



Universidad Autónoma de Querétaro
Facultad de Ingeniería



Desarrollo e implementación FPGA de metodología basada en tiempo,
tiempo-frecuencia y aprendizaje automático para diagnóstico de fallos en
motores eléctricos

TESIS

Que como parte de los requisitos para obtener el título de
MAESTRO EN CIENCIAS (MECATRÓNICA)

Presenta:

Alvaro Iván Alvarado Hernández

Dirigido por:

Dr. Roque Alfredo Osornio Ríos

San Juan del Río, Qro., abril, 2024

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



CC BY-NC-ND 4.0 DEED

Atribución-NoComercial-SinDerivadas 4.0 Internacional

Usted es libre de:

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

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

Bajo los siguientes términos:



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



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



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

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

Avisos:

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

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



Universidad Autónoma de Querétaro

Facultad de Ingeniería



Desarrollo e implementación FPGA de metodología basada en tiempo,
tiempo-frecuencia y aprendizaje automático para diagnóstico de fallos en motores
eléctricos

TESIS

Que como parte de los requisitos para obtener el título de

MAESTRO EN CIENCIAS (MECATRÓNICA)

Presenta:

Alvaro Iván Alvarado Hernández

Dirigido por:

Dr. Roque Alfredo Osornio Ríos

SINODALES:

Dr. Roque Alfredo Osornio Ríos

Presidente

Dr. Israel Zamudio Ramírez

Secretario

Dr. Irving Armando Cruz Albarrán

Vocal

M.C. Geovanni Díaz Saldaña

Suplente 1

Dr. José Alfonso Antonino Daviú

Suplente 2

Dedicatoria

*A mis padres, hermana,
familia y amigos.
Por todo su apoyo y cariño.*

Agradecimientos

Agradezco a mis padres, Juan Alvaro y Celia Lucina, por su apoyo y cariño incondicional. Gracias por siempre creer en mí y apoyarme a cumplir mis metas.

A mi hermana, Diana Karen, por siempre acompañarme y por todo el apoyo moral y emocional que me brindó en esta etapa de mi vida.

A mí asesor, Dr. Roque Alfredo Osornio Ríos por el constante apoyo, retroalimentación, y consejo que me brindaron para la elaboración de este trabajo.

Al Dr. José Alfonso Antonino Daviú por haberme recibido en su laboratorio en las instalaciones de la Universidad Politécnica de Valencia, España, y por todo el apoyo brindado durante la estadía.

A los miembros del sínodo por el apoyo brindado en la revisión, edición y corrección del contenido presentado.

A todos los profesores y personal de trabajo de la Universidad Autónoma de Querétaro por el conocimiento y apoyo recibido.

Al CONAHCYT por el apoyo económico brindado a lo largo de la maestría.

A mis amigos y compañeros, por siempre motivarme a seguir adelante.

Índice general

Índice de tablas	vi
Índice de figuras	vii
1. Introducción	1
1.1. Antecedentes	2
1.1.1. Diagnóstico de fallos en motores	2
1.1.2. Técnicas de análisis en el dominio del tiempo	3
1.1.3. Técnicas de análisis en el dominio tiempo-frecuencia	5
1.1.4. Técnicas de Machine Learning	6
1.1.5. Termografía infrarroja en la detección de fallos en motores . .	8
1.2. Descripción del problema	10
1.3. Justificación	12
1.3.1. Social y Ambiental	12
1.3.2. Científica y Tecnológica	13
1.4. Hipótesis	14
1.5. Objetivos	14
1.5.1. General	14
1.5.2. Específicos	15
2. Fundamentación teórica	17
2.1. Motores de inducción	17
2.1.1. Principio de operación	18
2.1.2. Fallas en los motores eléctricos	21

2.2.	Técnicas de procesamiento de señales	22
2.2.1.	Técnicas en el dominio del tiempo	22
2.2.2.	Técnicas en el dominio de frecuencia	27
2.2.3.	Técnicas en el dominio de tiempo-frecuencia	27
2.3.	Termografía infrarroja	29
2.4.	Procesamiento de imágenes termográficas	30
2.4.1.	Análisis cuantitativo de la imagen termográfica	30
2.4.2.	Histograma de la imagen	31
2.5.	Técnicas de Machine Learning	31
2.5.1.	Técnicas de Aprendizaje Supervisado	33
2.6.	Tarjeta de Desarrollo PYNQ Z2	37
3.	Metodología	39
3.1.	Procesamiento de los datos	40
3.1.1.	Implementación de algoritmos en FPGA	43
3.1.2.	IP-core de procesamiento de imágenes termográficas	44
3.1.3.	IP-core de procesamiento de señales de corriente	47
3.2.	Puesta de experimentos	49
3.2.1.	Banco de pruebas con motor WEG	49
3.2.2.	Banco de pruebas con motor de la UPV	52
3.3.	Sistemas de adquisición de datos	55
3.3.1.	Adquisición de imágenes termográficas	55
3.3.2.	Adquisición de señales de corriente	57
4.	Resultados	60
4.1.	Implementación de algoritmos en FPGA	60

4.2. Adquisición de datos	61
4.3. Procesamiento de los datos	64
4.3.1. Análisis de imágenes termográficas	64
4.3.2. Análisis de corriente eléctrica	70
4.4. Clasificación de estados de falla	75
4.5. Publicaciones y aportaciones	76
5. Conclusiones	79
Bibliografía	81

Índice de tablas

2.1.	Velocidad de sincronismo (en rpm) según el número de polos del estator	20
2.2.	Ecuaciones para el cálculo de indicadores estadísticos (Dhamande y Chaudhari, 2018)	24
2.3.	Especificaciones técnicas de la tarjeta PYNQ Z2	38
3.1.	Especificaciones del motor WEG en el banco de pruebas	49
3.2.	Casos de estudio en motor de inducción WEG	50
3.3.	Especificaciones del motor en el banco de pruebas de la UPV	53
3.4.	Casos de estudio en motor de inducción de la UPV	54
3.5.	Especificaciones del sensor infrarrojo FLIR Lepton 3.5	56
4.1.	Utilización de recursos por IP-core de indicadores termográficos	61
4.2.	Utilización de recursos por IP-core de FFT	62
4.3.	Matriz de confusión de clasificador kNN con indicadores termográficos en motor WEG	76
4.4.	Matriz de confusión de clasificador SVM con indicadores termográficos en motor WEG	76
4.5.	Publicaciones realizadas en congresos durante el período de la investigación	77
4.6.	Publicaciones realizadas en revistas científicas durante el período de la investigación	78

Índice de figuras

2.1.	Distribución de campo magnético en un motor de 4 polos (Barnes, 2003)	19
2.2.	Fallos eléctricos y mecánicos en motores de inducción.	23
2.3.	Representación del cálculo de la STFT de una señal (Kehtarnavaz, 2008)	28
2.4.	Termograma infrarrojo de un cubo de cobre con paleta de colores aplicada (Vollmer y Moellmann, 2018)	30
2.5.	Ilustración de la aplicación del algoritmo de clasificación de K-Veinos Cercanos con $K = 3$. La observación de prueba se representa con una cruz negra. La clase más común en el área de prueba es azul por lo que el clasificador predice que x_0 es azul (James <i>et al.</i> , 2013)	34
2.6.	Separación de clases obtenida por un clasificador SVM. El margen representa la capacidad del clasificador de adaptarse a datos no contemplados en el entrenamiento (<i>Data Classification: Algorithms and Applications</i> , 2020)	36
3.1.	Diagrama general de la metodología	40
3.2.	Procesamiento de imágenes termográficas	42
3.3.	Procesamiento de señales de corriente eléctrica	42
3.4.	Metodología general para la implementación de un IP-core en la unidad FPGA de la tarjeta PYNQ Z2	44
3.5.	Metodología para el cálculo de media y desviación estándar de la imagen termográfica en PYNQ Z2	45
3.6.	Diagrama a bloques de la conexión de descripciones digitales en Vivado para el algoritmo de cálculo de estadísticos	46

3.7. Método para cálculo de STFT con la unidad FPGA de tarjeta PYNQ Z2	48
3.8. Banco de pruebas con motor de inducción trifásico WEG conectado a alternador mediante banda de transmisión	51
3.9. Fallo por desgaste en caja de engranes conectada a motor WEG	52
3.10. Banco de pruebas con motor de la UPV conectado a motor de c.c.	54
3.11. Sistema de adquisición de termogramas infrarrojos en banco de pruebas	56
3.12. Sistema de Adquisición de Datos usado para medir señales de corriente eléctrica en motor WEG	58
3.13. Sistema de Adquisición de Datos usado para medir señales de corriente eléctrica en motor de la UPV	59
 4.1. Capturas termográficas de motores de inducción: a) motor WEG, b) motor de la UPV	63
4.2. Señales de corriente adquiridas del motor WEG en estado sano	63
4.3. Termograma infrarrojo del motor WEG con pseudo color aplicado	65
4.4. Termograma infrarrojo coloreado del motor WEG con caja de engranes	66
4.5. Evolución de indicadores termográficos en motor WEG: a) Media, b) Desviación Estándar	66
4.6. Datos agrupados de los indicadores estadísticos evaluados en las imágenes termográficas en motor WEG	67
4.7. Resultados del análisis de media y desviación estándar en MATLAB	68
4.8. Termograma infrarrojo del motor UPV con pseudo color aplicado	69
4.9. Evolución de indicadores termográficos en motor UPV: a) Media, b) Desviación Estándar	69

4.10. Datos agrupados de los indicadores estadísticos evaluados en las imágenes termográficas en motor UPV	70
4.11. Diagramas de caja de los indicadores estadísticos más representativos de señales de corriente eléctrica. a) media, b) desviación estándar, c) factor de cresta, d) asimetría	71
4.12. Espectrogramas del análisis tiempo-frecuencial de señales de corriente eléctrica en motor WEG: a) Motor Sano, b) 1/2 Barra rota, c) 1 Barra rota, d) Desbalance, y e) Desalineamiento	73
4.13. Espectrogramas del análisis tiempo-frecuencial de señales de corriente eléctrica en motor WEG: a) Motor Sano, b) 1/2 Barra rota, c) 1 Barra rota, d) Desbalance, y e) Desalineamiento	74

Resumen

En este trabajo se implementaron algoritmos en una tarjeta de desarrollo con unidad lógica FPGA (*Field Programmable Gate Array*, arreglo de puertas lógicas programables en campo) para el diagnóstico de fallos en motores eléctricos. La metodología estuvo basada en el procesamiento de señales de corriente eléctrica a través de la aplicación de técnicas en el dominio del tiempo y técnicas en el dominio tiempo-frecuencia. Además, el análisis de termogramas infrarrojos se realizó mediante técnicas de procesamiento de imágenes. El sistema procesó los parámetros de ambos tipos de señal con técnicas de aprendizaje automático (también conocido como *Machine Learning*). El desarrollo del sistema de diagnóstico se hizo con implementaciones digitales en hardware utilizando una tarjeta Xilinx PYNQ Z2 que integra un FPGA junto a un microprocesador, aprovechando así las ventajas de la adquisición y procesamiento de señales e imágenes digitales en hardware. La adquisición y procesamiento de las señales de corriente eléctrica y las imágenes termográficas se realizó con el desarrollo en hardware de componentes digitales, permitiendo la aplicación de algoritmos supervisados de clasificación por aprendizaje automático para el diagnóstico automático del estado de fallo en los motores eléctricos estudiados.

Palabras clave: *FPGA, motor eléctrico, diagnóstico, termografía, corriente eléctrica, machine learning.*

Abstract

This thesis presents algorithm implementation on a FPGA (Field Programmable Gate Array) logic board to diagnose fault conditions in induction motors. The method was based on the processing of electric current signals through the application of time domain techniques and time-frequency domain techniques. In addition, the analysis of infrared thermograms was performed using image processing techniques. The system processed the parameters of both signal types with machine learning techniques. The development of the diagnostic system was done with digital hardware implementations using a Xilinx PYNQ Z2 board that integrates an FPGA together with a microprocessor, thus taking advantage of the benefits of digital signal and image acquisition and processing in hardware. The acquisition and processing of electric current signals and thermographic images was performed with the hardware development of digital logic cores, allowing the application of supervised machine learning classification algorithms for the automatic diagnosis of fault conditions in the selected induction motors.

Keywords: *FPGA, electric motor, diagnostics, thermal imaging, electric current, machine learning.*

Capítulo 1

Introducción

Este trabajo presenta el procesamiento de señales de corriente eléctrica así como el procesamiento de imágenes termográficas mediante la implementación de diversas técnicas estadísticas, tiempo-frecuenciales, y de *Machine Learning*, en una tarjeta de desarrollo con una unidad lógica programable FPGA (*Field Programmable Gate Array*) y un núcleo microprocesador para el diagnóstico de fallos en motores eléctricos. El contenido de este trabajo está organizado en seis capítulos:

1. El Capítulo 1 presenta una recopilación y discusión de trabajos antecedentes, la descripción del problema, la justificación para el trabajo, y los objetivos propuestos.
2. El Capítulo 2 recopila los fundamentos teóricos utilizados en la realización del trabajo.
3. El Capítulo 3 plantea la metodología propuesta en el trabajo para el desarrollo e implementación de técnicas de procesamiento en una FPGA para el diagnóstico de fallas en motores eléctricos.
4. El Capítulo 4 presenta los casos de estudio considerados para la validación del trabajo, describiendo las pruebas y experimentos realizados.
5. En el Capítulo 5 se discuten los resultados obtenidos tras la culminación de la etapa de experimentación.

6. El Capítulo 6 presenta las conclusiones y prospectivas del trabajo realizado.

1.1. Antecedentes

1.1.1. Diagnóstico de fallos en motores

Los motores de inducción tienen un papel fundamental en el sector industrial debido a que son máquinas robustas, eficientes y de bajo costo. Rangel-Magdaleno *et al.* (2013) estimaron que los motores de inducción representan un 85 % de la potencia eléctrica consumida por el sector industrial. El uso generalizado de estos equipos electromecánicos ha generado un interés en su monitoreo continuo pues a pesar de ser máquinas robustas, los cambios en el ambiente, errores en la instalación, o modificaciones a las condiciones de trabajo pueden generar fallas en los motores de inducción (Benbouzid, 2000). Las fallas en los motores de inducción pueden clasificarse en fallas eléctricas y fallas mecánicas, siendo estas últimas las más comunes reportándose en un 55 % de los casos (Gangsar y Tiwari, 2020). Se estima que el 41 % de las fallas reportadas en motores de inducción están localizadas en el balero (también conocido como cojinete o rodamiento) teniendo como causas principales de falla las siguientes condiciones: mala lubricación, fracturas y daños en el balero, sobrecarga en el rotor, desalineamiento del balero, vibraciones y sobrecalentamiento del motor. Las fallas en el estator representan un 28 % de los fallos en motores de inducción, el 9 % de las fallas se da en el rotor y el 22 % restante se presenta en otros componentes de la máquina rotatoria (Choudhary *et al.*, 2019). El monitoreo continuo y el mantenimiento predictivo permite al sector industrial optimizar la disponibilidad, confiabilidad y eficiencia de las máquinas rotatorias. Por esta razón se han aplicado diversas técnicas no destructivas para el diagnóstico de fallas electromecánicas en

los motores de inducción a través de la medición de magnitudes físicas tales como vibración mecánica, firma de corriente eléctrica (*MCSA, Motor Current Signature Analysis*) torque mecánico, sonidos acústicos y ruido, temperatura, fluctuaciones de velocidad, flujo magnético y voltaje inducido (Kumar *et al.*, 2019). Las señales adquiridas por los sensores son procesadas utilizando herramientas matemáticas en el dominio del tiempo, tiempo-frecuencia, y recientemente se han adoptado técnicas de aprendizaje automático, teniendo un gran auge como herramientas para obtener un diagnóstico de la condición de fallo del motor de inducción estudiado.

1.1.2. Técnicas de análisis en el dominio del tiempo

Las técnicas matemáticas para el análisis de señales en el dominio del tiempo han sido ampliamente aplicadas en diversos trabajos enfocados al diagnóstico de fallas en equipos electromecánicos. En la Universidad Autónoma de Querétaro se han hecho algunas investigaciones al respecto, tal es el caso del trabajo de Arellano Espitia (2018) quien desarrolló un sistema para el análisis estadístico-temporal de señales de vibraciones mecánicas, velocidad y corriente eléctrica de un motor de inducción para el diagnóstico de fallas por barra rota y rodamientos dañados. El procesamiento de las señales consistió en segmentar cada señal adquirida en ventanas de tiempo uniforme y se calcularon 15 indicadores estadísticos para cada segmento que fueron reducidos a dos indicadores significativos a través del Análisis de Componentes Principales (*Principal Component Analysis, PCA*). La clasificación se realizó por medio de una Red Neuronal (*Neural Network, NN*) obteniendo una precisión del 60 % con los parámetros de corriente eléctrica, 80 % con los indicadores de vibración, y 95 % al fusionar las magnitudes físicas con el Análisis Discriminante Lineal (*Linear Discriminant Analysis, LDA*). Otro trabajo local pertenece a Ramírez Chávez

(2019), en este se estudiaron señales de vibración mecánica y corriente eléctrica de un motor de inducción para la identificación de fallas de 1 mm y 2 mm en la pista interior de rodamientos metálicos y cerámicos. El procesamiento se realizó mediante la segmentación de las señales en ventanas uniformes de tiempo y el cálculo de ocho indicadores estadísticos. Los indicadores fueron reducidos a dos indicadores característicos usando el método PCA y las fallas fueron clasificadas con la herramienta de K-Vecinos Cercanos (*K-Nearest Neighbors, KNN*) obteniendo una precisión del 62 % en la clasificación de fallas en baleros cerámicos y 97 % para baleros metálicos.

Las técnicas de análisis de señales en el dominio del tiempo también han sido reportadas en diversos artículos a nivel internacional por diversos investigadores, tales es el caso de Nayana y Geethanjali (2017) quienes hicieron el análisis de las señales de vibración mecánica disponibles en la base de datos de la Universidad de la Reserva de Case Western (*Case Western Reserve University, CWRU*), que fueron adquiridas de un motor de inducción con potencia de 2 HP que presentaba fallas inducidas en la pista interna, pista externa, y en los elementos rotatorios de rodamientos metálicos. El trabajo propuso el uso de los siguientes indicadores: longitud de onda (*waveform length*), cambio en signo de la pendiente (*slope sign change*), integración simple de la señal (*simple signal integral*), amplitud de Wilson (*Wilson amplitude*), valor promedio absoluto (*mean absolute value*), y cruces por cero (*zero crossing*) calculados a partir de segmentos uniformes de las señales de vibración. La clasificación fue hecha mediante el método de ponderación de indicadores de Laplace en combinación con la herramienta LDA y obtuvieron una precisión del 98.94 % en la clasificación de 10 casos de falla en el rodamiento del motor de inducción. Toma y Kim (2021) analizaron señales de corriente eléctrica de un motor de inducción calculando 10 indicadores estadístico-temporales: media, mediana, desviación estándar, varianza, sumatoria, asimetría, curtosis, energía, RMS, y factor de cresta. Los indicadores

fueron clasificados con tres modelos distintos: una Máquina de Soporte Vectorial (*Support Vector Machine, SVM*), un Bosque Aleatorio (*Random Forest, RF*), y un clasificador KNN obteniendo una precisión del 99 % para la identificación de tres estados del motor de inducción: sano, falla en la pista interna del rodamiento y falla en la pista externa del rodamiento.

1.1.3. Técnicas de análisis en el dominio tiempo-frecuencia

Las técnicas en el dominio tiempo-frecuencia también han sido ampliamente utilizadas para el diagnóstico de fallas en máquinas eléctricas presentes en los procesos industriales. Dentro de la Universidad Autónoma de Querétaro se han realizado trabajos como el de Saucedo Dorantes (2017) quien propuso el uso de algoritmos inteligentes y técnicas de fusión de datos para el diagnóstico en la condición de sistemas electromecánicos o cadenas cinemáticas. La cadena cinemática fue instrumentada con sensores para la adquisición de señales de vibración mecánica, corriente eléctrica y temperatura del motor de inducción; las señales fueron procesadas con las técnicas frecuenciales de Transformada Rápida de Fourier (*Fast Fourier Transform, FFT*) y Cálculo de Densidad Espectral de Potencia (Power Spectral Density, PSD). La metodología propuesta en el trabajo fue capaz de clasificar 10 condiciones de falla en la cadena cinemática: 6 fallas asociadas al motor de inducción (sano, desalineamiento, desbalance, media barra rota, una barra rota, rodamiento dañado) y 4 severidades de falla en la caja de engranajes a través del cálculo de quince indicadores estadísticos del espectro frecuencial de las señales multivariables; los indicadores fueron fusionados a través de la técnica de LDA y clasificados por una red neuronal logrando una precisión promedio del 92 % en el diagnóstico de falla. Cureño Osornio (2020) analizó señales de flujo magnético triaxial adquiridas de un motor de inducción de 1 HP por

medio de sensores de efecto Hall con el objetivo de identificar la severidad de daño por erosión eléctrica en rodamientos mecánicos considerando cinco estados de falla (1 mm, 2mm, 3 mm, 4 mm y 5 mm) y un estado sano referencial. Las señales de flujo magnético fueron analizadas usando la FFT y la Transformada Discreta Wavelet (*Discrete Wavelet Transform, DWT*), a su vez se calcularon quince indicadores estadísticos de las transformaciones frecuenciales que fueron reducidos a dos características principales por el método de PCA logrando la diferenciación gráfica de los 6 casos de estudio planteados.

Estas técnicas tiempo-frecuenciales también han sido abordadas en conferencias y revistas científicas internacionales. El trabajo de Asad *et al.* (2021) se enfocó en modelar y experimentar el fenómeno de falla por barras rotas en motores de inducción a través del análisis de señales de corriente eléctrica usando la DWT para generar representaciones tiempo-frecuenciales. Los investigadores consideraron el uso de un filtro pasa-banda de respuesta infinita al impulso (*infinite impulse response, IIR*) con el fin de reducir la frecuencia fundamental de la señal y mejorar la legibilidad de las representaciones obtenidas por la DWT en el régimen transitorio, concluyendo que el método propuesto puede ser utilizado en conjunto con técnicas de *Machine Learning* para la identificación de barras dañadas en el rotor.

