
TECNM AGUASCALIENTES
MAESTRÍA EN CIENCIAS DE LA INGENIERÍA



**DETECCIÓN Y CLASIFICACIÓN DE FALLAS EN MOTORES
IMPLEMENTANDO REDES NEURONALES**

TESIS PARA OBTENER EL GRADO DE:
MAESTRO EN CIENCIAS DE LA INGENIERÍA

PRESENTA:
ING. CARLOS JESÚS GONZÁLEZ BARRÓN

DIRECTOR DE TESIS:
DR. FRANCISCO JAVIER VILLALOBOS PIÑA

CO-DIRECTOR DE TESIS:
DR. JOSUÉ AUGUSTO REYES MALANCHE

AGUASCALIENTES, AGS.

NOVIEMBRE 2025



Instituto Tecnológico de Aguascalientes
División de Estudios de Posgrado e Investigación

Aguascalientes, Ags., 29/octubre/2025
Oficio No. DEPI 697/2025
Asunto: Autorización impresión tesis

C. CARLOS JESÚS GONZÁLEZ BARRÓN
PRESENTE

Los abajo firmantes, Miembros del Jurado para Examen de Grado de Maestría, hacemos **constar** que, habiendo revisado el Trabajo de Tesis desarrollado por Usted, bajo el título: **“Detección y Clasificación de Fallas en Motores Implementando Redes Neuronales”**, hemos dictaminado que éste es de aceptarse, por lo que se autoriza su impresión.

ATENTAMENTE

Excelencia en Educación Tecnológica®
Ingenio, Cultura y Saber, que conducen a la Excelencia®

PRESIDENTE

Fco. Javier Villalobos Piña

DR. FRANCISCO JAVIER VILLALOBOS PIÑA

SECRETARIO

José A. Reyes M.


DR. JOSUÉ AUGUSTO REYES MALANCHE

VOCAL

Carlos Humberto Saucedo Zárate

DR. CARLOS HUMBERTO SAUCEDO ZÁRATE

ccp. Archivo
JFLH/yevo



AUTORIZACIÓN DE USO DE DERECHOS DE AUTOR OTORGADO POR

Carlos Jesús González Barrón, mayor de edad, con domicilio ubicado en San Ignacio 162 Col. del Carmen CP 20050 Aguascalientes, Ags., en mi calidad de titular y autor de la tesis denominada **Detección y Clasificación de Fallas en Motores Implementando Redes Neuronales** quien para todos los fines del presente documento se denominará **EL AUTOR Y/O TITULAR**, suscribo el presente documento de autorización de uso de derechos patrimoniales de autor a favor del Tecnológico Nacional de México/Instituto Tecnológico de Aguascalientes el cual se registrá por las clausulas siguientes:

PRIMERA – AUTORIZACIÓN: **EL AUTOR Y/O TITULAR**, mediante el presente documento autoriza la utilización de los derechos patrimoniales de autor al Tecnológico Nacional de México/Instituto Tecnológico de Aguascalientes, de la tesis denominada **Aprendizaje por Refuerzo para la Conducción Autónoma de Agentes Móviles Inteligentes**, a través del Repositorio Institucional del Tecnológico Nacional de México (en lo sucesivo TecNM) y en el Repositorio Nacional, que puede ser consultado en la liga electrónica: (www.repositorionacionalcti.mx/).

SEGUNDA – OBJETO: Por medio del presente escrito, **EL AUTOR Y/O TITULAR** autoriza al Tecnológico Nacional de México/Instituto Tecnológico de Aguascalientes, a través del Repositorio Institucional del TecNM y en el Repositorio Nacional para que de conformidad con la Ley Federal del Derecho de Autor y la Ley de la Propiedad Industrial, use los derechos del documento antes referido, con fines exclusivamente académicos.

TERCERA – TERRITORIO: Los derechos aquí autorizados se dan sin limitación geográfica o territorial alguna.

CUARTA – ALCANCE: La presente autorización se da tanto para formato o soporte material, y se extiende a la utilización en medio óptico, magnético, electrónico, en red, mensajes de datos o similar conocido o por conocer, del ejemplar o número respectivo de la publicación.

QUINTA – EXCLUSIVIDAD: La autorización de uso aquí establecida no implica exclusividad en favor del Tecnológico Nacional de México/Instituto Tecnológico de Aguascalientes. Por lo tanto, **EL AUTOR Y/O TITULAR** en su carácter de autor de la obra objeto del presente documento se reserva el derecho de publicar directamente, u otorgar a cualquier tercero, autorizaciones de uso similares o en los mismos términos aquí acordados.

SEXTA – DERECHOS MORALES (Créditos y mención): La Autorización de los derechos antes mencionados no implica la cesión de los derechos morales sobre los mismos por cuanto en conformidad con lo establecido en los artículos 18, 19, 20, 21, 22 y 23 de la Ley Federal de Derechos de Autor, dada la cuenta que estos derechos son inalienables, imprescriptibles, irrenunciables e inembargables. Por lo tanto, los mencionados derechos seguirán radicados en cabeza de **EL AUTOR Y/O TITULAR**, y siempre deberá mencionarse su nombre cuando se utilice la obra.

SÉPTIMA – AUTORÍA: **EL AUTOR Y/O TITULAR**, declara y ratifica que el material objeto de la presente fue realizada por él o por ella sin violar o usurpar derechos de Propiedad Intelectual de terceros.

Aguascalientes, Aguascalientes, a 3 días del mes de noviembre de 2025.

Autor de la Tesis

Director de Tesis



Carlos Jesús González Barrón

Dr. Francisco Javier Villalobos Piña

Nombre y firma

Nombre y firma



Instituto Tecnológico de Aguascalientes
División de Estudios de Posgrado e Investigación

Aguascalientes, Ags., **3/noviembre/2025**
Asunto: Constancia de Originalidad

**CONSEJO DE POSGRADO
MAESTRÍA EN CIENCIAS DE LA INGENIERÍA
PRESENTE**

El director de tesis de **Carlos Jesús González Barrón**, estudiante de **Maestría en Ciencias de la Ingeniería** con número de control **G23153205**, hace constar que, después de haber realizado la revisión del informe de originalidad generado con la herramienta Turnitin, el trabajo **"Detección y Clasificación de Fallas en Motores Implementando Redes Neuronales"** es original conforme a los criterios establecidos. El porcentaje de similitud es de **15%** y se adjunta resumen del reporte.

ATENTAMENTE

Excelencia en Educación Tecnológica®

Ingenio, Cultura y Saber, que conducen a la Excelencia

Vo.Bo.


Fco. Javier Villalobos Piña

Mardel

DR. FRANCISCO JAVIER VILLALOBOS PIÑA
DIRECTOR DE TESIS

DR. MARIO ALBERTO RODRÍGUEZ DÍAZ
COORDINADOR DE LA MAESTRÍA EN CIENCIAS
DE LA INGENIERÍA

ccp. Archivo



2025
Año de
**La Mujer
Indígena**

Av. Adolfo López Mateos #1801. Fracc. Bona Gens
C.P. 20256 Aguascalientes, Ags. Tel. 449 910 5002 ext. 127
e-mail: jefatura.depi@aguascalientes.tecnm.mx
tecnm.mx | www.aguascalientes.tecnm.mx



Instituto Tecnológico®
de Aguascalientes



Tesis_MCI_Carlos Jesús González Barrón.pdf

-  Carlos Jesús González Barrón
-  Carlos Jesús González Barrón
-  Tecnológico Nacional de Mexico

Detalles del documento

Identificador de la entrega

trn:oid:::20755:522363923

Fecha de entrega

3 nov 2025, 12:46 p.m. GMT-6

Fecha de descarga

3 nov 2025, 12:56 p.m. GMT-6

Nombre del archivo

Tesis_MCI_Carlos Jesús González Barrón.pdf

Tamaño del archivo

13.9 MB

113 páginas

21.443 palabras

121.330 caracteres

15% Similitud general

El total combinado de todas las coincidencias, incluidas las fuentes superpuestas, para ca...

Filtrado desde el informe

- ▶ Bibliografía
- ▶ Texto citado
- ▶ Texto mencionado
- ▶ Coincidencias menores (menos de 8 palabras)

Fuentes principales

- 12%  Fuentes de Internet
- 8%  Publicaciones
- 13%  Trabajos entregados (trabajos del estudiante)

Marcas de integridad

N.º de alertas de integridad para revisión

No se han detectado manipulaciones de texto sospechosas.

Los algoritmos de nuestro sistema analizan un documento en profundidad para buscar inconsistencias que permitirían distinguirlo de una entrega normal. Si advertimos algo extraño, lo marcamos como una alerta para que pueda revisarlo.

Una marca de alerta no es necesariamente un indicador de problemas. Sin embargo, recomendamos que preste atención y la revise.

Resumen

El presente trabajo expone una investigación experimental sobre el diagnóstico de fallas en motores eléctricos sin escobillas de imanes permanentes (BLDC por sus siglas en inglés). Para el estudio se utilizó un banco de pruebas experimentales fruto de trabajos de investigación previa. El sistema consiste en un motor BLDC de vehículo eléctrico ligero de 500W, el motor se encuentra acoplado a un generador para producir par de carga.

El sistema cuenta con una unidad central de control basado en el procesador de señales digitales de la compañía Microchip, el dsPIC30F4011, cuenta además con una etapa de adquisición de las corrientes del estator basado en sensores de efecto Hall de la compañía Honey Well. La etapa de potencia consiste en un inversor trifásico de puente completo. El motor fue alterado en sus devanados para inducir diferentes escenarios de falla.

Se estudiaron varios escenarios de falla con diferentes porcentajes de corto circuito entre espiras del devanado iniciando en una falla de tipo incipiente y terminando con una falla de tipo drástica. El diagnóstico de fallas eléctricas del estator se lleva a cabo mediante el mapeo de las corrientes del estator al marco de referencia fijo de concordia, de las corrientes alfa-beta se obtiene el módulo del vector espacial instantáneo de Park (ISP por sus siglas en inglés) y posteriormente, el trabajo se centra en el diseño de un clasificador neuronal el cual es alimentado con información espectral procedente de la transformada discreta de Fourier (FFT por sus siglas en inglés) y de los coeficientes del análisis multiresolución (MRA por sus siglas en inglés) de la transformada discreta ondeleta.

Los mejores resultados se obtuvieron empleando de la amplitud de los espectros de la FFT resultantes de módulo del vector de Park de las corrientes del estator con normalización Min-Max en un perceptrón multicapa con dos niveles de capas ocultas (9 neuronas en la capa de entrada y 8 neuronas en la capa de salida) con funciones de activación sigmoide y 8 neuronas de salida con funciones de activación softmax, para el proceso de entrenamiento de la red neuronal se empleó el método del gradiente. Una vez entrenada fue validada la red y se obtuvo un porcentaje de efectividad del 99.54 %, siendo este el que tiene un costo

computacional más bajo.

El trabajo del desarrollo físico queda pendiente implementar para cualquier tipo de máquina eléctrica con uso de una raspberry pi, para ejecutar diferentes algoritmos para la detección y clasificación de fallas eléctricas de estator en el motor Brushless.

Esta investigación sienta las bases para un desarrollo futuro del tipo experimental, en el cual se pretende implementar un esquema de diagnóstico de fallas para otros tipos de máquinas, y como unidad central de procesamiento, la posibilidad de implementar un computador de bajo costo como lo es la RaspBerry PI, con la intención de ejecutar diversos algoritmos para efectuar la detección en primer instancia y posteriormente la detección, aislamiento y posible clasificación de las mismas.

Dedico este trabajo a...

Dedico esta tesis a mi familia, fuente inagotable de amor y fortaleza, cuyo apoyo incondicional me acompañó en cada etapa de este camino. A mis profesores y amigos, por su guía, enseñanzas y palabras de aliento que contribuyeron al logro de este objetivo.

Agradecimientos

Quiero expresar mi profundo agradecimiento a todas las personas e instituciones que contribuyeron a la realización de este trabajo. En primer lugar, agradezco a mi director de tesis, el Dr. Francisco Javier Villalobos Piña, por su asesoría experta, su orientación constante y sus valiosas sugerencias, las cuales enriquecieron la calidad de este estudio.

Extiendo mi gratitud al personal académico y administrativo del programa de posgrado del Tecnológico Nacional de México, campus Aguascalientes, por brindarme las facilidades necesarias para desarrollar la investigación y facilitar el acceso a los recursos técnicos e intelectuales.

A mis compañeros, colegas y amigos, gracias por los momentos de intercambio académico, colaboración y apoyo, que hicieron más llevadero el proceso de investigación.

Finalmente, mi agradecimiento más sincero va dirigido a mi familia, por su paciencia, estímulo y comprensión durante los momentos exigentes de este trayecto académico. Sin su respaldo incondicional, este logro no hubiera sido posible.

Lista de Símbolos

Símbolo	Descripción
X_k	Valor k -ésimo
x_n	Muestra n -ésima de la señal en el dominio del tiempo
N	Número total de muestras
j	Unidad imaginaria
k	Índice de frecuencia (entero)
n	Índice de tiempo
F	Fuerza resultante (vector)
I	Intensidad de corriente eléctrica
L	Vector de longitud del conductor inmerso en el campo
B	Densidad del campo magnético (vector)
a_k	Coefficiente de aproximación a nivel k en la DWT
d_k	Coefficiente de detalle a nivel k en la DWT
h_n	Coefficientes del filtro de escalamiento (low-pass)
g_n	Coefficientes del filtro de detalle (high-pass)
$\phi(t)$	Función de escalamiento de Haar
$\psi(t)$	Función wavelet (base) de Haar
$\phi_{j,k}(t)$	Función de escalamiento en nivel j , posición k
$\psi_{j,k}(t)$	Función wavelet en nivel j , posición k
$f(t)$	Señal continua reconstruida por descomposición wavelet
$a_{j_0,k}$	Coefficientes de escala inicial (nivel j_0)
$d_{j,k}$	Coefficientes de detalle en nivel j y posición k
ω	Frecuencia angular
f_s	Frecuencia de muestreo de la señal original
f_k	Frecuencia real asociada al índice
$ X_k $	Magnitud espectral de la FFT para la frecuencia k

Símbolo	Descripción
i_a, i_b, i_c	Corrientes instantáneas de las fases A, B y C del motor
i_α	Componente α en la transformación de Clarke
i_β	Componente β en la transformación de Clarke
i_d	Componente directa en la transformación de Park
i_q	Componente en cuadratura en la transformación de Park
θ	Ángulo eléctrico de referencia para la transformación de Park
i_{sP}	Módulo del vector de corriente en el plano Park
$\ ISP\ $	Módulo del espacio vectorial de corriente en el plano Park (también llamado módulo ISP)
$i_a(k), i_b(k), i_c(k)$	Corrientes instantáneas de las fases a, b, c .
$\alpha(k)$	Componente α de la transformada de Park.
$\beta(k)$	Componente β de la transformada de Park.
$ISP(k)$	Módulo ISP de Park.
N	Número de muestras originales de la señal.
N'	Longitud tras rellenar con ceros a potencia de 2.
$\widetilde{ISP}(k)$	Señal ISP ampliada a longitud potencia de 2.
cA_j, cD_j	Coefficientes de aproximación (cA_j) y detalle (cD_j) en nivel j de wavelet.
$RMS(v)$	RMS de vector v .
$Energ(v)$	Suma de cuadrados de v .
$Entrop(v)$	Entropía de Shannon de v .
$Varianza(v)$	Varianza de v .
X	Matriz de características antes de normalizar.
Y	Matriz de etiquetas one-hot (8 clases).
X_{norm}	Matriz de características normalizada Min Max.
$\text{mín}_j, \text{máx}_j$	Valores mínimo y máximo para normalización.
ε	Constante pequeña para estabilidad numérica.
$w^{[1]}, b^{[1]}, w^{[2]}, b^{[2]}, w^{[3]}, b^{[3]}$	Pesos y sesgos de las capas de la MLP.
$z^{[l]}, a^{[l]}$	Preactivación (z) y activación (a) en capa l .
$\sigma(x)$	Función sigmoide
$\text{softmax}(z)$	Softmax
$\ell(\hat{P}, Y)$	Pérdida de entropía cruzada.
$d^{[l]}$	Gradiente/ error en capa l .
η	Tasa de aprendizaje.
Q, K, V	Matrices Query, Key y Value en atención.
d_k	Dimensión de subespacio en atención.
attn	Matriz de pesos de atención.

