



Universidad Autónoma de Querétaro
Facultad de Ingeniería



Procesamiento de señales termográficas para integración en un *Smart Sensor* multivariable aplicado al diagnóstico de fallos en motores de inducción.

TESIS

Que como parte de los requisitos para obtener el título de
INGENIERO ELECTROMECAÁNICO

Presenta:

Alvaro Iván Alvarado Hernández

Dirigido por:

Dr. Roque Alfredo Osornio Ríos

San Juan del Río, Qro., octubre, 2021



Universidad Autónoma de Querétaro
Facultad de Ingeniería



Procesamiento de señales termográficas para integración en un *Smart Sensor*
multivariable aplicado al diagnóstico de fallos en motores de inducción.

TESIS

Que como parte de los requisitos para obtener el título de

INGENIERO ELECTROMECAÁNICO

Línea terminal:

MECATRÓNICA

Presenta:

Alvaro Iván Alvarado Hernández

Dirigido por:

Dr. Roque Alfredo Osornio Ríos

SINODALES:

Dr. Roque Alfredo Osornio Ríos (5620)

Presidente

M. Israel Zamudio Ramirez (16787)

Secretario

Dr. Miguel Trejo Hernández (6443)

Vocal

Dr. Arturo Yosimar Jaen Cuellar (11825)

Suplente

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 a lo largo de este viaje llamado vida, siendo mi motor para seguir adelante.

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 mis asesores, Dr. Roque Alfredo Osornio Ríos y Mtro. Israel Zamudio Ramírez, por el constante apoyo, retroalimentación, y consejo que me brindaron para la elaboración de este trabajo.

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.

A mis amigos y compañeros, por hacer de estos años algo digno de recordar por siempre.

Índice general

Índice de tablas VI

Índice de figuras VII

1. Introducción	1
1.1. Antecedentes	3
1.2. Descripción del problema	7
1.3. Justificación	8
1.4. Objetivos	9
1.4.1. Objetivo General	9
1.4.2. Objetivos Específicos	9
1.5. Planteamiento General	10
2. Fundamentación teórica	14
2.1. Fallas en motores de inducción	14
2.1.1. Fallas de barras rotas	16
2.1.2. Excentricidad o desbalance mecánico	16
2.1.3. Fallas en los baleros	16
2.1.4. Fallas de corto circuito interno	17
2.2. Termografía	17
2.2.1. Procesamiento de imágenes termográficas	17
2.2.2. Segmentación de la imagen	20
2.2.3. Extracción de características	23
2.3. Herramientas de clasificación	26

2.3.1. Técnicas de clasificación	26
2.4. Herramientas de programación	32
2.4.1. Lenguaje C++	32
2.4.2. Qt	34
2.4.3. OpenCV	35
3. Metodología	36
3.1. Módulo termográfico	38
3.1.1. Preprocesamiento de la imagen	39
3.1.2. Segmentación de la imagen termográfica	39
3.1.3. Extracción de características	41
3.2. Combinación de variables	41
3.3. Clasificación de estados del motor	42
4. Resultados	44
4.1. Experimentación y adquisición de datos	44
4.1.1. Matriz de pruebas	44
4.1.2. Bancada de experimentación	45
4.2. Procesamiento de imágenes termográficas	47
4.3. Combinación de variables	50
4.4. Clasificación de estados del motor	52
4.5. Interfaz de Usuario del Smart Sensor	52
5. Conclusiones	56
Bibliografía	58
A. Código para procesamiento de imágenes termográficas	63

Dirección General de Bibliotecas UAQ

Índice de tablas

2.1. Descripción de técnicas de segmentación (Dilpreet & Yadwinder, 2014)	21
2.2. Parámetros estadísticos del histograma	23
3.1. Organización general de la matriz de fusión de variables	41
4.1. Matriz de pruebas de la metodología	44
4.2. Datos técnicos del motor estudiado	46

Dirección General de Bibliotecas UAQ

Índice de figuras

1.1. Diagrama del planteamiento general	11
2.1. Clasificación de fallas en motores de inducción (Choudhary et al., 2019)	14
2.2. Incidencia de tipos de falla en motores eléctricos (Choudhary et al., 2019)	15
2.3. Comparación de imágenes termográficas al mejorar el detalle al aplicar una gradación no lineal (Vollmer & Möllmann, 2018)	18
2.4. Ecualización del histograma de imágenes termográficas para mejora del contraste (Vollmer & Möllmann, 2018)	19
2.5. Ilustración de construcción de árboles de decisión (Aggarwal, 2014) .	29
2.6. Clasificación “dura” y “suave” por medio de SVM (Aggarwal, 2014) .	29
2.7. Redes neuronales de una o varias capas (Aggarwal, 2014)	30
2.8. UI (<i>User Interface</i>) de Qt Creator 4.14.0	35
3.1. Estructura general del <i>Smart Sensor</i>	36
3.2. Diagrama de bloques de la metodología propuesta	37
3.3. Sensor infrarrojo de bajo costo, FLIR Lepton 3.5	38
3.4. Diagrama a bloques del método de segmentación implementado . . .	40
3.5. Estructura de la Red Neuronal implementada	43
3.6. Casos de falla considerados en el entrenamiento de la red neuronal . .	43
4.1. Sistema diseñado para la adquisición de imágenes termográficas . . .	46
4.2. Bancada de pruebas usada en la experimentación	47

4.3. UI de aplicación para captura y procesamiento de imágenes termográficas	48
4.4. Segmentación de ROI mediante uso de los métodos de Otsu y SIFT	49
4.5. Representación gráfica de los histogramas calculados a partir de imágenes térmicas. a) Motor Sano, b) Caso de una barra rota, c) Caso de dos barras rotas.	50
4.6. Reducción de dimensionalidad de la matriz combinada por PCA	51
4.7. Reducción de dimensionalidad de matriz termográfica por PCA	51
4.8. Matriz de confusión de red neuronal entrenada solamente con parámetros termográficos	53
4.9. Matriz de confusión de red neuronal entrenada con parámetros multivariados (termografía, flujo magnético, corriente eléctrica)	54
4.10. Capturas de pantalla de la Interfaz de Usuario (UI) del Smart Sensor	55

Capítulo 1

Introducción

El motor de inducción, también conocido como motor asíncrono, es un componente esencial en un gran número de procesos industriales en la actualidad gracias a su robustez, bajo costo y eficiencia, consumiendo alrededor del 85 % de la energía ocupada en plantas industriales (Hassan et al., 2018). Es por esto que la detección de fallas y el mantenimiento de estos equipos ha tomado un papel cada vez más importante en la ingeniería electromecánica.

Las técnicas y métodos utilizados para el monitoreo y diagnóstico de fallas reportados en la literatura actual se han basado en la adquisición y procesamiento de señales con sensores. Choudhary et al. (2019) recopilan algunas de las variables utilizadas en los sistemas actuales de monitoreo, entre estas se encuentran: vibración mecánica, emisiones acústicas, corriente eléctrica, y temperatura (mediante uso de termografía infrarroja). Además, el análisis del flujo magnético disperso en los motores asíncronos es un método de estudio que ha sido propuesto en trabajos recientes para el diagnóstico de fallas (Ramirez et al., 2018).

El uso de la termografía en la industria es trascendental debido a que esta técnica permite la visualización de los efectos típicamente invisibles del aumento en la temperatura en los equipos eléctricos, siendo una herramienta poderosa para el diagnóstico y monitoreo (Vollmer & Möllmann, 2018).

Por otro lado, el desarrollo de *Smart Sensors* —i. e., sensores inteligentes— ha ganado notoriedad en las últimas décadas gracias al avance tecnológico reciente, en

especial a la llegada y establecimiento de los sistemas microelectrónicos y la reciente popularización del Internet de las Cosas (*Internet of Things, IoT*). Como lo señala Frank (2013): “El creciente interés en los *Smart Sensors* es un resultado directo de la necesidad de comunicar y compartir la información de los sensores en sistemas de control distribuidos y redes de cualquier tipo”.

El presente trabajo complementa el desarrollo de un *Smart Sensor* multi-variable para el diagnóstico de fallas en motores de inducción con el diseño e implementación de un módulo de adquisición y procesamiento de señales termográficas, y adicionalmente, con la creación un módulo de clasificación para seleccionar la variable que permita realizar el diagnóstico más acertado.

El contenido de esta obra está organizado en cinco capítulos:

- En el **Capítulo 1** se presentan los objetivos y motivaciones del proyecto. Asimismo, se hace la discusión de algunos estudios significativos y relevantes para el desarrollo de este trabajo.
- En el **Capítulo 2** se recopilan los fundamentos teóricos del trabajo.
- En el **Capítulo 3** se describe el diseño e implementación de los módulos de procesamiento para el *Smart Sensor*, además, se plantean los experimentos para la validación del proyecto.
- En el **Capítulo 4** se presentan los resultados obtenidos a partir de la experimentación planteada en el capítulo anterior.
- Finalmente, en el **Capítulo 5** se discuten los resultados y la metodología propuesta, presentando los argumentos finales de la investigación.

1.1. Antecedentes

La detección de fallas electromecánicas en los motores de inducción es de suma importancia debido al papel esencial que estos equipos tienen en la industria moderna. Si bien el mantenimiento de los motores eléctricos suele ser programado, el rendimiento de estos equipos puede verse afectado en períodos irregulares. Por esta razón, diversos métodos para la detección de fallas han sido estudiados y reportados en la literatura, principalmente mediante la medición y análisis de corrientes, vibraciones mecánicas, flujo magnético y temperatura en los motores.

El análisis de la señal de corriente de un motor eléctrico es uno de los principales métodos documentados para la detección de fallas en estos equipos. En este ámbito, Deekshit et al. (2018) expusieron un método para la detección de fallas en baleros analizando la corriente del estator en un motor trifásico usando las técnicas Wavelet (*Discrete Wavelet Transform, DWT; Stationary Wavelet Transform, SWT; Wavelet Package Decomposition, WPD*) de descomposición de señales. La severidad de la falla es indicada mediante la relación de parámetros estadísticos adquiridos de un motor sano y aquellos que pertenecen a un motor en falla. Ghanbari (2016) desarrolló un modelo para el diagnóstico de fallas de corto circuito en el embobinado interno de un motor trifásico por medio del análisis de la autocorrelación de las señales de corriente medidas en el equipo a diagnosticar. El autor validó el método propuesto al comparar los resultados obtenidos contra otros métodos utilizados en el análisis de corrientes para la detección de falla, concluyendo que el modelo descrito tiene una sensibilidad del 0.47%. Frosini y Bassi (2010) propusieron el uso de la corriente eléctrica en el estator y la eficiencia del motor como indicadores en el diagnóstico de fallas en los baleros. El método propuesto se basó en la comparación

de los espectros frecuenciales obtenidos al medir la señal de corriente eléctrica en un motor sano y motores con falla en diferentes estados de carga. Además, se analizó el cambio en la eficiencia del motor usando las mediciones de corriente y considerando que la carga era constante en cada prueba. La metodología expuesta presentó resultados positivos para el diagnóstico de fallas cíclicas en los baleros (grieta en el balero y agujero externo en el balero). Ortiz et al. (2019) presentaron una metodología basada en el análisis de la corriente característica del motor (*Motor Current Signature Analysis, MCSA*) para la detección de desalineación del rotor. Para el análisis, los autores proponen la comparación de dos herramientas matemáticas: la transformada rápida de Fourier (*Fast Fourier Transform, FFT*) y la transformada de tiempo corto de Fourier (*Short Time Fourier Transform, STFT*) las cuales brindan una representación en el dominio frecuencial y en el dominio tiempo-frecuencia respectivamente, concluyendo que la *STFT* otorgaba mejores resultados de diagnóstico.

Otro enfoque en el monitoreo de motores de inducción es el análisis de señales de vibración mecánica. Delgado et al. (2017) presentaron una metodología para la detección de fallas en motores por medio de señales acústicas y de vibración mecánica, las cuales se adquirieron usando un micrófono y un acelerómetro de tres ejes. Los autores proponen el uso de la representación tiempo-frecuencia de Gabor (*Time-Frequency Domain of Gabor, TFDG*) para el análisis de las señales al tener una mejor resolución que la *STFT*. Sakhalkar y Korde (2018) realizaron la adquisición de señales de vibración mecánica usando un acelerómetro triaxial y de señales de corriente mediante un transformador de corriente para la detección de barras rotas en el rotor. El procesamiento de las señales adquiridas se realizó en MATLAB obteniendo el espectro frecuencial por medio de la *FFT*. Glowacz et al. (2019) propusieron una técnica para el análisis de las señales de vibración en motores trifásicos de inducción mediante el cálculo de vectores característicos a la que los autores deno-

minan *MSAF-12* (*Method of Selection of Amplitude of Frequencies*). Este método se basó en el cálculo de las diferencias en los espectros frecuenciales obtenidas a partir de la aplicación de la *FFT* a las señales de vibración adquiridas por un acelerómetro de tres ejes. Lee et al. (2019) desarrollaron un sistema de diagnóstico de fallas basado en la adquisición de señales de vibración de un motor trifásico de 2.2 kW. Los datos obtenidos fueron clasificados usando una red neuronal convolucional (*Convolutional Neural Network, CNN*) en tres posibles estados de falla: sano, falla en el rotor, falla en el balero. Las pruebas realizadas tuvieron una precisión en el diagnóstico del 98 %.

