0%	0 0.0%	98.4% 1.6%
3	3 0.5%	0 0.0%	124 19.7%	0 0.0%	0 0.0%	97.6% 2.4%	
4	0 0.0%	0 0.0%	0 0.0%	126 20.0%	0 0.0%	100% 0.0%	
5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	126 20.0%	100% 0.0%	
	97.6% 2.4%	100% 0.0%	98.4% 1.6%	100% 0.0%	100% 0.0%	99.2% 0.8%	
	1	2	3	4	5	Target Class	

Figura 4.14 red neuronal obtenida tras el procesamiento de la señal de flujo disperso en el eje axial (autoría propia)

En el cuarto análisis, se utilizó la señal combinada del flujo magnético disperso para evaluar su efectividad en la identificación de las condiciones de falla del motor. Al examinar los resultados obtenidos gráficamente a través del Análisis Discriminante Lineal (LDA) en la Figura 4.15, se pudo observar una destacada separación para la clase asociada a la falla de dos barras rotas (clase 5) en comparación con las demás clases. Sin embargo, se detectaron ligeros traslapes entre las características de las clases restantes, lo que sugiere una dificultad potencial en su clasificación

precisa al usar estos datos para el entrenamiento de la red neuronal. A pesar de estos traslapos, se destacó una mejora notable en la separación entre las clases de motor sano y desbalanceo. En contraste con los análisis anteriores, en esta ocasión se observó una aparente mejora en la capacidad del modelo para distinguir entre estas dos condiciones, con una separación visual más clara y sin traslapos evidentes entre ellas.

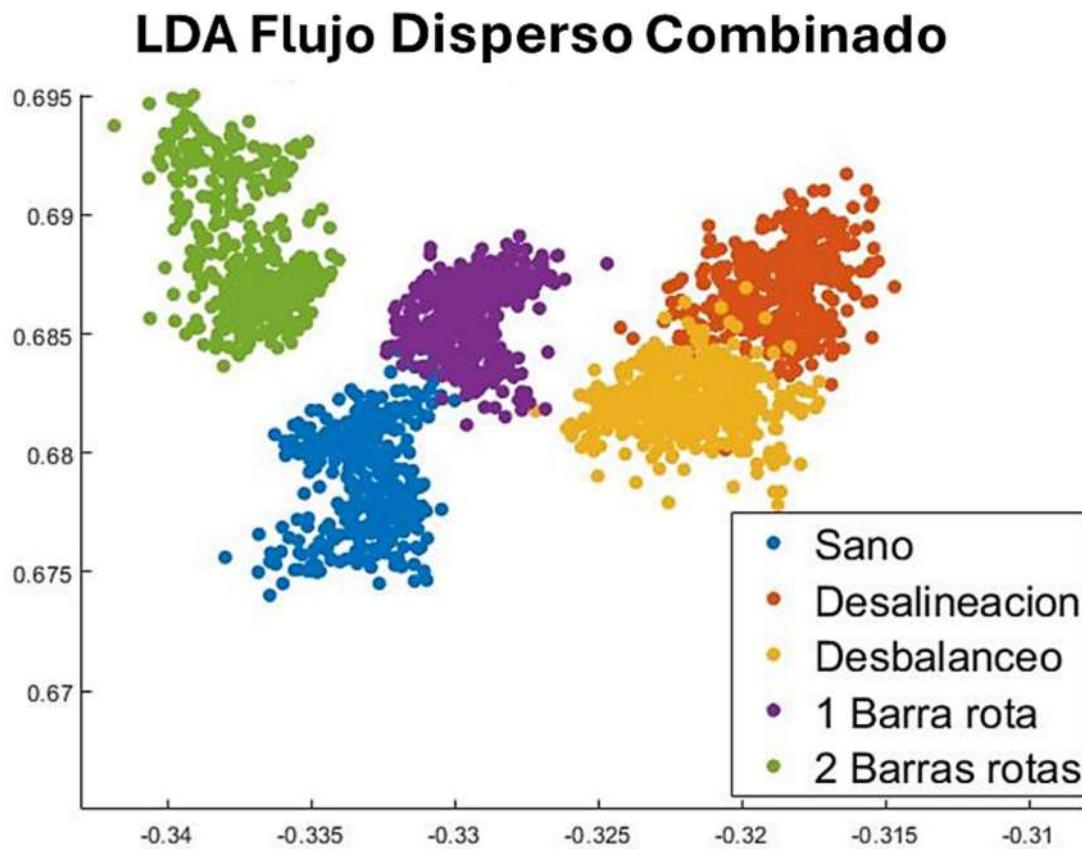


Figura 4.15 LDA obtenido tras el procesamiento de la señal de flujo disperso en el eje combinado (autoría propia)

Tras el entrenamiento en la red neuronal al emplear esta señal es posible observar una eficiencia de clasificación del 96.8% de los datos, obteniendo un 100% de clasificación solo en la condición de fallo por dos barras rotas (clase 5).