Símbolo	Descripción
H	Salida de la atención (context vector).
$\text{LayerNorm}(X)$	Normalización por capas de vector X .
d_{model}	Dimensión del modelo (embedding).
d_{ff}	Dimensión interna del feed-forward.
n_{layers}	Número de bloques Transformer.
X_{emb}	Salida de la capa de embedding en Transformer.
$Z_{\text{ff1}}, A_{\text{ff1}}$	Pre-activación y activación en feed-forward primero.
Z_{ff2}, F	Segunda etapa en feed-forward.
$\text{ReLU}(x)$	Activación ReLU: $\max(0, x)$.
$\hat{P}$	Predicciones finales softmax.
$\hat{c}$	Clase predicha: $\arg \max(\hat{P})$.

Índice general

Índice de figuras

Índice de tablas

Capítulo 1

Introducción

El nacimiento de los sistemas de diagnóstico surge, de una manera empírica, en los años treinta ante una demanda de la ingeniería de procesos en refinerías y petroquímicas [?]. Sin embargo, en las últimas 3 décadas la relevancia de los métodos de detección y diagnóstico de fallas ha aumentado en diferentes áreas como la ingeniería eléctrica, mecánica y química [?].

Actualmente, los fallos de sensores, actuadores, procesos y sistemas de control en procesos de laboratorio o industriales son temas de investigación que se analizan mediante métodos de observadores, estimación de parámetros y análisis espectral de frecuencias, entre otros.

Estudios recientes indican que el 90 % de los fallos en máquinas ocurren a raíz del funcionamiento anormal de los componentes internos, como es el caso del motor principal [?], que es la parte que transforma la energía eléctrica en movimiento. Ahora bien, el mantenimiento correctivo de un motor es una práctica muy costosa, ya que implica paradas no programadas y los daños provocados por las fallas de los componentes, donde se destacan las fallas en rodamientos (41 %) y el estator (37 %) [?], siendo este último el más apto para llevar a cabo un análisis no invasivo y por ende más práctico.

Los motores eléctricos de corriente directa sin escobillas (BLDC, por sus siglas en inglés) han sido ampliamente utilizados en varios sectores de la industria como es la automotriz, aeroespacial, robótica y generación de energía eléctrica, por mencionar algunos. La razón principal de la popularidad de estas máquinas sobre otros tipos de motores es su simplicidad de control; ya que basta conocer las seis posiciones lógicas que mandan los sensores digitales de la máquina en cada uno de los ciclos eléctricos para realizar un control simple de velocidad o posición. Esto lo ha llevado a ser uno de los favoritos de las principales marcas de vehículos eléctricos, como se muestra en la figura ?? el uso de este tipo de motores para la fabricación de motocicletas.



Figura 1.1. Ejemplo de uso de un motor en VE

Las ventajas del MB para aplicaciones de vehículos eléctricos (VE) ha crecido considerablemente en los últimos años, desde el desarrollo de propios cuadricopteros hasta fabricación y diseños de drones; siendo el MB, la máquina utilizada para el funcionamiento en estas aplicaciones. En la figura 1.2 ?? se puede presenciar el aumento de demanda de VE desde 2014, con datos de Statista.




Figura 1.2. Estadísticas de ventas de autos de 2014 al 2024

La necesidad hoy en día de los VE sigue creciendo, las mejores marcas constructoras de automóviles le han apostado al desarrollo de sus versiones eléctricas, haciendo comerciales varias marcas en los últimos 5 años.

En la actualidad continua la investigación de sistemas de control para velocidad y posición, buscando mejorar su rendimiento, la funcionalidad, la confiabilidad y la seguridad.

Esto ha intensificado la investigación de diversas técnicas para mejorar el rendimiento y ha dado pie al diagnóstico de fallas junto con los sistemas de control en motores eléctricos.

1.1. Motor eléctrico

Los motores eléctricos son dispositivos electromecánicos que convierten la energía eléctrica en energía mecánica mediante principios basados en las leyes del electromagnetismo. Su funcionamiento se fundamenta en la interacción de campos magnéticos y corrientes eléctricas, lo cual se traduce en la generación de fuerza y movimiento rotacional. La importancia de estos equipos radica en su amplia aplicación en sistemas industriales, automotrices, robóticos y domésticos, lo que subraya la necesidad de un análisis profundo de su diseño, eficiencia y mantenimiento. Además, la evolución tecnológica ha impulsado el desarrollo de nuevos métodos de control y monitoreo, permitiendo optimizar la operación de sistemas complejos en entornos de alta exigencia.



Figura 1.3. Ejemplo de motor eléctrico

1.1.1. Componentes principales de una máquina eléctrica

1. Estator

El estator es la parte fija del motor, encargada de generar el campo magnético necesario para inducir el movimiento del rotor. En motores AC, el estator contiene bobinados trifásicos que, al ser energizados, producen un campo magnético rotatorio. Comúnmente están fabricados con hierro laminado para minimizar pérdidas por corrientes parásitas, ranuras, y bobinas de cobre esmaltado.




Figura 1.4. Estator de motor eléctrico

2. Rotor

Es la parte móvil del motor, situada en el interior del estator. El rotor gira como consecuencia de la interacción entre el campo magnético del estator y las corrientes inducidas (en el caso de motores de inducción) o por imanes permanentes (en motores BLDC).



Figura 1.5. Rotor de motor eléctrico de DC

Tipos de rotor:

- Jaula de ardilla (en motores de inducción): está construido por barras de aluminio o cobre conectadas por anillos.
- Rotor bobinado: lleva devanados similares a los del estator.
- Rotor con imanes permanentes (en motores síncronos o BLDC).

3. Carcasa

Es la estructura externa que protege los componentes internos del motor. También sirve de soporte mecánico y puede facilitar la disipación del calor.

4. Ejes

Es el componente mecánico que transfiere el movimiento de rotación desde el rotor al sistema mecánico que acciona. Va montado sobre los rodamientos.

- Fabricado en acero de alta resistencia.
- Puede incluir chaveteros, acoplamientos o engranajes.




Figura 1.6. Rodamientos y eje de motor eléctrico

5. Rodamientos

Soportan el eje del rotor y permiten su giro con mínima fricción. Su calidad influye directamente en la vida útil del motor. Hay varios tipos, en los que destacan: rodamientos de bolas, rodamientos de rodillos y cojinetes lisos. Los rodamientos son una

de las fuentes más comunes de fallo en motores eléctricos debido a desgaste por carga axial, falta de lubricación o vibraciones., representando más del 40 % de las fallas según estudios industriales [?].




Figura 1.7. Partes de motor eléctrico

- Escobillas y conmutador (solo en motores DC con escobillas)
 - Escobillas: piezas de grafito o carbón que hacen contacto con el conmutador, permitiendo el paso de corriente al rotor. El desgaste de escobillas es una limitante importante en motores DC tradicionales, con necesidad de reemplazo periódico [?]
 - Conmutador: estructura cilíndrica segmentada que invierte la polaridad de la corriente para mantener la rotación.
- Bobinados o devanados

Son los conductores eléctricos enrollados sobre el núcleo del estator o rotor. Están formados por alambre de cobre con aislamiento térmico. Su configuración determina el comportamiento del motor (par, velocidad, consumo) y pueden estar conectados en estrella o triángulo en el caso de motores trifásicos.
- Sensores y sistemas de control

En motores como los BLDC o servomotores, pueden incorporarse sensores de posición, sensores de temperatura y módulos de control electrónico.




Figura 1.8. Fotografía con componentes que integran una motobomba con motor de inducción.

■ Sensores de efecto Hall

Los sensores de efecto Hall representan un componente fundamental en el control y supervisión de motores eléctricos, particularmente en máquinas de corriente continua sin escobillas y motores de imanes permanentes. Su función principal consiste en proporcionar información precisa acerca de la posición angular del rotor y la velocidad del mismo, permitiendo una conmutación electrónica adecuada y garantizando el control del par y la eficiencia energética del sistema [?].

El principio de funcionamiento de estos sensores se basa en el efecto Hall, según el cual, cuando un material conductor o semiconductor es atravesado por una corriente eléctrica y se expone simultáneamente a un campo magnético perpendicular, aparece una diferencia de potencial transversal denominada voltaje Hall. En el contexto de motores eléctricos, este voltaje se genera a partir del campo magnético producido por los imanes permanentes acoplados al rotor, lo que permite identificar su posición relativa con respecto al estator [?].

La información de los sensores Hall puede representarse mediante una tabla de conmutación que define el patrón de energización de los devanados del estator.

Entre las ventajas de los sensores Hall en el control de motores destacan su robustez, bajo costo, compacidad y capacidad de operar en condiciones ambientales adversas.

Además, su integración con tecnología CMOS facilita su implementación en sistemas embebidos y controladores industriales.

No obstante, los sensores Hall presentan ciertas limitaciones, como sensibilidad a variaciones térmicas, resolución angular limitada comparada con encoders ópticos o resolvers, y potencial susceptibilidad a interferencias magnéticas externas. [?].

■ Encoders

Los encoders son dispositivos de medición utilizados para determinar la posición angular, velocidad y sentido de giro de un eje mecánico. En motores eléctricos, estos sensores desempeñan un papel fundamental en los sistemas de control de movimiento, proporcionando realimentación precisa para aplicaciones de control de posición (servo control), velocidad y par en sistemas de alto desempeño [?]. Su uso es particularmente común en motores de imanes permanentes, motores síncronos y motores de inducción cuando se requiere una regulación precisa del movimiento.

Un encoder convierte el desplazamiento angular del eje del motor en señales eléctricas digitales o analógicas. Existen dos categorías principales:

- Encoders incrementales Generan un tren de pulsos proporcional al desplazamiento angular. Proporcionan información relativa de posición y velocidad mediante el conteo de impulsos. La frecuencia de los pulsos es proporcional a la velocidad del eje.
- Encoders absolutos Proporcionan un código digital que representa la posición angular absoluta del eje, permitiendo conocer la orientación del rotor incluso después de un apagado o reinicio del sistema. Pueden implementar codificación binaria o Gray para evitar ambigüedades en la transición de estados [?].

1.1.2. Tipos de motores eléctricos

La vasta familia de máquinas eléctricas se agrupa según principio de operación, construcción y alimentaciones. A continuación, se detallan las categorías principales.

1.1.3. Motores de corriente continua (CC)

Los motores de corriente continua (CC) son máquinas eléctricas rotativas que convierten energía eléctrica de corriente continua en energía mecánica de rotación. Su principio de




Figura 1.9. Tipos de motores eléctricos más comunes

funcionamiento se fundamenta en la interacción entre el campo magnético y las corrientes inducidas en el devanado del rotor, generando una fuerza electromagnética de acuerdo con la ley de Lorentz. Además, la conmutación de la corriente en los devanados del rotor asegura que el par electromagnético mantenga dirección constante, permitiendo un movimiento continuo y suave [?].

- Motor de imán permanente (PMDC)

En los motores de imán permanente, el campo magnético se genera mediante imanes permanentes ubicados en el estator, eliminando la necesidad de devanados de campo y excitación externa. Esto reduce el tamaño, peso y pérdidas del sistema, mejorando su eficiencia. Se caracterizan por su diseño compacto y buena relación potencia-tamaño, siendo comunes en dispositivos portátiles, juguetes eléctricos, pequeñas bombas, ventiladores y aplicaciones automotrices [?].

- Motor de excitación independiente

En este tipo, el devanado de campo es alimentado por una fuente de corriente independiente de la armadura. Esto permite un control preciso e independiente de la

corriente de campo y de armadura, otorgando una amplia gama de control de velocidad y par. Son empleados en aplicaciones industriales de gran potencia, bancos de pruebas y sistemas de tracción controlada [?].

- Motor de excitación en serie

En los motores CC de serie, el devanado de campo se conecta en serie con el devanado de armadura, de forma que el flujo magnético es proporcional a la corriente de armadura. Estos motores pueden generar altos valores de par en el arranque, lo que los hace apropiados para aplicaciones que demandan grandes esfuerzos iniciales como locomotoras, equipos de arranque de motores de combustión, montacargas y tranvías [?].

- Motor excitación en derivación (Shunt)

En los motores shunt, el devanado de campo se conecta en paralelo con la armadura. Estos motores presentan una velocidad relativamente constante bajo variaciones moderadas de carga, debido a que la corriente de campo permanece aproximadamente constante. Son adecuados para aplicaciones donde se requiere regulación estable de velocidad, como ventiladores industriales, tornos y cintas transportadoras [?].

1.1.4. Motores de corriente alterna (CA)

- Asíncronos El funcionamiento se basa en la inducción de corrientes en el rotor producto del campo magnético giratorio generado en el estator. La velocidad del rotor es ligeramente menor que la velocidad sincrónica.

- Motor de inducción de rotor en jaula de ardilla

Es el tipo más común. El rotor consiste en barras conductoras conectadas en cortocircuito por anillos extremos, formando una estructura similar a una jaula. Tiene una construcción sencilla y económica, cuenta con una alta confiabilidad y bajo mantenimiento, además de tener un arranque directo sencillo Sin embargo, su control de velocidad es limitado sin el uso de variadores de frecuencia.

- Motor de inducción de rotor bobinado

Este motor incorpora devanados en el rotor conectados a anillos rozantes y resistencias externas para controlar la corriente de arranque y el par motor. Proporciona un mayor control del torque a bajas velocidades, siendo apropiado para cargas pesadas tales como elevadores y molinos industriales [?].

- **Síncronos**

En los motores sincrónos el rotor gira a la misma velocidad que el campo magnético del estator, es decir, no existe deslizamiento en condiciones de operación estable. El rotor puede emplear imanes permanentes o devanados excitados con corriente continua [?].

- Motores de imanes permanentes (PMSM)

Utilizan imanes permanentes en el rotor para generar el campo magnético. Tienen alta eficiencia y densidad de potencia, excelente control en aplicaciones de servomotores y una operación silenciosa y torque elevado a bajas velocidades, por lo que son ampliamente utilizados en robots industriales, vehiculos electricos, compresores y aplicaciones de precision.

- Motores de excitación por CA

El rotor contiene devanados energizados mediante corriente continua suministrada frecuentemente a traves de anillos rozantes. Este diseño permite el control del flujo, regulando reactivas y mejorando el factor de potencia del sistema. Muy utilizados en sistemas de potencia y correccion de factor de potencia industrial [?].

- Motor Reluctante

Su funcionamiento se basa en la tendencia del rotor a alinearse con la trayectoria de menor reluctancia magnética. Posee estructura sencilla, alta confiabilidad y control avanzado cuando se emplean variadores de frecuencia.

1.1.5. Máquinas especiales

- **Reluctancia variable:** Basadas en el principio de mínima reluctancia, con control de pasos similares a los BLDC pero sin imanes (*switched reluctance*) [?].
- **Paso a paso:** Generan posicionamiento incremental preciso; existen variantes de reluctancia variable, imanes permanentes e híbridos [?].
- **Lineales:** Extienden el principio rotativo a traslación directa, útiles en transportadores y actuadores [?].
- **Universales:** Convierten entre CC y CA con rendimiento variable, comunes en electrodomésticos de bajo coste [?].

Cada tipo de máquina presenta un compromiso distinto entre complejidad del control, coste, densidad de potencia y eficiencia, por lo que la elección depende de la aplicación específica y las exigencias de rendimiento, durabilidad y mantenimiento.

1.1.6. Ventajas de las máquinas eléctricas

- **Alta Eficiencia Energética:** Los motores eléctricos, en especial aquellos diseñados con tecnologías modernas, permiten convertir la energía eléctrica en trabajo mecánico con pérdidas mínimas, lo que optimiza el rendimiento del sistema.
- **Control de Velocidad y Par:** Tanto en motores DC como en algunos tipos de motores AC, es posible ajustar parámetros clave mediante métodos de control avanzado, permitiendo una operación precisa y adaptativa a las variaciones de carga.
- **Bajo Nivel de Ruido y Vibraciones:** Las innovaciones en diseño y materiales han permitido minimizar el ruido y las vibraciones, mejorando la integración de estos sistemas en ambientes sensibles como hospitales y entornos residenciales.
- **Flexibilidad en Aplicaciones:** La diversidad de tipos y configuraciones de motores eléctricos posibilita su aplicación en un amplio rango de industrias, desde la fabricación industrial hasta la robótica y dispositivos portátiles.