1.1.4. Técnicas de Machine Learning

Cao *et al.* (2018) presentaron el análisis de señales de vibración mecánica por medio de una Red Neuronal Convolutacional (*Convolutional Neural Network, CNN*) en conjunto con una técnica matemática de Transferencia del Aprendizaje (*Transfer Learning*) para el diagnóstico de fallas en cajas de engranes conectadas a un motor de inducción, evaluando cuatro casos de estudio. La CNN toma como entrada

imágenes en escala de grises que representan la evolución en el dominio del tiempo de las señales adquiridas. El entrenamiento de la red neuronal se realizó en una GPU (*Graphics Processing Unit*, Unidad de Procesamiento de Gráficos) para compensar la carga computacional de la tarea. La arquitectura de la red fue capaz de detectar automáticamente indicadores significativos para la clasificación y diagnóstico de los fallos. La transferencia de aprendizaje utilizada permitió a los autores reducir el tamaño de la base de datos para el entrenamiento del clasificador usando 10 señales por fallo y obteniendo una precisión del 99.41 %. Jing *et al.* (2017) implementaron una red neuronal convolucional para encontrar indicadores en señales de vibración que permitieran diferenciar entre siete condiciones de operación (es decir: una sana y seis en fallo) de una caja de engranes planetaria conectada a un motor de inducción trifásico. Los investigadores compararon la clasificación obtenida por CNN con los resultados obtenidos por indicadores regulares clasificados por clasificadores SVM y RF, concluyendo que la mejora en la precisión del diagnóstico mejoraba con la aplicación de una CNN de un 92 % a un 98 %. Shao *et al.* (2017) implementaron un modelo de aprendizaje profundo basado en una Red de Creencias Profunda (*Deep Belief Network*, *DBN*) para el diagnóstico de fallos en motores de inducción usando señales de vibración mecánica. Los investigadores transformaron las señales al dominio frecuencial mediante la FFT para usar la distribución frecuencial como entrada para la red de clasificación. La arquitectura de la DBN consideró 1000 neuronas en la capa de entrada, cuatro capas ocultas con 500 neuronas cada una y una capa de salida de seis neuronas para los seis casos de estudio considerados: cortocircuito en el estator, desbalance, rodamiento dañado, barra del rotor rota, flexión en el rotor, y motor sano. El método obtuvo una precisión del 99.9 % en la clasificación de los fallos. Toma *et al.* (2020) analizaron señales de corriente eléctrica de un motor de inducción mediante algoritmos genéticos (*Genetic Algorithms*, *GA*) para seleccionar

los indicadores estadísticos calculados en el dominio del tiempo que otorguen la información más significativa para el diagnóstico de fallas en el rodamiento del motor. Los indicadores seleccionados por el algoritmo genético fueron usados en tres técnicas de clasificación: KNN, árbol de decisión (Decision Tree, DT), y bosque aleatorio con una precisión de clasificación de 97 %, 98 %, y 99 % respectivamente para tres casos de estudio en el rodamiento: sano, falla en pista interna, falla en pista externa.

1.1.5. Termografía infrarroja en la detección de fallos en motores

Enríquez Ugalde (2020) planteó una metodología para el procesamiento de imágenes termográficas en MATLAB a través del cálculo de indicadores estadístico-temporales a partir del histograma de la imagen para el diagnóstico de fallas en motores de inducción. Se utilizó una cámara termográfica marca FLIR y su software comercial para la adquisición y pre-procesamiento de 117 termogramas por caso de estudio. La clasificación se enfocó en el diagnóstico de tres estados de falla (balero dañado, desalineamiento, desbalance mecánico) usando los indicadores de entropía y desviación estándar del histograma de la imagen en un clasificador de Vecinos Cercanos (*Nearest Neighbors, NN*). Reséndiz Ochoa (2020) diseñó un sistema para la identificación de fallas en motores de inducción basado en el procesamiento de termogramas infrarrojos. El sistema fue implementado con las librerías de OpenCV en el lenguaje de programación C++. La metodología propuesta en el trabajo consistió en la segmentación automática de regiones de interés a través del método de Otsu, el cálculo de un indicador de temperatura y el área de la región de interés. El sistema clasificó las fallas usando un árbol de decisiones para clasificar las siguientes fallas: una barra rota, falla en el rodamiento, desalineamiento, y falla en los engranes.

Choudhary *et al.* (2021) diseñaron un sistema para el procesamiento de termogramas infrarrojos orientado al diagnóstico de fallas en el rodamiento considerando cuatro casos de estudio: sano, falla en pista interna, falla en pista externa, y falta de lubricación. Los termogramas infrarrojos fueron procesados usando una Transformada Wavelet Discreta Bidimensional (2D-DWT) con el objetivo de reducir el ruido y mejorar la calidad de las imágenes. Calcularon 10 indicadores estadísticos de los termogramas procesados, estos fueron normalizados en un rango de 0 a 1. El sistema consideró la selección de características usando la técnica de PCA junto al criterio de la Distancia de Mahalanobis reduciendo así la cantidad de indicadores significativos a seis. La clasificación de los fallos se realizó mediante una SVM obteniendo una precisión promedio del 97.9 %. Por otro lado, Khanjani y Ezoji (2021) adquirieron y procesaron termogramas infrarrojos de un motor de inducción trifásico para la detección de fallos eléctricos en los devanados del estator. La metodología consistió en segmentar la región de interés (*Region of Interest, ROI*) asociada al motor de inducción usando técnicas de segmentación automática y preparar las ROIs para que una red neuronal convolucional pre-entrenada encontrara características del estado de falla del motor. La red contaba con cinco capas de convolución con las que transformó cada termograma en un vector de características. Los vectores fueron clasificados en dos categorías usando un clasificador KNN y un clasificador SVM se utilizó para diferenciar seis casos de falla eléctrica en el motor de inducción. Mahami *et al.* (2021) presentaron una metodología para el análisis de imágenes termográficas infrarrojas de un motor de inducción basada en la utilización del método SURF (*Speeded Up Robust Feature*) que consiste en el cálculo de descriptores invariantes en la imagen. Los descriptores fueron organizados en una “Bolsa de Palabras Visuales” (*Bag of Visual Words, BoVW*) para ser clasificados en ocho casos de falla eléctrica por medio de un Árbol Extremadamente Aleatorio (*Extremely Randomized Tree*,

ERT).

Si bien la mayoría de los trabajos discutidos en esta sección reportaron resultados satisfactorios para la clasificación y diagnóstico de fallas en motores de inducción, trasciende que el procesamiento de las señales o termogramas se llevó a cabo en una PC después de la adquisición de los datos estudiados, es decir, el diagnóstico se realizó fuera de la línea de producción estudiada. Esto lleva a que la mayoría de los algoritmos actualmente reportados están implementados en software. La implementación en hardware de algoritmos permitirá la creación de sistemas embedidos eficientes que puedan realizar el diagnóstico automático de fallos en motores eléctricos mientras estos se encuentran en operación (diagnóstico online). Además, en los trabajos existentes se reporta el procesamiento de un solo tipo de señal física para el diagnóstico de un número limitado de fallas, por ejemplo: el análisis de señales de corriente eléctrica se ha utilizado para diagnosticar fallos en las barras del rotor o en los baleros pero no se ha reportado la aplicación de esta variable física para la detección de fallos en la caja de engranes. Finalmente, también se ha encontrado que la fusión de señales de corriente y termogramas infrarrojos no ha sido ampliamente reportada para el diagnóstico de fallos en motores eléctricos.

1.2. Descripción del problema

Hoy en día, los motores de inducción tienen un papel fundamental en los procesos de manufactura y producción a nivel mundial. Es por esta razón que el mantenimiento de estos equipos electromecánicos es esencial para el sector productivo, sin embargo, las empresas suelen priorizar el mantenimiento preventivo y correctivo. El mantenimiento predictivo consiste en la medición de las variables físicas asociadas al funcionamiento de los equipos mediante la instrumentación de sensores para su

análisis. Esta instrumentación no debe ser invasiva o afectaría negativamente el desempeño de los motores de inducción que monitorea. Actualmente, diversos trabajos en la literatura reportan el uso de técnicas no invasivas para el monitoreo continuo de motores de inducción, siendo la corriente eléctrica una de las variables físicas más relevantes. Esta señal ha sido utilizada en diversos trabajos reportados en la literatura pues permite la utilización de herramientas matemáticas de procesamiento en el dominio del tiempo, el dominio frecuencial, y el dominio tiempo-frecuencia y la instrumentación es no invasiva. Sin embargo, la mayoría de los trabajos reportados se enfoca en estudiar únicamente las señales de corriente de motores de inducción para un número reducido de casos de falla sin considerar el impacto que la condición de fallo en el motor de inducción puede tener sobre otros fenómenos físicos como la temperatura. La temperatura es otra variable física que puede ser medida gracias a técnicas no invasivas como la termografía infrarroja. Sin embargo, la mayoría de los sistemas de monitoreo basados en termografía infrarroja utilizan cámaras infrarrojas comerciales de alto costo junto al software propietario de arquitectura cerrada para la adquisición y pre-procesamiento de los termogramas lo que incrementa el costo de la implementación de termografía infrarroja en sistemas de diagnóstico y a su vez provoca que el análisis de los termogramas tenga que realizarse fuera de la línea de producción. A su vez, la mayoría de los trabajos ha implementado las técnicas para el procesamiento de señales en computadoras fuera de línea lo que impide un monitoreo continuo de la condición del motor de inducción, esto debido a que la mayoría de los sistemas de diagnóstico han sido implementados en computadoras y no en sistemas de hardware-software dedicados. Por último, las técnicas descritas en la literatura para el procesamiento de señales están enfocadas en la detección de un número limitado de fallas en los motores de inducción, o bien, los trabajos se enfocan en estudiar solamente una variable física, limitando la cantidad de fallas que

pueden ser detectadas en el motor de inducción por un solo sistema de adquisición y procesamiento de datos.

1.3. Justificación

1.3.1. Social y Ambiental

El monitoreo continuo de los motores de inducción permite realizar un diagnóstico temprano de fallas electromecánicas. El diseño e implementación de un sistema de hardware que integre diversos algoritmos para el procesamiento de señales de corriente e imágenes termográficas tendrá utilidad en la aplicación de mantenimiento predictivo en los motores eléctricos, prolongando la vida útil de los equipos y reduciendo la necesidad de reemplazar y desechar el motor defectuoso. La detección oportuna de fallos en motores eléctricos con ayuda del sistema de hardware propuesto permitirá a los técnicos e ingenieros de mantenimiento la corrección temprana de las causas de falla en el motor, con esto se reducirá el riesgo de accidentes en el área de trabajo industrial que puedan afectar a la integridad del personal. La presencia de fallas en los motores eléctricos provoca la caída de la eficiencia en estas máquinas y por esta razón los motores en fallo aumentan considerablemente el consumo de energía eléctrica del sector industrial. La implementación del sistema de diagnóstico propuesto ayudará a reducir las fugas energéticas provocadas por la existencia de fallas en los motores, lo que impacta positivamente al ambiente al reducir los requerimientos energéticos de la industria.

1.3.2. Científica y Tecnológica

La adquisición y procesamiento de datos por medio de algoritmos en los dominios del tiempo y tiempo-frecuencia, así como la aplicación de técnicas de aprendizaje automático en un sistema de monitoreo de motores de inducción complementará los programas de mantenimiento para estos equipos al ser una herramienta predictiva-correctiva. El uso de la termografía infrarroja para la medición sin contacto de la temperatura del motor de inducción es una opción no invasiva que permite a su vez el uso de técnicas espaciales diseñadas para el procesamiento de imágenes digitales. La instrumentación de una cámara termográfica infrarroja de bajo costo y el preprocesamiento de las imágenes sin necesidad de un software comercial harían posible la reducción del costo monetario del sistema automático de monitoreo. La aplicación de técnicas de aprendizaje automático enfocadas al análisis de imágenes complementará el análisis de las señales de corriente eléctrica en los dominios del tiempo y tiempo-frecuencia para el diagnóstico de fallas en motores de inducción. La aplicación de los algoritmos en una FPGA permitirá aprovechar la naturaleza reprogramable de estos equipos para lograr optimizar los recursos computacionales logrando una correcta implementación de los algoritmos en un sistema embebido. Aunado a ello, la adquisición de señales de múltiples variables físicas del motor de inducción (corriente eléctrica y temperatura) permitirá generalizar el sistema de diagnóstico a distintos casos de falla comunes en los motores. La aportación principal del trabajo radica en el desarrollo de una metodología que integre diversas técnicas de procesamiento de señales en los dominios del tiempo y tiempo-frecuencia, técnicas de procesamiento de imágenes, y técnicas de aprendizaje automático para ser implementadas en una plataforma de desarrollo que combina software y hardware. La implementación digital de los algoritmos de procesamiento permitirá al sistema de diagnóstico ad-

quirir y procesar señales de corriente eléctrica y termogramas infrarrojos, calculando indicadores de fallo y fusionando la información con los algoritmos de aprendizaje automático para otorgar un diagnóstico efectivo de la condición de falla en motores eléctricos.

1.4. Hipótesis

El conocimiento de las diferentes técnicas de procesamiento de señales de corriente e imágenes termográficas en el dominio del tiempo, tiempo-frecuencia y con técnicas de *Machine Learning* permitirá la generación de una metodología basada en la selección de las técnicas más adecuadas para la detección de diferentes fallos en motores de inducción; asimismo, ayudará a mejorar los parámetros de eficiencia (precisión, tiempos de cómputo, carga computacional) de un sistema automático de procesamiento con algoritmos diseñados en FPGA para la detección de fallas en motores de inducción en comparación con otros sistemas reportados en la literatura y/o sistemas comerciales.

1.5. Objetivos

1.5.1. General

Desarrollar e implementar un sistema de procesamiento en una tarjeta con arquitectura FPGA compuesto por la programación en software y descripción digital de diversas técnicas en los dominios: tiempo, tiempo-frecuencia y de Machine Learning, para el procesado de datos provenientes de diversos sensores enfocados al diagnóstico automático de fallos en motores eléctricos.

1.5.2. Específicos

1. Estudiar las técnicas en el tiempo, tiempo-frecuencia y de Machine Learning más reportadas en la literatura para detección de diversos fallos en motores de inducción con la intención de seleccionar las más adecuadas para la detección de fallas en el rodamiento y en la caja de engranes.
2. Realizar la simulación de las técnicas seleccionadas a implementar mediante MATLAB y los datos de señales (termográficas, corriente) adquiridos en bancos de pruebas donde esté incluido un motor de inducción, para generar la estrategia de implementación digital.
3. Programar en la tarjeta Xilinx PYNQ Z2 las técnicas de procesamiento seleccionadas y simuladas para la detección de diferentes estados de falla en motores eléctricos con señales de termografía infrarroja y corriente eléctrica de un banco de datos.
4. Establecer una interfaz para visualizar los resultados del procesamiento de las señales digitales de corriente eléctrica y termografía infrarroja de motores de inducción.
5. Validar el funcionamiento del sistema de procesamiento diseñado en FPGA para el diagnóstico automático de las fallas seleccionadas y las variables físicas a procesar, mediante la experimentación en una cadena cinemática que incluya un motor de inducción.
6. Comparar los resultados obtenidos del sistema respecto a otros trabajos o sistemas reportados en la literatura o comerciales, utilizando parámetros como

eficiencia, tiempo de procesamiento y/o carga computacional para concluir con el desempeño del sistema propuesto.

Capítulo 2

Fundamentación teórica

En este capítulo se muestra el contenido teórico que fundamentó el desarrollo del trabajo presentado. Primero, se presenta una introducción acerca de los componentes principales y el principio de funcionamiento del motor de inducción, uno de los tipos de motores eléctricos con mayor presencia en el sector industrial. Posteriormente se aborda los tipos de falla en los motores eléctricos. También se presentan las técnicas para el procesamiento de señales en el dominio del tiempo y tiempo-frecuencia, una introducción a la termografía infrarroja y el procesamiento de imágenes termográficas, y las técnicas para la clasificación de datos por *Machine Learning*.

2.1. Motores de inducción

El motor de inducción es una máquina asíncrona que convierte la energía eléctrica en energía mecánica. Karmakar *et al.* (2016) indican que los componentes principales de un motor de inducción son: el estator, el rotor y el rodamiento. El movimiento del rotor se genera al proveer energía eléctrica al bobinado del estator.

El estator está formado por un marco cilíndrico hecho de acero, hierro colado, o aluminio; dentro del soporte se encuentra el núcleo magnético. El núcleo está compuesto por láminas magnéticas con el objetivo de reducir las corrientes parásitas (o corrientes de Foucault) en el motor, reduciendo así las pérdidas de eficiencia y

disminuyendo la generación de calor. Finalmente, el estator cuenta con un conjunto de bobinados eléctricos aislados que están colocados en las ranuras del núcleo. Los motores trifásicos cuentan con tres bobinados de estator, uno asociado a cada fase eléctrica.

El rotor del motor es el otro componente fundamental de cualquier motor de inducción. Existen dos tipos de rotores: el rotor bobinado y el rotor con jaula de ardilla. Saad *et al.* (2018) indican que el rotor de jaula de ardilla es más común pues resulta más económico y robusto que el rotor bobinado, además, mencionan que el motor con rotor de jaula de ardilla es preferido para aplicaciones a altas velocidades. La jaula de ardilla está compuesta por barras conductoras cortocircuitadas entre sí por anillos conductores. Las barras conductoras suelen estar fabricadas con aluminio o cobre. El rotor de jaula de ardilla no tiene aislamiento eléctrico con el objetivo de permitir el flujo de corriente eléctrica.

Todo motor de inducción cuenta con al menos dos rodamientos que soportan al eje rotatorio, asegurando su posición dentro del motor y reduciendo la fricción en el rotor. Adicionalmente, los motores de inducción actuales cuentan también con un ventilador para enfriar al estator y rotor, así como una terminal de conexiones para recibir la energía eléctrica de alimentación.

2.1.1. Principio de operación

Al conectar una fuente de alimentación de corriente alterna (CA) trifásica a las terminales de un motor de inducción se generan corrientes trifásicas en los embobinados del estator. Estas corrientes eléctricas generan un flujo magnético que rota dentro del estator y atraviesa el núcleo magnético del motor como lo muestra la Figura 2.1.

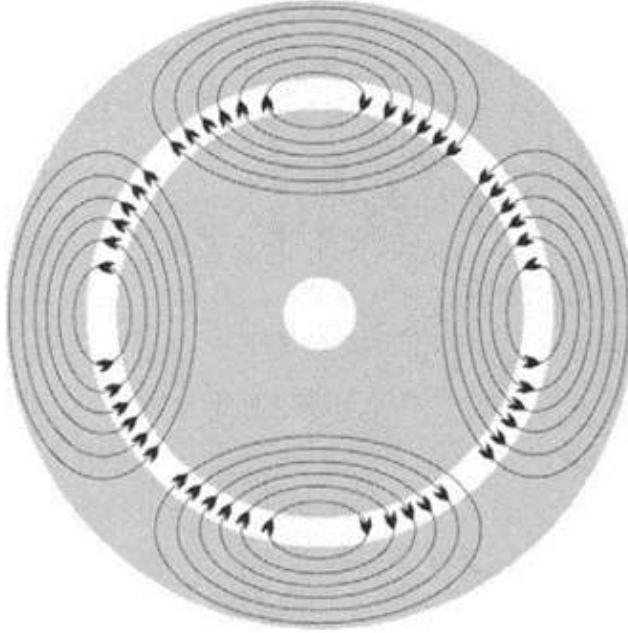


Figura 2.1: Distribución de campo magnético en un motor de 4 polos (Barnes, 2003)

La velocidad de rotación del campo magnético está sincronizada con la frecuencia de la tensión trifásica de alimentación, a esto se le conoce como velocidad de sincronismo. En una frecuencia de operación de 60 Hz, el campo magnético de un motor de 2 polos gira a 60 revoluciones por segundo, o bien, a 3600 rpm. La velocidad de sincronismo n_0 (en rpm) de un motor con p pares de polos trabajando con una frecuencia nominal f (en Hz) está dada por la ecuación (2.1):

$$n_0 = \frac{60f}{p} \quad (2.1)$$

En consecuencia, los motores de inducción pueden ser diseñados y manufacturados con el número de polos necesarios para adaptarse a la velocidad requerida por distintas aplicaciones como se observa en la Tabla 2.1

Tabla 2.1: Velocidad de sincronismo (en rpm) según el número de polos del estator

Polos	Frecuencia	50 Hz	60 Hz
2		3000	3600
4		1500	1800
6		1000	1200
8		750	900

El campo magnético rotatorio induce un voltaje en las barras conductoras del rotor, que de acuerdo a la Ley de Faraday tiene una magnitud proporcional a la tasa de cambio del flujo magnético. Como las barras conductoras se encuentran en corto circuito por los anillos conectores se genera un flujo de corriente eléctrica en las barras que a su vez genera un campo magnético. El campo magnético del rotor interactúa con el campo magnético rotatorio en el estator, generando el par rotacional del motor de inducción. En el arranque del motor, el rotor se encuentra estacionario por lo que el flujo magnético del estator atraviesa al rotor a la velocidad de sincronismo, induciendo el máximo valor de tensión en las barras, y en consecuencia, produciendo el valor máximo de corriente en el rotor. Cuando la velocidad del rotor es cercana a la velocidad de sincronismo, la magnitud y la frecuencia del voltaje en las barras disminuye considerablemente. Si el rotor alcanzara la velocidad de sincronismo en un estado *sin carga*, el voltaje inducido (y la corriente) en el rotor sería cero por lo que desaparecería el campo magnético del rotor, eliminando el par del rotor. Para mantener el par motriz, el rotor debe rotar a una velocidad menor o mayor a la velocidad de sincronismo, la diferencia de velocidades es conocida como el desplazamiento del motor (s) y suele expresarse en unidades porcentuales que varían

del 1 % al 6 %, por lo que la velocidad de rotación real del eje de un motor puede expresarse por la ecuación (2.2):

$$n = n_0(1 - s) \quad (2.2)$$

Donde n es la velocidad de rotación real (en revoluciones por minuto, rpm), n_0 es la velocidad de sincronismo del rotor (en rpm), y s es el desplazamiento del motor (expresado en por unidad, p. u.). La dirección de rotación del eje motriz depende de la secuencia en que se encuentran conectadas las fases de la tensión de alimentación en los embobinados del estator, si dos fases intercambian de lugar en la secuencia, el motor comenzaría a girar en dirección inversa a la dirección inicial (Barnes, 2003).