		Confusion Matrix					
		1	2	3	4	5	
Output Class	1	124 19.7%	0 0.0%	0 0.0%	1 0.2%	0 0.0%	99.2% 0.8%
	2	0 0.0%	116 18.4%	7 1.1%	0 0.0%	0 0.0%	94.3% 5.7%
	3	0 0.0%	10 1.6%	119 18.9%	0 0.0%	0 0.0%	92.2% 7.8%
	4	2 0.3%	0 0.0%	0 0.0%	125 19.8%	0 0.0%	98.4% 1.6%
	5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	126 20.0%	100% 0.0%
		98.4% 1.6%	92.1% 7.9%	94.4% 5.6%	99.2% 0.8%	100% 0.0%	96.8% 3.2%
		1	2	3	4	5	

Figura 4.16 red neuronal obtenida tras el procesamiento de la señal de flujo disperso en el eje combinado (autoría propia)

Finalizando el análisis de las señales en estado estable, se integraron las cuatro señales en una matriz de dimensiones 44 x n, donde n representa el número de muestras. y una vez se realizó la reducción a una matriz bidimensional por medio de LDA. se evidenció claramente la presencia

de una separación definida entre las cinco clases diferentes, sin detectarse traslapos entre ellas mediante la representación gráfica que se muestra en la Figura 4.17. Como ha sido posible observar en estos resultados, la integración de las cuatro señales en una matriz conjunta logró una separación nítida y sin superposiciones entre las diferentes condiciones de falla. lo que demuestra la mejoría al emplear diversas señales y medir diferentes magnitudes físicas.

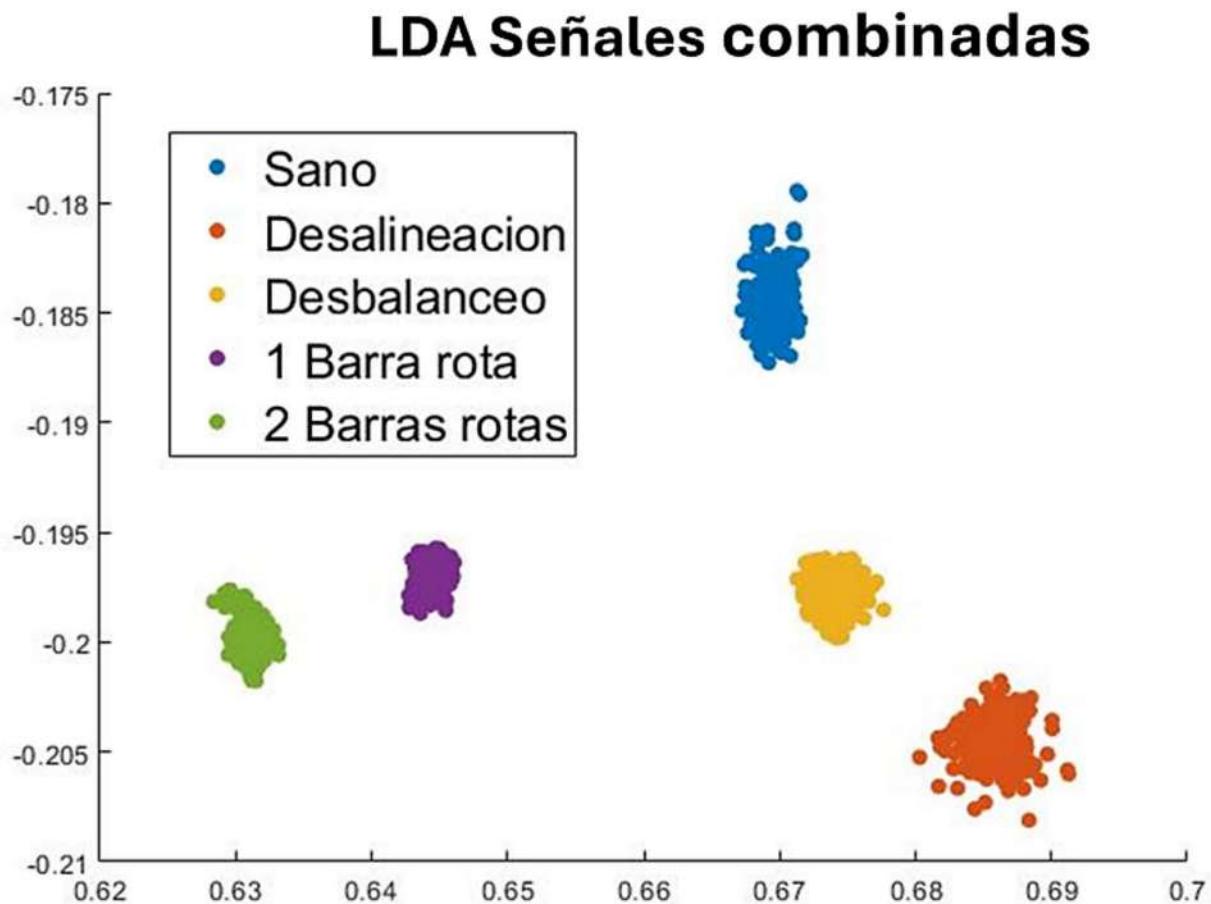


Figura 4.17 LDA obtenido tras el procesamiento de las señales de flujo disperso y corriente (autoría propia)

Al completar el proceso de entrenamiento de la red neuronal, se confirmó la mejora en el desempeño del modelo. En esta ocasión, como se muestra en la Figura 4.18 se logró alcanzar una tasa de clasificación del 100% para las cinco condiciones de motor evaluadas. lo que demuestra de forma clara una mayor capacidad para distinguir entre las diversas clases de falla del motor al emplear múltiples señales de diferentes magnitudes físicas, en comparación con los análisis individuales de las señales.