1.1.7. Desventajas de las máquinas eléctricas

- **Complejidad en el arranque y control:** Algunos motores, particularmente ciertos motores DC con escobillas, presentan dificultades para generar un par de arranque elevado sin la implementación de sistemas de control adicionales, lo que puede incrementar los costos y la complejidad del sistema.
- **Mantenimiento y desgaste de componentes:** El desgaste de componentes mecánicos, como las escobillas en motores DC, requiere intervenciones de mantenimiento periódico. Además, la dependencia de la calidad de la red eléctrica en motores AC puede influir en la estabilidad operativa.
- **Degradación de componentes electrónicos de potencia.** Constituye un factor crítico que puede afectar significativamente el desempeño y la confiabilidad del sistema electromecánico. Entre los mecanismos de degradación más relevantes se encuentran el envejecimiento térmico de los semiconductores de potencia, el deterioro de las uniones

soldadas, la fatiga por ciclos térmicos. Dichos fenómenos pueden ocasionar variaciones en la eficiencia de conversión energética, incremento en las pérdidas por conducción y conmutación, y mayor susceptibilidad a fallas como cortocircuitos o aperturas intempestivas. Asimismo, la exposición a condiciones ambientales adversas, fluctuaciones de carga y vibraciones mecánicas contribuye a acelerar los procesos de degradación.

- Sensibilidad a factores ambientales: Condiciones como la temperatura, humedad y la presencia de contaminantes pueden afectar el rendimiento y la vida útil de los motores. Por ello, es necesario un diseño adecuado del sistema de refrigeración y protección ambiental [?].
- Costo Inicial y complejidad del control electrónico: La implementación de motores sin escobillas y de sistemas de control avanzado puede implicar una inversión inicial mayor, lo que debe evaluarse frente a los beneficios operativos a largo plazo.

1.1.8. Consideraciones complementarias y recomendaciones

Para lograr una integración exitosa y sostenible de los motores eléctricos en sistemas complejos, se recomienda abordar aspectos complementarios que potencien el rendimiento y prolonguen la vida útil del equipo:

- **Diseño térmico y gestión de calor**

El diseño térmico es fundamental para la eficiencia y seguridad del motor. La implementación de sistemas de refrigeración permite disipar el calor generado durante la operación, previniendo sobrecalentamientos y posibles fallas. Se deben considerar disipadores, ventiladores y, en aplicaciones críticas, sistemas de refrigeración líquida.

- **Sistemas de control y automatización**

El avance en electrónica de potencia y control digital ha permitido desarrollar sistemas de monitoreo en tiempo real que ajustan parámetros operativos de manera automática. La incorporación de convertidores electrónicos, sensores de temperatura y vibración, junto con algoritmos de control predictivo, optimiza el funcionamiento y permite la detección temprana de anomalías.

- **Mantenimiento predictivo y preventivo**

Implementar estrategias de mantenimiento basadas en análisis predictivos y en el monitoreo continuo de variables operativas es esencial para minimizar tiempos de inactividad y reducir costos. La utilización de técnicas como el análisis de vibraciones y el monitoreo de la corriente eléctrica permite anticipar fallas y programar intervenciones de mantenimiento de manera planificada).

- **Innovaciones y tendencias tecnológicas** La investigación actual se orienta hacia la mejora en la eficiencia energética y la reducción de emisiones de los motores eléctricos. Las innovaciones en materiales superconductores, imanes de alta eficiencia y sistemas de inteligencia artificial aplicada al control están abriendo nuevas posibilidades para el diseño de motores más compactos, potentes y ecológicos. Además, la integración de la tecnología (IoT por sus siglas en inglés) permite la conexión de motores a redes inteligentes para una gestión remota y optimizada de los sistemas de producción.

1.2. Motor de corriente directa de imanes permanentes

Los motores de corriente directa sin escobillas (BLDC, por sus siglas en inglés: *Brushless Direct Current*) constituyen una de las tecnologías más relevantes en el campo de las máquinas eléctricas modernas. Su diseño elimina las escobillas mecánicas y el conmutador rotativo, sustituyéndolos por un sistema de conmutación electrónica gobernado por inversores y algoritmos de control. Esto permite una operación más silenciosa, eficiente y duradera que la de los motores tradicionales de corriente directa.



Figura 1.10. Imagen de motor BLDC

1.3. Control de motores BLDC

Los motores BLDC combinan las ventajas de los sistemas de corriente continua y los de corriente alterna, requiriendo una electrónica de potencia para la conmutación de fases. La estructura típica consta de un rotor con imanes permanentes y un estator trifásico alimentado mediante inversor de potencia y estrategia de control adecuada [?],[?].

1.3.1. Modos de conmutación

- **Trapezoidal (seis pasos):** aplica tensión constante a dos devanados y tercer devanado en flotación como se aprecia en la figura ??, generando un par casi constante pero con ondulación de corriente y par (*torque ripple*) que puede alcanzar el 10 % [?].
- **Senoidal:** inyecta corrientes senoidales en cada fase mediante modulación PWM, reduciendo ruido acústico y electromagnético, a cambio de mayor complejidad en la etapa




Figura 1.11. Corrientes derivadas de las lecturas de los sensores de efecto hall a seis pasos

Sensor hall	Paso 1	Paso 2	Paso 3	Paso 4	Paso 5	Paso 6
1	0	1	1	1	0	0 %
2	0	0	0	1	1	1 %
3	1	1	0	0	0	1 %

Tabla 1.1. Configuraciones en conmutación de seis pasos

de control [?]. Las corrientes suministradas a las fases del estator son formas de onda sinusoidales en lugar de impulsos trapezoidales. Este esquema de excitación senoidal se implementa comúnmente mediante modulación sinusoidal por ancho de pulso (SPWM por sus siglas en inglés), permitiendo el control preciso tanto de la amplitud como de la frecuencia de la corriente. A diferencia de la conmutación trapezoidal, la conmutación senoidal demanda mayor capacidad de procesamiento y una estimación de posición más precisa

1.3.2. Modos de control

- **Control vectorial (FOC)** El *Field-Oriented Control* transforma las corrientes trifásicas i_a, i_b, i_c al marco síncrono dq mediante la transformación de ClarkePark, permitiendo regular por separado el flujo (i_d) y el torque (i_q). Esta técnica ofrece alta dinámica y eficiencia superior al 90 % en amplia gama de velocidad [?],[?].
- **Métodos sensorless** Para reducir costes y aumentar fiabilidad se emplean estimadores de posición basados en:
 - Detección de cruces por cero de fuerza contraelectromotriz (Back EMF) [?].
 - Observadores de modo deslizante y filtros de Kalman extendido para estimar velocidad y posición con bajo ruido [?].
- **Control predictivo y DTC** El *Direct Torque Control* y el control predictivo de par modelan la dinámica instantánea de torque y flujo, eligiendo el vector de conmutación óptimo en cada ciclo de PWM para minimizar error y mejorar la respuesta transitoria [?].
- Aspectos de implementación
 - PWM de alta frecuencia para suavizar corrientes y reducir armónicos.
 - Protecciones contra sobrecorriente, sobretensión y fallo de sensor.

-
- Calibración de parámetros de resistencia, inductancia y constante de par para optimizar el lazo de control [?].

Gracias a estas estrategias, los BLDC alcanzan densa potencia específica, respuesta dinámica rápida y alto rendimiento en aplicaciones como vehículos eléctricos, aeronaves no tripuladas y robótica industrial [?, ?].

1.3.3. Modelado del motor BLDC

El modelo dinámico de un motor de imanes permanentes sin escobillas (BLDC) combina las ecuaciones eléctricas de los devanados del estator con las ecuaciones mecánicas del rotor, considerando además la interacción electromecánica a través de la constante de par y la fuerza contraelectromotriz (back EMF).

- Ecuaciones eléctricas

Para cada fase $x \in \{a, b, c\}$ se tiene:

$$v_x(t) = R i_x(t) + L \frac{di_x(t)}{dt} + e_x(t) \quad (1.1)$$

donde v_x es la tensión aplicada, i_x la corriente de fase, R la resistencia y L la inductancia de fase [?]. La back EMF e_x se modela como:

$$e_x(t) = K_e \omega(t) f_x(\theta(t)) \quad (1.2)$$

siendo K_e la constante de fuerza contraelectromotriz, ω la velocidad angular y $f_x(\theta)$ la función de onda (trapezoidal o senoidal) según la estrategia de conmutación [?].

- Ecuación de par y dinámica mecánica

El par electromagnético instantáneo viene dado por:

$$T_e(t) = K_t \sum_{x \in \{a, b, c\}} i_x(t) g_x(\theta(t)) \quad (1.3)$$

donde K_t es la constante de par y $g_x(\theta)$ representa la forma de interacción magnética conmutada [?]. La dinámica rotor carga se describe como:

$$J \frac{d\omega(t)}{dt} + B \omega(t) = T_e(t) - T_{\text{load}}(t) \quad (1.4)$$

con J inercia, B coeficiente de fricción viscosa y T_{load} par de carga.

- Representación en espacio de estados Definiendo el vector de estados

$$\mathbf{x}(t) = \begin{bmatrix} i_a(t) \\ i_b(t) \\ i_c(t) \\ \omega(t) \end{bmatrix}, \quad \mathbf{u}(t) = \begin{bmatrix} v_a(t) \\ v_b(t) \\ v_c(t) \\ T_{\text{load}}(t) \end{bmatrix},$$

las ecuaciones pueden expresarse en forma:

$$\dot{\mathbf{x}}(t) = \mathbf{A}(\theta) \mathbf{x}(t) + \mathbf{B}(\theta) \mathbf{u}(t), \quad y(t) = \mathbf{C} \mathbf{x}(t).$$

donde las matrices $\mathbf{A}(\theta)$ y $\mathbf{B}(\theta)$ dependen de la posición angular y las funciones de conmutación [?, ?].

1.3.4. Ventajas de un motor BLDC

- **Eficiencia Energética Superior:** La eliminación de componentes mecánicos de conmutación y el uso de imanes permanentes optimizan la conversión de energía, lo que resulta en un mayor rendimiento [?].
- **Bajo mantenimiento:** Al no requerir escobillas ni conmutadores mecánicos, los BLDC reducen significativamente la necesidad de mantenimiento, lo que se traduce en menores costos operativos a largo plazo.
- **Precisión y control dinámico:** Los sistemas electrónicos avanzados permiten un control preciso del par y la velocidad, adaptándose rápidamente a cambios en la carga, lo que es vital en aplicaciones de alta precisión.
- **Diseño compacto y ligero:** La alta densidad de potencia posibilita la construcción de motores compactos y ligeros, ideales para aplicaciones en movilidad eléctrica y sistemas portátiles.

1.3.5. Desventajas de un motor BLDC

- **Complejidad del sistema de control:** La necesidad de controladores electrónicos avanzados puede aumentar la complejidad y el costo inicial del sistema.
- **Sensibilidad térmica:** Aunque se implementen estrategias de gestión térmica, el motor BLDC puede enfrentar desafíos en entornos de alta carga térmica, requiriendo soluciones específicas para evitar el sobrecalentamiento.
- **Limitaciones en técnicas sin sensores:** Los métodos sensorless, si bien reducen la cantidad de componentes, pueden ofrecer menor precisión en el control durante el arranque o a bajas velocidades, lo cual demanda algoritmos de control más sofisticados.

1.4. Aplicaciones y perspectivas futuras de un motor BLDC

El motor BLDC se utiliza en diversos sectores gracias a sus características superiores:

- Movilidad eléctrica: Su alta eficiencia y diseño compacto lo convierten en la opción preferida para vehículos eléctricos, donde la optimización del consumo energético es fundamental [?].
- Robótica y drones: La precisión en el control y la alta densidad de potencia hacen que los BLDC sean ideales para aplicaciones en robótica y vehículos aéreos no tripulados.
- Electrodomésticos y climatización: La operación silenciosa y la eficiencia energética favorecen su aplicación en sistemas de climatización y dispositivos que requieren funcionamiento continuo.
- Automatización industrial: La rápida respuesta y la estabilidad operativa mejoran la productividad en procesos industriales automatizados, constituyendo un elemento clave en la modernización de las líneas de producción.



Figura 1.12. Aplicación de motor BLDC

1.5. Detección de fallas en motores BLDC

La creciente adopción de estos motores en aplicaciones críticas —como vehículos eléctricos, drones, sistemas aeroespaciales y robots de alta precisión— ha intensificado el interés por desarrollar estrategias de detección de fallas robustas. Un fallo inesperado en este tipo de motores no sólo representa un riesgo económico, sino también de seguridad, lo que convierte la monitorización y el diagnóstico en factores determinantes.

En el contexto de los sistemas eléctricos y electromecánicos, una *falla* se define como cualquier desviación o anomalía en el funcionamiento de un componente o conjunto de componentes que impide el desempeño adecuado de su función prevista [?]. Otra definición es: desviación no permitida en los parámetros del proceso [?]. Dichas desviaciones pueden originarse por causas eléctricas, mecánicas, térmicas o ambientales, y pueden manifestarse de manera gradual o repentina [?]. Desde una perspectiva técnica, la falla representa una transición del estado operativo normal a un estado degradado o de indisponibilidad parcial o total del sistema [?].

El estudio de las fallas resulta de vital importancia en el análisis y diagnóstico de motores eléctricos, ya que permite implementar estrategias de mantenimiento predictivo y sistemas de detección temprana que evitan paros no programados y pérdidas económicas significativas [?]. En este sentido, la detección de fallas se enfoca en identificar patrones anómalos en señales eléctricas o vibratorias que indiquen un comportamiento distinto al esperado bajo condiciones normales de operación [?].

1.5.1. Tipos de fallas en motores BLDC

El estudio de los modos de falla en motores BLDC es amplio y multidisciplinario. Cada componente del motor está expuesto a fenómenos de deterioro que, si no son identificados a tiempo, pueden desencadenar un fallo crítico. Las fallas pueden clasificarse según distintos criterios, entre los cuales destacan su naturaleza, su evolución temporal y su localización en el sistema.

- **Según su naturaleza:** Las fallas se dividen en *eléctricas* y *mecánicas*. Las fallas eléctricas incluyen cortocircuitos, aperturas de bobinado, desequilibrios de tensión o corriente, y defectos en el aislamiento [?]. Las fallas mecánicas, por otro lado, se relacionan con problemas en los cojinetes, desalineaciones, excentricidades o desgastes en el rotor [?].
- **Según su evolución:** Se distinguen *fallas incipientes* y *fallas abruptas*. Las fallas incipientes se desarrollan de manera progresiva y pueden detectarse mediante análisis

espectral o técnicas de inteligencia artificial antes de ocasionar daños mayores. Las fallas abruptas, en cambio, se presentan de forma instantánea y suelen provocar la detención inmediata del sistema [?].

- **Según su localización:** En motores eléctricos, las fallas se clasifican en *fallas en el estator*, *fallas en el rotor*, y *fallas en los cojinetes o rodamientos*. Las fallas en el estator suelen deberse a cortocircuitos entre espiras o fases; las fallas en el rotor se asocian a barras rotas o anillos defectuosos; y las fallas en los cojinetes representan una de las causas más comunes de vibración y ruido excesivo [?, ?].

En el marco de la detección de fallas en motores eléctricos, es fundamental considerar la evolución temporal de los parámetros eléctricos, la firma espectral de las corrientes y el comportamiento dinámico del sistema para identificar el tipo y la severidad de la falla [?, ?]. Este análisis constituye la base para el diseño de algoritmos avanzados de diagnóstico basados en técnicas de análisis de señales y aprendizaje automático.

Fallas en el estator

El estator alberga los devanados encargados de producir el campo magnético giratorio. Una de las fallas más frecuentes en esta parte es el cortocircuito entre espiras, donde el aislamiento dieléctrico que recubre los conductores se degrada, generando un camino de baja impedancia. Este tipo de falla se inicia normalmente como un defecto incipiente —microfisuras, contaminación por humedad, o deterioro térmico— que, con el tiempo, desemboca en un cortocircuito total. El fenómeno se agrava bajo condiciones de sobrecarga y ambientes de alta temperatura. Los síntomas comunes son un incremento abrupto de las corrientes de fase, pérdida de simetría en el campo magnético, generación de par pulsante y elevación de la temperatura localizada.