2.1.2. Fallas en los motores eléctricos

Los motores de inducción se ven expuestos a distintas condiciones adversas en su funcionamiento. Saad *et al.* (2018) presentaron algunas de las causas más comunes para fallos en los motores de inducción: mala ventilación en el área de trabajo, lubricación deficiente, vibración mecánica de la estructura, sobrecarga, arranque y paro continuo del motor, alimentación incorrecta del motor (tensión y corriente), errores en el mantenimiento, líneas de tensión de alimentación inestables, mala conexión a tierra, y condiciones extremas en el medio ambiente (temperatura, humedad, presión). La existencia de fallos en el motor de inducción repercute en el funcionamiento de la máquina, la cual llega a presentar tensiones y corrientes desbalanceadas en el estator, oscilaciones en el torque, reducción en la eficiencia y torque, sobrecaleamiento, y vibraciones excesivas. Asimismo, los fallos en el motor de inducción pueden generar o incrementar las componentes armónicas de las señales de tensión y

corriente. Las fallas en el motor de inducción se clasifican en fallas eléctricas y fallas mecánicas (Karmakar *et al.*, 2016). La Figura 2.2 muestra un mapa conceptual que ilustra la clasificación de los fallos más comunes en motores de inducción recopilados por Choudhary *et al.* (2019) quienes a su vez indican que los fallos más comunes están asociados con los rodamientos llegando a representar un 51 % de los fallos reportados. El 16 % se reporta en el estator del motor, 7 % de los fallos corresponde a fallas en el rotor o en el acoplamiento del rotor con la carga, 16 % se asigna a fallos por condiciones externas al motor como humedad o calor y el 10 % restante se adjudica a otras causas.

2.2. Técnicas de procesamiento de señales

En esta sección se compilan técnicas para el procesamiento de las señales de corriente eléctrica de los motores de inducción basadas en el análisis del dominio del tiempo y en el dominio tiempo-frecuencia.

2.2.1. Técnicas en el dominio del tiempo

El análisis de señales por medio de técnicas en el dominio del tiempo es uno de los métodos más sencillos pero eficaces para obtener información del estado de un motor de inducción. Uno de los enfoques más sencillos consiste en calcular la energía de la señal adquirida, esta técnica supone que conforme el estado de falla en el motor se deteriora, la energía aumentará. Otro enfoque relevante consiste en el cálculo de parámetros estadísticos de la señal. Estos parámetros estadísticos pueden ser calculados al tratar la señal a monitorear como una variable aleatoria haciendo posible el cálculo de los siguientes parámetros estadísticos: media, valor máximo,

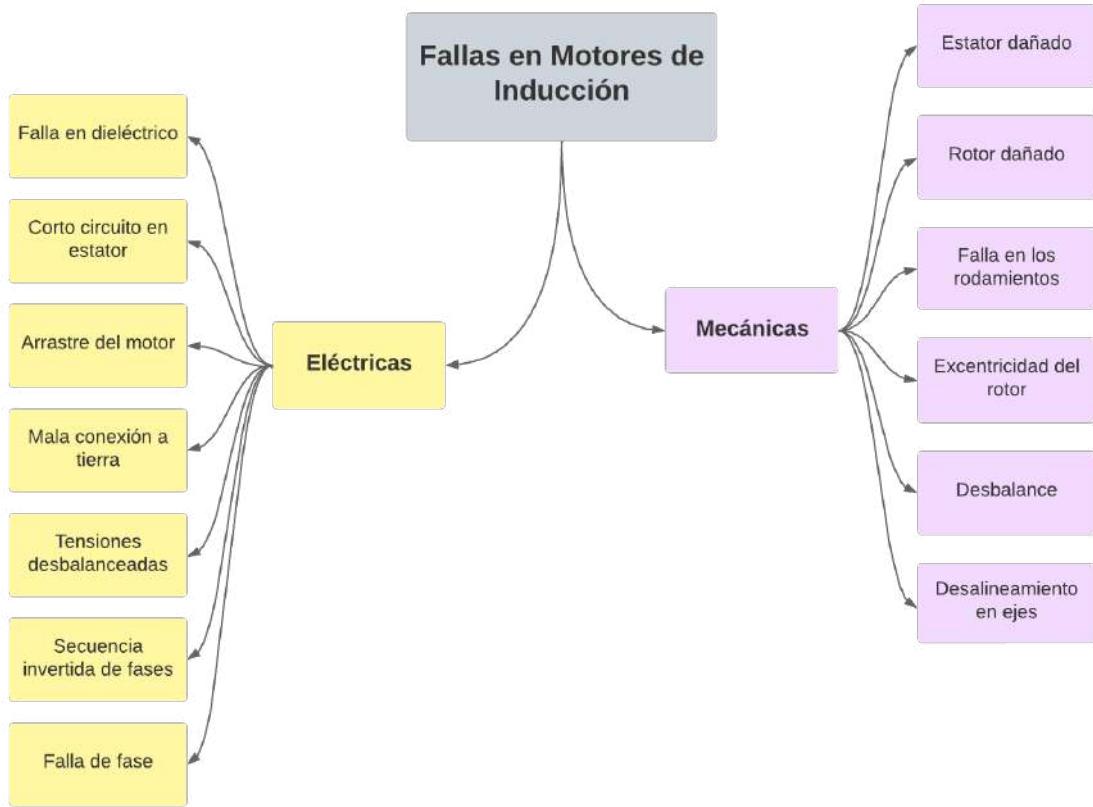


Figura 2.2: Fallos eléctricos y mecánicos en motores de inducción.

media cuadrática (*RMS*, *root mean square*), media cuadrada de raíces (*SMR*, *squared mean root*), desviación estándar, varianza, factor de forma con RMS, factor de forma con SMR, factor de cresta, factor de latitud, factor de impulso, asimetría, curtosis, 5º momento y 6º momento (Dhamande y Chaudhari, 2018).

La Tabla 2.2 lista las ecuaciones para el cálculo de quince indicadores estadísticos del dominio temporal de una señal discreta, donde $x(n)$ representa la señal discreta definida para N instantes de tiempo uniformes y constantes, los quince indicadores estadísticos previamente listados se representan en las ecuaciones (2.3) a

(2.17) usando la siguiente convención: $T_1, T_2, T_3, \dots, T_{15}$.

Tabla 2.2: Ecuaciones para el cálculo de indicadores estadísticos (Dhamande y Chaudhari, 2018)

Indicador estadístico	Ecuación
Media	$T_1 = \frac{\sum_{n=1}^N x(n)}{N} \quad (2.3)$
Valor máximo	$T_2 = \max x(n) \quad (2.4)$
Media cuadrática (RMS)	$T_3 = \sqrt{\frac{\sum_{n=1}^N (x(n))^2}{N}} \quad (2.5)$
SMR	$T_4 = \left(\frac{\sum_{n=1}^N \sqrt{ x(n) }}{N} \right)^2 \quad (2.6)$

Desviación Estándar	$T_5 = \sqrt{\frac{\sum_{n=1}^N (x(n) - T_1)^2}{N - 1}}$ (2.7)
Varianza	$T_6 = \frac{\sum_{n=1}^N (x(n) - T_1)^2}{N - 1}$ (2.8)
Factor de forma con RMS	$T_7 = \frac{T_3}{\frac{1}{N} \sum_{n=1}^N x(n) }$ (2.9)
Factor de forma con SMR	$T_8 = \frac{T_4}{\frac{1}{N} \sum_{n=1}^N x(n) }$ (2.10)
Factor de cresta	$T_9 = \frac{T_2}{T_3}$ (2.11)
Factor de latitud	$T_{10} = \frac{T_2}{T_4}$ (2.12)

Factor de impulso	$T_{11} = \frac{T_2}{\frac{1}{N} \sum_{n=1}^N x(n) }$ (2.13)
Asimetría	$T_{12} = \frac{1}{N} \cdot \frac{\sum_{n=1}^N (x(n) - T_1)^3}{T_5^3}$ (2.14)
Curtosis	$T_{13} = \frac{1}{N} \cdot \frac{\sum_{n=1}^N (x(n) - T_1)^4}{T_5^4}$ (2.15)
5º momento	$T_{14} = \frac{1}{N} \cdot \frac{\sum_{n=1}^N (x(n) - T_1)^5}{T_5^5}$ (2.16)
6º momento	$T_{15} = \frac{1}{N} \cdot \frac{\sum_{n=1}^N (x(n) - T_1)^6}{T_5^6}$ (2.17)

2.2.2. Técnicas en el dominio de frecuencia

Transformada Discreta de Fourier, DFT

La transformada discreta de Fourier (*Discrete Fourier Transform*, DFT) es el equivalente de la transformada continua de Fourier para señales discretas cuyo valor se conoce solo en N instantes de tiempo separados entre sí por intervalos T de tiempo. La DFT de una señal discreta $x[n]$ está dada por:

$$X[k] = \sum_{n=0}^{N-1} x[n]W_N^{nk} \quad (2.18)$$

Donde $k = 0, 1, \dots, N - 1$ y $W_N = e^{-j2\pi/N}$. La implementación de este cálculo requiere N multiplicaciones complejas y N sumas complejas para cada término. Para los N términos de la señal discreta se requerirían N^2 multiplicaciones complejas y $N^2 - N$ sumas complejas. Por lo que no es un algoritmo eficiente. Es por esta razón que existen alternativas que aprovechan las propiedades simétricas de la DFT para lograr un algoritmo más eficiente, a estos algoritmos se les conoce como Transformada Rápida de Fourier. Como existen diversas formas de optimizar el algoritmo, existen diversas interpretaciones de la FFT (Kehtarnavaz, 2008).

2.2.3. Técnicas en el dominio de tiempo-frecuencia

Transformada de Fourier de Tiempo Corto, STFT

La Transformada de Fourier de Tiempo Corto (*Short Time Fourier Transform*, STFT) es una secuencia de transformadas de Fourier en una señal seccionada en ventanas. Esta técnica proporciona el espectro frecuencial en periodos de tiempo localizados, esto resulta útil en situaciones donde la respuesta frecuencial de la señal

es variable respecto al tiempo. La STFT para señales discretas está definida por la ecuación (2.19):

$$X_{STFT}[m, n] = \sum_{k=0}^{L-1} x[k]g[k - m]e^{-j2\pi nk/L} \quad (2.19)$$

Donde $x[k]$ denota una señal y $g[k]$ es la función de ventana. La STFT puede ser interpretada como la Transformada de Fourier del producto $x[k]g[k - m]$. El proceso de cálculo de la STFT se ilustra en la Figura 2.3. La visualización de la STFT es posible a través de su espectrograma donde se gráfica la magnitud (m) de la STFT respecto al tiempo. Existe un intercambio entre la resolución en tiempo y frecuencia de la STFT. Una ventana estrecha produce una mejor resolución en el tiempo pero genera una mala resolución en el dominio de frecuencia, y viceversa. La visualización del análisis por STFT generalmente se hace mediante su espectrograma pues representa graficamente la magnitud de la STFT respecto a los ejes de tiempo y frecuencia (Kehtarnavaz, 2008).

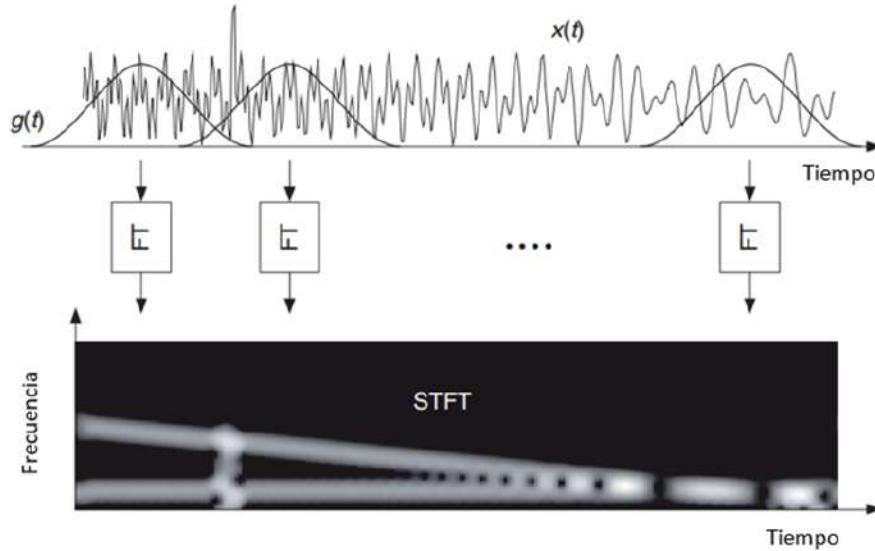


Figura 2.3: Representación del cálculo de la STFT de una señal (Kehtarnavaz, 2008)

2.3. Termografía infrarroja

Las tecnologías de termografía infrarroja se enfocan en capturar la radiación infrarroja presente en una escena observable con un sensor que interpreta la información para generar un mapa térmico bidimensional de la escena. A este mapa térmico se le conoce como termograma, o bien, como imagen termográfica. En la mayoría de las cámaras termográficas actuales existe un procesador interno que regula la calibración de la imagen obtenida para que esta represente la temperatura real de la escena observada. Los parámetros de calibración más comunes son: la emisividad de los objetos en la escena, la temperatura ambiente, la humedad relativa, la temperatura aparente reflejada en la cámara infrarroja y la distancia entre el lente de la cámara termográfica y el objeto estudiado.

El procesamiento de las imágenes termográficas suele enfocarse en dos aspectos principales: un procesamiento de mejora cualitativa que permite mejorar la resolución de la imagen, la aplicación de paletas de colores, y el ajuste del contraste de la imagen con la finalidad de obtener una representación del mapa térmico que pueda ser evaluada a simple vista; y un procesamiento cuantitativo, donde el objetivo principal consiste en la búsqueda y extracción de datos numéricos que representen la temperatura de la escena. La Figura 2.4 muestra la aplicación de una paleta de pseudocolores a los valores térmicos de la matriz termográfica, esta imagen termográfica a color viene acompañada de una barra de colores que representa el valor térmico que se asocia a cada color en la imagen. Para el análisis cuantitativo de las imágenes termográficas, un paso importante es la segmentación de la imagen por regiones de interés. Estas regiones de interés pueden ser definidas entre regiones calientes y regiones frías (Vollmer y Moellmann, 2018).

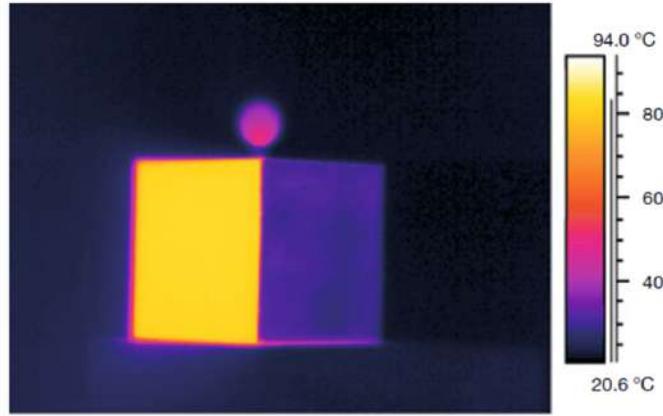


Figura 2.4: Termograma infrarrojo de un cubo de cobre con paleta de colores aplicada
(Vollmer y Moellmann, 2018)

2.4. Procesamiento de imágenes termográficas

2.4.1. Análisis cuantitativo de la imagen termográfica

La media y la desviación estándar son dos indicadores estadísticos que otorgan información cuantitativa de la imagen termográfica. Estos parámetros pueden calcularse de acuerdo a las ecuaciones (2.20) y (2.21). Donde $I(x, y)$ es el valor de intensidad del píxel en la ubicación (x, y) , w es el ancho de la imagen, y h es la altura de la imagen.

$$\mu = \frac{\sum_{y=0}^h \sum_{x=0}^w I(x, y)}{w * h} \quad (2.20)$$

$$\sigma = \sqrt{\frac{\sum_{y=0}^h \sum_{x=0}^w (\mu - I(x, y))^2}{w * h}} \quad (2.21)$$

2.4.2. Histograma de la imagen

El histograma es una representación de la distribución de los datos en una imagen. Al asemejarse a una variable discreta unidimensional, este puede ser analizado mediante parámetros estadísticos usando las ecuaciones (2.3) a (2.17) descritas previamente en este capítulo.

2.5. Técnicas de Machine Learning

El Aprendizaje Automático, también conocido por su nombre en inglés como *Machine Learning*, es la ciencia de programar equipos de cómputo para que aprendan información o patrones a partir de datos predefinidos (Geron, 2022). La aplicación de técnicas de *Machine Learning* es adecuada para:

- Resolver problemas que requieren una sintonización fina o cumplir con una larga lista de reglas y restricciones.
- Resolver problemas complejos y encontrar soluciones difíciles de proponer con metodologías clásicas.
- Adaptar sistemas a fluctuaciones de datos y mejorar su robustez
- Adquirir información *oculta* en problemas complejos o en conjuntos grandes de datos.

Las técnicas de aprendizaje automático se pueden clasificar de acuerdo a la cantidad y tipo de datos que reciben durante el entrenamiento. Existen cuatro categorías: Aprendizaje Supervisado, Aprendizaje No Supervisado, Aprendizaje Semisupervisado, y Aprendizaje Reforzado (Geron, 2022).

En el Aprendizaje Supervisado, el conjunto de datos de entrenamiento incluye una etiqueta que orienta al sistema de aprendizaje automático hacia la solución deseada. La clasificación de datos es una de las tareas que pueden desempeñar las técnicas supervisadas. Algunos de los algoritmos supervisados más importantes son:

- K-NN;
- Regresión Linear;
- Regresión Logística;
- Máquinas de Soporte Vectorial (SVM);
- Árboles de Decisión y Bosques Aleatorios;
- Redes Neuronales (estas también pueden llegar a funcionar sin supervisión o semi supervisadas).

El Aprendizaje No Supervisado funciona con datos sin etiquetar. En estas técnicas, el sistema intenta aprender sin necesidad de un mentor. Estas técnicas sirven para agrupar datos (*clustering*), detectar anomalías, reducir dimensionalidad y brindar visualización de datos. Algunas de estas técnicas no supervisadas son:

- K-Medias
- PCA
- LLE (*Locally Linear Embedding*, Inmersión Localmente Lineal)

El Aprendizaje Reforzado consiste en “recompensar” al sistema en mayor o menor medida dependiendo de su capacidad de cumplir una tarea previamente

definida. Se busca que el sistema obtenga la mayor cantidad de “recompensas” posibles, mejorando el desempeño del sistema para encontrar la solución al problema propuesto (Geron, 2022).

2.5.1. Técnicas de Aprendizaje Supervisado

K-Vecinos Cercanos

El método de clasificación de K-Vecinos Cercanos sirve para hacer una clasificación de dos casos al estimar la distribución condicional de Y dado X y clasificar la observación a la clase con mayor probabilidad estimada. James *et al.* (2013) indican que dado un número K definido como un número natural (\mathbb{N}) y una observación de prueba x_0 , el clasificador de vecinos cercanos identifica los K puntos en los datos de entrenamiento más cercanos a la observación x_0 , estos puntos son representados con el símbolo \mathcal{N}_0 . La técnica estima la probabilidad condicional para la clase j como la fracción de puntos en \mathcal{N}_0 cuya respuesta sea j a través de la ecuación (2.22):

$$\Pr(Y = j|X = x_0) = \frac{1}{K} \sum_{i \in \mathcal{N}_0} I(y_i = j) \quad (2.22)$$

El clasificador KNN asignará la observación x_0 a la clase con la mayor probabilidad obtenida en (2.22). La Figura 2.5 ilustra la aplicación de un clasificador KNN con $K = 3$ en una situación simple con seis observaciones azules y seis observaciones naranjas. La observación a clasificar se muestra con una cruz negra. Se identifican los tres puntos más cercanos y se predice que la observación de prueba pertenece a la clase azul pues resulta ser la clase más común en el área de prueba (James *et al.*, 2013).