		Confusion Matrix					
		1	2	3	4	5	
Output Class	1	126 20.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	2	0 0.0%	126 20.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
3	0 0.0%	0 0.0%	126 20.0%	0 0.0%	0 0.0%	100% 0.0%	
	4	0 0.0%	0 0.0%	0 0.0%	126 20.0%	0 0.0%	100% 0.0%
5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	126 20.0%	100% 0.0%	
		100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%
		1	2	3	4	5	
		Target Class					

Figura 4.18 red neuronal obtenida tras el procesamiento de las señales de flujo disperso y corriente (autoría propia)

#### 4.2.2 Procesamiento de señales ante un pico de arranque

Cuando el sistema detecta la presencia de un pico de arranque, se activa un procedimiento diferente al de la señal en estado estable para el procesamiento de señales, la información de cada señal es procesada mediante la transformada de Fourier de Tiempo Corto (STFT), como se muestra en la Figura 4.19.

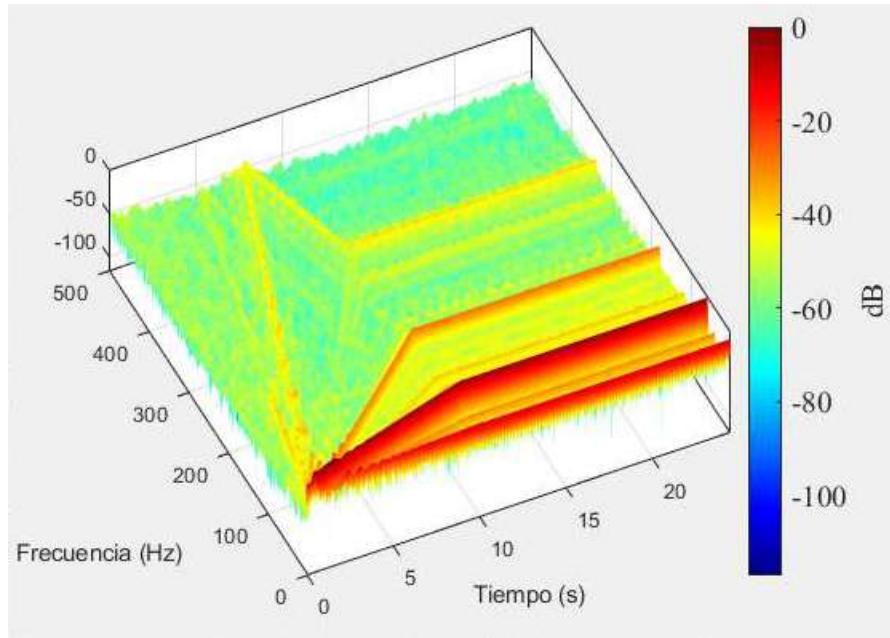


Figura 4.19 STFT obtenida del procesamiento de las señales (autoría propia)

Esta información es seccionada en 30 cuadrantes, empleando 3 divisiones en el eje del tiempo y 10 divisiones en el eje de frecuencia como se puede observar en la Figura 4.20 y obteniendo a partir de estos la mayor amplitud presente en cada cuadrante.