Paralelamente, el estudio del flujo magnético disperso (*stray flux*, en inglés) es un método que ha ganado relevancia en los últimos años al ser una variable medible por sensores no invasivos y de bajo costo. Zamudio et al. (2020) presentaron el desarrollo de un *Smart Sensor* para la detección automática de fallas electromecánicas en motores basado en el *stray flux*, se propone el uso de sensores de efecto Hall colocados a un costado de la carcasa del motor en tres posiciones diferentes con el fin de capturar las señales de flujos axiales y radiales. Estas señales son procesadas usando la transformada de Fourier de tiempo corto (*STFT*) y clasificadas usando redes neuronales (*Artificial Neural Network, ANN*) y análisis discriminante (*Linear Discriminant Analysis, LDA*). Ramirez et al. (2019) analizaron el espectro frecuencial de las señales de flujo magnético externo en un motor de inducción mediante el algoritmo de clasificación de señales múltiples (*Multiple Signal Classification, MUSIC*) para la detección de fallas en motores de inducción. Los autores argumentan que el método presentado tiene un gran potencial para aplicaciones de detección automática debido al bajo costo computacional del algoritmo. Ewert (2017) propuso el análisis de flujo magnético axial para la detección de fallas eléctricas en motores de inducción. La experimentación se realizó usando un motor especial que permite al autor controlar el número de espiras en corto circuito en cada prueba. Panagiotou et

al. (2019) presentaron un método enfocado a la detección de barras rotas mediante el análisis de los armónicos en el espectro frecuencial, extraído usando la *STFT* de la señal de *stray flux*. Los autores validan la metodología realizando pruebas en un motor trifásico de 1.1 kW y simulaciones de un motor de 1.1 MW usando métodos de Elemento Finito.

El uso de termografía y algoritmos de visión por computadora es otra alternativa ampliamente estudiada para la detección de fallas en motores de inducción gracias a que la captura de imágenes térmicas es no invasiva, permitiendo que el motor siga funcionando con normalidad mientras se realiza el diagnóstico. En este orden de ideas, Karvelis et al. (2014) presentaron una metodología para la segmentación y análisis de imágenes termográficas con el fin de automatizar el proceso de extracción de parámetros y la detección de fallas en motores eléctricos usando un algoritmo para la detección de puntos de interés en imágenes (*Scale Invariant Feature Transform, SIFT*) y haciendo la clasificación de fallas usando métodos estadísticos (C4.5 y Naïves Bayes). La metodología propuesta otorga buenos resultados para el diagnóstico de barras rotas, baleros en mal estado, desbalance en el estator, o fallas en el ventilador. Glowacz y Glowacz (2017) presentaron un método basado en el cálculo de la diferencia entre imágenes térmicas obtenidas de un único motor trifásico en distintos estados de falla para la extracción de características, mismas que son clasificadas para realizar el diagnóstico. La metodología propuesta se validó en condiciones de laboratorio considerando tres estados diferentes del motor: motor sano, motor con 2 barras rotas, motor con falla en la jaula de ardilla. Singh et al. (2016) propusieron un método para el diagnóstico de corto circuito en el bobinado interno de un motor eléctrico mediante termografía infrarroja. La metodología propuesta consistió en calcular un índice de calor basado en el histograma de la imagen térmica y obteniendo una relación lineal entre el índice propuesto y el porcentaje de falla en

el motor.

En la Universidad Autónoma de Querétaro (UAQ) se han realizado algunas investigaciones relacionadas con termografía y fallos en motores; uno de ellos es el de Garcia et al. (2014) quienes presentaron la adquisición y calibración de imágenes termográficas de una cadena cinemática para la detección de fallas. La imagen obtenida fue segmentada manualmente con el fin de calcular un coeficiente de temperatura para cada segmento que se comparó con un criterio propuesto por los autores basado en los estándares de la *ASTM* (*American Society for Testing and Materials*) para la clasificación de las fallas en la cadena cinemática. Resendiz et al. (2018) analizaron a través de una metodología de análisis de imágenes infrarrojas algunas fallas como barra rota, daño en balero, y desalineamiento. El aporte de este trabajo fue un método automático para la ubicación del fallo. Otro trabajo relacionado con termografía y aplicado en engranes de una cadena cinemática es el de Resendiz et al. (2020) donde se aplican métodos estadísticos y de reducción de dimensionalidad para la detección de fallas a través de redes neuronales, los niveles de desgaste que se analizaron fueron del 25 %, 50 %, y 75 %, estos dos últimos trabajos en conjunto con el de Garcia et al. (2014) constituyen los antecedentes para el desarrollo del trabajo aquí presentado en el área de termografía y fallas en maquinaria dentro de la UAQ.

1.2. Descripción del problema

El presente trabajo tiene como motivación una colaboración con la academia e industria internacional con la cual se tiene comprometido el desarrollo de un sistema inteligente para dar un diagnóstico más completo y confiable de las fallas en motores de inducción.

A la fecha se cuenta con una primera fase en el desarrollo de un sistema

donde se conjunta la adquisición y procesamiento de señales de corriente eléctrica y *stray flux*, sin embargo, aún no se tiene desarrollo alguno para el procesamiento de imágenes termográficas. También se carece de un método dedicado a la clasificación y ponderación de las variables adquiridas. Por lo que estos problemas se atacarán en la presente tesis.

Por otro lado, de acuerdo a la revisión del estado del arte, los motores de inducción son los mayores consumidores de energía eléctrica en la industria, es por esta razón que las fallas en estos equipos representan un grave problema en la actualidad. En dicha revisión de la literatura se reportan diversas metodologías enfocadas al diagnóstico de fallas, sin embargo, estos presentan los siguientes problemas que también se atacaron:

- La mayoría de los trabajos existentes solo se enfocan en el análisis de un tipo específico de falla en los motores de inducción.
- La metodología propuesta en los artículos revisados generalmente solo considera el uso de una variable para el diagnóstico.
- La mayoría de los métodos de diagnóstico por termografía implican el uso de equipos costosos y cerrados que limitan las posibilidades del manejo de los datos adquiridos.

1.3. Justificación

A partir de lo expuesto en la sección anterior, el presente trabajo pretende aportar dos módulos para un *Smart Sensor* enfocado a la detección de fallas en motores de inducción en respuesta a las necesidades de la industria mediante el análisis de señales de tres variables (corriente eléctrica, *stray flux*, y termografía).

Los módulos desarrollados son: un módulo de adquisición y procesamiento de imágenes termográficas usando un sistema propietario, y a su vez, un módulo enfocado a la ponderación y clasificación de las variables adquiridas por el *Smart Sensor*. Esto con el fin de que el sistema sea capaz de detectar los siguientes estados de falla en los motores: falla de barras rotas en el rotor (*Broken Bars Fault, BRB*), fallas en los baleros (*BAL*), desalineación del rotor (*Misalignment Fault, MAL*), falla de desbalance mecánico del motor (*Unbalance Fault, UNB*), y fallas en la caja de engranes conectada al motor (*Gearbox Fault, GR*). Se considera que con las variables elegidas se puede abarcar el diagnóstico de las fallas previamente listadas.

1.4. Objetivos

1.4.1. Objetivo General

Desarrollar dos módulos de procesamiento en un *Smart Sensor* multivariable propietario, para la evaluación de fallos en motores de inducción mediante imágenes termográficas y otro enfocado a la selección de la mejor variable de diagnóstico.

1.4.2. Objetivos Específicos

- Estudiar los métodos reportados para la identificación de fallos en motores por medio de termografía, realizando una búsqueda de trabajos relacionados en la literatura con la finalidad de recuperar los más eficientes en el diagnóstico y el tipo de fallo.
- Programar los métodos seleccionados como los más eficientes para cada fallo, con la finalidad de corroborar su desempeño en el diagnóstico utilizando señales

termográficas, mediante su programación en lenguaje de programación C++.

- Implementar en el *Smart Sensor* los métodos de procesamiento de Imágenes termográficas programados, mediante una tarjeta *Raspberry Pi*, para generar los índices de detección de los fallos y entregar el resultado al módulo de selección de la mejor variable de diagnóstico.
- Desarrollar un módulo de selección de la mejor variable de diagnóstico mediante herramientas de clasificación para determinar qué variable (termografía, *stray flux*, corriente, o una combinación de ellas) proporciona el mejor diagnóstico.

1.5. Planteamiento General

En la figura 1.1 se muestra el diagrama del planteamiento de este trabajo, mismo que se describe a continuación:

1. Investigación y documentación de temas de interés: fallas electromecánicas en motores de inducción, procesamiento de imágenes termográficas, herramientas de clasificación, y herramientas de programación.
2. Diseño e implementación del módulo termográfico, el cual consiste de una cámara termográfica FLIR Lepton 3.5 de FLIR Systems y una etapa de adquisición usando una tarjeta Raspberry Pi 4.
3. Realización de pruebas en un motor trifásico simulando distintos estados de falla para la adquisición de datos con el *Smart Sensor*.
4. Diseño e implementación del módulo de clasificación para el diagnóstico automático de fallas usando los datos de temperatura, corriente y *stray flux* adquiridos en las pruebas.

5. Recopilación y documentación de los resultados obtenidos a partir de las pruebas y análisis realizados.



Figura 1.1: Diagrama del planteamiento general

El motor de inducción, también conocido como motor asíncrono, es un componente esencial en un gran número de procesos industriales en la actualidad gracias a su robustez, bajo costo y eficiencia, consumiendo alrededor del 85% de la energía ocupada en plantas industriales (Hassan et al., 2018). Es por esto que la detección de fallas y el mantenimiento de estos equipos ha tomado un papel cada vez más importante en la ingeniería electromecánica.

Las técnicas y métodos utilizados para el monitoreo y diagnóstico de fallas reportados en la literatura actual se han basado en la adquisición y procesamiento de señales con sensores. Choudhary et al. (2019) recopilan algunas de las variables utilizadas en los sistemas actuales de monitoreo, entre estas se encuentran: vibración mecánica, emisiones acústicas, corriente eléctrica, y temperatura (mediante uso de termografía infrarroja). Además, el análisis del flujo magnético disperso en los motores asíncronos es un método de estudio que ha sido propuesto en trabajos recientes para el diagnóstico de fallas (Ramirez et al., 2018).

El uso de la termografía en la industria es trascendental debido a que esta técnica permite la visualización de los efectos típicamente invisibles del aumento en la temperatura en los equipos eléctricos, siendo una herramienta poderosa para el diagnóstico y monitoreo (Vollmer & Möllmann, 2018).

Por otro lado, el desarrollo de *Smart Sensors* —i. e., sensores inteligentes— ha ganado notoriedad en las últimas décadas gracias al avance tecnológico reciente, en especial a la llegada y establecimiento de los sistemas microelectrónicos y la reciente popularización del Internet de las Cosas (*Internet of Things, IoT*). Como lo señala Frank (2013): “El creciente interés en los *Smart Sensors* es un resultado directo de la necesidad de comunicar y compartir la información de los sensores en sistemas de control distribuidos y redes de cualquier tipo”.

El presente trabajo complementa el desarrollo de un *Smart Sensor* multivariable para el diagnóstico de fallas en motores de inducción con el diseño e implementación de un módulo de adquisición y procesamiento de señales termográficas, y adicionalmente, con la creación un módulo de clasificación para seleccionar la variable que permita realizar el diagnóstico más acertado.

El contenido de esta obra está organizado en cinco capítulos:

- En el Capítulo 1 se presentan los objetivos y motivaciones del proyecto. Asimismo, se hace la discusión de algunos estudios significativos y relevantes para el desarrollo de este trabajo.
- En el Capítulo 2 se recopilan los fundamentos teóricos del trabajo.
- En el Capítulo 3 se describe el diseño e implementación de los módulos de procesamiento para el *Smart Sensor*, además, se plantean los experimentos para la validación del proyecto.
- En el Capítulo 4 se presentan los resultados obtenidos a partir de la experimentación planteada en el capítulo anterior.
- Finalmente, en el Capítulo 5 se discuten los resultados y la metodología propuesta, presentando los argumentos finales de la investigación.

Capítulo 2

Fundamentación teórica

2.1. Fallas en motores de inducción

Los motores de inducción son las máquinas eléctricas más ampliamente utilizadas en la industria gracias a su alta eficiencia y confiabilidad. Sin embargo, debido a la creciente demanda de su uso en todo el mundo, los motores de inducción se ven expuestos a mayores esfuerzos y tensiones mecánicas, eléctricas, térmicas o magnéticas que a la larga pueden provocar una falla en el equipo. Estas fallas pueden clasificarse en fallas eléctricas o fallas mecánicas (Faiz et al., 2017).