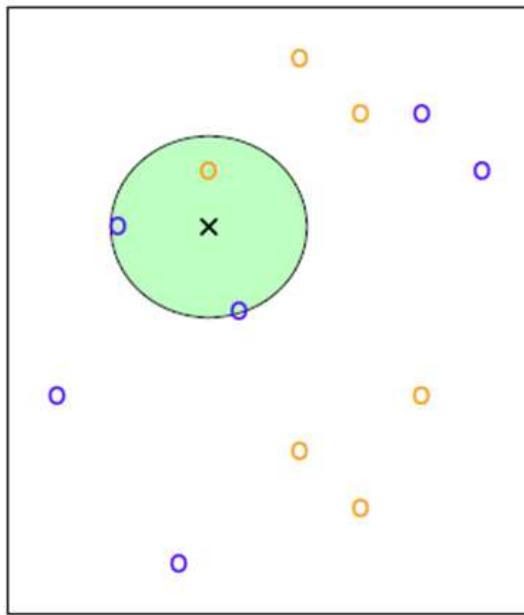


Figura 2.5: Ilustración de la aplicación del algoritmo de clasificación de K-Vecinos Cercanos con $K = 3$. La observación de prueba se representa con una cruz negra. La clase más común en el área de prueba es azul por lo que el clasificador predice que x_0 es azul (James *et al.*, 2013)

Máquinas de Soporte Vectorial

Las técnicas de clasificación de SVM usan condiciones lineales para separar las clases existentes. La idea principal de estas técnicas consiste en encontrar la condición lineal que mejor separe dos clases entre sí. Un clasificador de soporte vectorial puede considerarse como un árbol de decisión de un solo nivel con una condición de separación cuidadosamente definida. Este tipo de clasificador suele utilizarse en problemas de clasificación binaria. El criterio de separación de las clases en la máquina de vector de soporte consiste en definir hiperplanos de alta dimensionalidad que

permitan diferenciar los datos en las clases predefinidas (*Data Classification: Algorithms and Applications*, 2020). La Figura 2.6 muestra una representación gráfica de la separación de clases obtenida por un clasificador SVM.

La forma más común para generar el hiperplano de separación de un clasificador SVM consiste en la utilización de kernels. El kernel (K) es una función que cuantifica la similitud existente entre dos observaciones (x_i, x'_i). El planteamiento de un kernel polinomial (2.23) de grado d , donde d es un entero positivo y p es el número de entradas en el conjunto de datos de entrenamiento, es la forma más sencilla de generar una SVM (James *et al.*, 2013).

$$K(x_i, x'_i) = \left(1 + \sum_{j=1}^p x_{ij}x_{i'j}\right)^d \quad (2.23)$$

Redes Neuronales Artificiales

Las redes neuronales son sistemas de aprendizaje automático que imitan el comportamiento del cerebro humano. En el cerebro humano, las neuronas se conectan entre sí en un proceso llamado *sinapsis*. El aprendizaje humano se da al modificar la conexión sináptica entre las neuronas en función de impulsos biológicos. En la ANN (*Artificial Neural Network*, Red Neuronal Artificial) la unidad básica de cómputo se conoce como neurona. La configuración de la red neuronal depende de la cantidad de neuronas disponibles y la conexión que se haga entre estas. La arquitectura más simple que puede tener una red neuronal es el perceptrón, este tipo de red contiene una sola neurona con un conjunto de nodos de entrada y un solo nodo de salida. El nodo de salida está asociado con un conjunto de valores numéricos llamados pesos, representados tipicamente como \bar{W}_l . Los pesos se usan para calcular una función $f(\cdot)$ de las entradas (\bar{X}_l). Cada componente del vector de pesos se asocia a la conexión

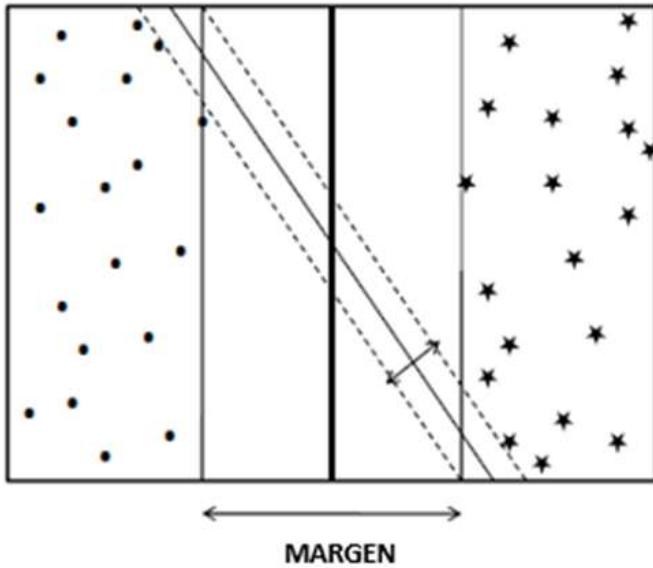


Figura 2.6: Separación de clases obtenida por un clasificador SVM. El margen representa la capacidad del clasificador de adaptarse a datos no contemplados en el entrenamiento (*Data Classification: Algorithms and Applications*, 2020)

entre las entradas y la salida del perceptrón. Los nodos de entrada en un perceptrón solamente transmiten información a la neurona de salida. Una función típica de este tipo de red neuronal es la función *signo* definida por la ecuación (2.24):

$$z_i = \text{signo}(\bar{W}_l \cdot \bar{X}_l + b) \quad (2.24)$$

La salida (z_i) es un valor predicho de clase binaria que puede tomar un valor del conjunto $[-1, +1]$. La notación b denota el bias. En un problema de clasificación binaria se pueden tomar todas las etiquetas de entrenamiento del conjunto $[-1, +1]$. Asumimos que la etiqueta de clase de la entrada (\bar{X}_i) es denotada por y_i . En ese caso, la función z_i indicará la etiqueta de clase predicha para la observación analizada. El

objetivo de la red neuronal es aprender el conjunto de pesos \bar{W} utilizando los datos de entrenamiento para minimizar el error cuadrático $(y_i - z_i)^2$. El entrenamiento comienza al asignar valores aleatorios a los pesos y actualizar su valor gradualmente. La función de actualización para el caso de redes neuronales está definida en la ecuación (2.25)

$$\bar{W}^{t+1} = \bar{W}^t + \lambda(y_i - z_i)\bar{X}_l \quad (2.25)$$

El valor λ es el coeficiente de aprendizaje de la red y determina la razón de cambio en los valores de los pesos. Por su parte, \bar{W}^t representa el valor de los pesos en la t -ésima iteración del entrenamiento de la red neuronal. La correcta selección del coeficiente de aprendizaje λ es importante pues de ser muy pequeño el valor, el entrenamiento de la red será muy lento. Por otro lado, si el valor es muy grande, el problema oscilaría entre soluciones subóptimas (*Data Classification: Algorithms and Applications*, 2020).

2.6. Tarjeta de Desarrollo PYNQ Z2

La tarjeta de desarrollo Xilinx PYNQ Z2 combina un sistema programable (*Programmable Software*, PS) basado en un microprocesador ARM Cortex Dual con una unidad lógica programable (*Programmable Logic*, PL) basada en un módulo de compuertas lógicas tipo FPGA. Tanto el microprocesador como el FPGA se conjuntan físicamente en un único sistema integrado: el *System on Chip* (SoC) modelo Zynq 7000. La Tabla 2.3 muestra las especificaciones técnicas de la placa de desarrollo PYNQ Z2.

La unidad FPGA, o PL, puede configurarse para ejecutar tareas específicas aligerando la carga computacional en el lado del microprocesador (PS). Se seleccionó

Tabla 2.3: Especificaciones técnicas de la tarjeta PYNQ Z2

SoC	ZYNQ XC7Z020-1CLG400C
Software Programable	PS
Microporcesador integrado	650MHz ARM Cortex-A9 dual-core
Memoria	DDR3 512MB @ 1050 Mbps
Lógica Programable	PL
Secciones lógicas (Logic Slices)	13 300
RAM de bloque	630 KB
Secciones DSP (DSP Slices)	220
Convertidores de señal	Convertidor Análogo-Digital
Programación de FPGA	JTAG, QUAD-SPI, Micro SD
Otras Especificaciones	
Alimentación	USB o regulador externo 7V - 15V
Periféricos	USB 2.0, USB-JTAG, USB-UART, Ethernet
Audio/Video	E/S HDMI, conector 3.5 mm
Interfaz Usuario	4 pulsadores, 2 interruptores, 6 LEDs
Conectores	2 PMODs, Conector Arduino, Conector RPi

la tarjeta PYNQ Z2 porque permite el procesamiento tanto con hardware como con software en un sistema integrado que puede utilizarse en distintas aplicaciones. Además, su soporte nativo de Python permitió la integración de las bibliotecas OpenCV en el microporcesador con las descripciones de hardware en el FPGA.

Capítulo 3

Metodología

En este capítulo del trabajo se abarca a detalle los métodos y recursos utilizados para la implementación del sistema de diagnóstico de fallos en motores de inducción a través del procesamiento de datos en un entorno que combine las capacidades de la programación en software con la descripción digital en arquitecturas FPGA. Para lograr esto se planteó un diagrama que ilustra la metodología general del trabajo, mismo que se muestra en la Figura 3.1. Primeramente, se monitoreó el funcionamiento de un motor de inducción a través de la adquisición de datos de dos variables físicas: temperatura y corriente eléctrica. En esta etapa se realizó un sistema de adquisición de imágenes termográficas basado en un sensor infrarrojo y un sistema de adquisición de señales de corriente eléctrica del motor. La adquisición de los datos se hizo tras realizar una serie de experimentos sobre dos bancos de pruebas diferentes. Tras la adquisición de las señales se generó un banco de datos que fue almacenado en una unidad de memoria MicroSD para ser analizadas en la tarjeta de desarrollo PYNQ Z2. En esta tarjeta se implementaron algoritmos de procesamiento de imágenes y algoritmos para el procesamiento de las señales de corriente eléctrica. El fin del procesamiento de los datos fue obtener indicadores de temperatura y corriente eléctrica del estado del motor que pudieran ser analizados usando los algoritmos de *Machine Learning* para llegar a una clasificación y diagnóstico del estado del motor de inducción.

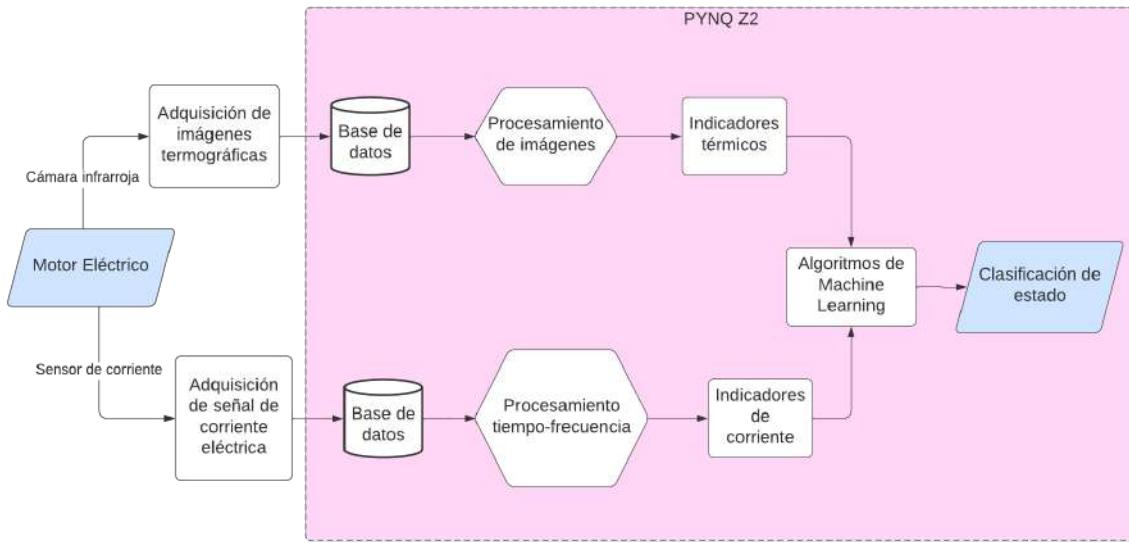


Figura 3.1: Diagrama general de la metodología

3.1. Procesamiento de los datos

El procesamiento de los datos adquiridos en los experimentos realizados se llevó a cabo en dos etapas: la primera etapa tuvo un carácter exploratorio, al analizar las imágenes termográficas y las señales de corriente eléctrica con distintos algoritmos estadísticos y tiempo-frecuenciales. Esta etapa se llevó a cabo en una computadora de escritorio usando el software MATLAB dado que este entorno de trabajo facilitó la aplicación de distintos algoritmos. La segunda etapa del procesamiento de los datos consistió en organizar e implementar los algoritmos de procesamiento en un sistema embebido usando una tarjeta Xilinx PYNQ Z2 para hacer el análisis de imágenes termográficas infrarrojas y el análisis de señales de corriente eléctrica de motores eléctricos.

Siguiendo el diagrama presentado en la Figura 3.1, se implementaron dos

líneas de procesamiento de datos en la tarjeta de desarrollo PYNQ Z2. Por un lado se procesaron las imágenes termográficas del motor de inducción. La Figura 3.2 muestra un diagrama de flujo que ilustra los pasos en el procesamiento de las imágenes termográficas. Primero, se tomó una captura termográfica del motor de inducción en escala de grises. La escala de grises representaba la temperatura medida por el sensor óptico infrarrojo. Se calcularon distintos indicadores termográficos del estado del motor. Dos de los estadísticos considerados fueron la media y la desviación estándar de la imagen, estos indicadores se usaron las ecuaciones (2.20) y (2.21) en la unidad lógica FPGA de la tarjeta de desarrollo. También se calculó el histograma de la imagen y se calcularon indicadores estadísticos de la distribución discreta de niveles de intensidad usando las ecuaciones (2.3) a (2.17). Adicionalmente se generaron capturas en pseudo-color para mejorar la percepción de la diferencia de temperaturas en la captura termográfica. Las capturas a pseudo-color se utilizaron con el fin de brindar una muestra cualitativa de la diferencia de temperaturas en distintas regiones de interés en la imagen termográfica.

El procesamiento de las señales de corriente eléctrica del motor se llevó a cabo utilizando las técnicas estadísticas, técnicas frecuenciales, y técnicas tiempo-frecuenciales descritas en la fundamentación teórica de este trabajo. El diagrama de flujo de la Figura 3.3 representa los pasos del procesamiento de la señal de corriente eléctrica del motor. El primer paso consistió en la normalización de la señal de corriente para representar el valor de amperios medidos en la línea de alimentación del motor de inducción. Una vez normalizada la señal de corriente, se hizo el análisis estadístico mediante el cálculo de indicadores estadísticos con las ecuaciones (2.3) a (2.17). El análisis frecuencial se realizó utilizando la Transforma Rápida de Fourier (FFT), misma que fue implementada en la unidad lógica FPGA de la tarjeta PYNQ Z2. Por otra parte, el análisis tiempo-frecuencial se hizo con la Transforma

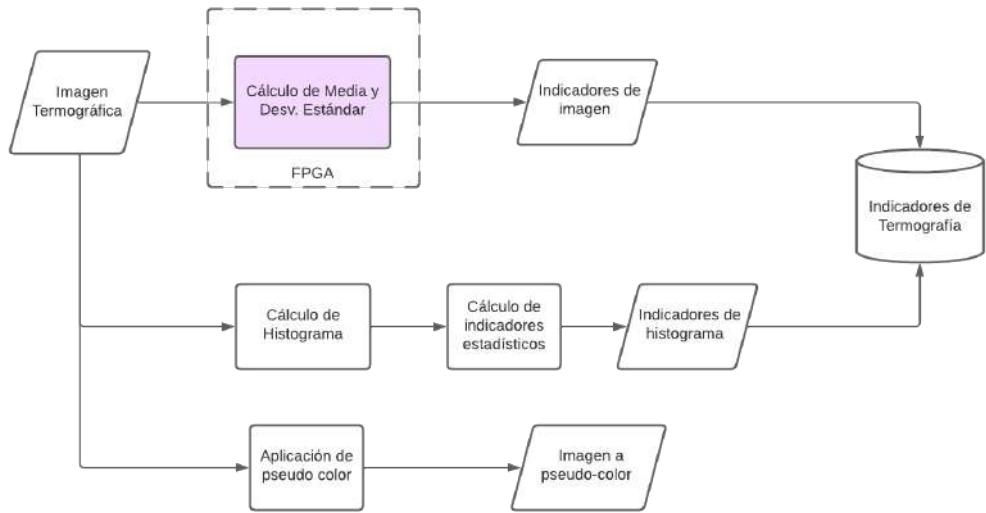


Figura 3.2: Procesamiento de imágenes termográficas

de Fourier de tiempo corto (STFT) descrita en la ecuación (2.19) aprovechando la implementación en hardware del algoritmo de FFT.

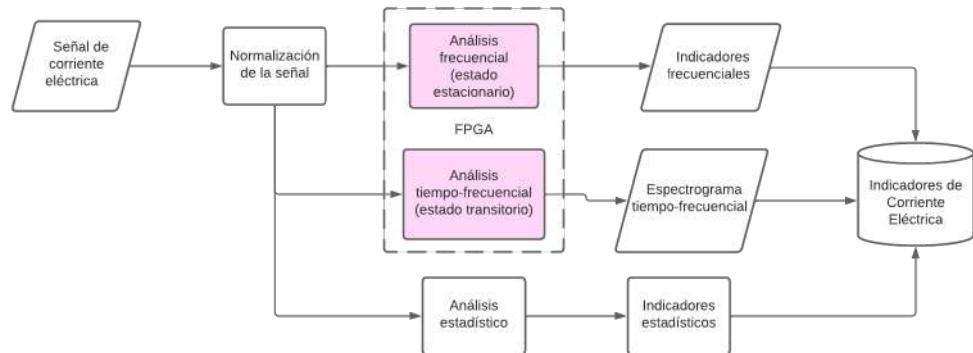


Figura 3.3: Procesamiento de señales de corriente eléctrica

3.1.1. Implementación de algoritmos en FPGA

La implementación de los algoritmos propuestos en la unidad FPGA se ilustra en la Figura 3.4. Para la creación de IP-cores enfocados a la ejecución de cálculos en la FPGA el primer paso consistía en plantear el algoritmo que se iba a implementar. Una vez planteado el algoritmo, se hacía la descripción en un lenguaje de síntesis de alto nivel (*High-Level Synthesis*, HLS). En este trabajo se utilizó el software Vitis como marco de desarrollo para las descripciones HLS. En este entorno de desarrollo se hizo la validación del funcionamiento de las descripciones a través de la simulación de las señales digitales del IP-core. Una vez validada la descripción, el IP-core se sintetizó en una serie de instrucciones abstraídas a un nivel de transferencia de registros (*Register Transfer Level*, RTL) y descritas con el lenguaje VHDL. El conjunto de archivos que describe a la arquitectura del IP-core fue importado en el software Vivado. En este software se realizó la conexión del IP-core descrito con bloques periféricos. Esta conexión permite la implementación del IP-core en la tarjeta PYNQ Z2 y aprovechar la comunicación entre la unidad FPGA y el microprocesador integrado. Finalmente, se validó la conexión de los bloques periféricos y el IP-core del algoritmo propuesto y se sintetizaba el archivo de extensión *.bit* para la configuración de las compuertas lógicas en la FPGA.

Se generaron dos archivos adicionales para la correcta utilización del IP-core en la tarjeta PYNQ Z2. El primer archivo corresponde al diseño de bloques generado en el software Vivado para la conexión del IP-core con los bloques periféricos. El segundo archivo indica las direcciones de memoria asignadas a cada puerto de la implementación realizada.

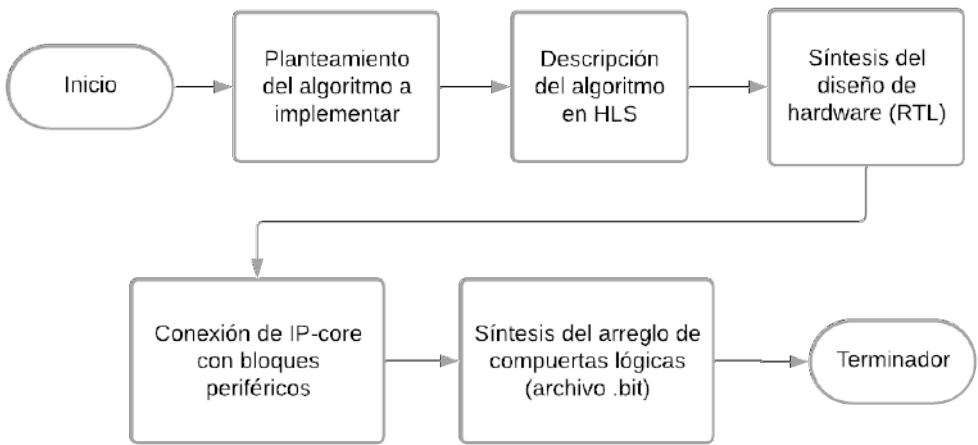


Figura 3.4: Metodología general para la implementación de un IP-core en la unidad FPGA de la tarjeta PYNQ Z2

3.1.2. IP-core de procesamiento de imágenes termográficas

El primer algoritmo implementado en la FPGA fue para el cálculo de índices estadísticos para la matriz termográfica. Los indicadores estadísticos de la imagen termográfica que se calcularon fueron la media (2.20) y la desviación estándar (2.21). La implementación del algoritmo para el cálculo de estos indicadores en la tarjeta PYNQ Z2 se realizó siguiendo el diagrama que se observa en la Figura 3.5 donde los bloques en color rosa se ejecutaron en el microprocesador de la tarjeta (PS) y los bloques en color púrpura se ejecutaron en el FPGA (PL).