Otro modo de falla frecuente es la degradación del aislamiento, la cual no siempre desemboca en un cortocircuito inmediato, pero reduce la resistencia de aislamiento a tierra, incrementando las corrientes de fuga. Esto acelera el envejecimiento del motor, incrementa las pérdidas y puede inducir resonancias térmicas peligrosas. Según estudios industriales, los fallos en devanados representan alrededor del 30–40 % de las averías reportadas en motores BLDC empleados en aplicaciones de uso continuo, especialmente en la industria automotriz.

Fallas en el rotor

El rotor de un motor BLDC contiene imanes permanentes que son responsables de mantener el flujo magnético necesario para la conmutación. La falla más crítica es la desmagnetización, que puede ser parcial o total. Una desmagnetización parcial reduce la densidad

de flujo, disminuyendo el par disponible y la eficiencia; mientras que una desmagnetización total puede impedir el arranque del motor. Entre las causas principales se encuentran las sobrecorrientes, la exposición a altas temperaturas superiores a la temperatura de Curie de los imanes, y el envejecimiento del material magnético.

Otro modo de falla importante es el desprendimiento o desplazamiento de imanes. Dado que estos elementos están fijados con adhesivos o mediante encajes mecánicos, vibraciones prolongadas, choques mecánicos o un mal diseño térmico pueden ocasionar que se desplacen, provocando un entrehierro no uniforme. Esto genera vibraciones, ruidos acústicos, desbalance del par y, en ocasiones, daños estructurales severos.

Fallas en rodamientos

Los rodamientos son considerados uno de los puntos más críticos en motores BLDC, y diversos estudios estiman que entre el 40–50 % de las fallas mecánicas provienen de este componente. Los defectos pueden deberse a lubricación insuficiente, contaminación con partículas sólidas, corrosión, desalineación o fatiga de contacto. Un rodamiento defectuoso se manifiesta inicialmente como vibraciones de alta frecuencia, que luego se propagan al resto de la máquina, afectando incluso la corriente consumida por el motor. La progresión de la falla suele ser rápida, pasando de un desgaste leve a una fractura de elementos rodantes, lo que puede dejar el motor completamente inoperativo.

El diagnóstico de fallas en rodamientos es un área de investigación muy activa. Se han propuesto métodos basados en el análisis de vibraciones, en el espectro de corriente del estator e incluso en la monitorización de emisiones acústicas. La ventaja de estos enfoques es que permiten detectar defectos incipientes, anticipando paradas imprevistas.

Fallas en la electrónica de potencia

Los controladores electrónicos y la etapa de potencia representan otro punto vulnerable en motores BLDC. El uso de dispositivos semiconductores como MOSFET o IGBT los hace susceptibles a picos de tensión, sobrecalentamientos o transitorios de conmutación. Una falla en el inversor provoca asimetría en las tensiones aplicadas, lo que deriva en un funcionamiento irregular y una degradación prematura del motor. Además, fallas en los sensores de posición (como sensores Hall u observadores electromagnéticos) producen errores de conmutación que afectan directamente el control del par y la velocidad.

Se estima que en aplicaciones de vehículos eléctricos, alrededor de un 20 % de los incidentes reportados en motores BLDC no provienen del motor en sí, sino de la electrónica asociada. Esto pone de manifiesto la necesidad de incluir sistemas de diagnóstico que supervisen tanto el motor como el controlador.

Fallas mecánicas adicionales

Adicionalmente, los motores BLDC pueden sufrir desbalance del rotor, causado por defectos de fabricación, acumulación de material en un lado del rotor o daños estructurales. El desbalance genera vibraciones excesivas y aumenta el desgaste de rodamientos y acoplamientos. La desalineación del eje es otra fuente común de problemas, especialmente cuando el motor está acoplado a transmisiones mecánicas. Esta condición incrementa las fuerzas radiales, acelera la fatiga del eje y eleva el consumo energético. El diagnóstico temprano de estas fallas es fundamental, ya que su combinación con defectos eléctricos produce fallos mixtos de difícil identificación.




Figura 1.13. Porcentaje de fallas por componente

1.5.2. Técnicas comunmente utilizadas

La detección temprana de fallas en motores eléctricos constituye un aspecto esencial para garantizar la continuidad operativa, mejorar la eficiencia energética y reducir costos de mantenimiento en sistemas industriales. Las fallas pueden originarse por defectos en el estator, rotor, cojinetes, sistema de aislamiento, suministro eléctrico o componentes electrónicos de potencia asociados. En la literatura técnica se han desarrollado diversos métodos para identificar dichas fallas, los cuales pueden clasificarse en enfoques basados en señales, modelos matemáticos y algoritmos de inteligencia computacional [?].

- **Análisis de firma de corriente del motor**

El método MCSA (Motor Current Signature Analysis) es una de las técnicas más empleadas debido a su naturaleza no invasiva y a la facilidad para acceder a las señales de corriente sin modificar el sistema. Este procedimiento examina componentes espectrales específicos asociados a fallas comunes tales como rotores en cortocircuito, desbalance de fases o excentricidad mecánica. Las frecuencias características proporcionan información directa sobre la naturaleza y severidad de la falla [?]. La señal de corriente se analiza mediante herramientas como la Transformada Rápida de Fourier (FFT), Transformada Wavelet (WT) y técnicas de filtrado adaptativo.

- **Análisis vibracional**

El análisis de vibraciones constituye un método eficaz en la detección de fallas mecánicas, incluyendo desgaste de rodamientos, desalineación, desequilibrios y holguras mecánicas. Las mediciones se obtienen mediante acelerómetros o sensores piezoeléctricos ubicados en los puntos críticos de soporte mecánico. El espectro de vibración revela patrones característicos que permiten identificar la falla, especialmente cuando se emplean técnicas de dominio tiempo-frecuencia como la transformada wavelet continua y la descomposición empírica en modos (Empirical Mode Decomposition, EMD) [?].

- **Análisis termográfico**

La termografía infrarroja constituye una herramienta no invasiva capaz de identificar anomalías térmicas asociadas con pérdidas excesivas, sobrecalentamiento de bobinados, fricción en rodamientos y fallas en componentes electrónicos de potencia. Este método permite evaluar el estado operativo sin interrumpir el funcionamiento del motor, proporcionando mapas térmicos que evidencian desviaciones respecto al comportamiento

térmico normal [?]. El análisis térmico predictivo es ampliamente utilizado en mantenimiento industrial preventivo.

- Métodos basados en modelos

Los métodos basados en modelos matemáticos comparan el comportamiento real del motor con su modelo teórico para detectar desviaciones atribuibles a fallas. En motores de inducción, modelos de circuito equivalente y modelos en espacio de estados son frecuentemente utilizados para estimar parámetros como resistencia del rotor, inductancias o flujo magnético [?]. Las discrepancias entre variables medidas y estimadas constituyen indicadores de deterioro o falla incipiente. Este enfoque encuentra aplicación en esquemas avanzados de control sensorless y diagnóstico en línea.

- Algoritmos de inteligencia artificial y aprendizaje automático

En los últimos años, el empleo de algoritmos de inteligencia artificial ha revolucionado el diagnóstico de fallas en maquinaria eléctrica. Técnicas como Redes Neuronales Artificiales (ANN), Máquinas de Vectores de Soporte (SVM), Random Forest, y métodos basados en deep learning han sido ampliamente investigados para clasificar condiciones operativas del motor a partir de características extraídas de señales eléctricas, vibracionales y térmicas. Estos métodos presentan alta capacidad de generalización y son particularmente efectivos en ambientes industriales con ruido o incertidumbre operacional [?].

- Análisis de Campo Magnético

Otra estrategia consiste en el monitoreo del campo magnético circundante al motor mediante sensores de efecto Hall o sondas de flujo. Cambios en los patrones magnéticos reflejan fallas en devanados, excentricidad rotórica, o daños en imanes permanentes. Este enfoque resulta ventajoso cuando se pretende evitar intervenciones directas en el circuito eléctrico [?].

La detección de fallas en motores BLDC es un campo en constante evolución. Mientras que las técnicas tradicionales siguen siendo de utilidad, los avances en inteligencia artificial, análisis tiempo-frecuencia e IoT están permitiendo sistemas de diagnóstico cada vez más precisos, autónomos y predictivos. La tendencia futura apunta hacia máquinas inteligentes capaces de autodiagnosticarse y de interactuar con sistemas de gestión en entornos industriales altamente automatizados.

1.6. Organización de la tesis

Para terminar el capítulo, se presenta la organización del trabajo de tesis a manera de resumen.

- Capítulo 1: En esta sección se presenta la introducción del trabajo de tesis; la teoría de los motores eléctricos, centrándonos en motores BLDC, su modelo dinámico, ventajas y desventajas. También, se presenta de manera general el principio del diagnóstico de fallas en específico para motores eléctricos.
- Capítulo 2: Se presenta la metodología a seguir, las diferentes técnicas de diagnóstico de fallas que se implementaron, así como la base matemática de herramientas de análisis espectral utilizadas. También, se presentan los principios de redes neuronales como estructura y componentes.
- Capítulo 3: En este capítulo del trabajo de tesis se presentan los resultados obtenidos, que se dividen de la siguiente forma:
 - Señales obtenidas del banco de pruebas
 - Resultados de diferentes técnicas de análisis espectral a manera de comparativa, para, de manera visual, tener noción de las características o detalles que resaltan diferentes análisis como la FFT, odeletas y módulo ISP
 - Resultados de ingresar los datos procesados como entrenamiento a diferentes estructuras con distintos parámetros de redes neuronales
- Capítulo 4: Por último se presentan las conclusiones generales del trabajo realizado, las oportunidades de mejora a futuro y las recomendaciones.

Capítulo 2

Metodología.

La creciente adopción de motores eléctricos sin escobillas de corriente continua (BLDC) en aplicaciones industriales, vehiculares y aeroespaciales ha impulsado el desarrollo de metodologías de diagnóstico más precisas y robustas. Los motores BLDC se caracterizan por su alta eficiencia, bajo mantenimiento, gran densidad de potencia y buena respuesta dinámica. No obstante, como cualquier equipo electromecánico, están expuestos a condiciones de falla debidas al envejecimiento, esfuerzos mecánicos, problemas de aislamiento, desequilibrio o variaciones en la alimentación eléctrica.

La detección de fallas tempranas no sólo evita paros no programados, sino que también permite optimizar el mantenimiento predictivo y alargar la vida útil de los motores. Entre las técnicas más prometedoras se encuentran el análisis espectral y la inteligencia artificial. El primero permite identificar patrones anómalos en la frecuencia de la señal, mientras que las redes neuronales facilitan la clasificación y predicción automática de estados de operación. Este capítulo explora en profundidad ambas técnicas y su sinergia en el contexto del diagnóstico de fallas en motores BLDC.

2.1. Fundamentos del análisis espectral

El análisis espectral constituye una herramienta fundamental en el estudio y diagnóstico de sistemas eléctricos rotatorios, especialmente en la detección de fallas en motores eléctricos. Su objetivo principal es descomponer una señal compleja en sus componentes frecuenciales, permitiendo identificar patrones característicos asociados al comportamiento dinámico del sistema [?]. A través de este procedimiento, es posible determinar la distribución de energía de una señal en el dominio de la frecuencia y reconocer la presencia de armónicos, subarmónicos o modulaciones que evidencian condiciones anómalas [?].

En el caso particular de los motores eléctricos, las fallas de tipo eléctrico o mecánico suelen manifestarse mediante variaciones en la amplitud o en la frecuencia de las señales de corriente, tensión o vibración. Por ello, el análisis espectral permite revelar estas desviaciones y facilitar su correlación con el tipo de defecto existente [?]. Entre las técnicas más empleadas se encuentran la Transformada Rápida de Fourier (FFT), la Transformada de Hilbert, la Transformada de Wavelet y el análisis espectrograma, cada una con ventajas particulares en la detección de patrones transitorios o estacionarios [?, ?].

2.1.1. Transformada Rápida de Fourier (FFT)

La FFT (Fast Fourier Transform) es un algoritmo que permite calcular la transformada discreta de Fourier de manera eficiente, reduciendo la complejidad computacional de N^2 a $N\log(N)$. Esto la convierte en una herramienta indispensable para analizar la composición frecuencial de una señal.

En el contexto de los motores BLDC, los armónicos generados por defectos mecánicos o eléctricos aparecen como componentes adicionales o atípicas en el espectro de frecuencia. Por ejemplo, un desequilibrio en el rotor puede generar una componente en la frecuencia de rotación (frecuencia sub-síncrona), mientras que un corto entre espiras puede provocar una distorsión espectral característica en los armónicos de corriente [?]. La FFT permite cuantificar estas componentes y extraer características como la magnitud, la frecuencia dominante, la energía en bandas específicas y el contenido armónico total.

Es común aplicar la FFT en ventanas segmentadas de la señal para obtener una resolución temporal, lo que se conoce como análisis espectral de ventana corta. En motores eléctricos, se ha demostrado que el seguimiento de la evolución de los armónicos en el tiempo permite identificar fallas progresivas [?].

$$X_k = \sum_{n=0}^{N-1} x_n e^{-j\frac{2\pi}{N}kn}, \quad k = 0, 1, \dots, N-1 \quad (2.1)$$

2.1.2. Análisis en bandas de frecuencia

El análisis en bandas de frecuencia consiste en segmentar el espectro resultante de la FFT en intervalos de interés (por ejemplo, bandas de 0-7 Hz, 8-15 Hz, etc.) y calcular medidas como el valor RMS, la energía total o el contenido porcentual. Cada banda puede relacionarse con diferentes tipos de fallas. Por ejemplo:

0-20 Hz: desbalance mecánico y defectos en cojinetes

20-60 Hz: armónicos de alimentación y errores de conmutación

100 Hz: ruido e interferencias

Este tipo de análisis ha sido utilizado para construir vectores de características robustos para clasificadores automáticos [?].

2.1.3. Transformada de fourier de tiempo corto (STFT) y espectrogramas

La STFT (Short-Time Fourier Transform) mejora la FFT tradicional al permitir el análisis de señales no estacionarias. Al aplicar una ventana móvil sobre la señal temporal, la STFT permite visualizar los cambios en el espectro de frecuencia a lo largo del tiempo, dando lugar al espectrograma. Esta herramienta es particularmente valiosa para detectar fallas transitorias, que se manifiestan durante cortos periodos. Los espectrogramas ofrecen una representación visual en 3D (tiempo, frecuencia, magnitud), que puede ser utilizada como entrada para redes neuronales convolucionales. En el caso de motores BLDC, eventos como arcos eléctricos, pulsos de alta frecuencia o conmutaciones defectuosas aparecen como patrones de alta energía localizados en el tiempo [?].

2.1.4. Transformada ondeleta discreta

La DWT por sus siglas en inglés permite representar una señal mediante una combinación de funciones llamadas wavelets, que están localizadas tanto en el tiempo como en la frecuencia. A diferencia de la FFT, la DWT proporciona una descomposición jerárquica en diferentes escalas de resolución.

El análisis con ondeletas constituye un marco matemático multirresolución idóneo para caracterizar fenómenos transitorios, no estacionarios y de banda ancha, comunes en las señales asociadas a fallas de máquinas eléctricas (corriente de línea, tensión, vibración, flujo magnético, emisiones acústicas). A diferencia de la FFT, que ofrece resolución uniforme en frecuencia, la transformada wavelet provee resolución dependiente de la escala, permitiendo

descubrir firmas de falla que se manifiestan como eventos localizados en tiempo y frecuencia [?],[?].

El principio central de la DWT consiste en representar una señal discreta $x[n]$ mediante un conjunto de funciones base obtenidas por traslación y escala de una ondeleta madre $\psi(t)$ y una función de escala $\phi(t)$. La señal se descompone en coeficientes de aproximación $a_j[k]$ y coeficientes de detalle $d_j[k]$ mediante bancos de filtros digitales:

$$a_{j+1}[k] = \sum_{n=-\infty}^{\infty} a_j[n] h[n - 2k], \quad d_{j+1}[k] = \sum_{n=-\infty}^{\infty} a_j[n] g[n - 2k],$$

donde $h[n]$ y $g[n]$ representan los coeficientes de los filtros pasa bajas y pasa altas respectivamente. Esta estructura permite que el algoritmo de Mallat reduzca la complejidad computacional a $O(N)$, favoreciendo su implementación en sistemas embebidos de monitoreo en línea [?].