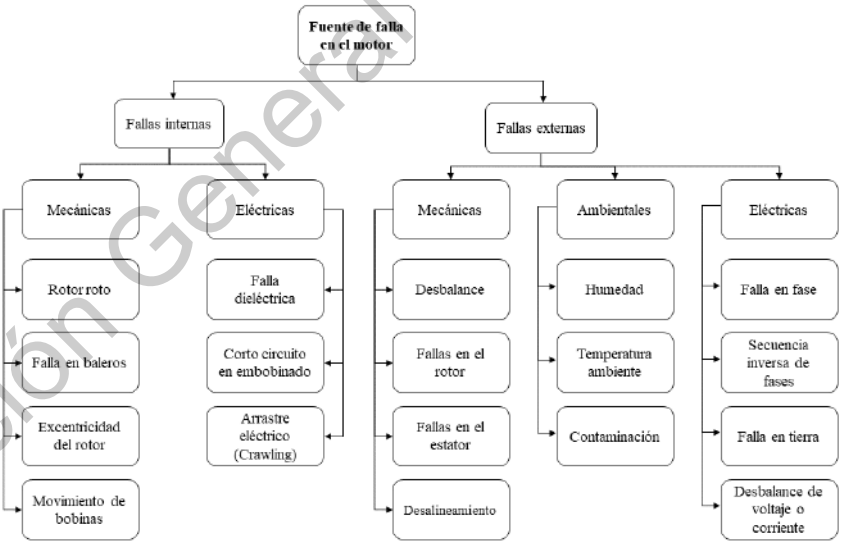


Figura 2.1: Clasificación de fallas en motores de inducción (Choudhary et al., 2019)




Figura 2.2: Incidencia de tipos de falla en motores eléctricos (Choudhary et al., 2019)

Choudhary et al. (2019) recopilan el diagrama comparativo de las causas y clasificación de fallas en motores de inducción, mismo que se muestra en la figura 2.1. Además, presentan un gráfico que ilustra los porcentajes de incidencia de falla en motores eléctricos basado en datos recopilados por la IEEE, el cual se observa en la figura 2.2. De acuerdo con Faiz et al. (2017) las fallas más comunes, y por lo tanto de mayor interés, son:

- Barras rotas en el rotor;
- Excentricidad o desbalance mecánico;
- Fallas en los baleros;
- Fallas de corto circuito interno.

2.1.1. Fallas de barras rotas

La rotura de las barras en el rotor generalmente ocurre debido a condiciones de trabajo estresantes para el motor que debilitan las uniones de las barras con el anillo conector del rotor, por ejemplo: la presencia de cargas oscilatorias, un mal ensamblaje o mala manufactura del motor, y esfuerzos mecánicos.

Esta falla provoca una asimetría mecánica en el rotor, lo que provoca una distorsión eléctrica en las barras restantes de la jaula de ardilla. La sobre corriente existente provoca una saturación del campo magnético y por último se produce un aumento en la temperatura del equipo (Faiz et al., 2017).

2.1.2. Excentricidad o desbalance mecánico

La desalineación del rotor es típicamente causado por alguna de las siguientes razones: desgaste de los baleros por envejecimiento, ejes torcidos, cargas oscilantes, o defectos en la manufactura y ensamble del motor. La falla por desalineación del rotor no solo afecta al motor, también puede afectar a otros equipos aledaños debido a los movimientos no controlados de la carga (Faiz et al., 2017).

2.1.3. Fallas en los baleros

Los baleros son las piezas responsables de mantener al rotor concéntrico respecto al estator, teniendo que soportar el peso del rotor y altos niveles de fricción. Por ello, su mantenimiento es una de los más importantes para el funcionamiento óptimo de un motor de inducción. Generalmente, se relacionan tres tipos de fallas con los baleros: defecto en el anillo exterior, defecto en el anillo interior, o defecto en los elementos rodantes (Faiz et al., 2017).

2.1.4. Fallas de corto circuito interno

Las fallas de corto circuito interno en un motor de inducción pueden ocurrir tanto en el rotor como en el estator en el caso de los motores con rotor bobinado, sin embargo, en los motores de jaula de ardilla (que suelen ser más comunes) esta falla se restringe al estator. Se pueden especificar cuatro tipos de fallas de corto circuito: espira a espira, espira a tierra, fase a fase, fase a tierra. La naturaleza de la falla permanece constante a pesar del tipo de corto circuito detectado, es decir, en cualquier tipo de falla por corto circuito se puede observar la circulación de una gran cantidad de corriente eléctrica a través de los embobinados del equipo sin aportar a la producción de energía mecánica (Faiz et al., 2017).

2.2. Termografía

La captura de imágenes térmicas infrarrojas, generalmente conocida como termografía, es un área de la ingeniería moderna que ha evolucionado rápidamente en las últimas décadas gracias al desarrollo de la tecnología electrónica. La termografía es una medición de radiación dentro de ciertas bandas limitadas en el espectro electromagnético, donde la selección de bandas depende directamente de las características físicas del objeto o fenómeno estudiado (Vollmer & Möllmann, 2018).

2.2.1. Procesamiento de imágenes termográficas

Una imagen termográfica es una representación espacial de la radiación incidente en el sensor. El primer procesamiento ocurre dentro de la cámara al calcular la temperatura de los objetos en la escena capturada a partir de la radiación medida, para esto se consideran diversos parámetros de calibración que generalmente son

definidos por el usuario tal como la emisividad, temperatura ambiente, humedad y distancia de medición.

Mejora digital de detalles y contraste

Generalmente, las cámaras infrarrojas trabajan con señales de 12 a 14 bits lo que equivale a tener de 4096 a 16 384 tonalidades distintas en una imagen a color. Sin embargo, la percepción de diferencias puede complicarse debido a la sensibilidad del ojo humano. El problema se acentúa en imágenes en escala de grises (Vollmer & Möllmann, 2018).

Es por esta razón que las técnicas digitales para la mejora del contraste son ampliamente utilizadas en el procesamiento de imágenes termográficas. Uno de los métodos más comunes en imágenes de alto rango dinámico —*i. e.*, la diferencia entre el tono más oscuro y el tono más claro de una imagen— consiste en ajustar la forma de la curva que define el control automático de la ganancia (*Automatic Gain Control, AGC*), un ejemplo de esto se puede observar en la figura 2.3.




Figura 2.3: Comparación de imágenes termográficas al mejorar el detalle al aplicar una gradación no lineal (Vollmer & Möllmann, 2018)

Otra herramienta utilizada para la mejora del contraste en imágenes termográficas es la ecualización del histograma. Esta técnica consiste en aplicar operaciones matemáticas al histograma inicial de la imagen, en el que generalmente se observan picos en la distribución de probabilidad (fig. 2.4a), con el fin de obtener un histograma ecualizado con una distribución más uniforme (fig. 2.4b).

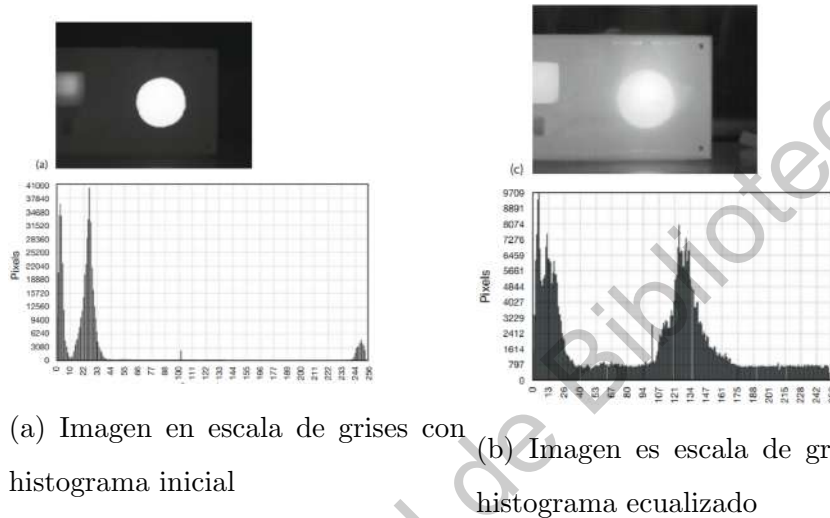


Figura 2.4: Ecualización del histograma de imágenes termográficas para mejora del contraste (Vollmer & Möllmann, 2018)

Sin embargo y como bien señalan Vollmer y Möllmann (2018), si bien la ecualización del histograma sirve para mejorar el contraste de las imágenes termográficas, la información de temperatura puede no estar directamente relacionada con el color de los píxeles en la imagen debido a las transformaciones matemáticas realizadas. Por esta razón, las imágenes térmicas mejoradas solo deben usarse para tener una mejor percepción de los objetos en la imagen, utilizando los datos brutos (*raw data*) obtenidos por la cámara para el análisis cuantitativo.

2.2.2. Segmentación de la imagen

La segmentación de las imágenes consiste en la búsqueda y selección de regiones de interés (*Region of Interest, ROI*) donde la información sea relevante para el estudio. La selección del método de segmentación depende de los objetivos del procesamiento de la imagen. Dilpreet y Yadwinder (2014) recopilan algunas técnicas de segmentación existentes, mismas que se describen en la tabla 2.1.

Por otro lado, la extracción de características (*feature extraction*) de una imagen es una forma especial de reducción de la misma, es decir, transforma la información de la imagen inicial en un conjunto de características representativas y no redundantes, llamados vectores característicos (*feature vector*), con el fin de reducir el tamaño de los datos a procesar y asimismo disminuir el costo computacional del análisis (Kumar & Bhatia, 2014).

Método de umbral de Otsu

Otsu (1979) propuso un método para la segmentación de imágenes que consiste en la selección de un umbral mediante el análisis de la varianza en las tonalidades de grises de la imagen a segmentar.

La idea principal de este método es dividir el histograma de la imagen en dos subconjuntos $K_0(t)$ y $K_1(t)$, definidos a partir del valor de umbral (o *threshold*) t . Siendo t el valor buscado para la segmentación. Para encontrar este valor de umbral, la meta es mantener la suma de la varianza interna de cada subconjunto (σ_{in}^2) lo más mínima posible y a su vez tener que la varianza entre subconjuntos (σ_{zw}^2) sea máxima, obteniendo la ecuación (2.1) que otorga el valor de umbral al despejar t .

$$Q(t) = \frac{\sigma_{zw}^2}{\sigma_{in}^2} \quad (2.1)$$

Tabla 2.1: Descripción de técnicas de segmentación (Dilpreet & Yadwinder, 2014)

Técnica de Segmentación	Descripción
<p>Thresholding Method <i>Método de Umbral</i></p>	<p>Basado en picos del histograma de la imagen para encontrar valores de umbral particulares. Son los métodos más sencillos de implementar.</p>
<p>Edge Based Method <i>Método de Bordes</i></p>	<p>Basado en la detección de discontinuidades en la intensidad de la imagen. Es recomendado para imágenes con buen contraste entre objetos.</p>
<p>Region Based Method <i>Método de Regiones</i></p>	<p>Basado en la partición de la imagen en regiones homogéneas. Funciona bien en imágenes sin ruido donde la detección de similitudes es más sencilla.</p>
<p>Clustering Method <i>Método de Grupos</i></p>	<p>Basado en la división de píxeles en grupos homogéneos, lo más común es definir grupos difusos debido a la existencia de ruido en la imagen.</p>
<p>PDE Based Method <i>Método basado en Ecuaciones Diferenciales Parciales</i></p>	<p>Basado en el cálculo de Ecuaciones Diferenciales Parciales en la imagen para resaltar las discontinuidades o reducir el ruido existente. Suelen ser métodos rápidos pero complejos.</p>
<p>Watershed Method <i>Método de cuencas o puntos de inflexión</i></p>	<p>Basado en la información topológica de la imagen, las fronteras detectadas son continuas pero los cálculos de gradientes son complejos.</p>
<p>ANN Based Method <i>Método basado en Redes Neuronales</i></p>	<p>Basado en la implementación de una red neuronal, suele dar buenos resultados pero requiere demasiado tiempo de entrenamiento.</p>

Algoritmo SIFT (Scale Invariant Feature Transform)

El algoritmo SIFT es un método usado en el área de visión artificial para la identificación de puntos característicos de una imagen, siendo usado en diversas aplicaciones relacionadas a la detección de objetos. Publicado por primera vez en 2004 por Lowe, este algoritmo de detección de características es invariante tanto a rotaciones como al escalado de la imagen.

Los pasos descritos en el trabajo de Lowe (2004) para la implementación de este algoritmo son los siguientes:

1. **Detección de extremos en la escala-espacio.** Esta etapa consiste en aplicar una diferencia gaussiana, la cual se calcula con la siguiente ecuación:

$$D(x, y, \sigma) = G(x, y, k\sigma) * I(x, y) - G(x, y, \sigma) * I(x, y) \quad (2.2)$$

en distintas escalas y posiciones de la imagen con el fin de encontrar potenciales puntos invariantes al escalado y rotaciones.