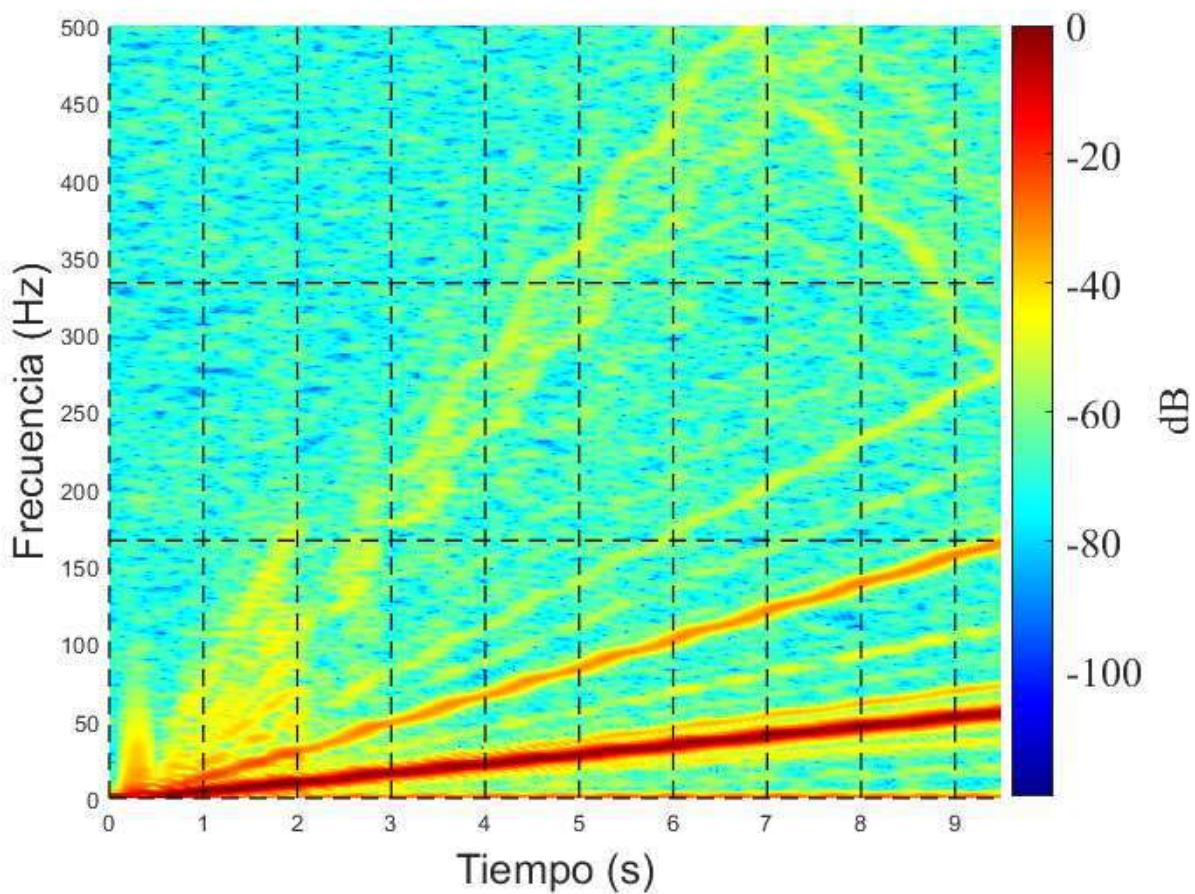


Figura 4.20 STFT obtenida dividida en cuadrantes (autoría propia)

Estos 30 valores de amplitud, derivados de la STFT, son utilizados como entradas para el procesamiento mediante el Análisis Discriminante Lineal (LDA) para reducir esta información multidimensional a una matriz bidimensional, facilitando así una representación visual y una interpretación más clara de las características. A partir de este punto los datos obtenidos son empleados de igual forma que en el caso del procesamiento en estado estable para el entrenamiento de las redes neuronales, utilizando un 70 % de las muestras para el entrenamiento y un 30 % de las muestras para la validación.

Como se aprecia en la Figura 4.21, en este análisis no se logró identificar con claridad ninguna de las clases respecto del resto, ya que se evidenciaron múltiples traslapes entre ellas. Sin embargo, es importante resaltar que se observó una distinción entre la clase asociada a una barra rota (clase 4) y las condiciones de desalineación y desbalanceo (clases 2 y 3). tras el entrenamiento mediante la red neuronal, fue posible observar una eficiencia considerable de clasificación del 84.4% como se aprecia en la Figura 4.22, lo que sugiere que si bien, esta información no brinda información determinante por si sola para poder confirmar una falla específica entre las fallas consideradas para este trabajo, esta información puede ser empleada para complementar el diagnóstico.

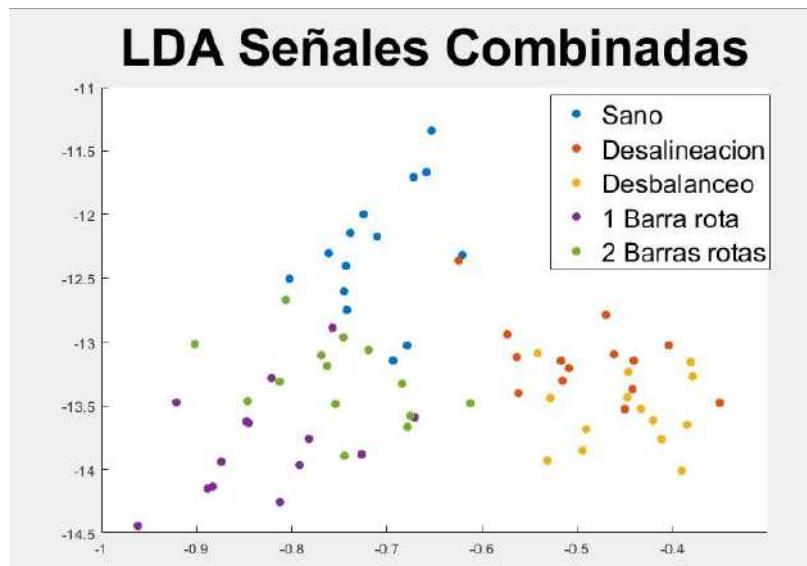


Figura 4.21 LDA obtenido tras el procesamiento de las señales de flujo disperso y corriente ante un pico de arranque (autoría propia)  
un pico de arranque (autoría propia)