2.1.5. Selección de la ondeleta madre y niveles de descomposición

La adecuada selección de la ondeleta madre es un aspecto crucial para el diagnóstico de fallas en motores. Ondeletas como Daubechies, Symlets y Coiflets presentan un elevado número de momentos de anulación, lo cual permite capturar singularidades y cambios abruptos en la señal, característicos de defectos mecánicos y eléctricos. Adicionalmente, el número de niveles de descomposición J se determina de acuerdo con la frecuencia de muestreo del sistema y el rango espectral donde se manifiestan las fallas. Para fallas en rodamientos y barras rotóricas, por ejemplo, niveles de descomposición entre 4 y 7 suelen ser adecuados [?].

2.1.6. Extracción de características para diagnóstico de fallas

Una vez obtenidos los coeficientes $\{a_J, d_1, d_2, \dots, d_J\}$, la detección de fallas se realiza mediante la extracción de variables descriptivas de la señal, tales como:

- Energía de niveles wavelet:

$$E_{d_j} = \sum_k |d_j[k]|^2$$

- Valores RMS y varianza por banda
- Curtosis y asimetría para caracterizar impulsividad
- Entropía de Shannon para cuantificar complejidad señal
- Relación de energía entre bandas para detectar severidad de falla

Estas características se integran posteriormente a clasificadores estadísticos o modelos de inteligencia artificial, tales como máquinas de soporte vectorial o redes neuronales, permitiendo la clasificación automática de condiciones normales y defectuosas en motores eléctricos [?].

La transformada wavelet se ha usado exitosamente para detectar fallas en los devanados del estator, cortocircuitos intervuelas y asimetrías de fase. Funciones como Haar y Daubechies son populares debido a su simplicidad y capacidad de detección de eventos abruptos [?]. Se pueden calcular los valores RMS o energías por nivel de descomposición, obteniendo un vector de características adecuado para clasificadores.

2.1.7. Ondeleta Haar

$$a_k = \frac{x[2k] + x[2k + 1]}{\sqrt{2}} \quad (2.2)$$

$$d_k = \frac{x[2k] - x[2k + 1]}{\sqrt{2}} \quad (2.3)$$

2.1.8. Ondeleta daubechies 4

$$a_k^{(j+1)} = \sum_n h_n \cdot a_{2k+n}^{(j)} \quad (2.4)$$

$$d_k^{(j+1)} = \sum_n g_n \cdot a_{2k+n}^{(j)} \quad (2.5)$$

La DWT ha demostrado eficacia en la detección temprana de diversas fallas en máquinas eléctricas, entre ellas:

1. **Fallas en rodamientos:** la DWT resalta eventos impulsivos asociados a defectos en pistas o elementos rodantes, facilitando su identificación incluso en presencia de ruido industrial.
2. **Barras rotóricas fracturadas:** la modulación en la corriente y vibración del motor genera componentes de baja frecuencia que la DWT separa eficazmente.
3. **Fallas en el estator:** cortocircuitos entre espiras y desequilibrio magnético producen patrones transitorios capturados en niveles medios y altos de la descomposición wavelet.
4. **Excentricidad y desalineación mecánica:** la DWT mejora la discriminación de componentes periódicas que no son evidentes en el espectro de frecuencia estático.

2.1.9. Ventajas y consideraciones de implementación

La DWT ofrece ventajas significativas, tales como mayor sensibilidad a fallas incipientes, robustez frente a ruido, y menor costo computacional comparado con otras técnicas tiempo-frecuencia. Sin embargo, su desempeño depende de la correcta selección de la ondeleta madre y del número de niveles, así como de una adecuada etapa de preprocesamiento y normalización de la señal.

2.2. Redes neuronales aplicadas al diagnóstico de fallas

La inteligencia artificial ha transformado el mantenimiento industrial, permitiendo la automatización de diagnósticos y la predicción de fallas. En particular, las redes neuronales artificiales (ANN) permiten modelar relaciones no lineales y extraer patrones complejos en datos multidimensionales. En motores BLDC, las ANN pueden ser entrenadas con datos espectrales o temporales para aprender a distinguir entre condiciones normales y defectuosas. Esta clasificación automática reduce la dependencia de expertos humanos y mejora la escalabilidad del mantenimiento [?].

El diagnóstico de fallas en motores eléctricos mediante redes neuronales (RN) se fundamenta en la extracción y modelado de patrones discriminativos presentes en señales eléctricas, vibracionales, térmicas y/o magnéticas. Frente a métodos lineales o puramente espectrales, las RN capturan relaciones no lineales y dependencias de orden superior, robusteciendo la detección de fallas incipientes en condiciones de operación variables. En general, el flujo de trabajo comprende: (i) adquisición y sincronización multimodal (corriente, tensión, vibración, temperatura, flujo), (ii) preprocesado (filtrado, normalización, segmentación, *order tracking*), (iii) ingeniería de características o representaciones aprendidas (espectros/escagramas), (iv) clasificación con RN y (v) validación cruzada con estratificación por carga y velocidad [?].

2.2.1. Modalidades de entrada y preprocesado

Las RN pueden consumir directamente series temporales $x(t)$ (1D), mapas tiempo-frecuencia $X(\tau, f)$ (2D, p.ej., STFT/escagramas), o vectores de características ingenierizadas (RMS por bandas, entropías, energías wavelet, curtosis). El preprocesado incluye eliminación de tendencia, normalización z -score, sincronización con velocidad y etiquetado cuidadoso por régimen. En escenarios ruidosos, se recomienda denoising (p.ej., wavelet con umbral suave) y *data balancing* (submuestreo/ponderación de clases).

2.2.2. Arquitecturas típicas

2.2.2.0.1. Perceptrón multicapa (MLP). Opera sobre vectores de características $\mathbf{z} \in \mathbb{R}^d$ (por ejemplo, energías por banda). Cada capa oculta aplica $\phi(\mathbf{W}\mathbf{h} + \mathbf{b})$ con ϕ no lineal (ReLU/tanh). Es eficaz cuando la ingeniería de características es informativa [?].

2.2.2.0.2. Redes convolucionales (CNN). Para series 1D, una convolución con kernel $w[k]$ implementa

$$y[n] = \sum_{k=0}^{K-1} w[k] x[n-k],$$

aprendiendo detectores de motivos locales (armónicos, impulsos). Para mapas 2D $X(\tau, f)$, las CNN capturan texturas tiempo–frecuencia asociadas a firmas de falla (bandas laterales, modulaciones). Las CNN son apropiadas cuando se trabaja con STFT/escagramas o paquetes de wavelet [?].

2.2.2.0.3. Redes recurrentes (RNN/LSTM/GRU). Modelan dependencias de largo plazo y variaciones lentas debidas a carga/velocidad. La LSTM mitiga gradientes desvanecientes mediante compuertas, resultando adecuada para secuencias largas de estado estacionario y transitorios de arranque.

2.2.2.0.4. Híbridas y profundas. Esquemas CNN+LSTM procesan primero patrones locales y luego su dinámica; *autoencoders* apilados aprenden representaciones invariantes al ruido; la atención/transformers facilitan selección adaptativa de regiones tiempo–frecuencia relevantes [?, ?].

2.2.3. Aprendizaje, funciones de pérdida y desequilibrio

En clasificación multiclase con *softmax*, para logits $\mathbf{o} \in \mathbb{R}^C$ y salida $p_c = \exp(o_c) / \sum_j \exp(o_j)$, la pérdida de entropía cruzada con ponderación por clase w_c es

$$\mathcal{L} = - \sum_{i=1}^N \sum_{c=1}^C w_c y_{i,c} \log p_{i,c},$$

con $w_c \propto 1/\text{freq}(c)$ para mitigar el desbalance. La regularización (L2, *dropout*) y la *early stopping* previenen sobreajuste; la validación cruzada estratificada por régimen operacional asegura generalización.

2.2.4. Representaciones: ingenierizadas vs aprendidas

2.2.4.0.1. Ingenierizadas. Conjuntos basados en física: MCSA (bandas laterales), energías por banda (FFT/WPD), entropías, estadísticos de impulsividad y métricas de asimetría. Estas se alimentan a MLP/SVM, reduciendo complejidad y datos requeridos [?, ?].

2.2.4.0.2. Aprendidas. CNN sobre STFT/escagramas o sobre tensores de paquetes de wavelet para evitar selección manual de bandas; autoencoders para detección no supervisada (anomalías); modelos con atención para focalizar regiones discriminativas [?].

2.2.5. Estrategias de entrenamiento y evaluación

Se recomiendan particiones por *maquina/instalación* (no sólo por ventana), para evaluar transferencia entre equipos. Métricas: exactitud, matriz de confusión, F1 por clase, AUC y curva PR (robusta a desbalance). La calibración de probabilidades (*temperature scaling*) mejora la toma de decisiones basada en umbrales. En despliegue, *moving windows* y votación temporal estabilizan predicciones.

2.2.6. Casos representativos en motores

2.2.6.0.1. Rodamientos. CNN sobre mapas tiempo–frecuencia y/o energías WPD logran alta sensibilidad a impulsos modulados; autoencoders de ruido reducen falsas alarmas bajo variabilidad de carga [?, ?].

2.2.6.0.2. Rotor (barras rotas) y estator. Características MCSA (bandas laterales) combinadas con MLP/CNN permiten robustez ante *slip* variable; enfoques híbridos integran la información de vector de Park como canal adicional [?, ?].

2.2.6.0.3. Excentricidad y desalineación. Fusión multimodal (vibración+corriente) en CNN 2D/3D mejora separabilidad bajo ruido estructural y resonancias.

2.2.7. Despliegue, interpretabilidad y confiabilidad

Para entorno industrial, se recomiendan: (i) cuantización/poda para ejecución en borde, (ii) monitorización de deriva de datos, (iii) explicabilidad con mapas de saliencia o *Grad-CAM* sobre STFT, (iv) umbrales adaptativos por régimen y (v) aprendizaje continuo con revisión humana. La trazabilidad de señal y metadatos (carga, velocidad, temperatura) es crucial para auditar decisiones del modelo.

2.2.8. Arquitectura de redes neuronales artificiales (ANN)

Las *estructuras* de redes neuronales (RN) abarcan desde arquitecturas *feedforward* clásicas hasta modelos profundos con conexiones residuales, mecanismos de atención y operadores sobre grafos. Su elección condiciona la capacidad de aproximación, la eficiencia del entrenamiento y la robustez frente a ruido y a variaciones de dominio. A nivel general, una RN define una aplicación paramétrica $\mathcal{F}_{\Theta} : \mathbb{R}^d \rightarrow \mathbb{R}^C$ compuesta por capas $\mathbf{h}^{(\ell)} = \phi^{(\ell)}(\mathbf{W}^{(\ell)}\mathbf{h}^{(\ell-1)} + \mathbf{b}^{(\ell)})$, donde $\phi^{(\ell)}$ es una no linealidad (p.ej., ReLU), y el ajuste de parámetros $\Theta = \{\mathbf{W}^{(\ell)}, \mathbf{b}^{(\ell)}\}$ se realiza por *backpropagation* y descenso estocástico.

2.2.9. Perceptrón multicapa (MLP) y propiedades universales

El MLP es una RN *feedforward* con capas densas que aproximan funciones continuas en compactos bajo condiciones suaves de activación (*universal approximation*). En práctica, varias capas ocultas de tamaño moderado, activaciones no saturantes (ReLU) y normalización adecuada proporcionan un compromiso favorable entre capacidad y generalización. Resulta especialmente eficaz con vectores de características ingenierizadas (*handcrafted*) y en problemas con entradas tabulares, donde la estructura local (espacial/temporal) es limitada.




Figura 2.1. Estructura básica de una red neuronal

2.2.10. Redes convolucionales (CNN)

El uso de CNN ha sido validado para clasificación de fallas en motores, con precisiones superiores al 95 % cuando se entrenan con conjuntos de datos bien etiquetados y balanceados [?].

Las CNN explotan *invariancia traslacional y conectividad local*. Una convolución 1D/2D aplica

$$y[i] = \sum_k w[k] x[i - k], \quad Y[u, v] = \sum_{m, n} W[m, n] X[u - m, v - n],$$

aprendiendo detectores de motivos (texturas, transiciones, impulsos). Diseños clásicos y profundos incluyen:

- VGG: pilas de filtros 3×3 con profundidad creciente y simplicidad estructural.
- Inception: *bloques* de múltiples anchos de filtro en paralelo para capturar escalas diversas.
- ResNet: conexiones residuales que aprenden $F(\mathbf{x}) = \mathcal{H}(\mathbf{x}) - \mathbf{x}$ y facilitan el entrenamiento profundo.
- DenseNet: conexiones densas que concatenan mapas de características inter-capas, fomentando la reutilización de representaciones.

En señales 1D (corriente, vibración), las CNN 1D capturan patrones locales, modulaciones y armónicos; en mapas tiempo–frecuencia, las CNN 2D modelan firmas distribuidas (bandas laterales, crestas de energía).

2.2.11. Redes recurrentes (RNN), LSTM y GRU

Las RNN modelan dependencias temporales mediante estados ocultos. Las variantes con compuertas (LSTM/GRU) mitigan gradientes desvanecientes y son idóneas para secuencias largas con dinámicas multiescala. Una celda GRU, por ejemplo, combina compuertas de actualización y reinicio para controlar la mezcla entre estado previo y nuevo candidato. Las RNN pueden apilarse o combinarse con CNN (CNN+LSTM) para capturar primero patrones locales y posteriormente su dinámica global.

Las redes LSTM (Long Short-Term Memory) están diseñadas para modelar dependencias temporales en series de datos. Esto las hace particularmente adecuadas para detectar la evolución de una falla incipiente. Cada unidad LSTM puede recordar información relevante durante intervalos largos, superando las limitaciones de las redes recurrentes tradicionales (RNN). En motores BLDC, una LSTM puede entrenarse para predecir la condición futura del motor o para identificar la transición de un estado saludable a uno defectuoso con base en las señales espectrales recientes [?].

2.2.12. Atención y arquitecturas tipo Transformer

El modelo Transformer está compuesto por dos bloques principales: el codificador (encoder) y el decodificador (decoder). Cada uno de estos bloques se compone de múltiples capas que incluyen los siguientes módulos fundamentales:

- Mecanismo de atención escalonada: Permite que el modelo se enfoque en diferentes partes de la secuencia de entrada para cada elemento de salida. Esta atención se calcula como una combinación ponderada de valores en función de la similitud entre claves y consultas [?].
- Atención multicabezal: Esta técnica mejora la capacidad del modelo al permitir que múltiples representaciones de atención se aprendan en paralelo, lo que proporciona una mayor riqueza contextual para cada posición de la secuencia [?].
- Retropropagación de red: Después de la atención, cada capa incluye una red neuronal completamente conectada que se aplica de manera independiente a cada posición de la secuencia.
- Normalización y residuos (Residual connections and layer normalization): Estas técnicas estabilizan y aceleran el entrenamiento al evitar problemas de degradación del gradiente en modelos profundos.
- Codificación posicional (Positional encoding): Dado que el Transformer no tiene una estructura secuencial explícita como las redes recurrentes, se introducen codificaciones posicionales que representan la posición relativa o absoluta de cada token dentro de la secuencia [?].

Una de las mayores ventajas del Transformer es su capacidad para procesar secuencias de datos de forma paralela, lo que reduce significativamente el tiempo de entrenamiento en comparación con modelos secuenciales como LSTM. Además, gracias al mecanismo de atención, el Transformer es capaz de modelar relaciones a largo plazo con mayor eficacia [?].

Esre tipo de estructura ha sido empleada enálisis de series temporales , en áreas como la detección de fallas industriales. Los Transformers permiten aprender patrones complejos en señales multivariadas como vibraciones o corrientes eléctricas, superando el rendimiento de enfoques tradicionales basados en técnicas espectrales [?].

A pesar de sus ventajas, los Transformers también presentan limitaciones importantes, entre ellas el alto consumo computacional y memoria cuando se aplican a secuencias largas, debido a la complejidad cuadrática del mecanismo de atención. Esto ha motivado la creación de variantes más eficientes como Linformer, Longformer, Performer, entre otros [?].




Figura 2.2. Funcionamiento red neuronal Transformer

Su aplicación en motores BLDC aún es incipiente, pero estudios recientes han mostrado su efectividad frente a redes LSTM en tareas de clasificación [?].

2.2.13. Arquitecturas especializadas

2.2.13.0.1. U-Net y segmentación. Estructura encoder-decoder con *skip connections* que preservan detalle y contexto, útil para localizar eventos impulsivos en tiempo-frecuencia.