2. **Localización de puntos de interés.** En este paso del algoritmo, se eliminan aquellas posiciones inestables encontrando todos los puntos de poco contraste o que están localizados sobre los bordes en la imagen.
3. **Asignación de orientaciones.** En esta etapa se asigna una orientación a cada punto de interés con el fin de garantizar la invariancia ante la rotación de la imagen, esto se logra al calcular el gradiente (magnitud y ángulo) de la imagen en cada punto candidato.
4. **Cálculo de descriptores de interés.** Finalmente, se calculan los descriptores de los puntos de interés al crear una matriz de orientaciones en la zona cercana

a cada punto detectado.

Los puntos de interés detectados en la imagen pueden ser utilizados para emparejar objetos en una imagen de entrenamiento y una imagen objetivo al calcular la distancia Euclidiana mínima entre los puntos de cada una de estas imágenes. Esto permite usar el algoritmo SIFT para la detección de objetos y regiones de interés en una imagen.

2.2.3. Extracción de características

Análisis del Histograma

El histograma es una representación gráfica de la distribución de los datos en una imagen. Este puede ser analizado utilizando los conceptos y definiciones de la estadística. De este modo, (Dhamande & Chaudhari, 2018) recopilan las expresiones matemáticas para representar algunos de los parámetros estadísticos de una señal discreta, mismos que se observan en la tabla 2.2. Donde el histograma se representa como una función $h(n)$ con $n = 1, 2, 3, \dots, N$ tomando en cuenta que N es el número de niveles de grises registrados en el histograma.

Tabla 2.2: Parámetros estadísticos del histograma

Media	$T_1 = \frac{\sum_{n=1}^N h(n)}{N}$	(2.3)
-------	-------------------------------------	-------

Valor máximo $T_2 = \max |h(n)|$ (2.4)

Media cuadrática (RMS) $T_3 = \sqrt{\frac{\sum_{n=1}^N (h(n))^2}{N}}$ (2.5)

SMR $T_4 = \left(\frac{\sum_{n=1}^N \sqrt{|h(n)|}}{N} \right)^2$ (2.6)

Desviación Estándar $T_5 = \sqrt{\frac{\sum_{n=1}^N (h(n) - T_1)^2}{N - 1}}$ (2.7)

Varianza $T_6 = \frac{\sum_{n=1}^N (h(n) - T_1)^2}{N - 1}$ (2.8)

Factor de forma con RMS $T_7 = \frac{T_3}{\frac{1}{N} \sum_{n=1}^N |h(n)|}$ (2.9)

Factor de forma con SMR $T_8 = \frac{T_4}{\frac{1}{N} \sum_{n=1}^N |h(n)|}$ (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 $T_{11} = \frac{T_2}{\frac{1}{N} \sum_{n=1}^N |h(n)|}$ (2.13)

Asimetría $T_{12} = \frac{1}{N} \cdot \frac{\sum_{n=1}^N (h(n) - T_1)^3}{T_5^3}$ (2.14)

Curtosis $T_{13} = \frac{1}{N} \cdot \frac{\sum_{n=1}^N (h(n) - T_1)^4}{T_5^4}$ (2.15)

$$5^{\circ} \text{ momento} \quad T_{14} = \frac{1}{N} \cdot \frac{\sum_{n=1}^N (h(n) - T_1)^5}{T_5^5} \quad (2.16)$$

$$6^{\circ} \text{ momento} \quad T_{15} = \frac{1}{N} \cdot \frac{\sum_{n=1}^N (h(n) - T_1)^6}{T_5^6} \quad (2.17)$$

2.3. Herramientas de clasificación

La clasificación de datos tiene un gran número de aplicaciones debido a que básicamente se describe como la búsqueda de relaciones entre un conjunto de datos base (*feature variables*) y un conjunto de datos objetivo (*target variable*). Se puede decir entonces que las técnicas de clasificación segmenta los datos de un conjunto en grupos definidos por una etiqueta, sea esta una etiqueta discreta o una puntuación numérica (Aggarwal, 2014).

2.3.1. Técnicas de clasificación

Métodos estadísticos-probabilísticos

Los métodos probabilísticos son fundamentales entre todos los métodos de clasificación. Están basados en el cálculo de propiedades estadísticas para encontrar la mejor clase para cada dato de entrenamiento. El más conocido de estos métodos es el clasificador de Bayes.

Considérese una instancia de prueba con d características diferentes, con

valores $X = \langle x_1 \dots x_d \rangle$ respectivamente. Se desea calcular la probabilidad posterior de que la clase $Y(T)$ de la instancia de prueba T sea i . Es decir, determinar la probabilidad posterior $P(Y(T) = i | x_1 \dots x_d)$. Entonces, aplicando la regla de Bayes se obtiene lo siguiente:

$$P(Y(T) = i | x_1 \dots x_d) = P(Y(T) = i) \cdot \frac{P(x_1 \dots x_d | Y(T) = i)}{P(x_1 \dots x_d)} \quad (2.18)$$

Como el denominador es constante a través de todas las clases, y solo se necesita saber la clase con la probabilidad posterior máxima, se puede aproximar la expresión anterior de la siguiente manera:

$$P(Y(T) = i | x_1 \dots x_d) \propto P(Y(T) = i) \cdot P(x_1 \dots x_d | Y(T) = i) \quad (2.19)$$

La clave en este momento es que se puede evaluar la parte derecha de la ecuación más fácilmente al usar la *suposición de Bayes* para simplificarla. Con esto se obtiene la ecuación:

$$P(x_1 \dots x_d | Y(T) = i) = \prod_{j=1}^d P(x_j | Y(T) = i) \quad (2.20)$$

El teorema de Bayes es fundamental para poder simplificar la expresión como productos. El término $P(x_j | Y(T) = i)$ se interpreta como la fracción de los datos de entrenamiento que corresponden a la i -ésima clase que contiene el valor característico x_j para el atributo j -ésimo. Este método es aplicado en una gran variedad de aplicaciones y a pesar de las suposiciones del mismo resulta ser efectivo en la práctica (Aggarwal, 2014).

Árboles de decisión

Los árboles de decisión crean una partición jerárquica de los datos, que relacionan los niveles de las hojas con diferentes clases. Para la partición de cada nivel se utiliza un *criterio de división*. Este puede ser univariable, o multivariable de acuerdo al número de condiciones o predicados considerados. El objetivo principal es intentar dividir los datos recursivamente para maximizar la discriminación entre las diferentes clases en cada nodo del árbol. La medición del *gini-index* o la *entropía* es usada para determinar el grado de discriminación. Por ejemplo, si $p_1 \dots p_k$ es la fracción de los datos pertenecientes a k clases diferentes en un nodo N , entonces el *gini-index* $G(N)$ del nodo N se define como:

$$G(N) = 1 - \sum_{i=1}^k p_i^2 \quad (2.21)$$

El valor de $G(N)$ se encuentra en el rango de 0 a $1 - 1/k$. Entre menor sea el valor de $G(N)$, mayor es el sesgo. Una medición alternativa es la *entropía* $E(N)$:

$$E(N) = - \sum_{i=1}^k p_i \cdot \log(p_i) \quad (2.22)$$

El valor de $E(N)$ se encuentra en el rango de 0 a $\log(k)$. El escenario de mayor entropía ($E(N) = \log(k)$) representa un balance entre las distintas clases, entre menor sea la entropía, mayor es el sesgo en los datos (Aggarwal, 2014). En la figura 2.5 se muestra la ilustración de la construcción de un árbol de decisiones.

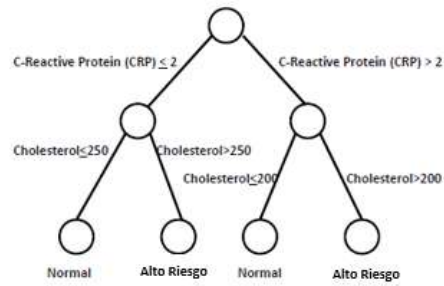


Figura 2.5: Ilustración de construcción de árboles de decisión (Aggarwal, 2014)

Clasificadores SVM

Los métodos SVM (*Support Vector Machines*) usan condiciones lineales para separar una clase de la otra. Un clasificador SVM puede considerarse como un árbol de decisión de un solo nivel usando una condición de división multivariable muy específica. Este tipo de clasificadores se define generalmente para problemas de clasificación binaria (Aggarwal, 2014).

Se muestra en la figura 2.6 una representación de este método.




Figura 2.6: Clasificación “dura” y “suave” por medio de SVM (Aggarwal, 2014)

Redes Neuronales

Las redes neuronales intentan simular sistemas biológicos, en específico al cerebro humano. En el cerebro humano las neuronas se conectan entre sí por medio de la *sinapsis*, donde el aprendizaje se lleva a cabo al fortalecer las conexiones sinápticas ante ciertos estímulos.

Esta analogía se mantiene en las redes neuronales, donde la unidad básica se denomina *neurona* o *unidad*. Estas unidades se pueden acomodar en diferentes arreglos al modificar las conexiones entre ellas. La arquitectura más básica de redes neuronales es un *perceptrón*, que contiene un conjunto de nodos de entrada y un único nodo de salida. El nodo de salida se asocia con un conjunto de pesos \bar{W} que se usa para calcular una función $f(\cdot)$ de sus entradas. Cada componente del vector de pesos \bar{W} se asocia a una conexión de la unidad de entrada a la unidad de salida. Los pesos son análogos a la fuerza de la sinapsis en el cerebro humano.

En la práctica, el *perceptrón* es raramente utilizado. En su lugar se usa un arreglo multinivel de tres capas, referidas como **capa de entrada**, **capa oculta** y **capa de salida**. En la figura 2.7 se muestran las representaciones de los arreglos usados en redes neuronales.




Figura 2.7: Redes neuronales de una o varias capas (Aggarwal, 2014)

La capa de entrada de una red neuronal solo transmite los datos a la capa

posterior sin hacer ningún cálculo, las capas oculta y de salida son las encargadas de procesar la información para obtener la clasificación de los datos. Este tipo de redes neuronales permite la aproximación de funciones no lineales y definir fronteras de decisión complejas al seleccionar correctamente la topología de la red y las funciones en los nodos, siendo una herramienta bastante poderosa para la aproximación de funciones arbitrarias.

Análisis de Componentes Principales

El análisis de componentes principales (*Principal Component Analysis, PCA*) es “un método para encontrar representaciones de baja dimensión de un conjunto de datos conservando la mayor cantidad posible de variación de los datos originales” (Boehmke & Greenwell, 2019). Cada una de las l nuevas dimensiones encontradas en el *PCA* es una combinación lineal de las p características originales.

Para implementar esta técnica de reducción de la dimensión de los datos se debe preparar la información como se describe a continuación:

1. Los datos deben estar organizados y ordenados;
2. Cualquier valor faltante en los datos debe ser removido o ingresado;
3. Los datos deben ser valores numéricos (asociar un valor numérico a cada variable cualitativa);
4. Los datos numéricos deben ser estandarizados (centrados y escalados) para hacer compatibles las características.

Con la información preparada y organizada en una matriz de $n \times p$, donde n es el número de observaciones realizadas y p es el número de dimensiones del

conjunto de datos, se obtiene la matriz de covarianza empírica de tamaño $p \times p$ usando la ecuación:

$$\mathbf{C} = \frac{1}{n-1} \mathbf{B}^* \cdot \mathbf{B} \quad (2.23)$$

Donde $*$ denota al operador de transpuesta conjugada, en casos donde todos los miembros de la matriz \mathbf{B} sean números reales, la matriz “transpuesta conjugada” es la misma que la matriz transpuesta regular.

Se calculan los eigenvectores y eigenvalores de la matriz de covarianza para determinar las componentes principales del sistema mediante la ecuación:

$$\mathbf{V}^{-1} \mathbf{C} \mathbf{V} = \mathbf{D} \quad (2.24)$$

Donde \mathbf{D} es la matriz diagonal de $p \times p$ con los eigenvalores de \mathbf{C} . La matriz \mathbf{V} , también de dimensiones $p \times p$ contiene los eigenvectores de la matriz de covarianza \mathbf{C} . El paso final para obtener la reducción de dimensionalidad consiste en multiplicar la matriz original \mathbf{B} de $n \times p$ por una matriz compuesta \mathbf{E} de los primeros l eigenvectores de la matriz \mathbf{C} .

2.4. Herramientas de programación

2.4.1. Lenguaje C++

C++ es un lenguaje de programación orientado a objetos que en palabras de Stroustrup: “fue diseñado para soportar la abstracción de datos, la programación orientada a objetos, y la programación genérica así como las técnicas de programación con C tradicional. Nunca fue pensado para imponer un estilo particular de programación sobre todos sus usuarios” (1997). C++ cuenta con algunas características del lenguaje C tradicional, sin embargo, expande las opciones y recursos disponibles.