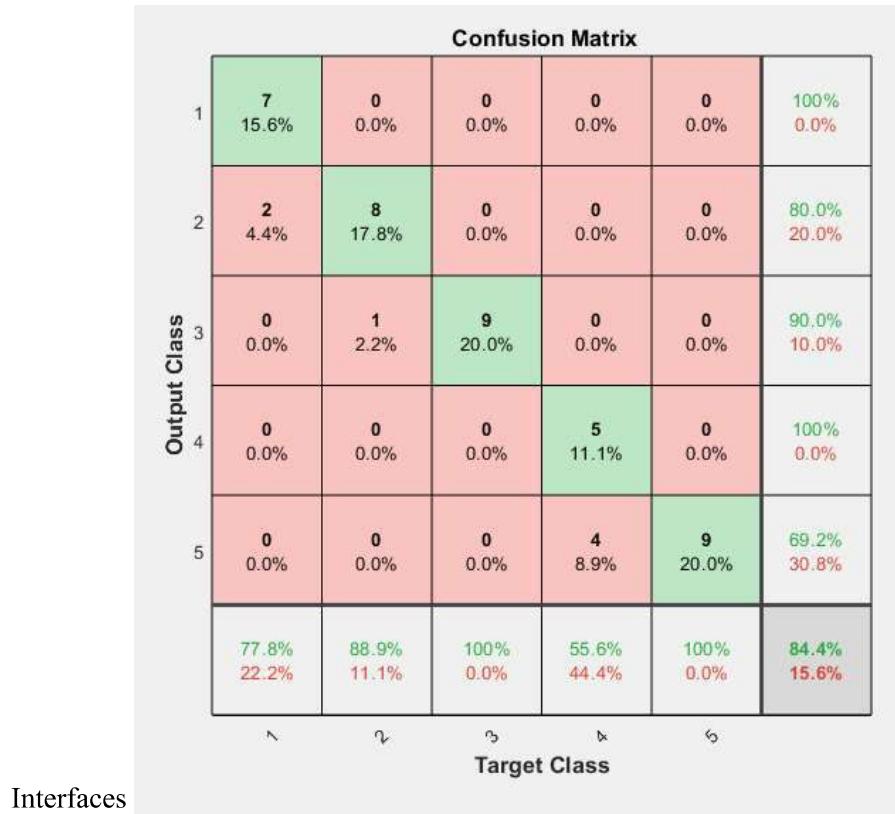


Figura 4.22 red neuronal obtenida tras el procesamiento de las de flujo disperso y corriente ante un pico de arranque (autoría propia)

### 4.3 Interfaces de comunicación y de usuario

En este proyecto, se llevó a cabo la implementación de interfaces de comunicación fundamentadas en los protocolos Ethernet y CAN. Estas interfaces fueron esenciales para facilitar la comunicación del sensor inteligente, se eligieron estos protocolos ya que, en el caso de Ethernet, este es un protocolo de comunicación muy utilizado en entornos de redes de área local y es conocido por su alta velocidad y confiabilidad en la transmisión de datos. Proporciona una base sólida para la conectividad en entornos como oficinas e industrias. En el caso del protocolo CAN este es un protocolo diseñado principalmente para aplicaciones automotrices e industriales, donde la fiabilidad y la comunicación en tiempo real son esenciales. Permite la comunicación entre dispositivos electrónicos distribuidos, como sensores y actuadores, en sistemas complejos y robustos. Se caracteriza por su capacidad para operar en entornos hostiles, con altos niveles de ruido electromagnético.

Para la interfaz de usuario, se diseñó una interfaz gráfica que como se puede observar en la Figura 4.23 consta de dos páginas principales. En la primera página, se proporciona una visualización de los datos generales del motor, acompañada de un diagnóstico simplificado de la condición detectada por el sensor. Esta sección ofrece una visión general y accesible del estado del motor, brindando información clave de manera concisa y comprensible para los usuarios.

En la segunda página, se ofrece una representación gráfica más detallada de las diferentes señales recopiladas a lo largo del tiempo. Aquí, se presentan gráficos que muestran las variaciones temporales de las señales y sus respectivos procesamientos. En caso de ser aplicable, se emplean técnicas de análisis de Fourier para proporcionar una comprensión más profunda de la información recopilada. Esta representación visual permite una observación más detallada y técnica de las señales, lo que puede ser útil para un análisis más profundo por parte de usuarios con experiencia en el campo. Esta disposición busca atender las necesidades de diversos usuarios, desde aquellos interesados en una evaluación rápida hasta los que requieren un análisis más profundo de los datos recopilados por el sensor.