2.2.13.0.2. TCN (Temporal Convolutional Networks). Convoluciones causales dilatadas y campos receptivos extensos, alternativa eficiente a RNN en series temporales.

2.2.13.0.3. Redes sobre grafos (GNN). Operadores espectrales o espaciales sobre topologías irregulares; las GCN aplican promedios ponderados de vecindad y no linealidades, idóneas cuando hay relaciones inter-sensores o módulos.

2.2.13.0.4. Autoencoders y modelos generativos. Autoencoders (clásicos/denoising/variacionales) aprenden representaciones compactas o distribuciones latentes; útiles para detección no supervisada de anomalías.

El entrenamiento se realiza mediante retropropagación del error y optimización por descenso de gradiente. Para evitar el sobreajuste, se utilizan técnicas como regularización, dropout y validación cruzada [?].

2.2.14. Método del gradiente

El método de la gradiente constituye el pilar fundamental para el entrenamiento de redes neuronales artificiales (RNA), permitiendo la optimización de sus parámetros mediante la minimización de una función de pérdida asociada al error de clasificación o estimación. En el contexto del diagnóstico de fallas en motores eléctricos, este método resulta esencial para ajustar modelos predictivos capaces de discriminar entre condiciones normales y diversas fallas eléctricas y mecánicas, tales como cortocircuitos en el estator, barras rotas en el rotor, defectos en rodamientos y excentricidad mecánica. El entorno industrial, caracterizado por ruido, variaciones de carga y cambios en la velocidad, exige algoritmos de optimización robustos basados en gradiente para lograr generalización y resiliencia frente a condiciones no estacionarias.

El método del gradiente optimiza la función de pérdida $J(\mathbf{w})$ mediante actualizaciones iterativas:

$$\mathbf{w}^{(t+1)} = \mathbf{w}^{(t)} - \eta \nabla_{\mathbf{w}} J(\mathbf{w}^{(t)}), \quad (2.6)$$

con η tasa de aprendizaje. Variantes incluyen:

- **SGD**: usa un solo ejemplo por actualización, favoreciendo convergencia rápida pero ruidosa.
- **Mini-batch GD**: compromiso entre SGD y GD completo.
- **Momentum**: acumula un término de momento $v^{(t+1)} = \mu v^{(t)} - \eta \nabla J$, mejorando la estabilidad [?].
- **Optimizadores adaptativos** (RMSProp, Adam): ajustan η en cada dimensión según estadísticas de gradientes, acelerando la convergencia [?].

Diversas variantes del método del gradiente mejoran la convergencia y estabilidad del entrenamiento, especialmente en condiciones industriales donde las señales del motor presentan ruido, cambios de carga o transitorios:

- **Gradiente estocástico (SGD por sus siglas en inglés)**: actualiza los parámetros usando muestras individuales o minibatches, reduciendo el costo computacional y mejorando la capacidad de escapar de mínimos locales.
- **Gradiente con momentum**: incorpora una memoria del gradiente previo mediante un término inercial que suaviza las oscilaciones en valles pronunciados y acelera la convergencia.
- **Adam (Adaptive moment estimation)**: combina momentum y promedios móviles de segundo orden, ajustando el paso de actualización individualmente por parámetro; resulta ampliamente utilizado en diagnóstico de fallas debido a su robustez numérica y rapidez de convergencia.
- **RMSProp y adagrad**: adaptan la tasa de aprendizaje en función de la magnitud acumulada de los gradientes locales, adecuadas para datos ruidosos y características dispersas.

Estas variantes permiten enfrentar la variabilidad inherente en señales industriales y reducir problemas como gradientes explosivos o desvanecidos, especialmente relevantes en arquitecturas profundas y recurrentes utilizadas para monitoreo de condiciones de motor en tiempo real.

2.2.15. Funciones de activación

Las funciones de activación introducen no linealidad en las redes neuronales, permitiendo aproximar relaciones complejas.

Las funciones de activación constituyen un elemento esencial en las redes neuronales artificiales (RNA), dado que introducen no linealidad en el modelo y permiten aproximar funciones complejas presentes en sistemas dinámicos industriales. En el diagnóstico de fallas en motores eléctricos, la naturaleza no lineal de las interacciones electromecánicas, los fenómenos transitorios y la influencia de perturbaciones externas (variaciones de carga, vibraciones mecánicas, ruido eléctrico) requieren el empleo de funciones de activación adecuadas para capturar comportamientos sutiles y relaciones de alta complejidad en las señales adquiridas [?].

El proceso de detección de fallas basado en datos incluye la extracción de características en los dominios temporal, frecuencial y tiempo–frecuencia (por ejemplo, FFT, DWT, STFT) y posteriormente su alimentación a una RNA. La selección de la función de activación incide en la capacidad de aprendizaje del modelo, su estabilidad numérica y su velocidad de convergencia. Entre los criterios de selección destacan: no linealidad suficiente, diferenciabilidad, baja susceptibilidad a problemas de gradientes desvanecientes y saturación, y capacidad para manejar dispersiones numéricas provenientes de datos industriales.




Figura 2.3. Estructura básica de una red neuronal con función de activación

Entre las más empleadas figuran:

- **Sigmoidal (logística):**

$$\sigma(x) = \frac{1}{1 + e^{-x}}, \quad \sigma'(x) = \sigma(x)[1 - \sigma(x)]. \quad (2.7)$$

Presenta *vanishing gradient* para $|x|$ grandes [?].




Figura 2.4. Función de activación sigmoide

■ **Tangente hiperbólica:**

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}, \quad \tanh'(x) = 1 - \tanh^2(x), \quad (2.8)$$




Figura 2.5. Función de activación tangente hiperbólica

Centrada en cero, reduce el sesgo en gradientes pequeños [?].

■ **ReLU (Rectified Linear Unit):**

$$\text{ReLU}(x) = \max(0, x), \quad \text{ReLU}'(x) = \begin{cases} 1, & x > 0, \\ 0, & x \leq 0, \end{cases} \quad (2.9)$$

Simple y eficiente, combate parcialmente el desvanecimiento de gradiente.

- **Variantes de ReLU:** *Leaky ReLU*, *ELU* y *SELU* mejoran la propagación de gradientes para $x < 0$ [?].




Figura 2.6. Función de activación ReLU

Tabla 2.1. Comparación de funciones de activación en el contexto de diagnóstico de fallas

Función	Rango	Ventajas	Desventajas
Sigmoide	$(0, 1)$	Interpretación probabilística	Saturación y gradientes pequeños
Tanh	$(-1, 1)$	Simétrica, mejor que sigmoide	Saturación en valores altos
ReLU	$[0, \infty)$	Simple, eficiente, no saturante	Neuronas muertas si $x < 0$ persiste
Leaky ReLU	$(-\infty, \infty)$	Evita neuronas muertas	Parámetro α a ajustar
ELU	$(-\alpha, \infty)$	Suave, reduce sesgo	Costo computacional mayor
Swish	$(-\infty, \infty)$	Suave, no monótona, buena generalización	Mayor complejidad computacional
Mish	$(-\infty, \infty)$	No monótona, suavidad elevada	Costo computacional

2.2.16. Dropout

El *dropout* es una técnica de regularización que consiste en desactivar aleatoriamente cada neurona con probabilidad p durante el entrenamiento. El proceso:

$$\tilde{h}_i = h_i \cdot z_i, \quad z_i \sim \text{Bernoulli}(1 - p). \quad (2.10)$$

En test-time se escala la salida h_i por $(1 - p)$ para conservar la magnitud esperada. Dropout actúa como un conjunto de modelos en forma de *bagging* y reduce el sobreajuste [?].

2.2.17. Validación cruzada

La validación cruzada (CV, por sus siglas en inglés) evalúa la generalización dividiendo el conjunto de datos en k particiones. En *k-fold CV*:

$$\text{Error}_{\text{CV}} = \frac{1}{k} \sum_{i=1}^k \text{Error}(\mathcal{D}_{\setminus i}, \mathcal{D}_i),$$

donde $\mathcal{D}_i$ es el subconjunto de validación y $\mathcal{D}_{\setminus i}$ el de entrenamiento. Para conjuntos pequeños se emplea *leave-one-out*. CV es esencial para ajustar hiperparámetros y prevenir sesgos de muestreo [?].

2.3. Proceso de extracción de características y clasificación

La extracción de características constituye una etapa crítica en los sistemas de diagnóstico de fallas en motores eléctricos, pues permite transformar las señales medidas en representaciones compactas y discriminativas que capturan información relevante del estado operacional de la máquina. Debido a la naturaleza dinámica, no lineal y frecuentemente no estacionaria de los fenómenos asociados a fallos (p.ej., cortocircuitos entre espiras, barras rotas del rotor, degradación de rodamientos y excentricidad mecánica), se requiere un pipeline de preprocesamiento y selección de características robusto que preserve la información significativa y reduzca el ruido de medición [?].

El proceso general consiste en: (i) adquisición de señales, (ii) preprocesamiento y filtrado, (iii) transformación de dominio, (iv) cálculo de características descriptivas y (v) selección/normalización para alimentar algoritmos de aprendizaje automático o redes neuronales.

2.3.1. Preprocesamiento y filtrado de señales

El preprocesamiento se orienta a eliminar ruido, tendencia y artefactos de medición. Entre las técnicas más comunes destacan:

- **Filtrado digital:** filtros FIR/IIR pasa-banda o pasa-altas para aislar regiones frecuenciales asociadas a componentes armónicas y subarmónicas de falla [?].
- **Eliminación de ruido:** filtrado adaptativo, media móvil y desnoisado wavelet.
- **Normalización y escalado:** estandarización z -score o min-max para garantizar estabilidad numérica en modelos de aprendizaje.
- **Segmentación:** ventanas temporales solapadas y segmentación basada en eventos (arranque/parada).
- **Sincronización:** alineación de la señal respecto a velocidad mecánica, corriente o tensión, especialmente en variadores de velocidad.

2.3.2. Vector de Características

Este vector se construye a partir de:

- Magnitudes y fases de FFT
- Energías por nivel de wavelet
- Valores RMS por banda
- Módulo de la transformada de Park
- Estadísticas del dominio temporal (media, desviación, curtosis, etc.)

El uso combinado de técnicas de análisis espectral y redes neuronales representa una solución de vanguardia en el diagnóstico de fallas en motores BLDC. La extracción de características espectrales permite una representación rica de las señales, mientras que las redes neuronales permiten modelar relaciones complejas y tomar decisiones autónomas. El futuro apunta al uso de modelos auto-supervisados, redes híbridas y aprendizaje federado para entornos industriales distribuidos.

Capítulo 3

Resultados

En este capítulo se presenta los resultados al ingresar las señales a códigos empleando diferentes algoritmos de análisis espectral como la FFT, ondeletas, módulo ISP de Park, transformada de Hilbert-Huang y su comparación

Los algoritmos son realizado en python sin el uso de librerías, a excepción de os para la lectura de archivos, numpy para cálculos matemáticos y matplotlib para visualización de los resultados.

Los datos obtenidos en las siguientes secciones serán los datos que serían ingresados en las redes neuronales que se analizarán en el siguiente capítulo.

3.1. Banco de pruebas experimentales con motor BLDC de vehículo eléctrico ligero

El banco de pruebas se construyó derivado de varios casos de investigación previa dirigidos por el Dr. Francisco Javier Villalobos Piña. Este está construido de manera modular y consta de las siguientes partes

- Un sistema de monitoreo y diagnóstico de fallas, basado en un DSP de Microchip dsPIC30F4011, con la instrumentación necesaria para la adquisición de señales de la máquina a diagnosticar.
- Un MB modificado de tipo in-wheel, de una motocicleta eléctrica de 500W de potencia; modificado para insertar diferentes fallas de corto-circuito o circuito abierto en los devanados del estator.

- Un programa de computadora personal en lenguaje visual de alto nivel llamado Embarcadero Delphi XE7, que incorpora los algoritmos de control, así como el sistema de adquisición de señales de interés.

El MB tiene 17 bobinas por fase, cada una con 7 vueltas de enrollamiento y 9 cables magnetos en paralelo calibre #22.

Etiquetado de fallas		
Nombre	Número de bobinas	Porcentaje de falla
T1	7	41.76 %
T2	6	35.29 %
T3	5	29.41 %
T4	4	23.52 %
T5	3	17.64 %
T6	2	11.76 %
T7	1	5.88 %
T8	Fase A	0 %

Tabla 3.1. Detalle de los taps para inducir diferentes escenarios de corto circuito del estador del motor BLDC




Figura 3.1. Banco de pruebas

3.2. Análisis de motor BLDC en caso sano

Para esta sección, se analizan las señales obtenidas con el motor girando libremente, sin carga y a una velocidad constante

Los resultados que se presentan a continuación corresponden al análisis de señales trifásicas provenientes de un motor BLDC operando a una velocidad supuesta constante de 215 revoluciones por minuto (RPM), bajo una frecuencia de muestreo de 11 kHz. Estas señales han sido sometidas a diversas técnicas de análisis espectral, incluyendo transformada rápida de Fourier, análisis wavelet, y cálculo del módulo ISP de Park. Con cada técnica se busca observar la firma espectral o dinámica que permite identificar o anticipar fallas incipientes en el sistema. A continuación, se describen brevemente las figuras que acompañan esta sección.

Las imágenes de las señales originales muestran el comportamiento crudo de las tres fases de corriente del motor (A, B y C), tal como se obtuvieron tras la digitalización. Esto nos permite tener un referente temporal y contextual de la condición operativa del motor antes de aplicar cualquier transformación.

También, se pudieron adquirir las señales obtenidas del sensor de efecto hall de la compañía Honey Well, mostrando un comportamiento uniforme al tener el motor en movimiento, dando validez al patrón de conmutación con el que trabaja.




Figura 3.2. FFT de las señales




Figura 3.3. Lecturas de sensores de efecto hall

3.2.1. Transformada rápida de Fourier

Las gráficas de FFT permiten visualizar el contenido en frecuencia de cada fase. Gracias a la resolución espectral proporcionada por la frecuencia de muestreo de 11 kHz, es posible identificar armónicos relevantes y componentes subarmónicas que pueden ser indicativas de fallas mecánicas (como desequilibrio) o eléctricas (como cortocircuitos parciales).

Para obtener las imágenes se implementó el algoritmo de cooley-tukey como se muestra en la figura ??

```
def fft_cooley_tukey(x):
    N = len(x)
    if N <= 1:
        return x
    even = fft_cooley_tukey(x[0::2])
    odd = fft_cooley_tukey(x[1::2])
    factor = np.exp(-2j * np.pi * np.arange(N // 2) / N)
    return np.concatenate([even + factor * odd, even - factor * odd])
```

Figura 3.4. Subrutina para la obtención de la FFT

Resultados:




Figura 3.5. FFT de las señales

Como se muestra en la figura ??, podemos observar a simple vista diferencias en el primer armónico generado, confirmando así las diferencias en frecuencia presentadas según las condiciones del motor.

3.2.2. Análisis con ondeleta wavelet haar

El análisis con la transformada wavelet permite descomponer la señal original en diferentes niveles jerárquicos de frecuencia, conservando la localización temporal. Las imágenes asociadas a este análisis muestran la energía contenida en las componentes de detalle y aproximación, lo que facilita la detección de eventos transitorios o abruptos como impulsos de corriente o asimetrías intermitentes en la señal. En este caso se ha empleado una función wavelet de tipo Haar y db4, debido a su simplicidad computacional y sensibilidad a cambios rápidos.

Resultados:




Figura 3.6. Coeficientes wavelet de las señales

Como se muestra en la figura ??, no podemos observar a simple vista una diferencia notoria para cada caso, sin embargo, al obtener datos estadísticos de los coeficientes de

amplitud y detalle podremos observar las diferencias (especialmente en energíaa) como se verá en la tabla 3.5.

3.2.3. Vector de Park

Para efectuar el diagnóstico de las condiciones de salud del motor BLDC se utiliza el módulo del vector de corrientes de Park, también conocido como modulo del fasor espacial instantáneo de Park (ISP por sus siglas en inglés). Este módulo obtenido a partir de las corrientes trifásicas de cada fase del moto BLDC permite cuantificar el desbalance en las corrientes generado por una falla en los devanados de la máquina. El fundamento matemático para el uso de este módulo se basa en el hecho de que la fuente de tensión debe seguir una forma sinusoidal, cosa que para el caso particular de la máquina no se cumple, pues la fuente de alimentación es de tipo trapezoidal, pero, tomando en cuenta la naturaleza de la corriente fundamental senoidal con base en la transformada de Fourier de la señal de alimentación, se toma la decisión de explorar su uso en máquinas de este tipo BLDC.