En C++ existen los siguientes tipos de datos predeterminados:

- Booleanos (***bool***), usados para almacenar valores lógicos.
- Caracteres (***char***), usados para almacenar caracteres de 8 bits.
- Enteros (***int***), usados para almacenar números enteros. Por defecto se trabaja en sistema decimal pero se pueden expresar enteros con los sistemas binario, hexadecimal y octal según la preferencia del usuario.
- Punto flotante (como ***double*** y ***float***), usados para almacenar números de punto flotante los cuales son reconocidos por un punto decimal (*e. g.* 0.541) o un exponente (*e. g.* 2e-3).
- Arreglos (*arrays*), usados para agrupar datos del mismo tipo en una variable de fácil acceso. Se expresan con el comando [] a la derecha del tipo de dato del arreglo (*e. g.* ***int***[5]).
- Apuntadores (o *pointers*), usados para almacenar la dirección de memoria de otro dato, vector o función. Se expresan con el comando * a la derecha del tipo de dato (*e. g.* ***int****).
- Vacío (***void***), usado para indicar la ausencia de información.

Además, se introduce la creación de tipos de datos definidos por el usuario: ***enum***, ***structure***, y ***classes*** (Stroustrup, 2018).

Clases y Estructuras

Las **estructuras** son un conjunto de elementos de diferentes tipos de datos que una vez declarados pueden ser utilizados como un nuevo tipo de dato definido por el usuario.

Las clases son el elemento central de C++. Una clase es un tipo de dato definido por el usuario con la intención de representar un concepto u objeto en el programa. La importancia de estas radica en que una buena selección de clases permite que el código sea más legible y fácil de entender.

Las similitudes entre clases y estructuras son evidentes, la principal diferencia entre ambos tipos de datos radica en que las clases permiten el control del acceso a ciertos elementos agrupados en el objeto, dicho en otras palabras, las clases pueden proteger los datos almacenados en ellas para no ser manipulados por otras instancias en el código (Stroustrup, 2018).

2.4.2. Qt

Qt es un entorno de trabajo para C++ que proporciona herramientas enfocadas al desarrollo de aplicaciones multiplataforma en computadoras, sistemas embebidos y dispositivos móviles. Además del entorno de trabajo, Qt cuenta con su propio Entorno de Desarrollo Integrado (*Integrated Development Environment, IDE*) llamado Qt Creator. Este *IDE* facilita la tarea de programación al usuario al brindar opciones de revisión de sintaxis, *debugger*, y la integración de los paquetes de trabajo y librerías desarrollados por Qt (Qt, 2018).

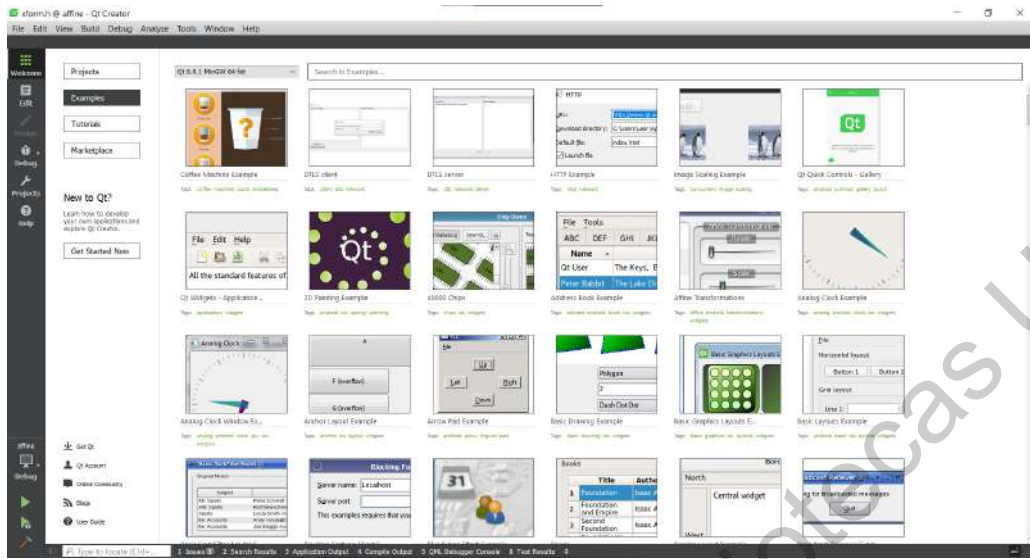


Figura 2.8: UI (*User Interface*) de Qt Creator 4.14.0

2.4.3. OpenCV

OpenCV es una librería de código abierto enfocada a las aplicaciones de visión por computadora y *machine learning* que contiene un amplio conjunto de técnicas clásicas y recientes y más de 2500 algoritmos optimizados. Esta librería está escrita en C++ y ofrece soporte a otros lenguajes de programación como: Python, Java, y MATLAB (OpenCV, 2021).

Capítulo 3

Metodología

En la figura 3.1 se muestra la estructura general del *Smart Sensor* para la detección de fallas en motores de inducción. Este dispositivo tiene como objetivo la adquisición y procesamiento de señales de corriente, flujo y termografía para el diagnóstico de condiciones de falla en motores eléctricos. En este capítulo se presenta el proceso de desarrollo del módulo de adquisición de imágenes termográficas y el módulo de clasificación.



Figura 3.1: Estructura general del *Smart Sensor*

En la figura 3.2 se presenta un diagrama a bloques que describe la metodo-

logía de este trabajo. Primero, se hace la adquisición de imágenes termográficas de un motor de inducción en condición sana y en distintos estados de falla, a las imágenes adquiridas se le aplican técnicas de procesamiento digital para la obtención de rasgos estadísticos característicos que representen la información contenida.

El segundo módulo corresponde al procesamiento de los indicadores característicos de las tres variables consideradas en el *Smart Sensor* por medio de métodos de clasificación para relacionar los datos adquiridos con los distintos estados considerados en el motor de inducción y poder proporcionar un diagnóstico del equipo.

La implementación de los módulos descritos se hace en una computadora de placa reducida Raspberry Pi en un sistema con pantalla táctil con el fin de garantizar la accesibilidad y movilidad del sistema diseñado.

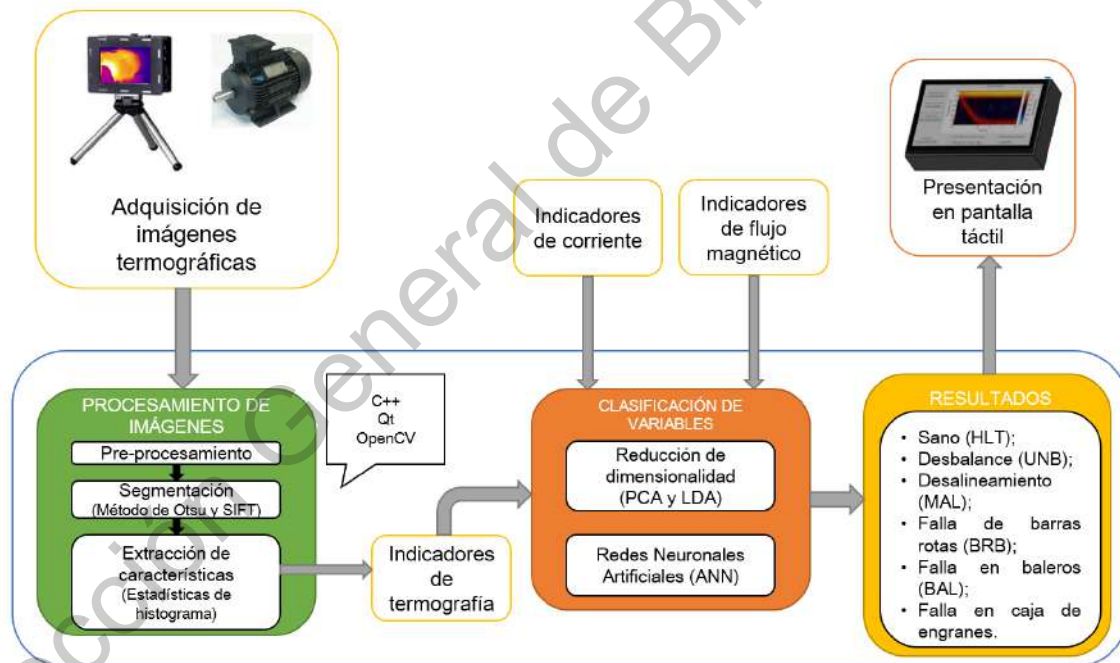


Figura 3.2: Diagrama de bloques de la metodología propuesta

3.1. Módulo termográfico

Para la adquisición de imágenes térmicas se utilizó la cámara termográfica infrarroja FLIR Lepton 3.5 (Fig. 3.3), cuya interfaz de comunicación permite al usuario utilizar los datos brutos (en inglés, *raw data*) de la cámara, o imágenes térmicas a pseudo color. Esta sensor es de bajo costo y está diseñado para ser utilizado en aplicaciones de sistemas y plataformas móviles ofreciendo una imagen térmica calibrada en una matriz de 19200 píxeles distribuidos en una relación de 160×120 píxeles (FLIR, 2021).



Figura 3.3: Sensor infrarrojo de bajo costo, FLIR Lepton 3.5

3.1.1. Preprocesamiento de la imagen

La imagen obtenida por la cámara termográfica de 160×120 píxeles (px.) se envía a la Raspberry Pi en paquetes de 14 bits a través de los pines de comunicación presentes en la tarjeta. La imagen termográfica adquirida es preprocesada inicialmente al realizar una cuantificación de los datos de la imagen a un formato de 8 bits, con valores de 0 a 255, y conservando una copia de la *raw data*. Para reducir la carga computacional y el tiempo de procesamiento se analizaron solamente las imágenes en escala de grises, utilizando las imágenes a pseudo color solo para fines ilustrativos en la interfaz del usuario.

El siguiente paso de preprocesamiento fue aplicar un escalado a la imagen cuyo tamaño original es de 160×120 px. a un tamaño de 520×390 px. mediante una interpolación bilineal, esto con el fin de incrementar la información disponible para los algoritmos de detección de características.

3.1.2. Segmentación de la imagen termográfica

La segmentación consiste en encontrar una región de interés (*ROI*, *Region of Interest*) asociada al motor de inducción a analizar en la imagen termográfica. Para esto fue implementado el método *SIFT* con las librerías de OpenCV, este algoritmo cual resulta ser útil para la extracción de características invariantes a las transformaciones geométricas de los objetos en una imagen tales como la rotación o el escalado. Para ser aplicado en la detección automática de objetos y regiones de interés se consideran dos etapas del método: la primera etapa es de entrenamiento (o *training*) y la segunda etapa es de emparejamiento (o *matching*). En la figura 3.4 se muestra un diagrama que ilustra este proceso.

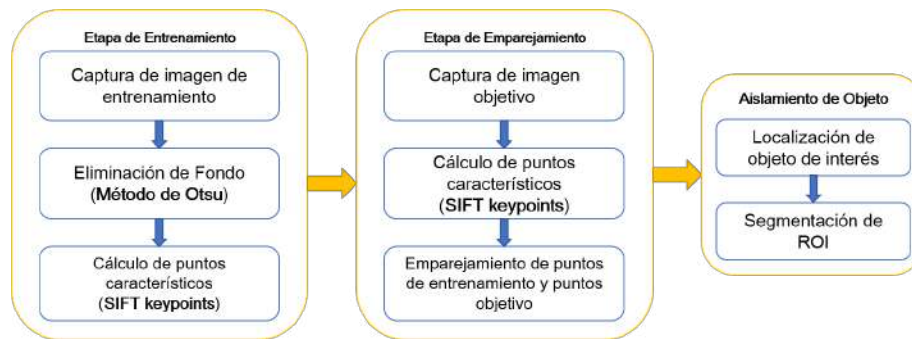


Figura 3.4: Diagrama a bloques del método de segmentación implementado

En la etapa de entrenamiento se tomó una imagen termográfica preprocesada en escala de grises y se aplicó el algoritmo de Otsu con el fin de eliminar el fondo de la imagen para reducir la carga computacional y eliminar posibles causas de ruido en el procesamiento. Después, se aplicó el método de SIFT en la imagen para obtener los puntos característicos invariantes (o *key points*) asociados al motor estudiados, los *key points* obtenidos fueron guardados en la memoria de la tarjeta Raspberry Pi para ser usados como referencia en la siguiente etapa del método.

La etapa de emparejamiento consistió en tomar una nueva imagen termográfica preprocesada a la que se aplica el método de SIFT para obtener sus puntos característicos. El conjunto de puntos característicos de la nueva imagen fue comparado con el conjunto de *key points* adquiridos en la etapa de entrenamiento para poder encontrar la homografía entre ambas imágenes. Conociendo esta transformación geométrica entre las dos imágenes analizadas fue posible aislar la ROI correspondiente al motor en la segunda imagen adquirida. Esta región de interés detectada es almacenada en la memoria de la tarjeta Raspberry Pi para poder extraer sus características estadísticas.

3.1.3. Extracción de características

El histograma de la región de interés segmentada de la imagen termográfica adquirida representa la distribución de las tonalidades de gris en los píxeles de la imagen, y aplicando las ecuaciones de la tabla 2.2 descritas en el capítulo 2 se calcularon los parámetros estadísticos del histograma los cuales resumen la información de la imagen termográfica. Se calculó un total de 15 parámetros estadísticos relacionados con el histograma de la imagen termográfica: media, valor máximo, media cuadrática (RMS), SMR, desviación estándar, varianza, factor de forma con RMS, factor de forma con SMR, factor de cresta, factor de latitud, factor de impulso, asimetría, curtosis, 5^o momento, y 6^o momento.