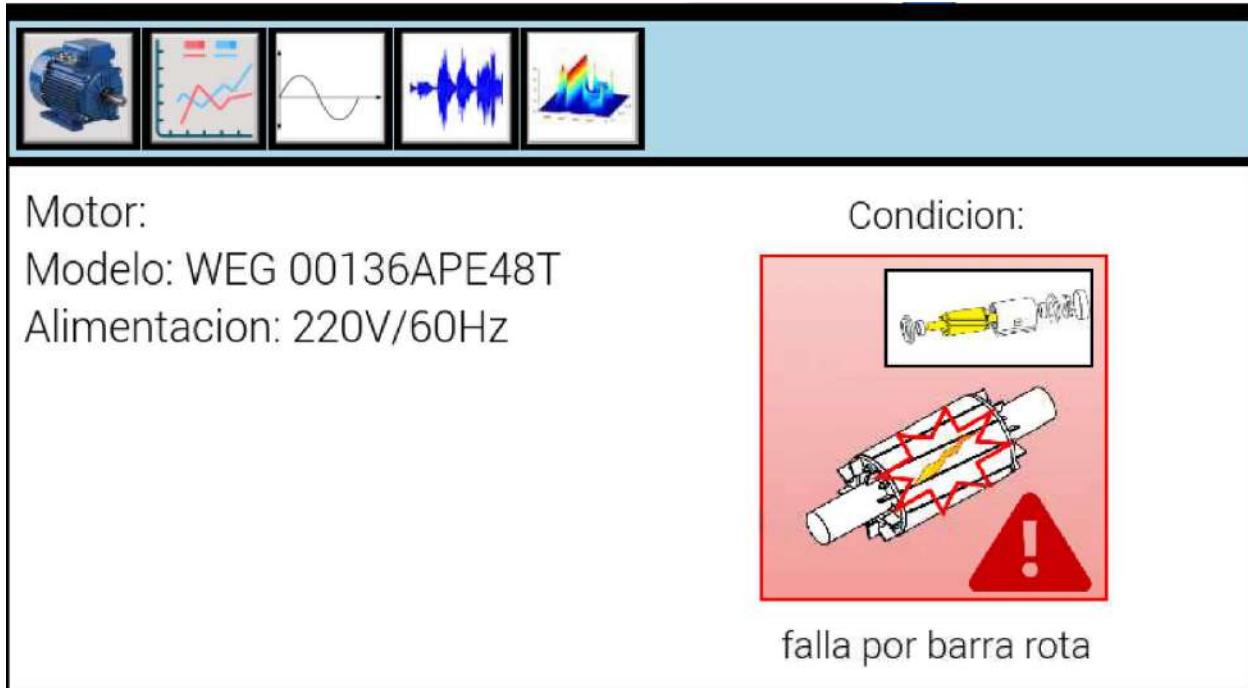


Figura 4.23 interfaz de usuario del sensor inteligente (autoría propia).

Para contrastar los resultados que pueden ser obtenidos con un sensor inteligente comercial, se puede observar un ejemplo de un reporte de diagnóstico emitido por un sensor modelo Ability Smart Sensor de la marca ABB en la Figura 4.24. Como se puede observar, este sensor puede emitir información muy general sobre el tiempo que ha detectado algún tipo de problema con rodamientos, desalineación o vibración durante el tiempo de operación mediante tres tipos de condición, siendo buena condición, tolerable o pobre. Sin embargo, no ofrece un diagnóstico simplificado y esta información debe ser interpretada por personal con conocimiento sobre lo que puede indicar esta información.

# Equipment view

Start date: 2022-02-11 09:30:20

End date: 2022-02-25 09:30:36.135675

Total hours: 336 h

## Overall Vibration



- OK: 10 d 21 h
- No data: 2 d 23 h
- Tolerable: 2 h 0 min
- Poor: 2 h 0 min

## Bearing Condition



- No data: 13 d 16 h
- OK: 8 h 0 min
- Tolerable: 0 min 0 s
- Poor: 0 min 0 s

## Simple Misalignment



- OK: 11 d 1 h
- No data: 2 d 23 h
- Tolerable: 0 min 0 s
- Poor: 0 min 0 s

## Motor Running Time



- Off: 10 d 19 h
- No data: 2 d 23 h
- On: 6 h 0 min

Figura 4.24 ejemplo de un reporte emitido por el sensor Ability Smart Sensor ABB

# Capítulo 5

## 5 Conclusiones y prospectivas

### 5.1 Conclusiones

El análisis de los resultados obtenidos revela la efectividad y la importancia del procesamiento y la fusión de múltiples señales en distintos dominios, como el tiempo, la frecuencia y tiempo-frecuencia, para el análisis de fallas en motores de inducción. Esta integración de información permitió observar una mejora importante en la detección y discriminación de diversas fallas en comparación con el procesamiento individual de las señales, también se evidenció a lo largo del proyecto que el análisis individual de las señales no fue capaz de proporcionar una separación completa y precisa entre las diferentes condiciones consideradas en este proyecto.

Además, se observó que diagnosticar la condición de un motor resulta más complicada cuando la señal no exhibe un comportamiento estable. Esta dificultad subraya la importancia de desarrollar técnicas y algoritmos robustos que puedan manejar y detectar eficazmente anomalías o variaciones en las señales, especialmente para procesos en donde los motores no presentan un comportamiento estable en su señal debido a sus condiciones de operación.

Los hallazgos de este estudio destacan la relevancia y la necesidad de considerar el procesamiento y la fusión de múltiples señales para mejorar la precisión y la confiabilidad en el diagnóstico de fallas en motores de inducción, ya que como se demostró en este trabajo, la adición de señales de diferentes magnitudes puede contribuir al desarrollo de sistemas más efectivos y confiables para la detección temprana y la prevención de fallas en estos motores, y planificación de mantenimiento preventivo y reducción de costos al implementar estos sistemas a nivel industrial.

## 1.1 Prospectivas

Como se ha evidenciado en este estudio, la combinación de diversas señales de entrada enriquece significativamente la base de datos, lo que conduce a una identificación más precisa de fallas específicas en motores durante el proceso de diagnóstico. Por lo tanto, la metodología presentada en este proyecto podría ser ampliada y enriquecida al considerar la medición de magnitudes adicionales que no fueron abordadas en este trabajo, como la temperatura o la vibración mecánica. El análisis de estas señales, complementado con distintos enfoques de procesamiento, podría proporcionar una perspectiva más completa y detallada del estado de los motores, mejorando así la efectividad del diagnóstico de fallas.