El primer paso consistió en guardar las imágenes termográficas de los motores de inducción adquiridas durante la serie de experimentos en una memoria MicroSD. La memoria MicroSD estuvo montada en la tarjeta PYNQ Z2. Los valores de intensidad de las imágenes termográficas se reasignaron en un rango de 0 a 255 con el fin de poder almacenar la información en paquetes de datos de 8 bits. Luego, se

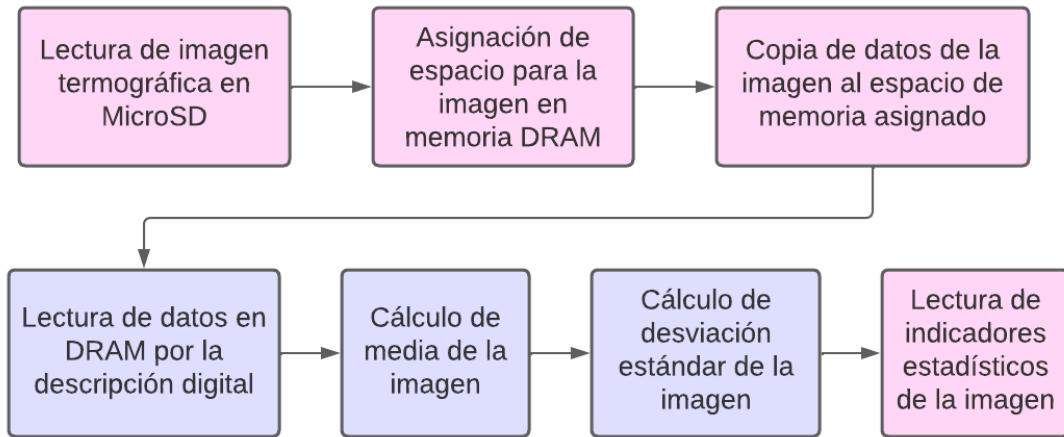


Figura 3.5: Metodología para el cálculo de media y desviación estándar de la imagen termográfica en PYNQ Z2

guardaron las imágenes en formato *jpeg*. La imagen termográfica se cargó al entorno de trabajo en Python usando las librerías de procesamiento de imágenes de OpenCV. Una vez que la imagen termográfica fue cargada al entorno de trabajo en Python, se asignó un espacio en la memoria DRAM que pudiera almacenar los datos de la imagen a analizar y se hizo una copia de los datos de la imagen en el espacio asignado. La memoria DRAM sirve como interfaz de comunicación entre el microprocesador y la FPGA de la tarjeta de desarrollo.

El diagrama a bloques periféricos para la implementación de este IP-core se muestra en la Figura 3.6. En este diagrama se observan los puertos periféricos utilizados para la interconexión del IP-core generado (ubicado en la esquina inferior derecha del diagrama). Los puertos AXI se definieron con tres interfaces maestras AXI-4 con canales independientes de escritura y lectura de datos. Una de estas interfaces se dedicó a leer los datos de la imagen desde la memoria DRAM de la

tarjeta. Las otras dos interfaces se dedicaron para almacenar los resultados del cálculo de indicadores estadísticos. Adicionalmente se definieron puertos AXI-4 Lite con canales de solo lectura para comunicar las dimensiones de la imagen a la descripción del algoritmo. Una vez que los puertos estuvieron definidos, los datos de la imagen termográfica almacenados en el espacio asignado de la DRAM fueron enviados a través de puertos periféricos AXI al puerto de entrada de datos. El vector de datos recibido a través del periférico se organizó en forma de matriz bidimensional usando los datos del tamaño de la matriz definidos en los puertos AXI-4 Lite.

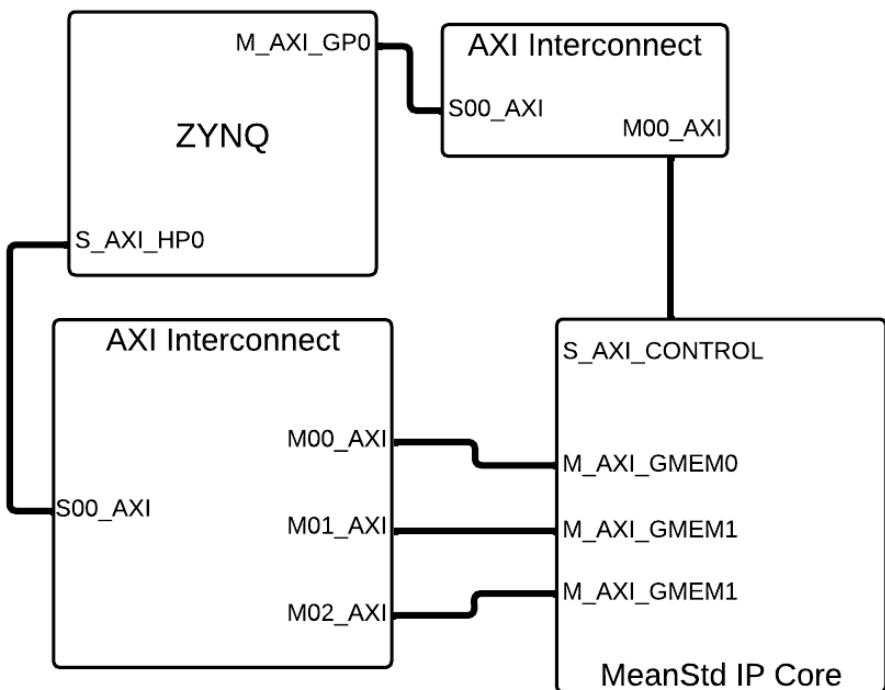


Figura 3.6: Diagrama a bloques de la conexión de descripciones digitales en Vivado para el algoritmo de cálculo de estadísticos

3.1.3. IP-core de procesamiento de señales de corriente

El algoritmo implementado en la FPGA para el procesamiento de señales de corriente fue la FFT. Este algoritmo es una optimización del método que obtiene la Transformada Discreta de Fourier (2.18). Se diseñaron dos IP-cores de FFT, uno enfocado al análisis frecuencial del estado estacionario de la señal de corriente, y otro enfocado al análisis tiempo-frecuencial de la señal de corriente. Para el caso del análisis frecuencial se diseñó un IP-core que calculaba la FFT con un tamaño fijo de $N_{FFT} = 2^{16} = 65536$. Esto permitió tomar una mayor cantidad de datos de muestreo para el análisis. El otro IP-core diseñado se enfocó al cálculo de la STFT. Para el diseño de este IP-core se determinó un tamaño fijo $N_{FFT} = 2^{10} = 1024$ para la extensión de la transformada. Se determinó este tamaño de la transformada tomando en cuenta que el IP-core se utilizaría en la implementación de la STFT. La Figura 3.7 ilustra la metodología para calcular la STFT de una señal de corriente con el IP-core de la FFT en la unidad lógica FPGA de la tarjeta PYNQ Z2. El primer paso consiste en leer la señal de corriente desde la memoria MicroSD al entorno de trabajo en el microprocesador operado con el lenguaje de programación Python. En este entorno de trabajo se normalizó la señal a fin de que representara la magnitud real de la corriente medida. Una vez que se leyó la señal de corriente, se calculó el número de ventanas en las que se iba a dividir para su análisis de tiempo corto siguiendo la ecuación (3.1), donde k es la longitud inicial de la señal, N_{FFT} es el tamaño de la FFT, y Ov es el valor de superposición de las ventanas por unidad (p.u.) (Kehtarnavaz, 2008).

$$N_w = \left\lceil \frac{k - N_{FFT}}{(1 - Ov)N_{FFT}} \right\rceil \quad (3.1)$$

Luego de determinar el número de ventanas en las que se dividió la señal

se multiplica la ventana recortada de la señal con una ventana Hamming de tamaño N_{FFT} . La implementación del IP-core se hizo en una representación de números decimales de punto fijo con un registro de memoria de 32 bits para la señal de entrada. Los 16 bits más significativos del registro correspondían a la parte imaginaria, y los 16 bits restantes correspondían a la parte real de la señal. Como las señales de corriente eléctrica del motor fueron puramente reales, los 16 bits más significativos del registro se fijaron con un valor 0. La señal de corriente normalizada y preprocesada para el cálculo de la FFT en la FPGA se copió a un espacio asignado en la memoria DRAM de la tarjeta de desarrollo, desde ahí el módulo de Acceso Directo a la Memoria del IP-core podía acceder a los valores de la señal. El IP-core calculó la FFT de cada una de las N_w ventanas de la señal de corriente. Al final se generó una matriz que contiene la FFT de cada una de las ventanas de la señal de corriente analizada.

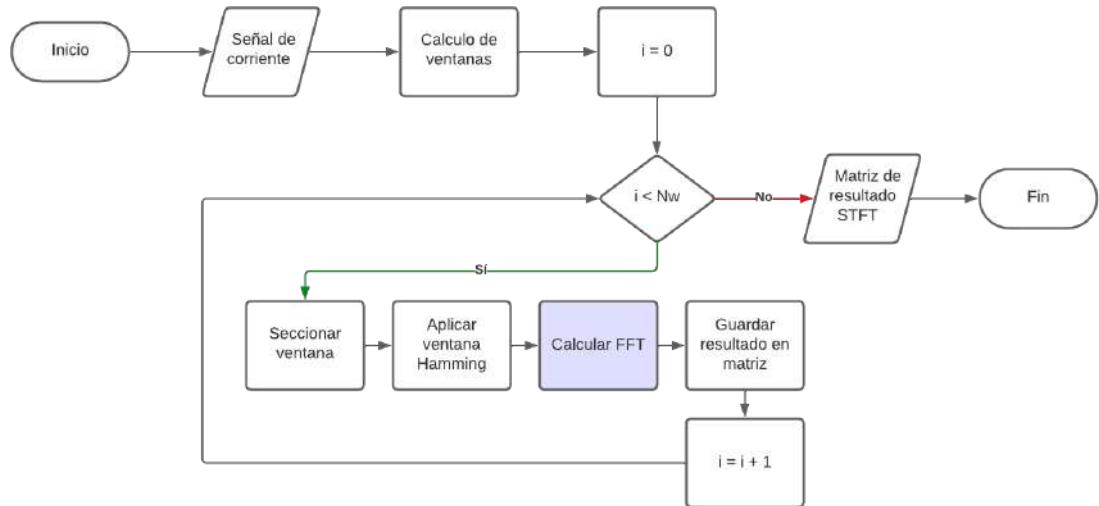


Figura 3.7: Método para cálculo de STFT con la unidad FPGA de tarjeta PYNQ Z2

3.2. Puesta de experimentos

3.2.1. Banco de pruebas con motor WEG

El primer banco de pruebas utilizado en la realización de los experimentos estuvo localizado en el laboratorio de máquinas eléctricas de la Facultad de Ingeniería en la Universidad Autónoma de Querétaro, Campus SJR. El motor de inducción era un motor WEG trifásico modelo 3F A.E. 00136AP3E48TCT. La Tabla 3.1 muestra las especificaciones del motor WEG.

Tabla 3.1: Especificaciones del motor WEG en el banco de pruebas

Parámetro	Especificación	Unidades
Tensión de alimentación	208-230 /460	V
Velocidad nominal (@ 60 Hz)	3355	rpm
Potencia	746	W
Eficiencia nominal	75.5	%
Corriente nominal (@ 460 V / 60 Hz)	1.4	A
Factor de potencia	0.87	
Peso	9	kg

El motor de inducción WEG estaba conectado a un alternador que sirvió como una carga mecánica para el mecanismo. La conexión entre el motor y el alternador se hizo mediante un juego de poleas y una banda plástica de transmisión de potencia. La Figura 3.8 muestra el banco de pruebas descrito previamente. Los experimentos en esta bancada de pruebas se llevaron a cabo con arranque directo a una frecuencia de operación de 60 Hz. Para medir la temperatura estable del motor,

cada ensayo tuvo una duración de 90 minutos. El sistema de adquisición de imágenes termográficas indicado en la Figura 3.8 realizó una captura del motor de inducción cada 10 segundos, con esto se obtuvo una base de datos de 540 capturas termográficas por caso de estudio. Adicionalmente, se hizo la adquisición de señales de corriente del motor de inducción. La frecuencia de muestreo de la adquisición de señales de corriente fue de 4 kHz. Para cada caso de estudio se hicieron cinco ensayos con una duración de 30 segundos. Los primeros 10 segundos de la señal corresponden a la etapa de arranque del motor y los 20 segundos restantes corresponden al estado estable de la señal de corriente. En este banco de prueba se estudiaron cinco casos de fallo en el motor de inducción o en los componentes conectados al mismo: sano, defecto en rodamiento, barras rotas, desbalance, y desalineamiento. Los casos de estudio se describen en la Tabla 3.2, asimismo, se lista la etiqueta a utilizar para referirse a los casos de estudio de aquí en adelante.

Tabla 3.2: Casos de estudio en motor de inducción WEG

Caso de Estudio	Etiqueta	Descripción
Sano	HLT	Motor y cadena cinemática sanos
Defecto en rodamiento	BDF	Defecto en el rodamiento del motor
Barras rotas	BRB	Barras rotas en el rotor del motor
Desbalance	UNB	Desbalance mecánico en el eje del motor
Desalineamiento	MAMT	Desalineamiento entre el motor y la carga
Caja de engranes	GRF	Desgaste en caja de engranes conectada al motor

Se tomaron en cuenta distintas severidades para dos de los casos de estudio mostrados en la Tabla 3.2, los casos de estudio con severidades diferentes fueron el

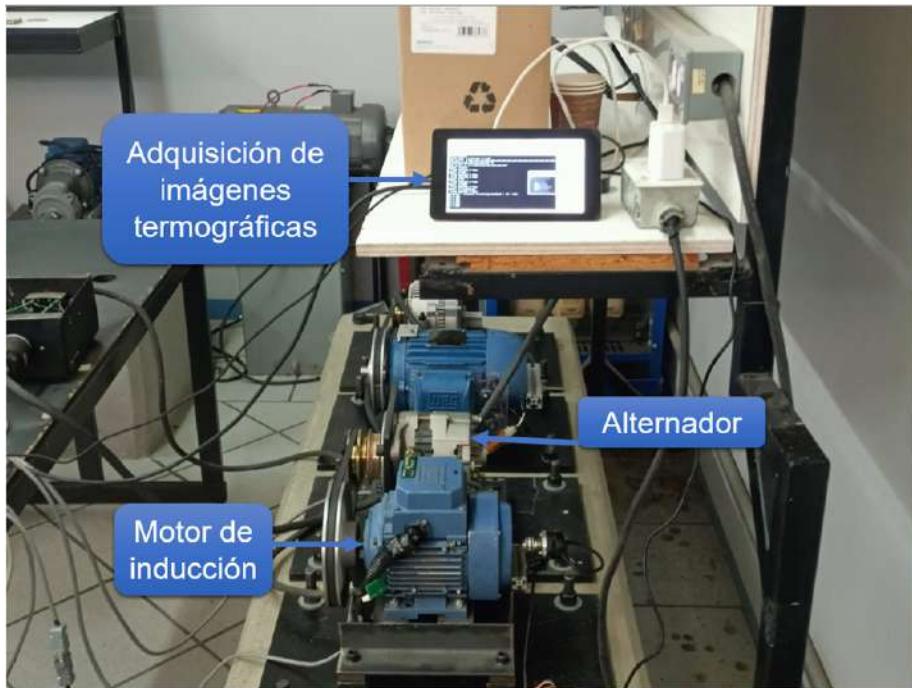


Figura 3.8: Banco de pruebas con motor de inducción trifásico WEG conectado a alternador mediante banda de transmisión

fallo por defecto en rodamiento y el fallo por barras rotas. Para el caso de defecto en rodamiento se realizaron ensayos con cinco severidades de daño en la pista externa de rodamientos metálicos. Las severidades fueron inducidas al hacer un barrenado sobre la pista externa con los siguientes diámetros: 1 mm, 2 mm, 3 mm, 4 mm, y 5 mm. Se usaron cinco rodamientos metálicos modelo SKF 6203. En el caso de estudio de barras rotas se consideraron tres severidades durante los experimentos: media barra rota, una barra rota, y dos barras rotas. Para el caso de falla en caja de engranes (GRF) se conectó una caja de engranes al motor de inducción WEG en lugar de la conexión de polea con banda. Se consideraron cuatro severidades de desgaste en la caja de engranes: sano, desgaste del 25 %, desgaste del 50 %, y desgaste del 75 %. La

Figura 3.9 muestra el desgaste inducido en los engranes y la configuración del banco de pruebas.

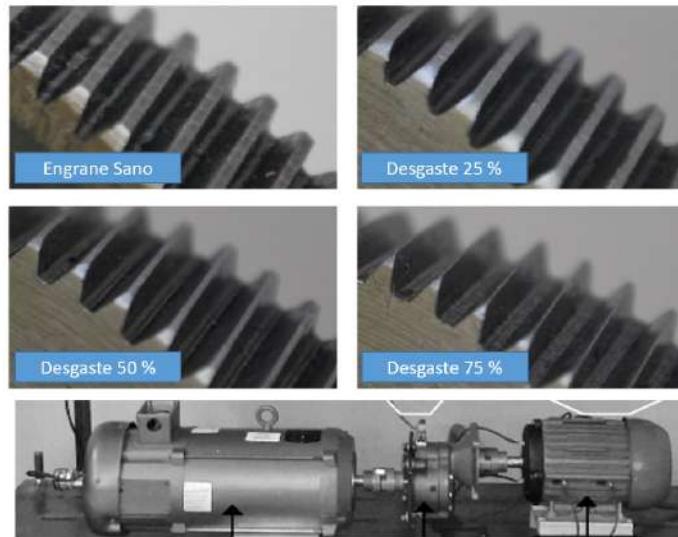


Figura 3.9: Fallo por desgaste en caja de engranes conectada a motor WEG

Se dedicó un tiempo de 3 horas para el reposo del motor tras finalizar cada prueba con el fin de homogeneizar la temperatura del motor al momento de iniciar la adquisición de nuevas imágenes termográficas.

3.2.2. Banco de pruebas con motor de la UPV

El segundo banco de pruebas utilizado en los ensayos estuvo localizado en el laboratorio del Instituto Tecnológico de la Energía de la Universidad Politécnica de Valencia (UPV) en Valencia, España. El motor de inducción fue un motor trifásico de 1 HP. La Tabla 3.3 muestra las especificaciones del motor.

El motor de pruebas de la UPV se conectó a un motor de corriente continua como se muestra en la Figura 3.10. El estator del motor de corriente continua se

Tabla 3.3: Especificaciones del motor en el banco de pruebas de la UPV

Parámetro	Especificación	Unidades
Tensión de alimentación	220 / 460	V
Velocidad nominal (@ 60 Hz)	1140	rpm
Potencia	746	W
Corriente nominal (@ 460 V / 60 Hz)	1.8	A

conectó a un reostato con el objetivo de poder controlar el nivel de carga en el motor de inducción, lo que permitió realizar los experimentos bajo cuatro niveles de carga: carga nominal (100 %), carga al 75 %, carga al 50 %, y sin carga (0 %). Los ensayos se realizaron en arranque directo a una frecuencia de operación de 50 Hz con un voltaje de alimentación de 220 V.

En este banco de pruebas se estudiaron seis casos de fallo en el montaje del motor de inducción: sano, desbalance (con dos severidades), desalineamiento horizontal, desalineamiento vertical, y mala montura por tornillo suelto. La Tabla 3.4 describe los casos de estudio y lista la etiqueta a utilizar para referirse a estos. Dado que el motor utilizado en estas pruebas no contaba con un sistema de refrigeración propio se limitó la duración de los ensayos para la adquisición de imágenes termográficas a 5.5 minutos dando un tiempo de reposo de 3 minutos entre pruebas. La frecuencia de muestreo de la cámara termográfica en estos experimentos fue de 9 capturas por segundo (o fps, *frames per second*). Para la adquisición de las señales de corriente eléctrica se hicieron ensayos de 30 segundos. Los primeros 10 segundos correspondieron al arranque del motor y los 20 segundos restantes al estado estable de la corriente. Las señales se adquirieron con una frecuencia de muestreo de 10 kHz.

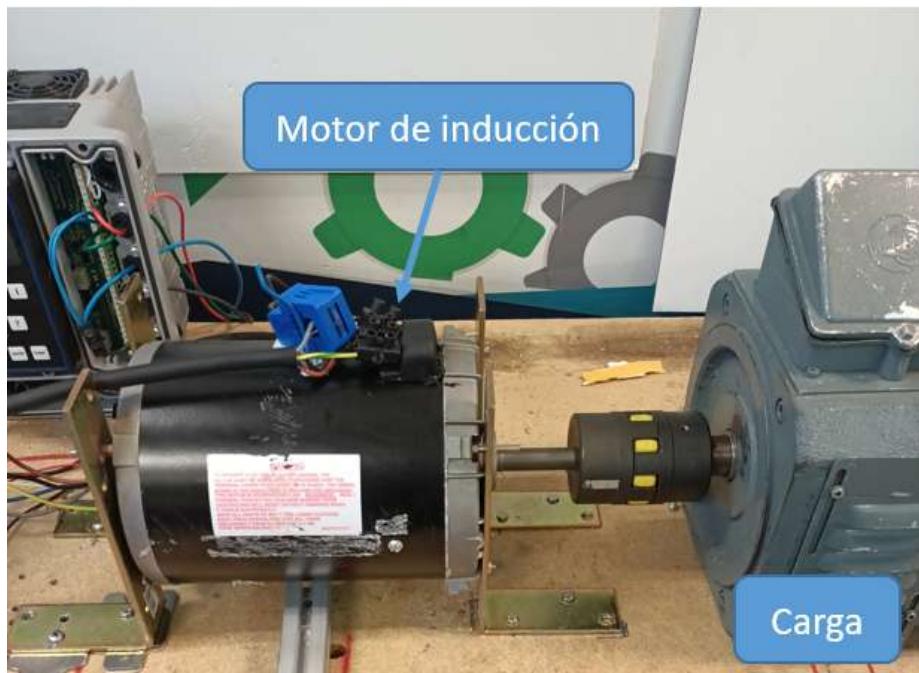


Figura 3.10: Banco de pruebas con motor de la UPV conectado a motor de c.c.