3.2. Combinación de variables

Para la combinación de los indicadores estadísticos de las tres variables consideradas (termografía, flujo magnético, y corriente eléctrica) se creó una matriz combinada de datos al concatenar horizontalmente las matrices correspondientes a los parámetros de cada variable. En la tabla 3.1 se muestra la organización general de las columnas en la matriz de fusión de variables.

Tabla 3.1: Organización general de la matriz de fusión de variables

Termografía	Flujo Magnético <i>(stray flux)</i>	Corriente Eléctrica
15 columnas de parámetros estadísticos	63 columnas de parámetros estadísticos (21 columnas por eje)	21 columnas de parámetros estadísticos

Para reducir la carga computacional en el análisis de los parámetros descritos en la matriz de fusión de variables es necesario encontrar las tres Componentes Principales que mejor conserven la variación de los datos usando los procedimientos descritos en la sección 2.3.1 del capítulo 2. Es importante recalcar que estas componentes principales no tienen relación directa con las variables físicas medidas por los sensores utilizados en este sistema.

3.3. Clasificación de estados del motor

El método de clasificación utilizado para discriminar y organizar los datos que describen los estados del motor fue la implementación de una red neuronal artificial de cinco capas: una capa de entrada, tres capas ocultas, y una capa de salida (fig. 3.5). La capa de entrada se componía de 3 nodos, las capas ocultas de 3, 6, y 12 nodos respectivamente y la capa de salida contaba con 14 nodos donde cada uno de estos estaba asociado a uno de los estados de falla considerados durante la experimentación. Para implementar la red neuronal se tomaron 180 muestras por cada uno de los casos de falla en el motor de inducción considerados durante la experimentación, estos casos son mostrados en la figura 3.6; 156 de las muestras fueron usadas como material de entrenamiento y las 54 muestras restantes como material de prueba.




Figura 3.5: Estructura de la Red Neuronal implementada

Estado del motor	
Sano (HLT)	Falla en balero, 3 mm (BAL3)
Desalineamiento (MAL)	Falla en balero, 4 mm (BAL4)
Desbalance (UNB)	Falla en balero, 5 mm (BAL5)
1 barra rota (1BRB)	Caja de engranes sana (GRH)
2 barras rotas (2BRB)	Falla en engranes, 25% (GR25)
Falla en balero, 1 mm (BAL1)	Falla en engranes, 50% (GR50)
Falla en balero, 2 mm (BAL2)	Falla en engranes, 75% (GR75)

Figura 3.6: Casos de falla considerados en el entrenamiento de la red neuronal

Capítulo 4

Resultados

4.1. Experimentación y adquisición de datos

4.1.1. Matriz de pruebas

Para el diseño del *Smart Sensor* enfocado a la detección de fallas en motores de inducción fue necesario realizar una serie de pruebas con el fin de adquirir datos que permitan entrenar al sistema así como validar los resultados obtenidos. Con esto en mente en la tabla 4.1 se describe los detalles de la matriz de pruebas considerada para este trabajo.

Tabla 4.1: Matriz de pruebas de la metodología

Descripción de Estado	Detalles de la Prueba	Número de capturas tomadas
Sano (HLT)	Motor sin fallas, estado de referencia	540 capturas, 90 minutos.
Fallas en balero (BAL)	Falla de 1 mm (BAL1), 2mm (BAL2), 3mm (BAL3), 4mm (BAL4), y 5mm (BAL5)	540 capturas, 90 minutos (por grado de falla).

Fallas de barra rota (BRB)	Falla de 1 barra rota (1BRB) y falla de 2 barras rotas (2BRB)	540 capturas, 90 minutos (por grado de falla).
Falla de desalineamiento (MAL)	Motor y carga desalineados	540 capturas, 90 minutos.
Falla de desbalance (UNB)	Motor desbalanceado	540 capturas, 90 minutos.
Caja de Engranés	Engranés sanos, falla del 25 %, falla del 50 %, y falla de 75 %	540 capturas, 90 minutos (por grado de falla).

De las 540 capturas termográficas adquiridas por cada caso de estudio durante la experimentación solamente se utilizaron las últimas 180 imágenes (asociadas a los últimos 30 minutos de cada prueba) para el entrenamiento de la red neuronal. Esto se hizo considerando que el motor de inducción usado en los experimentos alcanzaba un equilibrio térmico al pasar una hora en funcionamiento continuo.

4.1.2. Bancada de experimentación

Las pruebas listadas en la tabla 4.1 se realizaron en el laboratorio de Máquinas Eléctricas de la Facultad de Ingeniería, Campus San Juan del Río. En la tabla 4.2 se muestran los datos del motor de inducción estudiado durante las pruebas realizadas:

Tabla 4.2: Datos técnicos del motor estudiado

Dato técnico	Descripción
Modelo	WEG 3F A.E. 00136AP3E48TCT
Tensión de alimentación	208-230 / 460 V
Frecuencia	60 Hz
Velocidad de operación	3355 rpm
Potencia	1 HP / 0.74 kW

En la figura 4.1 se muestra el sistema de adquisición de imágenes termográficas diseñado para este trabajo, mientras que en la figura 4.2 se muestra una foto de la bancada de pruebas utilizada en las pruebas realizadas.



Figura 4.1: Sistema diseñado para la adquisición de imágenes termográficas



Figura 4.2: Bancada de pruebas usada en la experimentación

4.2. Procesamiento de imágenes termográficas

Las imágenes termográficas adquiridas con la cámara térmica FLIR Lepton 3.5 durante las pruebas realizadas fueron procesadas de acuerdo a la metodología descrita en el capítulo anterior. Para la adquisición de las imágenes térmicas se desarrolló una aplicación usando el ambiente de desarrollo de Qt y el lenguaje de programación C++. La interfaz de usuario diseñada se muestra en la figura 4.3. En esta aplicación también se programaron los algoritmos para el procesamiento de las imágenes infrarrojas usando las librerías de Qt y OpenCV.

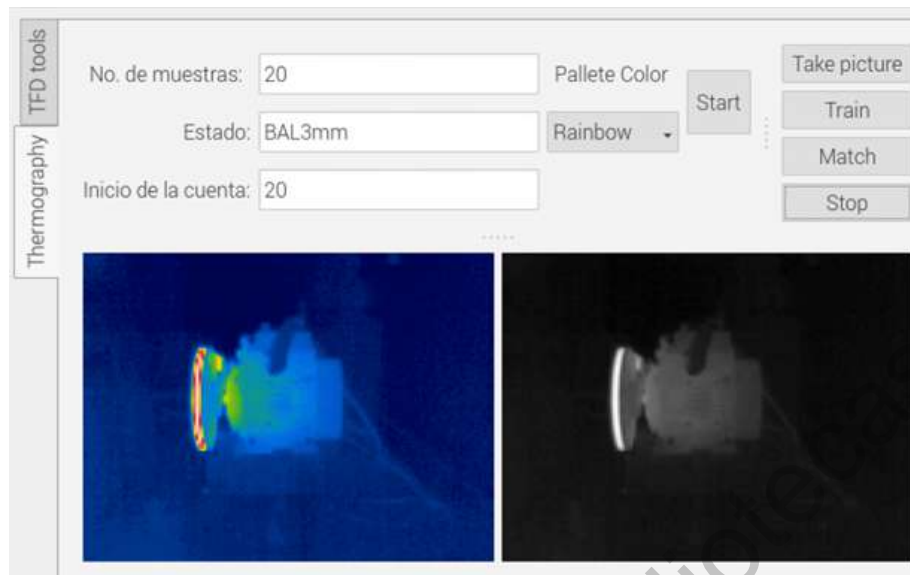


Figura 4.3: UI de aplicación para captura y procesamiento de imágenes termográficas

En la figura 4.4 se muestran el resultado obtenido al segmentar de una imagen termográfica. Primero se observa la identificación de los puntos característicos por medio del método SIFT en dos imágenes térmicas: la primera imagen sirve para el entrenamiento del método de detección de objetos y la segunda sirve como la imagen objetivo en la etapa de emparejamiento. Se ilustran las correlaciones encontradas en la etapa de emparejamiento entre los puntos característicos de ambas imágenes. Finalmente, se generó una nueva imagen donde solo se conserva la región de interés aislada del resto de la escena capturada.




Figura 4.4: Segmentación de ROI mediante uso de los métodos de Otsu y SIFT

A partir de la región de interés aislada se calculó el histograma para observar la distribución de las tonalidades de grises y poder calcular los parámetros estadísticos de la imagen termográfica. Los histogramas calculados tienen un rango dinámico acorde a la diferencia entre la temperatura máxima y la temperatura mínima registrada por la cámara infrarroja en cada imagen adquirida y procesada. La figura 4.5 muestra una representación gráfica del histograma para los casos de: motor sano (HLT), falla de una barra rota (1BRB), y falla de dos barras rotas (2BRB).

La información presente en los histogramas fue caracterizada al calcular 15 parámetros estadísticos: media, valor máximo, media cuadrática (RMS), SMR, desviación estándar, varianza, factor de forma con RMS, factor de forma con SMR, factor de cresta, factor de latitud, factor de impulso, asimetría, curtosis, 5^o momento, y 6^o momento. Estos parámetros fueron utilizados para crear la base de datos




Figura 4.5: Representación gráfica de los histogramas calculados a partir de imágenes térmicas. a) Motor Sano, b) Caso de una barra rota, c) Caso de dos barras rotas.

necesaria para la categorización del estado del motor estudiado.

4.3. Combinación de variables

Al construir la matriz de datos con los valores adquiridos de las tres variables consideradas (termografía, flujo magnético, y corriente eléctrica) descrita en la tabla 3.1 y hacer el análisis de componentes principales (PCA) para la reducción de la dimensionalidad de la matriz se obtuvo la distribución de los datos observada en la figura 4.6. Con fines comparativos se muestra la reducción de dimensionalidad lograda al considerar solo los parámetros termográficos en la figura 4.7.

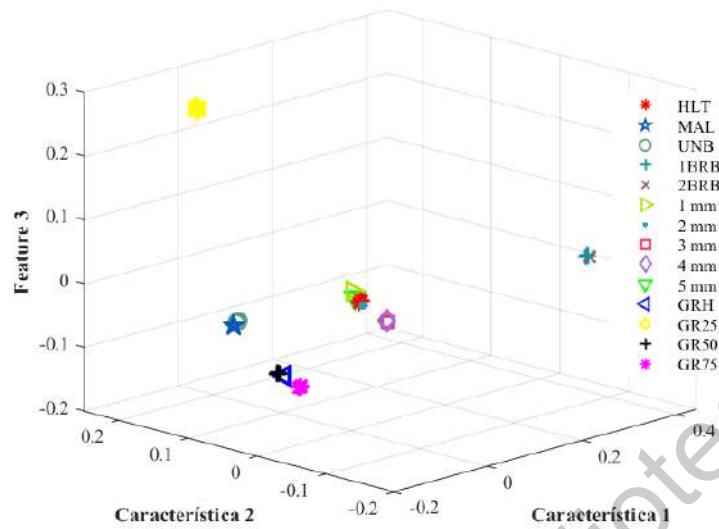


Figura 4.6: Reducción de dimensionalidad de la matriz combinada por PCA

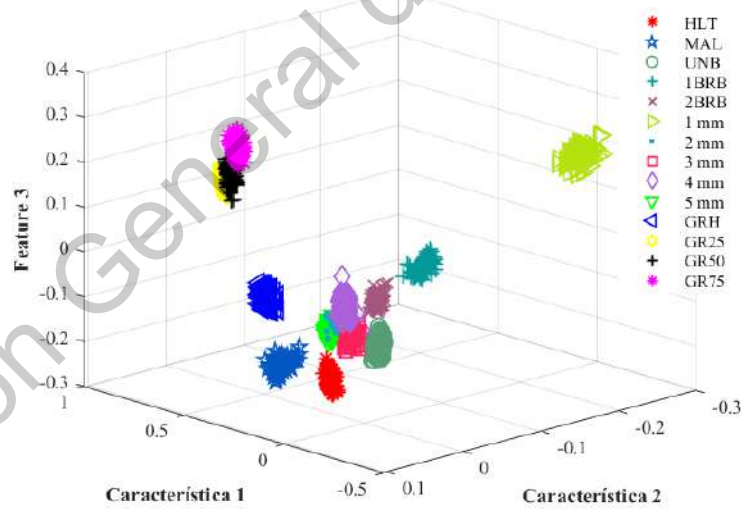


Figura 4.7: Reducción de dimensionalidad de matriz termográfica por PCA

4.4. Clasificación de estados del motor

La clasificación del estado del motor se llevó a cabo mediante la implementación de una red neuronal con la estructura mostrada en la figura 3.5. Los resultados del entrenamiento de esta red neuronal se observan en las matrices de confusión. La primera matriz de confusión (Fig. 4.8) muestra el desempeño de la red neuronal para clasificar los estados del motor de inducción al ser entrenada solamente con los parámetros termográficos, mientras que en la segunda matriz de confusión (Fig. 4.9) se observa el desempeño obtenido al entrenar la red neuronal con las componentes multivariantes combinadas.