Además, para futuras investigaciones, sería beneficioso explorar la inclusión de una variedad más amplia de tipos de fallas. La introducción de un espectro más diverso de fallas y severidades en el conjunto de datos podría conducir a un entrenamiento más completo de los algoritmos de clasificación, lo que a su vez conlleva una mejor capacidad de diferenciación entre los distintos tipos de fallas. Este enfoque ampliado no solo aumentaría la robustez y la versatilidad de los sistemas de diagnóstico, sino que también abriría nuevas oportunidades para la detección temprana y la mitigación eficaz de problemas en los motores de inducción.

# Referencias

- Agatonovic-Kustrin, S., & Beresford, R. (2000). Basic concepts of artificial neural network (ANN) modeling and its application in pharmaceutical research. *Journal of Pharmaceutical and Biomedical Analysis*, 22(5), 717–727. [https://doi.org/10.1016/S0731-7085\(99\)00272-1](https://doi.org/10.1016/S0731-7085(99)00272-1)
- Alvarado, A. (2021). *Procesamiento de señales termográficas para integración en un Smart Sensor multivariable aplicado al diagnóstico de fallos en motores de inducción*.
- Amanuel, T., Ghirmay, A., Ghebremeskel, H., Ghebrehewet, R., & Bahlibi, W. (2021). Comparative Analysis of Signal Processing Techniques for Fault Detection in Three Phase Induction Motor. *Journal of Electronics and Informatics*, 3(1), 61–76. <https://doi.org/10.36548/jei.2021.1.006>
- Antonino-daviu, J., Zamudio-ramirez, I., & Dunai, L. (n.d.). *SMART SENSOR FOR ADVANCED ELECTRIC MOTORS CONDITION*.
- Ceban, A., Pusca, R., & Romary, R. (2012). Study of rotor faults in induction motors using external magnetic field analysis. *IEEE Transactions on Industrial Electronics*, 59(5), 2082–2093. <https://doi.org/10.1109/TIE.2011.2163285>
- Ciabattoni, L., Cimini, G., Ferracuti, F., Freddi, A., Ippoliti, G., & Monteriù, A. (2015). A novel LDA-based approach for motor bearing fault detection. *Proceeding - 2015 IEEE International Conference on Industrial Informatics, INDIN 2015*, 771–776. <https://doi.org/10.1109/INDIN.2015.7281834>
- Cureño, J. (2020). *Ánalisis de desgaste mediante flujo magnético en la pista exterior de rodamientos bajo diversas severidades de daño*.
- Faiz, J., Takbash, A. M., & Mazaheri-Tehrani, E. (2017). A Review of Application of Signal Processing Techniques for Fault Diagnosis of Induction Motors – Part I. *AUT Journal of Electrical Engineering*, 49(2), 109–122. <https://doi.org/10.22060/eej.2017.13219.5142>
- Faiz, Jawad, & Ojaghi, M. (2009). Different indexes for eccentricity faults diagnosis in three-

- phase squirrel-cage induction motors: A review. *Mechatronics*, 19(1), 2–13. <https://doi.org/10.1016/j.mechatronics.2008.07.004>
- Gaeid, K. S., Lumpur, K., & Darul, S. (2010). Diagnosis and Fault Tolerant Control of the Induction Motors Techniques a Review. *Signal Processing*, 4(2), 227–246.
- 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. <https://doi.org/10.1016/j.ymssp.2020.106908>
- Garcia-Ramirez, A. G., Osornio-Rios, R. A., Granados-Lieberman, D., Garcia-Perez, A., & Romero-Troncoso, R. J. (2012). Smart sensor for online detection of multiple-combined faults in VSD-fed induction motors. *Sensors (Switzerland)*, 12(9), 11989–12005. <https://doi.org/10.3390/s120911989>
- Hand, A. (2011). Electric Motor Maintenance and Troubleshooting Second Edition. In *The McGraw-Hill Companies*.
- Hu, Y. H., & Hwang, J. N. (2001). Handbook of neural network signal processing. In *Handbook of Neural Network Signal Processing*. <https://doi.org/10.1121/1.1480419>
- IEEE. (1997). *IEEE Recommended Practice for the Design of Reliable Industrial and Commercial Power Systems* (Vol. 1997).
- Karmakar, S., Chattopadhyay, S., Mitra, M., & Sengupta, S. (2016). Induction Motor Fault Diagnosis. In *ISA Transactions*.
- Liu, S., Xie, J., Shen, C., Shang, X., Wang, D., & Zhu, Z. (2020). Bearing fault diagnosis based on improved convolutional deep belief network. *Applied Sciences (Switzerland)*, 10(18). <https://doi.org/10.3390/APP10186359>
- Luis Enrique Garfias Nieto. (2020). *Monitoreo y análisis de vibraciones en motores de inducción para la detección de fallas de corto circuito*.
- Luong, P., & Wang, W. (2020). Smart Sensor-Based Synergistic Analysis for Rotor Bar Fault Detection of Induction Motors. *IEEE/ASME Transactions on Mechatronics*, 25(2), 98

1067–1075. <https://doi.org/10.1109/TMECH.2020.2970274>

Mazaheri-Tehrani, E., & Faiz, J. (2022). Airgap and stray magnetic flux monitoring techniques for fault diagnosis of electrical machines: An overview. *IET Electric Power Applications*, 16(3), 277–299. <https://doi.org/10.1049/elp2.12157>

Meijer, G. C. M. (2008). Smart Sensor Systems. In *Smart Sensor Systems*.  
<https://doi.org/10.1002/9780470866931>

Meyer, D. (2009). Support Vector Machines Na Support Vector Machines Na. *지능정보연구*, 16(1), 130.