Tabla 3.4: Casos de estudio en motor de inducción de la UPV

Caso de Estudio	Etiqueta	Descripción
Sano	HLT	Motor de inducción sano
Desbalance	UNB	Desbalance en el rotor del motor
Desalineamiento horizontal	HML	Desalineamiento del motor y carga sobre el mismo plano horizontal
Desalineamiento vertical	VML	Diferencia de alturas del motor y carga
Tornillo suelto	LB	Tornillo suelto en la barra que sujetta el motor al banco

3.3. Sistemas de adquisición de datos

3.3.1. Adquisición de imágenes termográficas

La adquisición de los termogramas infrarrojos se realizó utilizando como base el sensor infrarrojo *FLIR Lepton 3.5*. Este sensor infrarrojo captura imágenes radiométricas con una resolución de 160 por 120 píxeles en paquetes de datos de 14 bits a través de un protocolo de comunicación de video por interfaz periférica serial, o en inglés, *Video Over Serial Peripheral Interface* (VoSPI). Con el módulo *PureThermal 2* se puede hacer la comunicación con el sensor infrarrojo y transmitir el video termográfico por medio de una conexión USB usando los protocolos para cámaras web. La adquisición de imágenes termográficas se hace con un sistema que integra el sensor FLIR Lepton 3.5 con una tarjeta de cómputo Raspberry Pi 4. El sistema permite la adquisición y almacenamiento de termogramas infrarrojos con frecuencia de muestreo variable. La frecuencia de muestreo límite es de 9 fps dadas las limitaciones técnicas del sensor infrarrojo. La Figura 3.11 muestra el sistema de adquisición de termogramas infrarrojos en el banco de pruebas. Por otro lado, la Tabla 3.5 muestra las especificaciones técnicas del sensor infrarrojo FLIR Lepton 3.5.

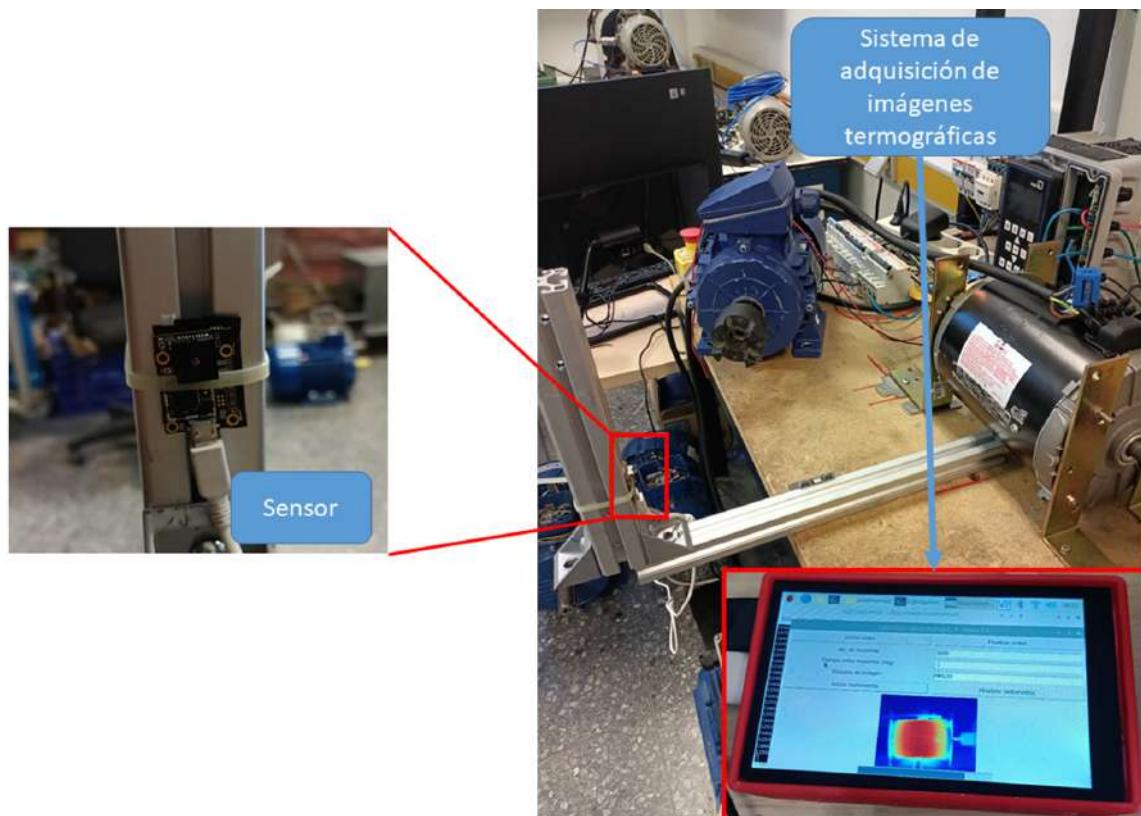


Figura 3.11: Sistema de adquisición de termogramas infrarrojos en banco de pruebas

Tabla 3.5: Especificaciones del sensor infrarrojo FLIR Lepton 3.5

Especificación	Detalle
Matriz de salida	160 x 120
Rango infrarrojo	8 μm a 15 μm
Emisividad	95 %
Sensibilidad Térmica	50 mK

Las imágenes son almacenadas en archivos de imagen con formato .tiff con el fin de conservar la información de temperatura de la imagen. La imagen termográfica

almacena los valores de temperatura de la escena de acuerdo a la ecuación (3.2) donde $T_K(x, y)$ es la temperatura en kelvin en el píxel (x, y) y $V(x, y)$ es el valor registrado en la imagen:

$$V(x, y) = 100 * T_K(x, y) \quad (3.2)$$

Para convertir la temperatura en kelvin (K) a temperatura en grados Celsius ($^{\circ}\text{C}$) basta con usar la ecuación (3.3):

$$T_C(x, y) = T_K(x, y) - 273.15 \quad (3.3)$$

3.3.2. Adquisición de señales de corriente

En los experimentos llevados a cabo en el primer banco de pruebas con el motor WEG se hizo la adquisición de las señales de corriente eléctrica del motor con el sistema de adquisición de datos mostrado en la Figura 3.12 usando cuatro sensores de corriente eléctrica. Cada sensor adquirió la señal de una de las líneas de alimentación del motor trifásico, el cuarto sensor midió la señal de corriente en la línea de conexión a tierra. La frecuencia de muestreo del sistema de adquisición de señales fue de $F_s = 4000$ Hz. En los experimentos realizados con el segundo banco de pruebas basado en el motor de la UPV, se hizo la adquisición de la señal de corriente de una sola de las líneas de alimentación trifásica al motor de inducción. La adquisición de los datos se hizo con un osciloscopio digital de la marca Yokogawa y una pinza amperimétrica, los cuales se muestran en la Figura 3.13. La frecuencia de muestreo para la señal de corriente del motor de la UPV fue de $F_s = 10000$ Hz.

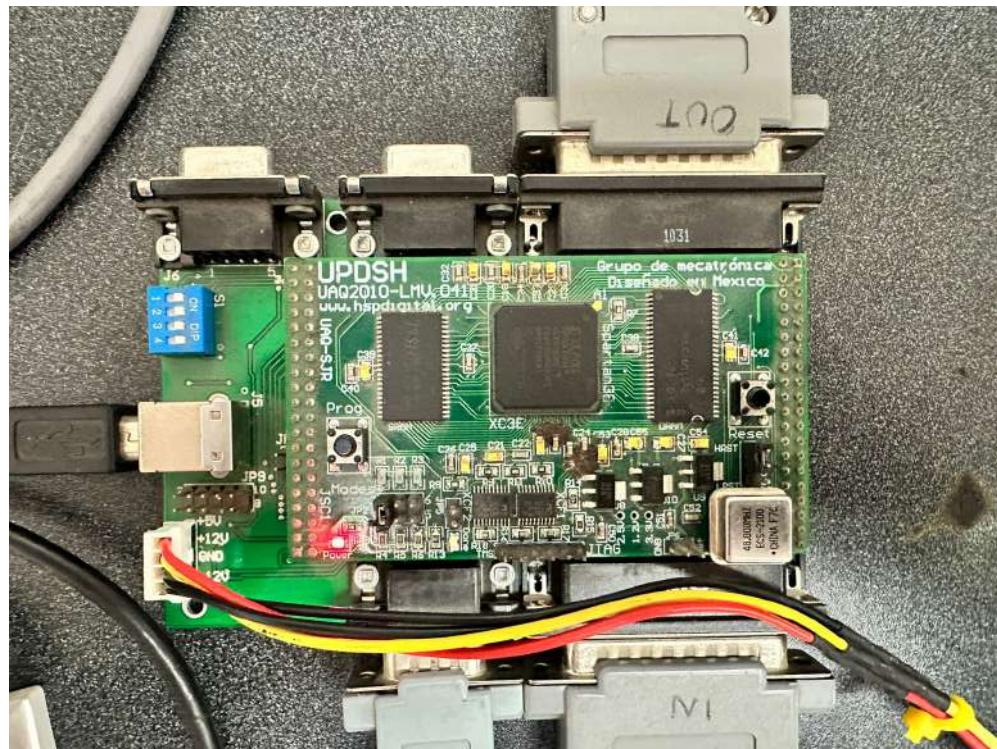


Figura 3.12: Sistema de Adquisición de Datos usado para medir señales de corriente eléctrica en motor WEG



Figura 3.13: Sistema de Adquisición de Datos usado para medir señales de corriente eléctrica en motor de la UPV

Capítulo 4

Resultados

En este capítulo se presentan y discuten los resultados obtenidos en la ejecución del trabajo. El capítulo pretende abordar los resultados obtenidos en la implementación de los algoritmos en la unidad lógica FPGA de la tarjeta de desarrollo PYNQ Z2, una discusión de los datos adquiridos, los resultados obtenidos por el procesamiento de los datos adquiridos, y los resultados obtenidos en la aplicación de algoritmos de Machine Learning para la clasificación de los datos.

4.1. Implementación de algoritmos en FPGA

La Tabla 4.1 muestra la utilización de recursos en la unidad FPGA de la tarjeta PYNQ Z2 requerida por el algoritmo de cálculo de indicadores estadísticos (media y desviación estándar). La descripción del algoritmo para el cálculo de estadísticos de la imagen fue capaz de reducir el tiempo de cómputo necesario para completar las tareas asignadas. Esto se observó al comparar el desempeño al ejecutar el algoritmos en el microprocesador de la PYNQ Z2 y el desempeño al ejecutar el algoritmos en la unidad FPGA en conjunto con el microprocesador de la PYNQ Z2. El algoritmo de cálculo de indicadores se probó con una base de datos de 900 imágenes termográficas, mismas que fueron procesadas en 1.4 s por el microprocesador y en 346 ms por el IP-core implementado en la unidad FPGA. Por otro lado, la Tabla 4.2 muestra la utilización de recursos en la unidad lógica FPGA requerida por el

IP-core para el cálculo de la FFT de una señal discreta. A su vez, la implementación del IP-core en la FPGA permitió reducir el tiempo de cómputo comparado con hacer el cálculo en el microprocesador ARM integrado en la tarjeta de desarrollo. El tiempo que le tomó al microprocesador para calcular la FFT fue de $385 \mu\text{s}$, usando la implementación de la librería *numpy* de Python. Por su parte, la implementación en el IP-core en la FPGA calculó la FFT en $79.6 \mu\text{s}$.

Tabla 4.1: Utilización de recursos por IP-core de indicadores termográficos

Recurso	Utilización %
LUTs	13.65
Registros	8.85
Porciones lógicas (Slices)	11.38
LUT Lógica	12.63
LUT Memoria	3.14
RAM de bloque	3.57
DSPs	3.18

4.2. Adquisición de datos

La adquisición de los termogramas infrarrojos del motor y el preprocesamiento para poder visualizar la información en forma de una imagen a escala de grises se realizó de manera satisfactoria (Figura 4.1). La Figura 4.1a muestra la representación termográfica del costado del motor WEG durante los ensayos del caso de estudio de motor sano. A su vez, la Figura 4.1b muestra la representación termográfica del costado del motor de la UPV durante los ensayos en condición sana.

Tabla 4.2: Utilización de recursos por IP-core de FFT

Recurso	Utilización %
LUTs	12.62
Registros	9.38
Porciones lógicas (Slices)	10.43
LUT Lógica	8.86
LUT Memoria	4.81
RAM de bloque	6.07
DSPs	5.45

Por su parte, se adquirieron cuatro señales de corriente del motor WEG durante las pruebas con una frecuencia de muestreo $F_s = 4000$ Hz. La Figura 4.2 muestra la evolución en el tiempo de las cuatro señales adquiridas. Las señales C1, C2, y C3 corresponden a la corriente medida en las líneas de alimentación del motor trifásico. La señal C4 corresponde a la corriente medida en la linea de conexión a tierra.

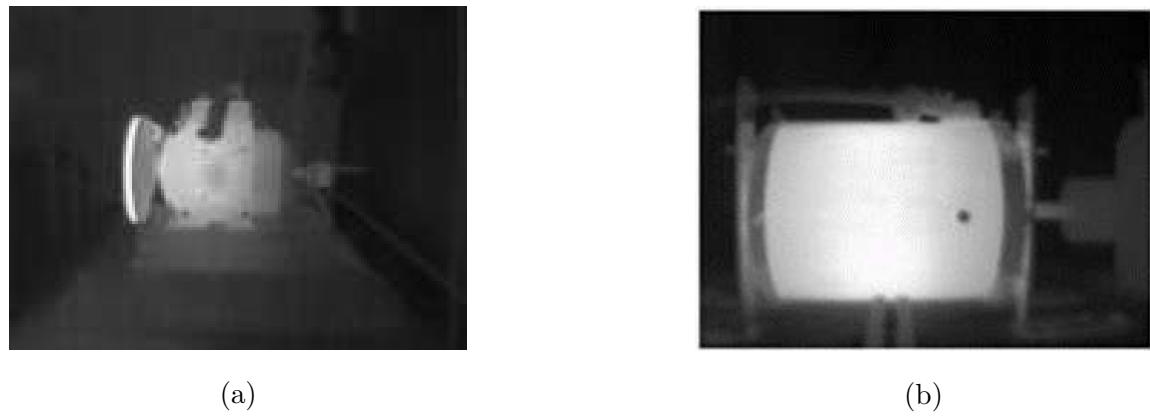


Figura 4.1: Capturas termográficas de motores de inducción: a) motor WEG, b) motor de la UPV

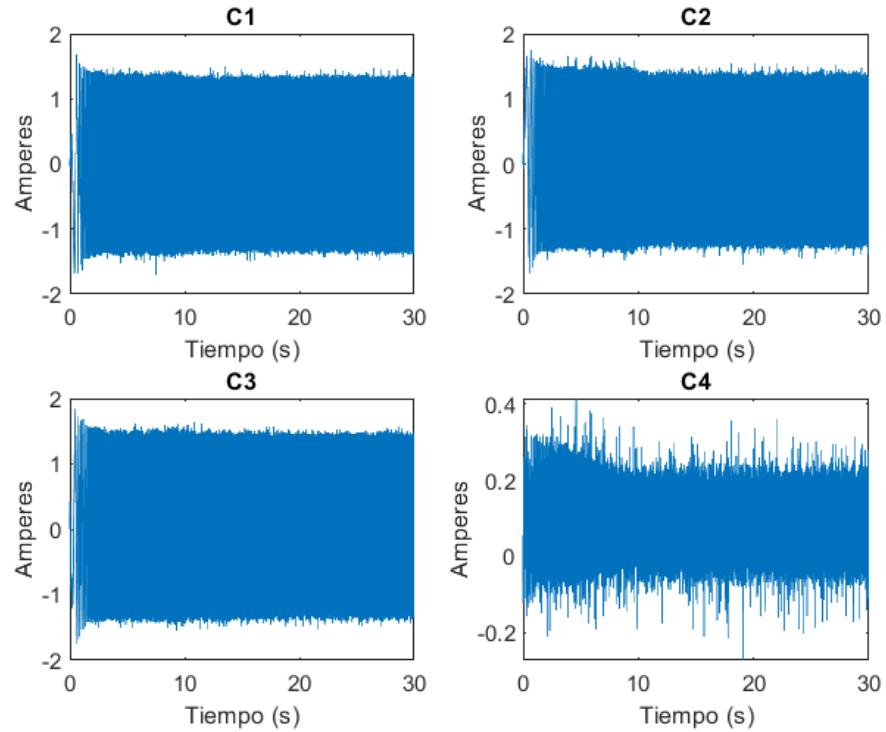


Figura 4.2: Señales de corriente adquiridas del motor WEG en estado sano

4.3. Procesamiento de los datos

4.3.1. Análisis de imágenes termográficas

El análisis de las imágenes termográficas de los motores de inducción se realizó con el cálculo de dos indicadores estadísticos de la imagen: la media y la desviación estándar. También se obtuvo el histograma de las imágenes termográficas y se calcularon los indicadores estadísticos de las ecuaciones (2.3) a (2.17). Adicionalmente, se aplicó una paleta de colores a las imágenes termográficas. La paleta de pseudo color

Motor WEG

La Figura 4.3 muestra la aplicación de la paleta de pseudo colores a la imagen termográfica infrarroja del motor de inducción WEG en condición sana, gracias a la paleta de colores se puede apreciar cualitativamente la región de mayor temperatura en el motor. A su vez, la Figura 4.4 muestra la aplicación del pseudo color a la captura del motor WEG conectado a la caja de engranes en condición sana. Asimismo, para el análisis cuantitativo de las capturas termográficas se utilizó el IP-core para el cálculo de indicadores estadísticos. Al calcular la media y la desviación estándar de las imágenes termográficas se obtuvo una base de datos de indicadores cuantitativos de las imágenes. Dichos indicadores se graficaron para observar su comportamiento al realizar cinco ensayos con estado de falla diferente. La Figura 4.5a muestra la evolución en el estado estable de la media en la imagen termográfica. Por su parte, la Figura 4.5b muestra la evolución en el estado estable de la desviación estándar en la imagen termográfica. A su vez, se graficaron las dos variables una respecto a la otra para observar que los indicadores se agrupaban de acuerdo al estado

de falla al que pertenecían (Figura 4.6). Los estados de falla analizados fueron: sano (HLT), desalineamiento (MAMT), desbalance (UNB), rodamiento dañado (BDF) y una barra rota (BRB).

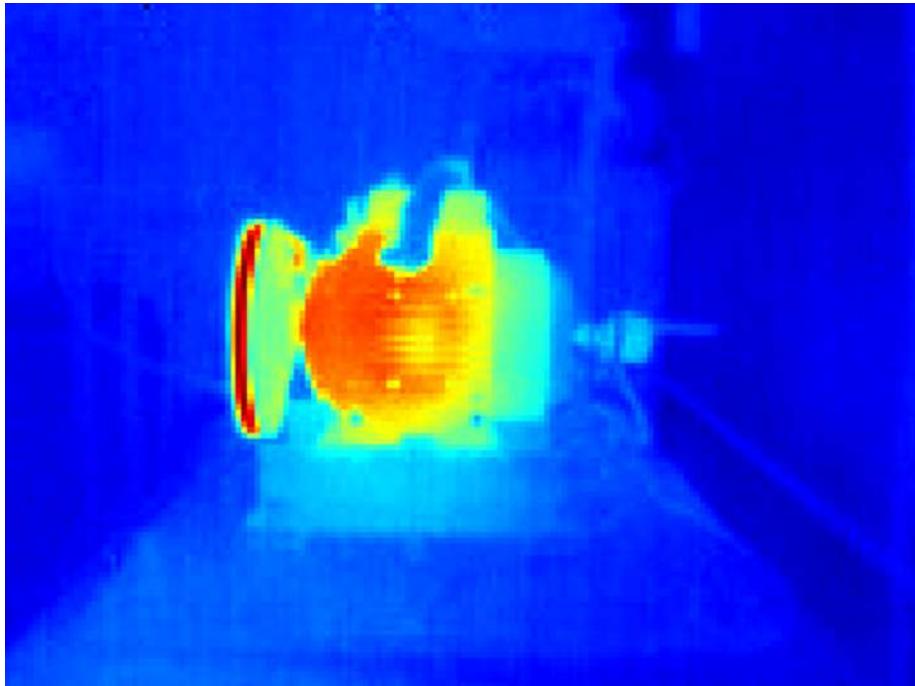


Figura 4.3: Termograma infrarrojo del motor WEG con pseudo color aplicado

El procesamiento de los datos de las imágenes termográficas del motor WEG al ser procesados en la unidad FPGA de la tarjeta Xilinx PYNQ Z2 se validó al comparar los resultados obtenidos con el análisis de la media y la desviación estándar de las imágenes termográficas en MATLAB. La Figura 4.7 muestra la agrupación de los indicadores estadísticos de acuerdo al caso de falla en el motor de inducción. Se puede observar que el resultado en las Figuras 4.6 y 4.7 es el mismo, lo que indica que el análisis en la tarjeta PYNQ Z2 fue correcto.