Las figuras del módulo de la transformada de Park muestran la evolución de la señal en el plano alpha-beta, representando el módulo ISP . Esta representación transforma las señales trifásicas en un sistema de coordenadas ortogonales que facilita la observación de desequilibrios y cambios en la simetría del sistema. Un aumento en la dispersión o patrones anómalos en este módulo puede ser indicativo de una condición de falla latente o inminente. Cada una de estas representaciones aporta una perspectiva complementaria sobre la condición del motor, permitiendo una caracterización más completa de su estado y facilitando el posterior entrenamiento de modelos basados en redes neuronales para la detección automática de fallas.

Resultados:




Figura 3.7. Módulo ISP de Park de las señales

3.3. Esquema de diagnóstico de fallas basado en clasificador neuronal de espectros de frecuencia

3.3.1. Lectura y preprocesado de datos

El conjunto de entrenamiento se encuentra en un libro de Excel, que contiene:

- Una columna con identificadores de caso (p.ej. CASO_FALLA_T3_).
- Nueve columnas con valores RMS de la FFT del módulo ISP de Park de los diferentes anchos de banda (0-1024 Hz) como se muestran en la siguiente tabla:

Ejemplo de datos ingresados									
Falla	BF-1	BF-2	BF-3	BF-4	BF-5	BF-6	BF-7	BF-8B	F-9
T1	770357	1394	10100	1151	1727	1564	2664	12537	3618
T2	666706	2590	7062	1906	1702	1274	2173	10074	2945
T3	568839	3385	5741	1246	1652	1194	2169	8008	2506
T5	395002	845	1951	1274	1923	1172	2010	5526	1722
T6	339190	915	884	1145	1614	919	2233	4463	1499
T7	301091	343	1272	923	1234	797	1899	3983	1554
SANO	285690	1919	2011	1167	1177	969	2380	4092	1568

Tabla 3.2. Datos para red neuronal empleando valores rms de la FFT del módulo ISP

Las etiquetas se extraen del identificador:

$$\text{SANO} \rightarrow 0, \quad \text{FALLA_T1} \rightarrow 1, \dots, \text{FALLA_T7} \rightarrow 7,$$

y se codifican como vectores one hot de dimensión 8.

Para cada característica j se aplica normalización Min Max:

$$\min_j \triangleq \min_i X_{ij}, \quad \max_j \triangleq \max_i X_{ij}, \quad X'_{ij} = \frac{X_{ij} - \min_j}{\max_j - \min_j}. \quad (3.1)$$

Los vectores $\min_j$ y $\max_j$ se almacenan para la fase de evaluación.

3.3.2. Definición de la red neuronal MLP

Se implementa íntegramente empleando la librería NumPy, con la siguiente arquitectura:

- Capa de entrada: $n_{in} = 9$ características.
- Capa oculta 1: $n_1 = 9$ neuronas, activación sigmoide.
- Capa oculta 2: $n_2 = 8$ neuronas, activación sigmoide.
- Capa de salida: $n_{out} = 8$ neuronas, activación softmax.




Figura 3.8. Estructura de red neuronal

Las funciones de activación son:

$$\sigma(z) = \frac{1}{1 + e^{-z}}, \quad \text{softmax}(\mathbf{z})_i = \frac{\exp(z_i - \max_j z_j)}{\sum_k \exp(z_k - \max_j z_j)}. \quad (3.2)$$

y la función de coste es la entropía cruzada:

$$L = -\frac{1}{N} \sum_{i=1}^N \sum_{c=1}^8 y_{i,c} \log(\hat{y}_{i,c}). \quad (3.3)$$

3.3.3. Proceso de entrenamiento de la red tipo MLP

El entrenamiento sigue el siguiente procedimiento:

1. **Propagación** : cálculo de activaciones en cada capa.

2. **retropropagación** : cálculo de gradientes mediante la regla de la cadena.

3. **Actualización de pesos y sesgos**:

$W \leftarrow W - \eta \nabla_W L$, $b \leftarrow b - \eta \nabla_b L$ con tasa de aprendizaje $\eta = 0.005$.

4. Impresión de la pérdida L cada 100 épocas para seguimiento.

Al finalizar, se almacenan en formato npz los parámetros:

$$\{w_1, b_1, w_2, b_2, w_3, b_3, \text{mín}, \text{máx}\}.$$

3.3.4. Módulo evaluador de nueva señal

- Lectura y transformación de la señal Se parte de un archivo `.txt` con muestras trifásicas donde las columnas 2, 3 y 4 contienen las corrientes instantáneas i_a, i_b, i_c . Se aplica la transformada de Park:

$$\begin{aligned}\alpha(k) &= \frac{2}{3}(i_a(k) - 0.5 i_b(k) - 0.5 i_c(k)), \\ \beta(k) &= \frac{2}{3} \frac{\sqrt{3}}{2}(i_b(k) - i_c(k)), \\ \text{ISP}(k) &= \sqrt{\alpha(k)^2 + \beta(k)^2}.\end{aligned}\tag{3.4}$$

A continuación, se calcula la FFT de longitud 1024 (completando con ceros si la señal es más corta) y se extraen las magnitudes $|X(f)|$, $f=0, \dots, 1023$.

- Cálculo de RMS por bandas Para cada banda $[f_{\text{ini}}, f_{\text{fin}}]$ se calcula:

$$\text{RMS} = \sqrt{\frac{1}{N} \sum_{f=f_{\text{ini}}}^{f_{\text{fin}}} |X(f)|^2},\tag{3.5}$$

generando un vector de nueve características.

- Normalización y clasificación

El vector de características se normaliza con los valores mín_j y máx_j :

$$x'_j = \frac{x_j - \text{mín}_j}{\text{máx}_j - \text{mín}_j}.\tag{3.6}$$

Se carga el modelo previamente entrenado y se realiza un *forward pass*, obteniendo la distribución:

$$\mathbf{p} = \text{softmax}(z_3) \in \mathbb{R}^8. \quad (3.7)$$

La predicción final se define como:

$$\hat{c} = \arg \max_i p_i \quad (0 = \text{Sano}, \dots, 7 = \text{Falla_T7}). \quad (3.8)$$

En la siguiente tabla, se puede ver un resumen de la efectividad con cada uno de los métodos analizados contemplando los mismos parámetros en el entrenamiento y evaluación.

Efectividad según análisis	
Análisis	Efectividad
Señales sin procesamiento	4.76 %
Módulo ISP	56.66 %
FFT	63.80 %
FFT del módulo ISP	99.52 %
Datos estadísticos de ondeleta Haar	88.09 %
Datos estadísticos de ondeleta db4	82.85 %
Datos estadísticos de ondeleta db6	84.76 %
Datos estadísticos de ondeleta mexican hat	66.19 %

Tabla 3.3. Efectividad según procesamiento de la señal empleado

3.4. Implementación de un Clasificador MLP basado en ondeleta haar: Arquitectura y flujo de entrenamiento

3.4.1. Definición de la red neuronal MLP

Se implementa íntegramente empleando la librería NumPy, con la siguiente arquitectura:

- Capa de entrada: $n_{in} = 15$ características.
- Capa oculta 1: $n_1 = 10$ neuronas, activación sigmoide.
- Capa oculta 2: $n_2 = 8$ neuronas, activación sigmoide.
- Capa de salida: $n_{out} = 8$ neuronas, activación softmax.

3.4.2. Descomposición Wavelet Discreta (Haar)

Se aplica la descomposición discreta con la base Haar (ψ_{Haar}) hasta 4 niveles. Denotemos por $\text{DWT}_{\text{Haar}}^{(4)}\{\widetilde{\text{ISP}}(k)\}$ el conjunto de coeficientes:

$$\{cA_4, cD_4, cD_3, cD_2, cD_1\}.$$

Aquí:

- $cA_4 \in \mathbb{R}^{N'/16}$ son los *coeficientes de aproximación* en el nivel 4.
- Para cada $j = 1, \dots, 4$, $cD_j \in \mathbb{R}^{N'/2^j}$ son los *coeficientes de detalle* en el nivel j .

3.4.3. Cálculo de Características Estadísticas

Para cada vector de coeficientes $v = cA_4, cD_4, cD_3, cD_2, cD_1$, se calcula:

$$\text{RMS}(v) = \sqrt{\frac{1}{|v|} \sum_{i=1}^{|v|} v_i^2}, \quad (3.9)$$

$$\text{Energía}(v) = \sum_{i=1}^{|v|} v_i^2, \quad (3.10)$$

$$\text{Varianza}(v) = \frac{1}{|v|} \sum_{i=1}^{|v|} (v_i - \bar{v})^2, \quad \bar{v} = \frac{1}{|v|} \sum_i v_i. \quad (3.11)$$

Así, se generan 5 grupos de $\{\text{RMS}, \text{Energía}, \text{Varianza}\}$ para los niveles:

$$\{cA_4, cD_4, cD_3, cD_2, cD_1\}.$$

En total, $5 \times 3 = 15$ características por cada señal, como se muestra en la tabla a continuación:

Falla	cA			cD4			cD3			cD2			cD1		
	RMS	E	V	RMS	E	V	RMS	E	V	RMS	E	V	RMS	E	V
T1	378	146363338	3338	41.02	172278681	1681	21.63	958097467	167	12.64	654468159	159	8.31	56619539.12	159
T2	324	107652413	2413	37.25	1421052387	1287	20.34	847193113	113	11.67	557506136	136	7.42	45070055.01	136
T3	279	801035657	1657	31.47	101398990	890	19.2	816599398	98	10.81	489076119	119	6.77	37570245.86	119
T5	193	383791681	1681	27.70	785659767	967	21.52	948306163	163	11.09	50353822	22	5.92	28708335.04	22
T6	162	270855072	1072	26.01	692850676	676	22.20	100908392	92	11.13	507585123	123	5.62	2586531.57	123
T7	148	225573633	1633	24.89	634513619	1619	22.78	106254218	118	11.17	510820124	124	5.61	2582341.52	124
T8	140	200725027	1527	24.42	610597596	796	22.87	107123523	123	11.54	545131133	133	5.57	2540761.00	133

Tabla 3.4. Datos para red neuronal empleando valores rms, varianza y energía con ondeleta haar

3.5. Implementación de un Clasificador MLP basado en ondeleta db4: Arquitectura y flujo de entrenamiento

En lugar de Haar, se emplea la base Daubechies de longitud 8 (ψ_{db4}) para realizar la descomposición discreta a 4 niveles del módulo ISP. Sea

$$\text{DWT}_{db4}^{(4)}\{\widetilde{\text{ISP}}(k)\} = \{cA_4, cD_4, cD_3, cD_2, cD_1\}.$$

Las ecuaciones de filtro para db4 tienen coeficientes $h[n]$ y $g[n]$ (de longitud 8) específicos, que satisfacen propiedades de ortogonalidad y regularidad:

$$h[n] = \begin{cases} \frac{1+\sqrt{3}}{4\sqrt{2}}, & n = 0, \\ \frac{3+\sqrt{3}}{4\sqrt{2}}, & n = 1, \\ \frac{3-\sqrt{3}}{4\sqrt{2}}, & n = 2, \\ \frac{1-\sqrt{3}}{4\sqrt{2}}, & n = 3, \\ 0, & n \geq 4, \end{cases}$$

y

$$g[n] = (-1)^n h[3 - n], \quad n = 0, 1, 2, 3.$$

El procedimiento de descomposición iterativa es análogo al de Haar, pero usando estos nuevos filtros sobre cA_j para obtener cA_{j+1} y cD_{j+1} . Al final se obtienen:

$$cA_4 = \sum_n h[n] cA_3(2m + n), \quad cD_4 = \sum_n g[n] cA_3(2m + n),$$

y sucesivamente hasta cD_1 .

3.5.1. Cálculo de Características Estadísticas

De manera idéntica al caso Haar, para cada conjunto de coeficientes $\{cA_4, cD_4, cD_3, cD_2, cD_1\}$ se extraen:

$$\text{RMS}(v) = \sqrt{\frac{1}{|v|} \sum_{i=1}^{|v|} v_i^2}, \quad (3.12)$$

$$\text{Energía}(v) = \sum_{i=1}^{|v|} v_i^2, \quad (3.13)$$

$$\text{Varianza}(v) = \frac{1}{|v|} \sum_{i=1}^{|v|} (v_i - \bar{v})^2, \quad \bar{v} = \frac{1}{|v|} \sum_i v_i. \quad (3.14)$$

De nuevo se obtienen $5 \times 3 = 15$ características por señal como se muestran en la siguiente tabla:

Ejemplo de datos ingresados									
Falla	BF-1	BF-2	BF-3	BF-4	BF-5	BF-6	BF-7	BF-8B	F-9
T1	770357	1394	10100	1151	1727	1564	2664	12537	3618
T2	666706	2590	7062	1906	1702	1274	2173	10074	2945
T3	568839	3385	5741	1246	1652	1194	2169	8008	2506
T5	395002	845	1951	1274	1923	1172	2010	5526	1722
T6	339190	915	884	1145	1614	919	2233	4463	1499
T7	301091	343	1272	923	1234	797	1899	3983	1554
SANO	285690	1919	2011	1167	1177	969	2380	4092	1568

Tabla 3.5. Datos para red neuronal empleando valores rms, varianza y energía con ondeleta haar

3.5.2. Resumen Comparativo

- **Base Haar:** filtros muy simples ($h = \frac{1}{\sqrt{2}}[1, 1]$, $g = \frac{1}{\sqrt{2}}[1, -1]$), poca longitud de soporte (2 muestras). Genera coeficientes con alta sensibilidad a cambios bruscos (ideal para detectar transientes).
- **Base db4:** filtros de longitud 8, mayor regularidad y suavidad. Captura información espectral más fina; requiere más cómputo pero suele ofrecer mejor discriminación para señales suavizadas.

En la siguiente tabla se puede ver la comparación de eficiencia lograda según el tipo de ondeleta empleado. Para la comparación se emplean los mismos parámetros de entrenamiento (learning rate: 0.005 y 500,000 épocas) y estructura de red descrita anteriormente.

Efectividad según tipo de ondeleta	
Ondeleta	Efectividad
Haar	99.54 %
Db4	97.73 %
Db6	94.76 %
Sombrero mexicano	90.95 %

Tabla 3.6. Efectividad según tipo de ondeleta

3.6. Motor BLDC con carga constante

Los resultados que se presentan a continuación corresponden al análisis de señales trifásicas provenientes de un motor BLDC operando a una velocidad relativa constante de 30 revoluciones por minuto (RPM), bajo una frecuencia de muestreo de 11 kHz. Estas señales han sido sometidas a las técnicas de análisis espectral con mejor resultado en el análisis anterior.

En este caso se tiene un dinamo automotriz que tiene como carga un par de lamparas de halógeno que demandan 5A cada una a 12V, lo que equivale a 120 Watts de carga sobre el motor BLDC aproximadamente. Es poco mas del 20 % de la potencia nominal del motor de 500W.

3.6.1. Señales originales bajo un régimen de carga constante.

A continuación se presentan las señales originales




Figura 3.9. Señales originales

3.6.2. Módulo ISP de Park

Las figuras del módulo de la transformada de Park muestran la evolución de la señal en el plano alpha-beta, representando el módulo ISP. Esta representación transforma las señales trifásicas en un sistema de coordenadas ortogonales que facilita la observación de desequilibrios y cambios en la simetría del sistema. Un aumento en la dispersión o patrones anómalos en este módulo puede ser indicativo de una condición de falla latente o inminente.

Resultados:




Figura 3.10. Módulo ISP de Park de las señales

3.6.3. Transformada rápida de Fourier

Las gráficas de FFT permiten visualizar el contenido en frecuencia del modulo ISP. Gracias a la resolución espectral proporcionada por la frecuencia de muestreo de 5 kHz, es posible identificar armónicos relevantes y componentes subarmónicas que pueden ser indicativas de fallas mecánicas (como desequilibrio) o eléctricas (como cortocircuitos parciales).