El sistema de clasificación entrenado solamente con los 15 parámetros termográficos propuestos tuvo una exactitud del 90,5%. La combinación de variables para el entrenamiento del sistema de clasificación hizo posible obtener una exactitud del 99,9%.

4.5. Interfaz de Usuario del Smart Sensor

Se diseñó una interfaz de usuario (*UI, User Interface*) para el *Smart Sensor* con el objetivo de presentar los resultados del diagnóstico automático de la condición de un motor de inducción y presentar el resultado del procesamiento de las señales adquiridas de termografía, flujo magnético (o *stray flux*), y corriente eléctrica. Se muestran algunas capturas de pantalla en la figura 4.10. La figura 4.10a muestra la interfaz del *Smart Sensor* al detectar que el motor de inducción analizado se encuentra en estado sano. En 4.10b se muestra la captura de pantalla del dispositivo al detectar falla de barra rota y desalineamiento en el rotor del motor de inducción. Las figuras 4.10c, 4.10d, y 4.10e muestran la interfaz diseñada para representar las

señales de termografía, flujo magnético, y corriente eléctrica respectivamente.

Confusion Matrix

1	54 7.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
2	0 0.0%	54 7.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 0.1%	0 0.0%	0 0.0%	98.2% 1.8%
3	0 0.0%	0 0.0%	54 7.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
4	0 0.0%	0 0.0%	0 0.0%	54 7.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	53 7.0%	0 0.0%	0 0.0%	3 0.4%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	94.6% 5.4%
6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	54 7.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
7	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	NaN% NaN%
8	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 0.1%	53 7.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	98.1% 1.9%
9	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 0.1%	0 0.0%	1 0.1%	0 0.0%	51 6.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	96.2% 3.8%
10	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	52 6.9%	1 0.1%	0 0.0%	54 7.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	50.5% 49.5%
11	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	52 6.9%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
12	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	54 7.1%	3 0.4%	0 0.0%	94.7% 5.3%
13	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 0.1%	0 0.0%	51 6.7%	8 1.1%	85.0% 15.0%
14	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	46 6.1%	100% 0.0%
	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	98.1% 1.9%	100% 0.0%	98.1% 1.9%	94.4% 5.6%	100% 0.0%	96.3% 3.7%	100% 0.0%	94.4% 5.6%	85.2% 14.8%	90.5% 9.5%
	1	2	3	4	5	6	7	8	9	10	11	12	13	14
	Target Class													

Figura 4.8: Matriz de confusión de red neuronal entrenada solamente con parámetros termográficos

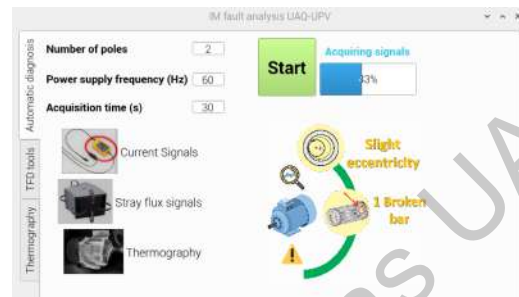
Confusion Matrix

1	53 7.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
2	0 0.0%	54 7.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
3	0 0.0%	0 0.0%	54 7.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
4	0 0.0%	0 0.0%	0 0.0%	54 7.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	54 7.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	54 7.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
7	1 0.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	54 7.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	98.2% 1.8%
8	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	54 7.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
9	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	54 7.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
10	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	54 7.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
11	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	54 7.1%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
12	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	54 7.1%	0 0.0%	0 0.0%	100% 0.0%
13	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	54 7.1%	0 0.0%	100% 0.0%
14	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	54 7.1%	100% 0.0%
	98.1% 1.9%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	99.9% 0.1%
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	
	Target Class														

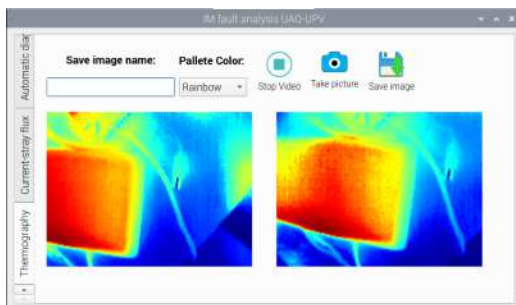
Figura 4.9: Matriz de confusión de red neuronal entrenada con parámetros multivariados combinados (termografía, flujo magnético, corriente eléctrica)




(a) UI con motor de inducción sano



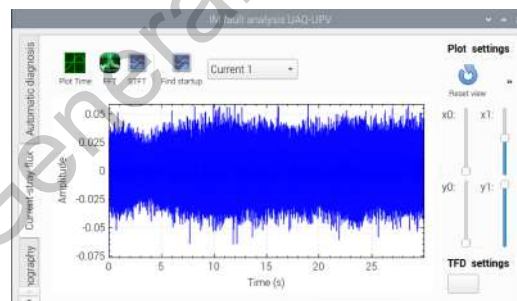
(b) UI con falla detectada en motor



(c) UI de captura de imágenes termográficas



(d) UI de procesamiento de señales de *stray flux*



(e) UI de procesamiento de señales de corriente eléctrica

Figura 4.10: Capturas de pantalla de la Interfaz de Usuario (UI) del Smart Sensor

Capítulo 5

Conclusiones

El desarrollo de este trabajo de investigación tuvo como objetivo principal el diseño y la implementación de un sistema propietario para la detección automática de fallas en motores de inducción basado en el procesamiento de señales multivariables. El enfoque que se dio a este proyecto fue el procesamiento de imágenes termográficas como un medio de apoyo para los métodos tradicionalmente usados en el monitoreo de motores eléctricos: análisis de señales de corriente eléctrica, flujo magnético disperso, y vibraciones mecánicas.

Una de las limitaciones de la investigación realizada fue la falta de motores de inducción con diferentes especificaciones técnicas durante la experimentación. Dado que el trabajo ha sido realizado en un contexto de colaboración internacional con el objetivo de desarrollar un sistema inteligente capaz de dar un diagnóstico confiable del estado de los motores inducción, se contempla la futura realización de pruebas del *Smart Sensor* en distintos bancos de prueba con el apoyo de las instituciones académicas e industriales colaboradoras ubicadas en Europa. Adicionalmente, se considera la posibilidad de realizar simulaciones numéricas del motor de inducción ante distintos estados de falla, esto con el fin de crear un sistema de referencia que sirva como apoyo en la etapa de entrenamiento y calibración del *Smart Sensor*.

La metodología propuesta para el manejo y procesamiento de las imágenes adquiridas con un sensor infrarrojo de bajo costo demostró ser efectiva para la obtención de parámetros estadísticos significativos para la identificación de trece casos

distintos de falla con una exactitud del 90.5 %, desafiando así la suposición de que el análisis de imágenes termográficas no es efectivo para la detección de fallas en motores de inducción. Sin embargo, los resultados obtenidos tras el entrenamiento de los métodos de clasificación automáticos mostraron que la combinación de características multivariantes es capaz de llegar a predicciones más exactas (99.9 %).

Dirección General de Bibliotecas UAQ

Bibliografía

- Aggarwal, C. C. (Ed.). (2014). *Data classification: algorithms and applications* [OCLC: 904721748]. CRC Press/Chapman & Hall.
- Boehmke, B. & Greenwell, B. (2019). *Hands-On Machine Learning with R*. CRC Press. <https://books.google.com.mx/books?id=aXC9DwAAQBAJ>
- 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>
- Deekshit, K. C., Venu Gopala Rao, M. & Srinivasa Rao, R. (2018). Bearing fault detection in a 3 phase induction motor using stator current frequency spectral subtraction with various wavelet decomposition techniques. *Ain Shams Engineering Journal*, 9(4), 2427-2439. <https://doi.org/10.1016/j.asej.2017.06.002>
- Delgado, P. A., Morinigo-Sotelo, D., Osornio-Rios, R. A., Avina-Cervantes, J. G., Rostro-Gonzalez, H. & Romero-Troncoso, R. d. J. (2017). Methodology for fault detection in induction motors via sound and vibration signals. *Mechanical Systems and Signal Processing*, 83, 568-589. <https://doi.org/10.1016/j.ymsp.2016.06.032>
- Dhamande, L. S. & Chaudhari, M. B. (2018). Compound gear-bearing fault feature extraction using statistical features based on time-frequency method. *Measurement: Journal of the International Measurement Confederation*, 125 (January), 63-77. <https://doi.org/10.1016/j.measurement.2018.04.059>

- Dilpreet, K. & Yadwinder, K. (2014). Various Image Segmentation Techniques: A Review. *International Journal of Computer Science and Mobile Computing*, 3(5), 809-814. www.ijcsmc.com
- Ewert, P. (2017). Use of axial flux in the detection of electrical faults in induction motors. *2017 International Symposium on Electrical Machines, SME 2017*. <https://doi.org/10.1109/ISEM.2017.7993571>
- Faiz, J., Ghorbanian, V. & Joksimovic, G. (2017). *Fault diagnosis of induction motors* [OCLC: ocn982652724]. The Institution of Engineering; Technology.
- FLIR, T. (2021). FLIR Lepton 3 and 3.5 Datasheet [(Accessed on 07/10/2021)].
- Frank, R. (2013). *Understanding smart sensors*. Artech House.
- Frosini, L. & Bassi, E. (2010). Stator current and motor efficiency as indicators for different types of bearing faults in induction motors. *IEEE Transactions on Industrial Electronics*, 57(1), 244-251. <https://doi.org/10.1109/TIE.2009.2026770>
- Garcia, A. G., Morales-Hernandez, L. A., Osornio-Rios, R. A., Benitez-Rangel, J. P., Garcia-Perez, A. & Romero-Troncoso, R. D. J. (2014). Fault detection in induction motors and the impact on the kinematic chain through thermographic analysis. *Electric Power Systems Research*, 114, 1-9. <https://doi.org/10.1016/j.epsr.2014.03.031>
- Ghanbari, T. (2016). Autocorrelation function-based technique for stator turn-fault detection of induction motor. *IET Science, Measurement and Technology*, 10(2), 100-110. <https://doi.org/10.1049/iet-smt.2015.0118>
- Glowacz, A., Glowacz, W., Kozik, J., Piech, K., Gutten, M., Caesarendra, W., Liu, H., Brumerick, F., Irfan, M. & Faizal Khan, Z. (2019). Detection of Deterioration of Three-phase Induction Motor using Vibration Signals. *Measurement Science Review*, 19(6), 241-249. <https://doi.org/10.2478/msr-2019-0031>

- Glowacz, A. & Glowacz, Z. (2017). Diagnosis of the three-phase induction motor using thermal imaging. *Infrared Physics and Technology*, 81, 7-16. <https://doi.org/10.1016/j.infrared.2016.12.003>
- Hassan, O. E., Amer, M., Abdelsalam, A. K. & Williams, B. W. (2018). Induction motor broken rotor bar fault detection techniques based on fault signature analysis – A review. *IET Electric Power Applications*, 12(7), 895-907. <https://doi.org/10.1049/iet-epa.2018.0054>
- Karvelis, P., Georgoulas, G., Stylios, C. D., Tsoumas, I. P., Antonino-Daviu, J. A., Rodenas, M. J. P. & Climente-Alarcon, V. (2014). An automated thermographic image segmentation method for induction motor fault diagnosis. *IECON Proceedings (Industrial Electronics Conference)*, 3396-3402. <https://doi.org/10.1109/IECON.2014.7049001>
- Kumar, G. & Bhatia, P. K. (2014). A detailed review of feature extraction in image processing systems. *International Conference on Advanced Computing and Communication Technologies, ACCT*, 5-12. <https://doi.org/10.1109/ACCT.2014.74>
- Lee, J. H., Pack, J. H. & Lee, I. S. (2019). Fault diagnosis of induction motor using convolutional neural network. *Applied Sciences (Switzerland)*, 9(15). <https://doi.org/10.3390/app9152950>
- Lowe, D. G. (2004). Distinctive image features from scale-invariant keypoints. *International Journal of Computer Vision*, 60(2), 91-110. <https://doi.org/10.1023/B:VISI.0000029664.99615.94>
- OpenCV. (2021). About - OpenCV [(Accessed on 03/03/2021)].
- Ortiz, A., Garrido, J., Hernandez-Escobedo, Q. & Escobedo-Trujillo, B. (2019). Detection of misalignment in motor via transient current signature analysis. *2019*