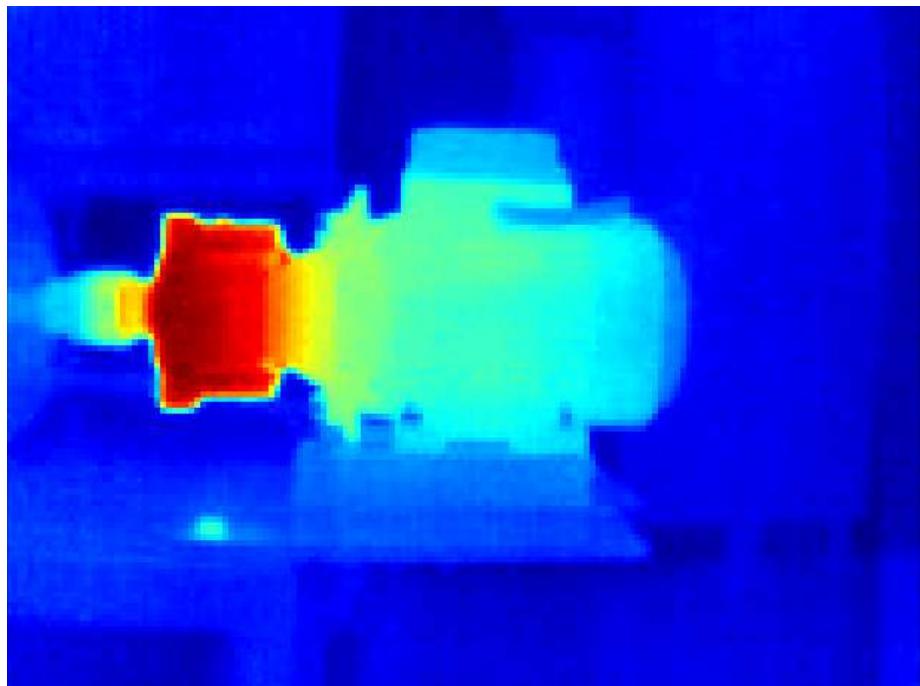


Figura 4.4: Termograma infrarrojo coloreado del motor WEG con caja de engranes

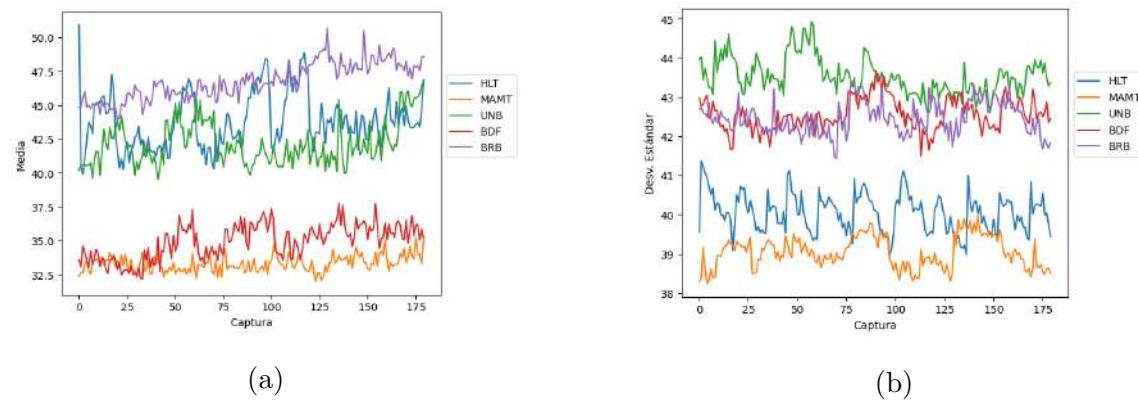


Figura 4.5: Evolución de indicadores termográficos en motor WEG: a) Media, b) Desviación Estándar

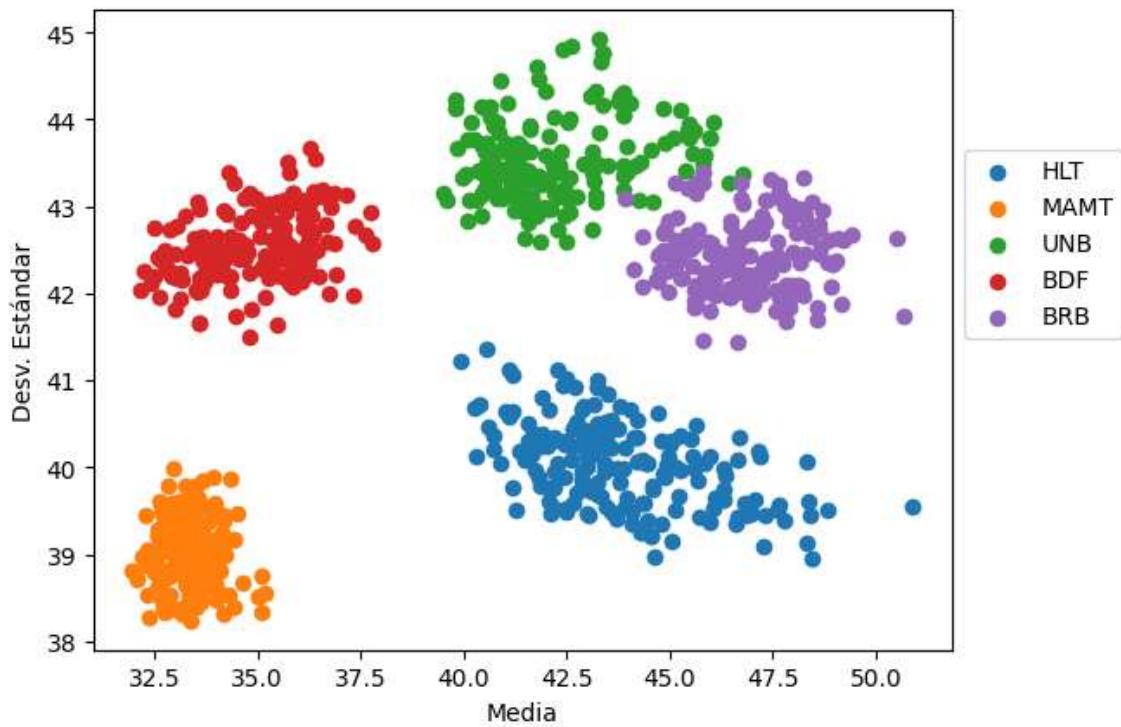


Figura 4.6: Datos agrupados de los indicadores estadísticos evaluados en las imágenes termográficas en motor WEG

Motor UPV

La Figura 4.8 muestra la aplicación de la paleta de pseudo colores a la imagen termográfica infrarroja del motor de inducción de la UPV en condición sana, gracias a la paleta de colores se puede apreciar cualitativamente la región de mayor temperatura en el motor.

El IP-core implementado en la FPGA se usó para calcular los dos estadísticos del conjunto de imágenes termográficas adquiridas, con esto se obtuvo una base de datos de indicadores cuantitativos de las imágenes. La Figura 4.9a muestra la evolución de la media de las imágenes termográficas, mientras que la Figura 4.9b muestra

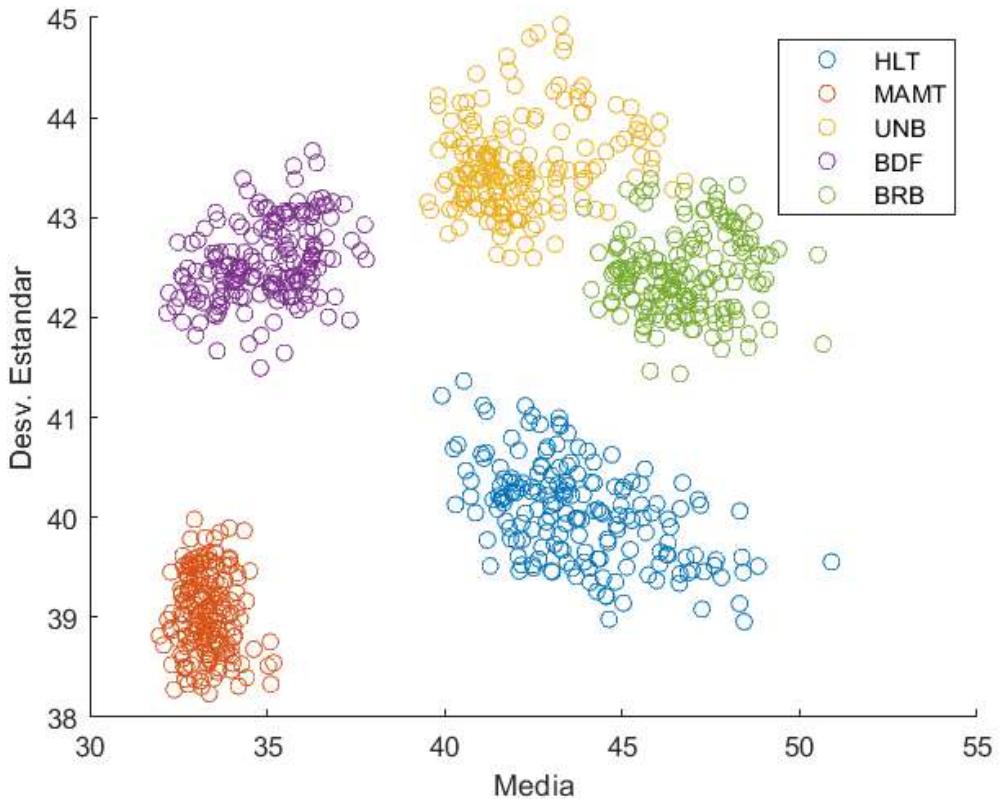


Figura 4.7: Resultados del análisis de media y desviación estándar en MATLAB

la evolución de la desviación estándar de las imágenes termográficas. Finalmente, en la Figura 4.10 se muestra la agrupación de los datos obtenidos tomando los dos indicadores estadísticos como referencia. Los casos de estudio que se muestran son: motor sano (HLT), desalineamiento horizontal (HML), tornillo suelto (LB), desbalance menor (UNB0), desbalance mayor (UNB1), y desalineamiento vertical (VML).

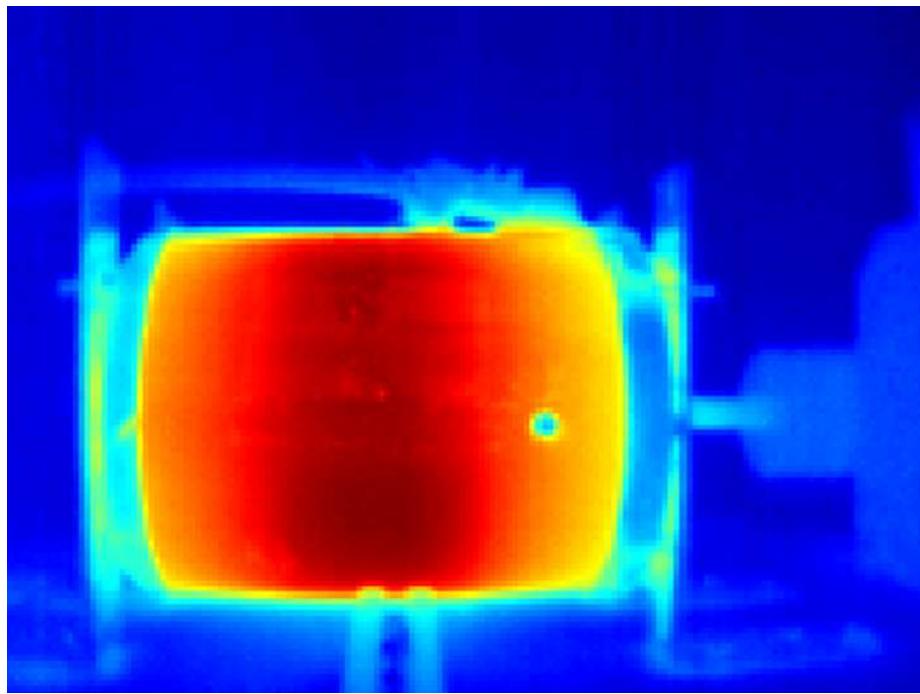


Figura 4.8: Termograma infrarrojo del motor UPV con pseudo color aplicado

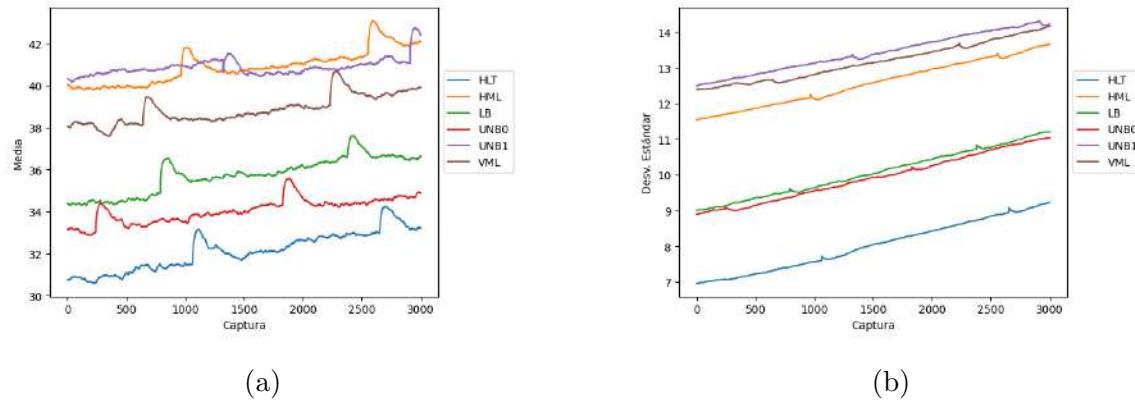


Figura 4.9: Evolución de indicadores termográficos en motor UPV: a) Media, b) Desviación Estándar

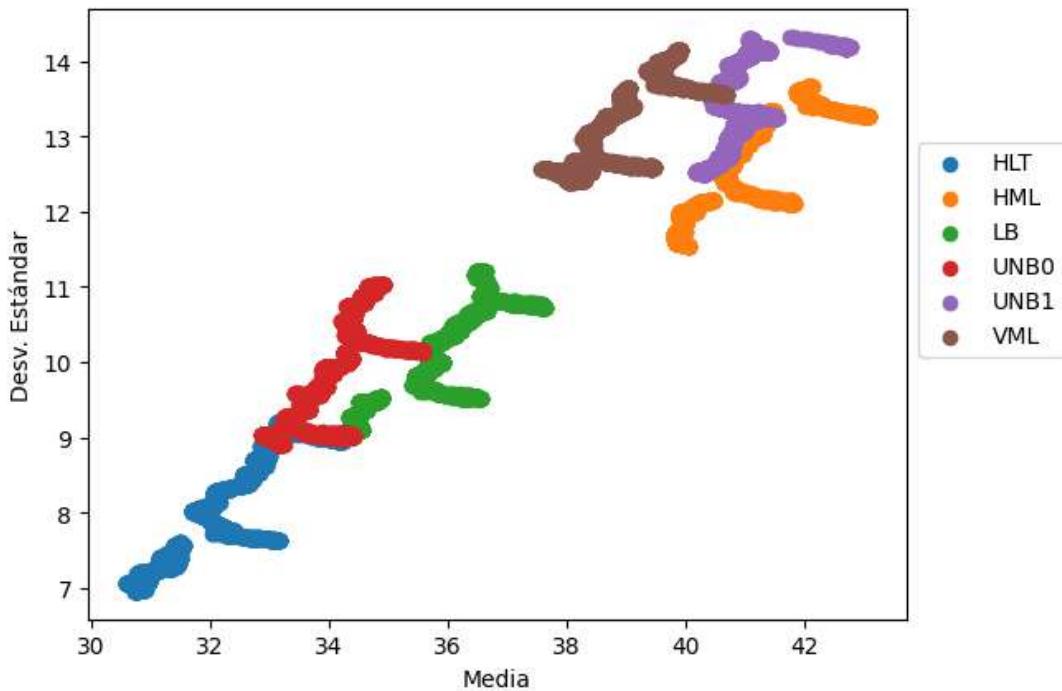


Figura 4.10: Datos agrupados de los indicadores estadísticos evaluados en las imágenes termográficas en motor UPV

4.3.2. Análisis de corriente eléctrica

El análisis de las señales de corriente eléctrica de los motores de inducción se hizo con tres enfoques: primero, se hizo un análisis estadístico temporal de las señales adquiridas con los indicadores de las ecuaciones (2.3) a (2.17); en segundo lugar, se hizo el análisis frecuencial de las señales con la FFT; y finalmente, se obtuvieron espectrogramas tiempo-frecuenciales con la técnica de la STFT.

Tras hacer el análisis estadístico de las señales de corriente eléctrica se obtuvo una matriz de los quince indicadores estadísticos presentados en la tabla 2.2. Se hicieron gráficas del tipo diagrama de caja para observar la distribución de cada

uno de los indicadores estadísticos dependiendo de la condición de estudio del motor de inducción del banco de pruebas. La Figura 4.11 muestra los diagramas de caja obtenidos para los casos de fallo en la caja de engranajes donde se analizaron cuatro severidades de falla: sano o 0 % de desgaste, 25 % de desgaste, 50 % de desgaste, y 75 % de desgaste.

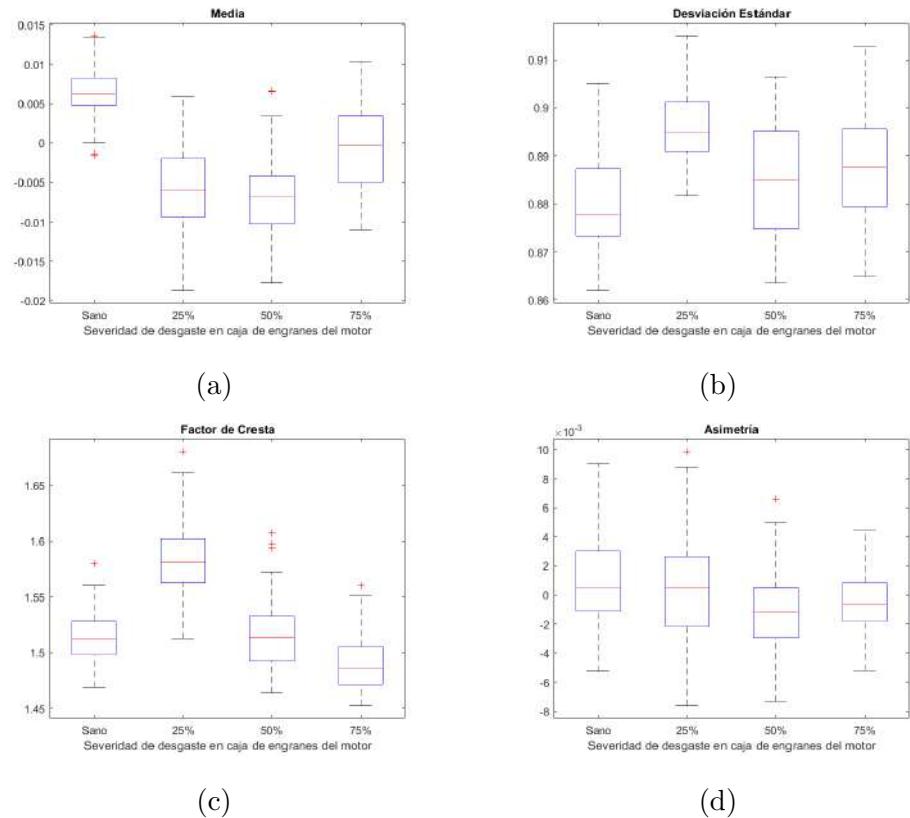


Figura 4.11: Diagramas de caja de los indicadores estadísticos más representativos de señales de corriente eléctrica. a) media, b) desviación estándar, c) factor de cresta, d) asimetría

En el análisis frecuencial se calculó la Transformada Rápida de Fourier (FFT) de las señales de corriente eléctrica del motor. La Figura 4.12 muestra la

representación gráfica de los resultados obtenidos tras el cálculo de la FFT de las señales para distintos casos de falla: motor sano, media barra rota, una barra rota, desbalance, y desalineamiento. El análisis tiempo-frecuencial efectuado en el régimen transitorio (de 10 segundos de duración) y estacionario (20 segundos de duración) en las señales de corriente del motor WEG se observa en los espectrogramas mostrados en la Figura 4.13. Los espectrogramas mostrados en la Figura 4.13 se calcularon tomando una frecuencia de muestreo $F_s = 4000$ Hz, un tamaño de ventana de $N_{FFT} = 1024$ muestras, y una superposición de las ventanas del 75 %. Estos espectrogramas se generaron en la tarjeta de desarrollo PYNQ Z2 con el IP-core implementado para el cálculo de la FFT.