Muhammad Irfan, Saad, N., & Ibrahim, R. (2021). Condition Monitoring and Faults Diagnosis of Induction Motors Electrical Signature Analysis. In *Angewandte Chemie International Edition*, 6(11), 951–952.

Nandi, S., Toliyat, H. A., & Li, X. (2005). Condition monitoring and fault diagnosis of electrical motors - A review. *IEEE Transactions on Energy Conversion*, 20(4), 719–729.  
<https://doi.org/10.1109/TEC.2005.847955>

Ortiz, A., Garrido, J., Hernandez-Escobedo, Q., & Escobedo-Trujillo, B. (2019). Detection of misalignment in motor via transient current signature analysis. *2019 IEEE International Conference on Engineering Veracruz, ICEV 2019, I*, 1–5.  
<https://doi.org/10.1109/ICEV.2019.8920719>

Popović, R. S., & Kejik, P. (2008). Integrated Hall Magnetic Sensors. In *Smart Sensor Systems*.  
<https://doi.org/10.1002/9780470866931.ch9>

Ramírez, M. (2019). *Sensor inteligente basado en técnicas de tiempo-frecuencia para supervisión de fallas en cojinetes cerámicos y metálicos*. (p. 88).

Saucedo-Dorantes, J. J., Jaen-Cuellar, A. Y., Delgado-Prieto, M., Romero-Troncoso, R. de J., & Osornio-Rios, R. A. (2021). Condition monitoring strategy based on an optimized selection of high-dimensional set of hybrid features to diagnose and detect multiple and combined faults in an induction motor. *Measurement: Journal of the International Measurement*

*Confederation, 178*(March), 109404. <https://doi.org/10.1016/j.measurement.2021.109404>

Sen, P. C., Hajra, M., & Ghosh, M. (2020). Supervised Classification Algorithms in Machine Learning: A Survey and Review. In *Advances in Intelligent Systems and Computing* (Vol. 937). Springer Singapore. [https://doi.org/10.1007/978-981-13-7403-6\\_11](https://doi.org/10.1007/978-981-13-7403-6_11)

Silva, A. M. (2014). *Induction Motor Fault Diagnostic and Monitoring Methods*. May.

Thorsen, O. V., & Dalva, M. (1995). A Survey of Faults on Induction Motors in Offshore Oil Industry, Petrochemical Industry, Gas Terminals, and Oil Refineries. *IEEE Transactions on Industry Applications, 31*(5), 1186–1196. <https://doi.org/10.1109/28.464536>

Tian, Y., Guo, D., Zhang, K., Jia, L., Qiao, H., & Tang, H. (2018). A Review of Fault Diagnosis for Traction Induction Motor. *Chinese Control Conference, CCC, 2018-July*, 5763–5768. <https://doi.org/10.23919/ChiCC.2018.8484044>

Tong, W. (2022). *Mechanical Design and Manufacturing of Electric Motors*.  
[https://www.bertelsmann-stiftung.de/fileadmin/files/BSt/Publikationen/GrauePublikationen/MT\\_Globalization\\_Report\\_2018.pdf](https://www.bertelsmann-stiftung.de/fileadmin/files/BSt/Publikationen/GrauePublikationen/MT_Globalization_Report_2018.pdf)  
[http://eprints.lse.ac.uk/43447/1/India\\_globalisation%2C\\_society\\_and\\_inequalities%28lsero%29.pdf](http://eprints.lse.ac.uk/43447/1/India_globalisation%2C_society_and_inequalities%28lsero%29.pdf)  
<https://www.quora.com/What-is-the>

Van Der Horn, G., & Huijsing, J. H. (1997). Integrated Smart Sensor Calibration. *Analog Integrated Circuits and Signal Processing, 14*(3), 207–222.  
<https://doi.org/10.1023/a:1008289918937>

Waide, P., & Brunner, C. U. (2011). Energy-Efficiency Policy Opportunities for Electric Motor-Driven Systems. *Internationale Energy Agency*, 132.

Webb, G. I. (2020). Encyclopedia of Machine Learning and Data Science. *Encyclopedia of Machine Learning and Data Science, January 2016*. <https://doi.org/10.1007/978-1-4899-7502-7>

Zamudio Ramirez, I., Osornio Rios, R. A., Antonino-Daviu, J. A., Razik, H., & Romero-Troncoso, R. (2022). Magnetic Flux Analysis for the Condition Monitoring of Electric

Machines: A Review. *IEEE Transactions on Industrial Informatics*, 18(5), 2895–2908.  
<https://doi.org/10.1109/TII.2021.3070581>

Zupan, J. (1994). *Introduction to Artificial Neural Network ( ANN ) Methods : What They Are and How to Use Them \**. September, 327–352.

Fluke. (2022). MDA-550 Series III Motor Drive Analyzer. Fluke. Retrieved November 18, 2022, from <https://www.fluke.com/en-us/product/electrical-testing/portable-oscilloscopes/mda-550>

NCD. (2019, July 29). Top 3 motor failure detection sensors & benefits. ncd.io. Retrieved November 18, 2022, from <https://ncd.io/top-3-motor-failure-detection-sensors/>