Resultados:




Figura 3.11. Módulo ISP de Park de las señales

3.7. Implementación de redes neuronales

Dados los resultados favorables en el experimento llevado a cabo con el motor sin carga, se empleó el mismo análisis espectral (Valores RMS de diferentes anchos de banda de la FFT del ISP) y una estructura de red neuronal idéntica, es decir:

- Capa de entrada: $n_{in} = 9$ características.
- Capa oculta 1: $n_1 = 9$ neuronas, activación sigmoide.
- Capa oculta 2: $n_2 = 8$ neuronas, activación sigmoide.
- Capa de salida: $n_{out} = 8$ neuronas, activación softmax.

Ejemplo de datos empleados para el entrenamiento empleando valores RMS de diferentes anchos de banda en el análisis anterior

Ejemplo de datos ingresados								
Falla	BF-1	BF-2	BF-3	BF-4	BF-5	BF-6	BF-7	BF-8B
SANO	11000	1.1675	0.2178	0.7859	0.1662	0.1347	0.1830	0.501
T3	11000	1.3185	0.1300	0.7524	0.1915	0.1541	0.1780	0.0508
T6	11000	1.1165	0.2009	0.6647	0.1971	0.1481	0.1785	0.0509

Tabla 3.7. Datos para red neuronal empleando valores rms de la FFT del módulo ISP

Se obtuvo una efectividad del 98.9% , una evaluación prácticamente inmediata y un costo computacional bajo, siendo resultados que se consideran fiables para la detección de fallas incipientes.

Efectividad según análisis	
Análisis	Efectividad
Señales sin procesamiento	4.44 %
Módulo ISP	53.33 %
FFT	56.66 %
Valores RMS de la FFT del módulo ISP	98.88 %
Datos estadísticos de ondeleta Haar	92.22 %
Datos estadísticos de ondeleta db4	93.33 %
Datos estadísticos de ondeleta db6	93.33 %
Datos estadísticos de ondeleta mexican hat	89.99 %

Tabla 3.8. Efectividad según procesamiento de la señal empleado

Capítulo 4

Conclusiones

En el presente trabajo de investigación se abordó el problema de la detección de fallas eléctricas del estator de un motor BLDC de vehículo eléctrico ligero alterando en sus devanados para inducir diferentes escenarios de falla eléctrica de cortocircuito entre espiras. Se efectuó un trabajo de investigación en el cual se efectuó una comparativa de herramientas de diagnóstico que utilizan como fuente de información las corrientes del estator las cuales fueron adquiridas mediante una técnica no invasiva lograda mediante el uso de sensores de corriente de efecto hall.

La intención principal es comparar las herramientas tradicionales de tiempo frecuencia la transformada discreta de Fourier en su versión rápida utilizando los algoritmos de Cooley y Tukey y por otra parte el uso de herramientas de manejo de datos basadas en algoritmos de inteligencia artificial, para lo cual se utilizan redes neuronales artificiales implementadas sin el uso de librerías en Python.

- Fueron obtenidas señales del banco de pruebas experimental con diferentes regímenes de velocidad, tanto con par de carga constante como sin el en diferentes escenarios de falla, desde un 5.88 % de falla por fase que representaría una falla incipiente hasta un escenario de falla del 41,76 %, lo que representa una falla crítica
- Las señales obtenidas fueron procesadas con diferentes técnicas de análisis espectral como FFT, Módulo ISP de Park, diferentes ondeletas, buscando el procesamiento que destaque los cambios presentados en dominio de frecuencia al presentarse un escenario de falla
- Los resultados obtenidos del procesamiento de las señales fueron utilizados como datos de entrenamiento en diferentes estructuras de redes neuronales, realizando más de 150

experimentos de los cuales se destaca el uso valores RMS en diferentes anchos de banda del módulo ISP de Park en conjunto de la FFT, logrando una efectividad del 99.54 %, cifra que se considera confiable

- Las técnicas de análisis espectral utilizadas para la búsquedas de fallas eléctricas de estator en MB es una buena opción frente a otros enfoques que requieren conocer muy bien el modelo y los parámetros del motor.
- Respecto a las herramientas tiempo frecuencia se utilizó la caja provista por el lenguaje de programación Python con la librería de la transformada discreta de Fourier en su versión rápida con la cual se obtuvieron los diferentes espectros de frecuencia para cada escenario de falla y dichos resultados fueron comparados con el análisis multiresolución ondeleta logrando un buen desempeño respecto a la detección, logrando un porcentaje mayor al 99 % de efectividad.
- Se realizó una comparativa de las diferentes Wavelets y la FFT con el módulo del ISP, bajo diferentes condiciones de operación, para saber que técnica se comporta mejor y logra destacar firmas de fallas o características que vuelvan más sencillo el entrenamiento de una red neuronal
- Se encuentra un procesamiento de las señales con bajo costo computacional para el entrenamiento y posteriormente evaluación de nuevas señales, manteniendo un promedio de efectividad que se considera confiable.

4.1. Trabajo a futuro

- En la presente investigación se estudió un régimen de velocidad y par de carga consante, por lo que, en futuras investigaciones, se busca implementar estas técnicas para la detección y clasificación de fallas en diferentes escenarios de velocidad y par de carga variable.
- El banco de pruebas experimental trabaja en lazo abierto, por lo que se busca, en un futuro, un control de lazo cerrado y experimentar una nueva base de datos con los métodos empleados en la presente investigación
- La detección y clasificación de fallas se realizó fuera de línea, sin embargo, se puede considerar implementar los algoritmos en un sistema implementando una computadora Raspberry Pi para hacer el sistema más versátil manteniendo el mismo entorno de programación.

-
- Se priorizó un costo computacional bajo para mantener un tiempo de respuesta mínimo y lograr un sistema de detección y clasificación de fallas en tiempo real implementando comunicación entre el sistema actual y una Raspberry Pi para mantener un lenguaje de programación de alto nivel como Python.

Apéndice A

Nombre del apéndice A

En el siguiente apartado, se comparten los códigos realizados en python para la obtención de características del análisis con ondeleta haar, además de la creación de una red neuronal, su entrenamiento y posterior evaluación para calificar el desempeño de la red.

A.1. Obtención de características

```
import os
import math
import numpy as np
import pywt
import pandas as pd

def leer_senal_trifasica(ruta_txt):
    ia, ib, ic = [], [], []
    with open(ruta_txt, 'r') as f:
        for linea in f:
            partes = linea.strip().split()
            if len(partes) >= 4:
                try:
                    ia.append(float(partes[1]))
                    ib.append(float(partes[2]))
                    ic.append(float(partes[3]))
                except ValueError:
                    continue
```

```
return np.array(ia), np.array(ib), np.array(ic)
```

```
def modulo_isp_park(ia, ib, ic):  
alpha = (2/3)*(ia - 0.5*ib - 0.5*ic)  
beta = (2/3)*(math.sqrt(3)/2)*(ib - ic)  
return np.sqrt(alpha**2 + beta**2)
```

```
def rms(coefs):  
return np.sqrt(np.mean(coefs**2))
```

```
def energia(coefs):  
return np.sum(coefs**2)
```

```
def entropia(coefs):  
sq = coefs**2  
total = np.sum(sq)  
if total == 0:  
return 0.0  
p = sq / total
```

```
p = p[p > 0]  
return -np.sum(p * np.log(p))
```

```
def varianza(coefs):  
return np.var(coefs)
```

```
def extraer_caracteristicas_wavelet(isp, niveles=4, wavelet='haar'):  
coefs = pywt.wavedec(isp, wavelet=wavelet, level=niveles)  
caracteristicas = {}  
cA = coefs[0]  
caracteristicas[f"nivel{niveles}_aprox"] = {  
'rms': rms(cA),  
'energia': energia(cA),  
'varianza': varianza(cA)  
}  
for i in range(1, niveles+1):
```

```

cD = coefs[i]
nivel = niveles - i + 1
caracteristicas[f"nivel{nivel}_detalle"] = {
    'rms': rms(cD),
    'energia': energia(cD),
    'varianza': varianza(cD)
}
return caracteristicas

def procesar_carpeta_wavelet(ruta_carpeta, ruta_salida_excel):

    registros = []
    archivos = [f for f in os.listdir(ruta_carpeta) if f.lower().endswith('.txt')]
    archivos.sort()
    for nombre_arch in archivos:
        ruta_arch = os.path.join(ruta_carpeta, nombre_arch)
        ia, ib, ic = leer_senal_trifasica(ruta_arch)
        if ia.size == 0:
            continue
        isp = modulo_isp_park(ia, ib, ic)
        if len(isp) < 1024:
            isp = np.pad(isp, (0, 1024 - len(isp)), 'constant', constant_values=0)
        caracteristicas = extraer_caracteristicas_wavelet(isp, niveles=4, wavelet='haar')
        registro = {'archivo': nombre_arch}
        for clave, vals in caracteristicas.items():
            registro[f"{clave}_rms"] = vals['rms']
            registro[f"{clave}_energia"] = vals['energia']
            registro[f"{clave}_varianza"] = vals['varianza']
        registros.append(registro)

    df = pd.DataFrame.from_records(registros)
    df.to_excel(ruta_salida_excel, index=False)
    print(f"Características wavelet guardadas en: {ruta_salida_excel}")

if __name__ == "__main__":
    carpeta_txt =

```

```
salida_excel = "caracteristicas_wavelet_isp.xlsx"
procesar_carpeta_wavelet(carpeta_txt, salida_excel)
```

A.2. Entrenamiento de la red

```
import numpy as np
import pandas as pd
from sklearn.model_selection import train_test_split
```

```
def cargar_datos_wavelet_db4(ruta_excel):
```

```
    df = pd.read_excel(ruta_excel)
    nombres = df.iloc[:, 0].astype(str).values
    X = df.iloc[:, 1:].values
```

```
    Y = []
    for nombre in nombres:
        nombre_up = nombre.upper()
        if "SANO" in nombre_up:
            cls = 0
        elif "FALLA_T1" in nombre_up:
            cls = 1
        elif "FALLA_T2" in nombre_up:
            cls = 2
        elif "FALLA_T3" in nombre_up:
            cls = 3
        elif "FALLA_T4" in nombre_up:
            cls = 4
        elif "FALLA_T5" in nombre_up:
            cls = 5
        elif "FALLA_T6" in nombre_up:
            cls = 6
        elif "FALLA_T7" in nombre_up:
            cls = 7
        else:
```

```
continue
one_hot = [1 if i == cls else 0 for i in range(8)]
Y.append(one_hot)

return X[:len(Y)], np.array(Y)

def minmax_normalize(X):

    X = X.astype(float)
    mins = X.min(axis=0)
    maxs = X.max(axis=0)
    ranges = maxs - mins
    ranges[ranges == 0] = 1e-8
    X_norm = (X - mins) / ranges
    return X_norm, mins, maxs

def sigmoid(x):
return 1 / (1 + np.exp(-x))

def dsigmoid(y):
return y * (1 - y)

def softmax(z):
e = np.exp(z - np.max(z, axis=1, keepdims=True))
return e / e.sum(axis=1, keepdims=True)

def cross_entropy(pred, target):
eps = 1e-12
return -np.sum(target * np.log(pred + eps)) / pred.shape[0]

class MLP:
def __init__(self, n_inputs, n_hidden1, n_hidden2, n_outputs, lr=0.005):
self.lr = lr
self.w1 = np.random.uniform(-0.1, 0.1, (n_inputs, n_hidden1))
self.b1 = np.zeros((1, n_hidden1))
self.w2 = np.random.uniform(-0.1, 0.1, (n_hidden1, n_hidden2))
```

```
self.b2 = np.zeros((1, n_hidden2))
self.w3 = np.random.uniform(-0.1, 0.1, (n_hidden2, n_outputs))
self.b3 = np.zeros((1, n_outputs))
```

```
def forward(self, X):
    self.z1 = X.dot(self.w1) + self.b1
    self.a1 = sigmoid(self.z1)
    self.z2 = self.a1.dot(self.w2) + self.b2
    self.a2 = sigmoid(self.z2)
    self.z3 = self.a2.dot(self.w3) + self.b3
    self.a3 = softmax(self.z3)
    return self.a3
```

```
    def backward(self, X, Y):
        m = X.shape[0]
        dz3 = self.a3 - Y
        dw3 = self.a2.T.dot(dz3) / m
        db3 = np.sum(dz3, axis=0, keepdims=True) / m
```

```
        da2 = dz3.dot(self.w3.T)
        dz2 = da2 * dsigmoid(self.a2)
        dw2 = self.a1.T.dot(dz2) / m
        db2 = np.sum(dz2, axis=0, keepdims=True) / m
```

```
        da1 = dz2.dot(self.w2.T)
        dz1 = da1 * dsigmoid(self.a1)
        dw1 = X.T.dot(dz1) / m
        db1 = np.sum(dz1, axis=0, keepdims=True) / m
```

```
        self.w3 -= self.lr * dw3
        self.b3 -= self.lr * db3
        self.w2 -= self.lr * dw2
        self.b2 -= self.lr * db2
        self.w1 -= self.lr * dw1
        self.b1 -= self.lr * db1
```

```
def train(self, X, Y, epochs=500):
for epoch in range(epochs):
pred = self.forward(X)
loss = cross_entropy(pred, Y)
self.backward(X, Y)
if epoch
print(f"Epoch {epoch}, Loss: {loss:.4f}")

def predict(self, X):
return np.argmax(self.forward(X), axis=1)

if __name__ == "__main__":
ruta_excel = "caracteristicas_wavelet_db4.xlsx"
X, Y = cargar_datos_wavelet_db4(ruta_excel)
X_norm, mins, maxs = minmax_normalize(X)

X_train, X_val, Y_train, Y_val = train_test_split(
X_norm, Y, test_size=0.2, random_state=42
)

mlp = MLP(
n_inputs=X_train.shape[1],
n_hidden1=16,
n_hidden2=8,
n_outputs=8,
lr=0.005
)
mlp.train(X_train, Y_train, epochs=1000)

preds_val = mlp.predict(X_val)
reales_val = np.argmax(Y_val, axis=1)
acc_val = np.mean(preds_val == reales_val) * 100
print(f"Validación Accuracy: {acc_val:.2f} %")

np.savez(
"modelo_wavelet_db4.npz",
```

```
w1=mlp.w1, b1=mlp.b1,
w2=mlp.w2, b2=mlp.b2,
w3=mlp.w3, b3=mlp.b3,
mins=mins, maxs=maxs
)
print("Modelo guardado en modelo_wavelet_haar.npz")
```

A.3. Evaluador

```
import numpy as np
import pandas as pd
from openpyxl import load_workbook

def sigmoid(x):
    return 1 / (1 + np.exp(-x))

def softmax(z):
    e = np.exp(z - np.max(z, axis=1, keepdims=True))
    return e / e.sum(axis=1, keepdims=True)

def mlp_forward(X, model):

    w1, b1 = model['w1'], model['b1']
    w2, b2 = model['w2'], model['b2']
    w3, b3 = model['w3'], model['b3']

    z1 = X.dot(w1) + b1
    a1 = sigmoid(z1)
    z2 = a1.dot(w2) + b2
    a2 = sigmoid(z2)
    z3 = a2.dot(w3) + b3
    a3 = softmax(z3)
    return a3

def evaluar_wavelet_excel(ruta_excel, modelo_npz):
```

```
df = pd.read_excel(ruta_excel)
nombres = df.iloc[:, 0].astype(str).values
X_raw = df.iloc[:, 1:].values

data = np.load(modelo_npz)
model = {
    'w1': data['w1'], 'b1': data['b1'],
    'w2': data['w2'], 'b2': data['b2'],
    'w3': data['w3'], 'b3': data['b3']
}
mins = data['mins']
maxs = data['maxs']
ranges = maxs - mins
ranges[ranges == 0] = 1e-8

X_norm = (X_raw - mins) / ranges

probs = mlp_forward(X_norm, model)
clases = np.argmax(probs, axis=1)

for i, nombre in enumerate(nombres):
    vec_norm = X_norm[i]
    clase = int(clases[i])
    prob = probs[i]
    print(f"Fila {i+1} | Caso: {nombre}")
    print(f"Entrada normalizada: {np.round(vec_norm, 4)}")
    print(f"Clase predicha: {clase}")

if __name__ == "__main__":
    ruta_excel = "caracteristicas_wavelet_isp_haar.xlsx"
    modelo_npz = "modelo_wavelet_rms_isp_npz"
    evaluar_wavelet_excel(ruta_excel, modelo_npz)
```