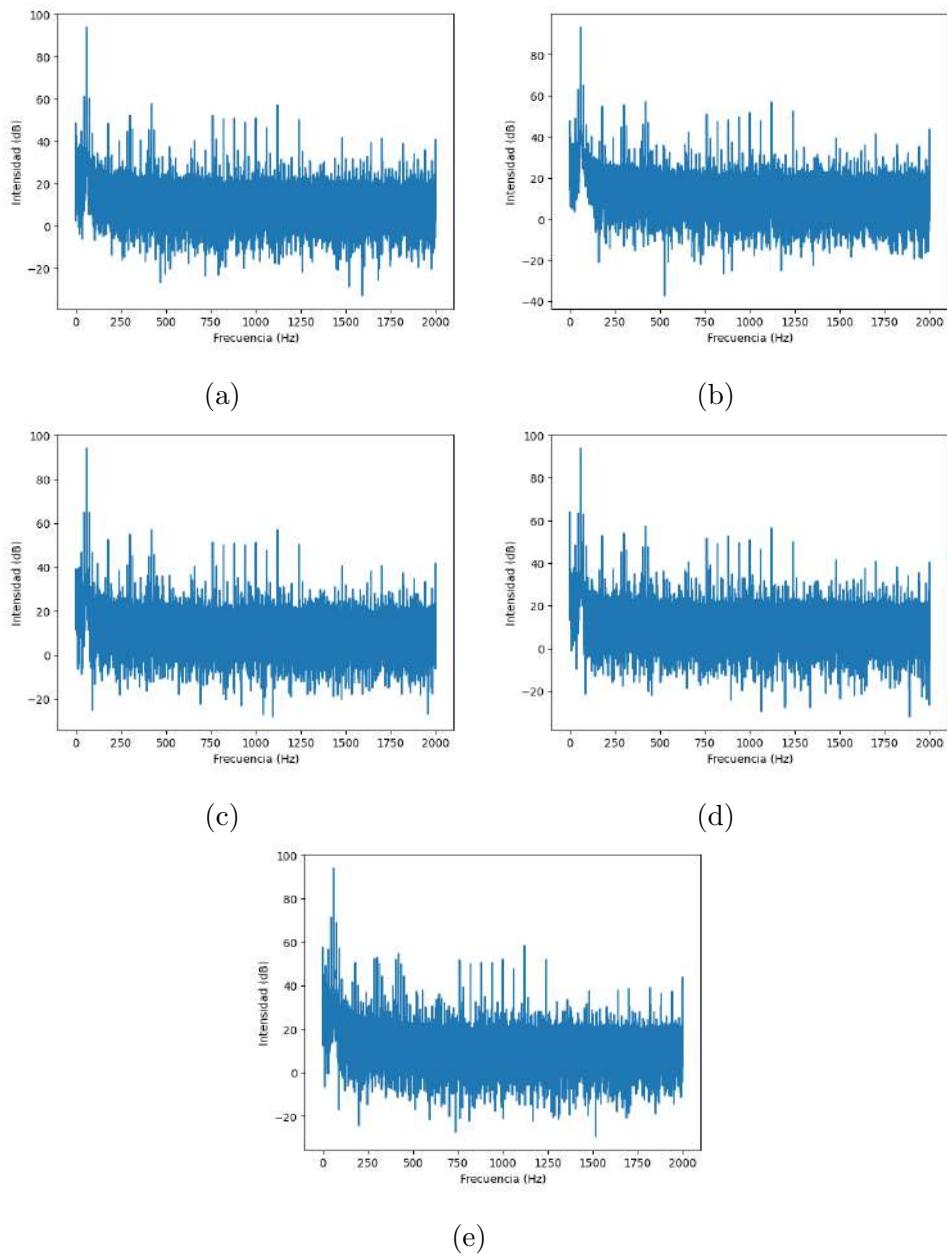


Figura 4.12: Espectrogramas del análisis tiempo-frecuencial de señales de corriente eléctrica en motor WEG: a) Motor Sano, b) 1/2 Barra rota, c) 1 Barra rota, d) Desbalance, y e) Desalineamiento

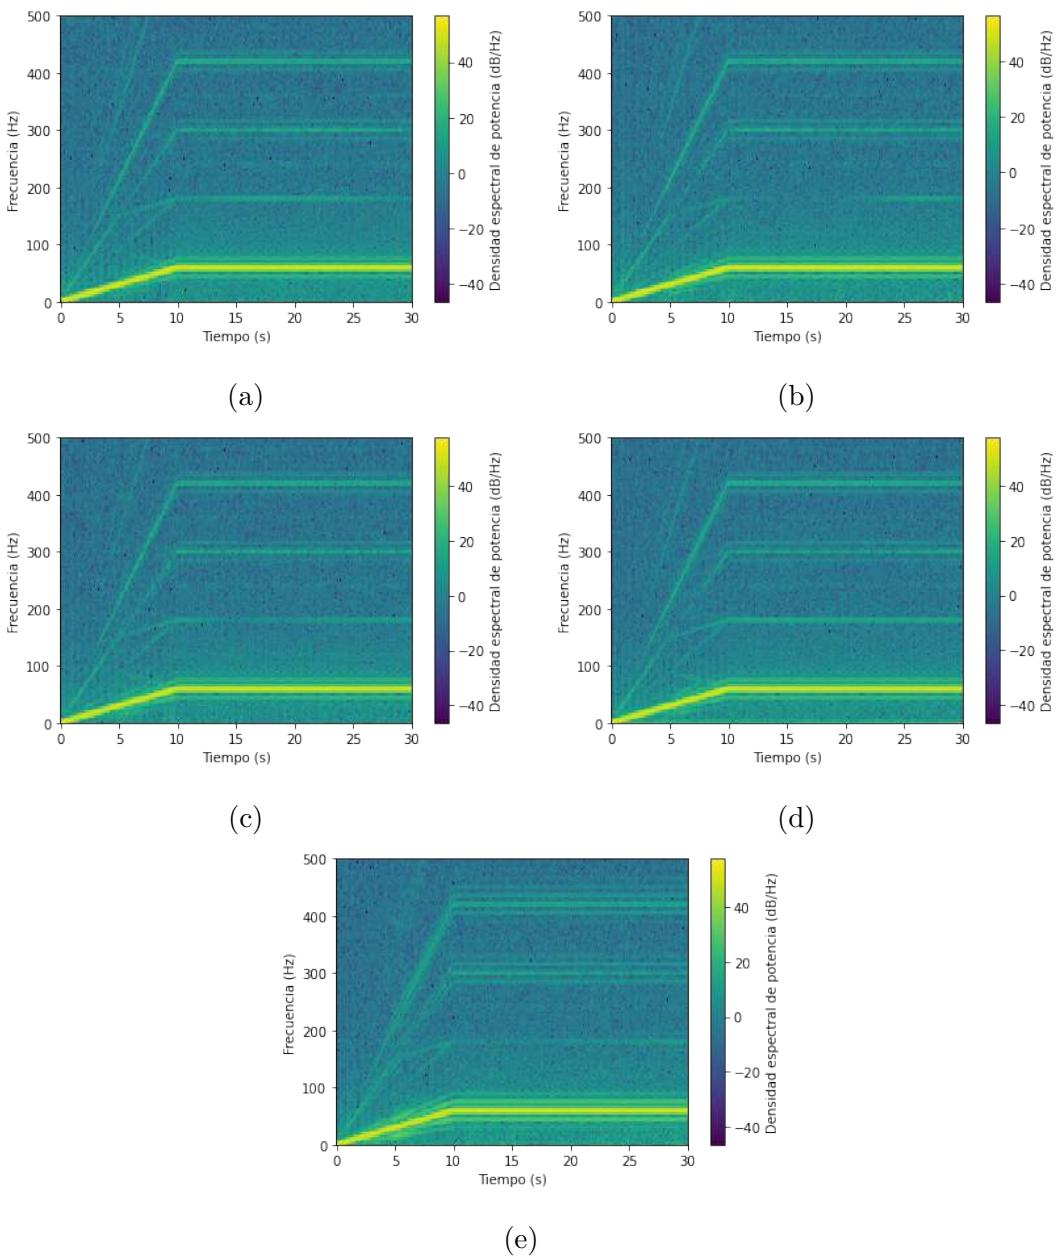


Figura 4.13: Espectrogramas del análisis tiempo-frecuencial de señales de corriente eléctrica en motor WEG: a) Motor Sano, b) 1/2 Barra rota, c) 1 Barra rota, d) Desbalance, y e) Desalineamiento

4.4. Clasificación de estados de falla

Asimismo, se entrenaron distintos modelos de clasificación con algoritmos de Machine Learning en el software de MATLAB con los datos de media y desviación estándar de las imágenes termográficas como indicadores del estado de falla del motor. Uno de los modelos entrenados fue un clasificador de K-Vecinos Cercanos Ponderados (*Weighted K-Nearest Neighbours*) considerando $k = 10$, tomando la distancia euclíadiana entre puntos, y usando la inversa del cuadrado de la distancia para la ponderación. El resultado del entrenamiento dio un 99.4 % de exactitud en la predicción de los casos de falla. El entrenamiento se validó haciendo una validación cruzada de 5 iteraciones, obteniendo la matriz de confusión de la Tabla 4.3. Otro modelo de clasificador de Machine Learning que se entrenó con este conjunto de datos fue un modelo de Máquina de Soporte Vectorial Líneal (*Lineal Support Vector Machine*). El modelo clasificador obtenido como resultado del entrenamiento dio una exactitud del 99.0 % en la predicción de los cinco casos de falla. La Tabla 4.4 es la matriz de confusión del modelo clasificador SVM.

Tabla 4.3: Matriz de confusión de clasificador kNN con indicadores termográficos en motor WEG

Pronosticada \ Verdadera	HLT	MAMT	UNB	BDF	BRB
HLT	100.0 %	0.0 %	0.0 %	0.0 %	0.0 %
MAMT	0.0 %	100.0 %	0.0 %	0.0 %	0.0 %
UNB	0.0 %	0.0 %	97.8 %	0.0 %	2.2 %
BDF	0.0 %	0.0 %	0.0 %	100 %	0.0 %
BRB	0.0 %	0.0 %	0.6 %	0.0 %	100 %

Tabla 4.4: Matriz de confusión de clasificador SVM con indicadores termográficos en motor WEG

Pronosticada \ Verdadera	HLT	MAMT	UNB	BDF	BRB
HLT	100.0 %	0.0 %	0.0 %	0.0 %	0.0 %
MAMT	0.0 %	100.0 %	0.0 %	0.0 %	0.0 %
UNB	0.0 %	0.0 %	98.9 %	0.0 %	1.1 %
BDF	0.0 %	0.0 %	0.0 %	100 %	0.0 %
BRB	0.0 %	0.0 %	3.9 %	0.0 %	96.1 %

4.5. Publicaciones y aportaciones

El trabajo realizado en la adquisición y procesamiento de las imágenes termográficas y señales de corriente eléctrica de los motores de inducción se vio reflejado

en la publicación de artículos en congresos nacionales e internacionales. Además, se logró la publicación de un artículo en la revista científica MDPI SENSORS figurando como primer autor y un artículo en la revista científica MEASUREMENT participando como autor colaborador. La Tabla 4.5 lista las publicaciones realizadas en congresos en el tiempo de elaboración de la investigación y la Tabla 4.6 lista las publicaciones aceptadas en revistas científicas.

Tabla 4.5: Publicaciones realizadas en congresos durante el período de la investigación

Nombre de la publicación	Congreso
<i>Hardware Accelerated Thermal Image Processing for the Detection of Induction Motor Faults Based on Statistical Features</i> (Alvarado-Hernandez <i>et al.</i> , 2023)	IECON 2023
<i>Infrared Thermographic Image Processing for Identification of Gradual Damage to the Outer Race of Bearings in Induction Motors</i> (Alvarado-Hernandez, Osornio-Rios y Antonino-Daviu, 2022)	IECON 2022
<i>Design and Development of Virtual Reality Application Based on Infrared Thermography for the Detection of Multiple Faults in Kinematic Chains</i> (Alvarado-Hernandez, Checa <i>et al.</i> , 2022)	ICEM 2022

Tabla 4.6: Publicaciones realizadas en revistas científicas durante el período de la investigación

Nombre de la publicación	Revista
<i>Infrared Thermography Smart Sensor for the Condition Monitoring of Gearbox and Bearings Faults in Induction Motors</i> (Alvarado-Hernandez, Zamudio-Ramirez <i>et al.</i> , 2022)	Sensors
<i>Fault detection and classification in kinematic chains by means of PCA extraction-reduction of features from thermographic images</i> (Osornio-Rios <i>et al.</i> , 2022)	Measurement

Capítulo 5

Conclusiones

El desarrollo de este trabajo permitió la implementación de técnicas estadísticas y técnicas tiempo-frecuenciales en una unidad lógica FPGA a través del diseño de entidades de hardware conocidos como IP-cores. Estos IP-cores estuvieron dedicados a tareas específicas de cálculo y fueron utilizados en conjunto con algoritmos implementados en un microprocesador ARM dentro de un mismo sistema embebido en una tarjeta de desarrollo. La ejecución de los algoritmos en los IP-cores digitales implementados fue sustancialmente más rápida en comparación con la ejecución de los mismos algoritmos en el microprocesador de la tarjeta de desarrollo, consumiendo una baja proporción de los recursos computacionales de la unidad FPGA (cerca del 15 % por IP-core). Además, al hacer la implementación en la tarjeta PYNQ Z2 de Xilinx se pudo establecer una fácil comunicación entre la interfaz de registros de memoria del FPGA y el entorno de programación de Python. La visualización de los resultados de los procesamientos se realizó a través de una serie de gráficas elaboradas con las librerías *open-source* de Python. La metodología propuesta para el manejo y procesamiento de las imágenes termográficas adquiridas con un sensor infrarrojo de bajo costo demostró ser efectiva para la obtención de parámetros estadísticos significativos para la identificación de distintos casos distintos de falla con una exactitud cercana al 99 % con clasificadores de Machine Learning como fueron los de tipo K-Vecinos Cercanos y Máquina de Soporte Vectorial. Además, los datos de las señales de corriente eléctrica se pudieron procesar con las técnicas

tiempo-frecuenciales propuestas, logrando obtener espectrogramas bidimensionales que ilustran el comportamiento de las componentes frecuenciales respecto al tiempo. Los algoritmos implementados en la tarjeta de desarrollo se probaron en dos bancos de datos que incluyeron termogramas infrarrojos y señales de corriente de dos motores distintos en bancadas diferentes. No obstante las diferencias en las señales adquiridas, la implementación de los algoritmos en la FPGA tuvo la robustez necesaria para entregar resultados de análisis satisfactorios y certeros en comparación con implementaciones en software como MATLAB. Como prospectivas del trabajo se propone ampliar la base de datos que se tiene de los motores de inducción con más casos de falla. Otra prospectiva se encuentra en la implementación de otro tipo de clasificadores por Machine Learning que permita aprovechar la información en los espectrogramas tiempo-frecuenciales de las señales de corriente, poniendo como ejemplo las redes neuronales convolucionales.

Bibliografía

- Alvarado-Hernandez, A. I., Checa, D., Osornio-Rios, R. A., Bustillo, A., & Antonino-Daviu, J. A. (2022). Design and Development of Virtual Reality Application Based on Infrared Thermography for the Detection of Multiple Faults in Kinematic Chains. *2022 International Conference on Electrical Machines (ICEM)*. <https://doi.org/10.1109/icem51905.2022.9910772>
- Alvarado-Hernandez, A. I., Osornio-Rios, R. A., & Antonino-Daviu, J. A. (2022). Infrared Thermographic Image Processing for Identification of Gradual Damage to the Outer Race of Bearings in Induction Motors. *IECON 2022 - 48th Annual Conference of the IEEE Industrial Electronics Society*. <https://doi.org/10.1109/iecon49645.2022.9969081>
- Alvarado-Hernandez, A. I., Osornio-Rios, R. A., Zamudio-Ramirez, I., & Antonino-Daviu, J. A. (2023). Hardware Accelerated Thermal Image Processing for the Detection of Induction Motor Faults Based on Statistical Features. *IECON 2023- 49th Annual Conference of the IEEE Industrial Electronics Society*. <https://doi.org/10.1109/iecon51785.2023.10311683>
- Alvarado-Hernandez, A. I., Zamudio-Ramirez, I., Jaen-Cuellar, A. Y., Osornio-Rios, R. A., Donderis-Quiles, V., & Antonino-Daviu, J. A. (2022). Infrared Thermography Smart Sensor for the Condition Monitoring of Gearbox and Bearings Faults in Induction Motors. *Sensors*, 22(16), 6075. <https://doi.org/10.3390/s22166075>
- Arellano Espitia, F. (2018). *Análisis Estadístico de Señales Aplicado a Cadenas Cinemáticas* [Tesis de Maestría]. Universidad Autónoma de Querétaro.

- Asad, B., Vaimann, T., Belahcen, A., Kallaste, A., Rassõlkin, A., Ghafarokhi, P. S., & Kudelina, K. (2021). Transient Modeling and Recovery of Non-Stationary Fault Signature for Condition Monitoring of Induction Motors. *Applied Sciences*, 11(6). <https://doi.org/10.3390/app11062806>
- Barnes, M. (2003). 3-Phase AC induction motors. En *Practical Variable Speed Drives and Power Electronics* (pp. 36-67). Elsevier. <https://doi.org/10.1016/b978-075065808-9/50002-4>
- Benbouzid, M. E. H. (2000). A review of induction motors signature analysis as a medium for faults detection. *IEEE Transactions on Industrial Electronics*, 47(5), 984-993. <https://doi.org/10.1109/41.873206>
- Cao, P., Zhang, S., & Tang, J. (2018). Preprocessing-Free Gear Fault Diagnosis Using Small Datasets With Deep Convolutional Neural Network-Based Transfer Learning. *IEEE Access*, 6, 26241-26253. <https://doi.org/10.1109/ACCESS.2018.2837621>
- Choudhary, A., Goyal, D., & Letha, S. S. (2021). Infrared Thermography-Based Fault Diagnosis of Induction Motor Bearings Using Machine Learning. *IEEE Sensors Journal*, 21(2), 1727-1734. <https://doi.org/10.1109/JSEN.2020.3015868>
- Choudhary, A., Goyal, D., Shimi, S. L., & Akula, A. (2019). Condition Monitoring and Fault Diagnosis of Induction Motors: A Review. *Archives of Computational Methods in Engineering*, 26(4), 1221-1238. <https://doi.org/10.1007/s11831-018-9286-z>
- Cureño Osornio, J. (2020). *Análisis de desgaste mediante flujo magnético en la pista exterior de rodamientos bajo diversas severidades de daño* [Tesis de Maestría]. Universidad Autónoma de Querétaro.
- Data Classification: Algorithms and Applications*. (2020). CRC Press.

- Dhamande, L. S., & Chaudhari, M. B. (2018). Compound gear-bearing fault feature extraction using statistical features based on time-frequency method. *Measurement*, 125, 63-77. <https://doi.org/10.1016/j.measurement.2018.04.059>
- Enríquez Ugalde, J. M. (2020). *Diagnóstico multi-falla en cadena cinemática utilizando termografía infrarroja y análisis de componentes principales* [Tesis de Maestría]. Universidad Autónoma de Querétaro.
- Gangsar, P., & Tiwari, R. (2020). Signal based condition monitoring techniques for fault detection and diagnosis of induction motors: A state-of-the-art review. *Mechanical Systems and Signal Processing*, 144, 106908. <https://doi.org/10.1016/j.ymssp.2020.106908>
- Geron, A. (2022). *Hands-on machine learning with scikit-learn, keras, and TensorFlow 3e: Concepts, tools, and techniques to build intelligent systems* (3.^a ed.). O'Reilly Media.
- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). *An introduction to statistical learning: with applications in R* [Includes bibliographical references and index.]. New York : Springer, [2013] ©2013. <https://search.library.wisc.edu/catalog/9910207152902121>
- Jing, L., Zhao, M., Li, P., & Xu, X. (2017). A convolutional neural network based feature learning and fault diagnosis method for the condition monitoring of gearbox. *Measurement*, 111, 1-10. <https://doi.org/https://doi.org/10.1016/j.measurement.2017.07.017>
- Karmakar, S., Chattopadhyay, S., Mitra, M., & Sengupta, S. (2016). Introduction. En *Induction Motor Fault Diagnosis: Approach through Current Signature Analysis* (pp. 1-6). Springer Singapore. https://doi.org/10.1007/978-981-10-0624-1_1

- Kehtarnavaz, N. (2008). CHAPTER 7 - Frequency Domain Processing. En N. Kehtarnavaz (Ed.), *Digital Signal Processing System Design (Second Edition)* (Second Edition, pp. 175-196). Academic Press. <https://doi.org/https://doi.org/10.1016/B978-0-12-374490-6.00007-6>
- Khanjani, M., & Ezoji, M. (2021). Electrical fault detection in three-phase induction motor using deep network-based features of thermograms. *Measurement*, 173, 108622. <https://doi.org/https://doi.org/10.1016/j.measurement.2020.108622>
- Kumar, S., Mukherjee, D., Guchhait, P. K., Banerjee, R., Srivastava, A. K., Vishwakarma, D. N., & Saket, R. K. (2019). A Comprehensive Review of Condition Based Prognostic Maintenance (CBPM) for Induction Motor. *IEEE Access*, 7, 90690-90704. <https://doi.org/10.1109/ACCESS.2019.2926527>
- Mahami, A., Rahmoune, C., Bettahar, T., & Benazzouz, D. (2021). Induction motor condition monitoring using infrared thermography imaging and ensemble learning techniques. *Advances in Mechanical Engineering*, 13(11), 168781402110609. <https://doi.org/10.1177/16878140211060956>
- Nayana, B. R., & Geethanjali, P. (2017). Analysis of Statistical Time-Domain Features Effectiveness in Identification of Bearing Faults From Vibration Signal. *IEEE Sensors Journal*, 17(17), 5618-5625. <https://doi.org/10.1109/JSEN.2017.2727638>
- Osornio-Rios, R. A., Jaen-Cuellar, A. Y., Alvarado-Hernandez, A. I., Zamudio-Ramirez, I., Cruz-Albarran, I. A., & Antonino-Daviu, J. A. (2022). Fault detection and classification in kinematic chains by means of PCA extraction-reduction of features from thermographic images. *Measurement*, 197, 111340. <https://doi.org/10.1016/j.measurement.2022.111340>

- Ramírez Chávez, M. (2019). *Sensor Inteligente basado en técnicas de tiempo-frecuencia para supervisión de fallas en cojinetes cerámicos y metálicos* [Tesis de Maestría]. Universidad Autónoma de Querétaro.
- Rangel-Magdaleno, J., Ramirez-Cortes, J., & Peregrina-Barreto, H. (2013). Broken bars detection on induction motor using MCSA and mathematical morphology: An experimental study. *Conference Record - IEEE Instrumentation and Measurement Technology Conference*, (10), 825-829. <https://doi.org/10.1109/I2MTC.2013.6555530>
- Reséndiz Ochoa, E. (2020). *Sistema de visión artificial para el monitoreo de motores de inducción eléctrica y la cadena cinemática mediante termografía infrarroja* [Tesis Doctoral]. Universidad Autónoma de Querétaro.
- Saad, N., Irfan, M., & Ibrahim, R. (2018). *Condition Monitoring and Faults Diagnosis of Induction Motors*. CRC Press. <https://doi.org/10.1201/9781351172561>
- Saucedo Dorantes, J. (2017). *Metodologías para mejorar la confiabilidad del diagnóstico de fallas en cadenas cinemáticas basado en algoritmos inteligentes y fusión de datos* [Tesis Doctoral]. Universidad Autónoma de Querétaro.
- Shao, S.-Y., Sun, W.-J., Yan, R.-Q., Wang, P., & Gao, R. X. (2017). A Deep Learning Approach for Fault Diagnosis of Induction Motors in Manufacturing. *Chinese Journal of Mechanical Engineering*, 30(6), 1347-1356. <https://doi.org/10.1007/s10033-017-0189-y>
- Toma, R. N., & Kim, J.-M. (2021). Induction Motor Bearing Fault Diagnosis Using Statistical Time Domain Features and Hypertuning of Classifiers. En J. J. Park, S. J. Fong, Y. Pan & Y. Sung (Eds.), *Advances in Computer Science and Ubiquitous Computing* (pp. 259-265). Springer Singapore.

- Toma, R. N., Prosvirin, A. E., & Kim, J.-M. (2020). Bearing Fault Diagnosis of Induction Motors Using a Genetic Algorithm and Machine Learning Classifiers. *Sensors*, 20(7). <https://doi.org/10.3390/s20071884>
- Vollmer, M., & Moellmann, K.-P. (2018). *Infrared thermal imaging* (2.^a ed.). Wiley-VCH Verlag.