- IEEE International Conference on Engineering Veracruz, ICEV 2019, 1, 1-5.*
<https://doi.org/10.1109/ICEV.2019.8920719>
- Otsu, N. (1979). A threshold selection method from gray level histograms. *IEEE Transactions on Systems, Man, and Cybernetics, 9*, 62-66.
- Panagiotou, P. A., Arvanitakis, I., Lophitis, N., Antonino-Daviu, J. A. & Gyftakis, K. N. (2019). A New Approach for Broken Rotor Bar Detection in Induction Motors Using Frequency Extraction in Stray Flux Signals. *IEEE Transactions on Industry Applications, 55*(4), 3501-3511. <https://doi.org/10.1109/TIA.2019.2905803>
- Qt. (2018). *About Qt* [https://wiki.qt.io/About_Qt/es].
- Ramirez, J. A., Antonino-Daviu, J., Osornio-Rios, R. A., Quijano-Lopez, A., Razik, H. & Romero-Troncoso, R. J. (2019). Transient analysis of the external magnetic field via MUSIC methods for the diagnosis of electromechanical faults in induction motors. *Proceedings of the 2019 IEEE 12th International Symposium on Diagnostics for Electrical Machines, Power Electronics and Drives, SDEMPED 2019*, 303-308. <https://doi.org/10.1109/DEMPED.2019.8864858>
- Ramirez, J. A., Antonino-Daviu, J. A., Clemente-Alarcon, V., Quijano-Lopez, A., Razik, H., Osornio-Rios, R. A. & Romero-Troncoso, R. D. J. (2018). Evaluation of the Detectability of Electromechanical Faults in Induction Motors Via Transient Analysis of the Stray Flux. *IEEE Transactions on Industry Applications, 54*(5), 4324-4332. <https://doi.org/10.1109/TIA.2018.2843371>
- Resendiz, E., Osornio-Rios, R. A., Benitez-Rangel, J. P., Romero-Troncoso, R. D. J. & Morales-Hernandez, L. A. (2018). Induction Motor Failure Analysis: An Automatic Methodology Based on Infrared Imaging. *IEEE Access, 6*, 76993-77003. <https://doi.org/10.1109/ACCESS.2018.2883988>

- Resendiz, E., Saucedo-Dorantes, J. J., Benitez-Rangel, J. P., Osornio-Rios, R. A. & Morales-Hernandez, L. A. (2020). Novel methodology for condition monitoring of gear wear using supervised learning and infrared thermography. *Applied Sciences (Switzerland)*, 10(2), 1-18. <https://doi.org/10.3390/app10020506>
- Sakhalkar, N. P. & Korde, P. (2018). Fault detection in induction motors based on motor current signature analysis and accelerometer. *2017 International Conference on Energy, Communication, Data Analytics and Soft Computing, ICECDS 2017*, 363-367. <https://doi.org/10.1109/ICECDS.2017.8390117>
- Singh, G., Anil Kumar, T. C. & Naikan, V. N. (2016). Induction motor inter turn fault detection using infrared thermographic analysis. *Infrared Physics and Technology*, 77, 277-282. <https://doi.org/10.1016/j.infrared.2016.06.010>
- Stroustrup, B. (1997). *The C++ programming language* (3rd). Addison-Wesley.
- Stroustrup, B. (2018). *A tour of C++* (2nd). Addison-Wesley.
- Vollmer, M. & Möllmann, K. (2018). *Infrared Thermal Imaging: Fundamentals, Research and Applications*. Wiley.
- Zamudio, I., Osornio-Ríos, R. A., Antonino-Daviu, J. A. & Quijano-Lopez, A. (2020). Smart-sensor for the automatic detection of electromechanical faults in induction motors based on the transient stray flux analysis. *Sensors (Switzerland)*, 20(5). <https://doi.org/10.3390/s20051477>

Apéndice A

Código para procesamiento de imágenes termográficas

En este apéndice se muestra el código implementado en el *Smart Sensor* para el procesamiento de las imágenes termográficas adquiridas con el sensor infrarrojo FLIR Lepton 3.5. La primera función descrita sirve para la etapa de entrenamiento del algoritmo SIFT (Fig. 3.4).

```
1 void SIFTTraining(cv::Mat &image){
2     cv::Mat img1, imgTh;
3
4     cv::resize(image, img1, cv::Size(520, 390), 0,0, cv::INTER_LINEAR)
5
6     //Otsu Thresholding
7     double th = cv::threshold(img1, imgTh, 0,255,cv::THRESH_TOZERO | cv
8         ::THRESH_OTSU);
9
10    //Declaracion de detector SIFT
11    Ptr<SIFT> detector = cv::SIFT::create();
12    std::vector<KeyPoint> keypoints;
13    cv::Mat descriptors;
14    //Deteccion de keypoints por SIFT
```

```

15     detector->detectAndCompute(imgTh, Mat(), keypoints, descriptors)
16     ;
17     //Guardar datos de entrenamiento
18     myfunc->SaveSIFTkeydesc(img1, descriptors, keypoints, "
19     SIFT_testresults.yml");

```

Listing A.1: Entrenamiento de algoritmo SIFT

La función mostrada a continuación describe la etapa de emparejamiento de puntos clave del método de segmentación por medio del algoritmo SIFT y la etapa del cálculo del histograma de la imagen termográfica y sus características estadísticas.

```

1 void HistImgCalc(cv::Mat &image, QVector<float> &results){
2     //FUNCION PARA CALCULO DE HISTOGRAMA Y PARAMETROS ESTADISTICOS
3     DE UNA IMAGEN EN B/N.
4     //Nota: Esta es para cuando ya se tiene "entrenado" al algoritmo
5     SIFT
6
7     std::vector<KeyPoint> keypoints1, keypoints2;
8     cv::Mat descriptors1, descriptors2;
9     cv::Mat img1, img2;
10    Ptr<SIFT> detector = cv::SIFT::create();
11
12    //Carga de datos de entrenamiento
13    myfunc->LoadSIFTkeydesc("SIFT_testresults.yml", descriptors1,
14    keypoints1, img1);
15    cv::resize(image, img2, cv::Size(520, 390), 0,0, cv::INTER_LINEAR)
16    ;
17
18    //Deteccion de puntos SIFT

```

```

15  detector->detectAndCompute(img2, Mat(), keypoints2, descriptors2);
16
17  //Emparejamiento de puntos SIFT
18  Ptr<DescriptorMatcher> matcher = cv::DescriptorMatcher::create(
19      DescriptorMatcher::FLANNBASED);
20  std::vector< std::vector<DMatch> > knn_matches;
21  matcher->knnMatch(descriptors1, descriptors2, knn_matches, 2);
22
23  //Criterio de Lowe para filtrar matches
24  const float ratio_thresh = 0.8f;
25  std::vector<DMatch> good_matches;
26  for (size_t k = 0; k < knn_matches.size(); k++)
27  {
28      if (knn_matches[k][0].distance < ratio_thresh * knn_matches[k
29          ][1].distance)
30      {
31          good_matches.push_back(knn_matches[k][0]);
32      }
33  }
34
35  if(good_matches.size() > MIN_MATCHES)
36  {
37      std::vector<Point2f> obj;
38      std::vector<Point2f> scene;
39
40      for(size_t k=0; k < good_matches.size(); k++)
41      {
42          obj.push_back(keypoints1[good_matches[k].queryIdx].pt);
43          scene.push_back(keypoints2[good_matches[k].trainIdx].pt);

```

```

44     cv::Mat H = cv::findHomography(obj, scene, RANSAC);
45
46     //Esquinas del objeto a detectar
47
48     std::vector<Point2f> obj_corners(4);
49     std::vector<Point2f> scene_corners(4);
50
51     /*En esta seccion van las coordenadas de las esquinas
52     / del rectangulo que cubre a la zona de interes en la imagen
53     usada en el entrenamiento
54     */
55     obj_corners[0] = Point2f(105, 85);
56     obj_corners[1] = Point2f(475, 85);
57     obj_corners[2] = Point2f(475, 285);
58     obj_corners[3] = Point2f(105, 285);
59
60     cv::perspectiveTransform(obj_corners, scene_corners, H);
61
62     cv::Mat maskt = cv::Mat(img2.rows, img2.cols, CV_8UC1, cv::
63     Scalar(0));
64
65     std::vector<vector<Point>> mask_corners;
66     mask_corners.push_back(vector<Point>());
67     mask_corners[0].push_back(scene_corners[0]);
68     mask_corners[0].push_back(scene_corners[1]);
69     mask_corners[0].push_back(scene_corners[2]);
70     mask_corners[0].push_back(scene_corners[3]);
71
72     cv::drawContours(maskt, mask_corners, 0, Scalar(255), FILLED,
73     8);

```

```

72
73     std::cout << "Matches found: " << good_matches.size() << std::
endl;
74
75     double min, max = 0.;
76
77     int totpx = cv::countNonZero(maskt);
78
79     cv::minMaxLoc(img2, &min, &max, 0, 0, maskt);
80     int histSize = static_cast<int>(max - min);
81
82     float range[] = {static_cast<float>(min), static_cast<float>(
max)};
83     const float* histRange = {range};
84
85     bool uniform = true, accumulate = false;
86
87     cv::Mat hist;
88
89     cv::calcHist(&img2, 1, 0, maskt, hist, 1, &histSize, &histRange
, uniform, accumulate);
90
91     QVector<float> histvec(histSize);
92
93     myfunc->MatToQVector(hist, histvec);
94
95     results.fill(0.0, 15);
96
97     myfunc->HistStats(histvec, results, histSize);
98
99 }

```

```

100     else
101     {
102         std::cout << "Not enough matches found:" << good_matches.size
103         () << "/" << MIN_MATCHES << std::endl;
104     }
105 }

```

Listing A.2: Emparejamiento de puntos clave por SIFT

Finalmente, se anexa la función implementada para el cálculo de las características estadísticas del histograma.

```

1 void extrafunctions::HistStats(QVector<float> &hist, QVector<float>
  &stats, int size){
2     /* Rasgos caracteristicos de historial
3     * Pos 0: mean
4     * Pos 1: max
5     * Pos 2: RMS
6     * Pos 3: SMR
7     * Pos 4: Std Dev
8     * Pos 5: Var
9     * Pos 6: Shape Factor (RMS)
10    * Pos 7: Shape Factor (SMR)
11    * Pos 8: Crest Factor
12    * Pos 9: Latitude Factor
13    * Pos 10: Impulse Factor
14    * Pos 11: Skewness
15    * Pos 12: Kurtosis
16    * Pos 13: 5th Moment
17    * Pos 14: 6th Moment
18    */
19

```

```

20 stats.fill(0, 15);
21
22 float sfa = 0;
23
24 for(int i=0; i<size; i++){
25     stats[0] += hist[i];
26     if(hist[i]>stats[1]){ //max
27         stats[1] = hist[i];
28     }
29 }
30
31 stats[0] /= size;
32
33 for(int i=0; i<size; i++){
34     stats[4] += powf((hist[i] - stats[0]),2.0);
35 }
36
37 stats[4] /= (size-1);
38
39 stats[5] = stats[4]; //varianza
40 stats[4] = sqrt(stats[4]); // desv. estandar
41
42 for(int i=0; i<size; i++){
43     stats[2] += powf(hist[i],2.0); //rms
44     stats[3] += sqrt(hist[i]); //smr
45     sfa += hist[i];
46     stats[11] += powf((hist[i] - stats[0]),3.0);
47     stats[12] += powf((hist[i] - stats[0]),4.0);
48     stats[13] += powf((hist[i] - stats[0]),5.0);
49     stats[14] += powf((hist[i] - stats[0]),6.0);
50

```

```

51     }
52
53     stats[2] /= size;
54     stats[2] = sqrt(stats[2]);
55
56     stats[3] /= size;
57     stats[3] = powf(stats[3], 2.0);
58
59     sfa /= size;
60
61     stats[6] = stats[2] / sfa; //shape factor
62     stats[7] = stats[3] / sfa; //shape factor
63     stats[8] = stats[1] / stats[2]; //crest
64     stats[9] = stats[1] / stats[3]; //latitude
65     stats[10] = stats[1] / sfa; //impulse
66
67     stats[11] /= size;
68     stats[11] /= powf(stats[4],3.0); //skew
69
70     stats[12] /= size;
71     stats[12] /= powf(stats[4],4.0); //kurtosis
72
73     stats[13] /= size;
74     stats[13] /= powf(stats[4],5.0); //5th moment
75
76     stats[14] /= size;
77     stats[14] /= powf(stats[4],6.0); //6th moment
78
79 }

```

Listing A.3: Cálculo de características estadísticas

Apéndice B

Artículo publicado en IECON 2021

A continuación se anexa un artículo producto del trabajo realizado en este proyecto de tesis que fue sometido y publicado en la sesión especial *Advanced signal and image processing techniques for condition monitoring of Electric Machines and Drives* (Técnicas avanzadas de procesamiento de señales e imágenes para el monitoreo de la condición de Máquinas Eléctricas) del IECON 2021 (*Industrial Electronics, Control, and Instrumentation Conference*, Conferencia de Electrónica Industrial, Control e Instrumentación).

Infrared thermography image processing for the electromechanical fault detection on the kinematic chain

Alvaro Ivan Alvarado-Hernandez
Facultad de Ingenieria
Universidad Autonoma de Queretaro
Queretaro, Mexico
aalvarado40@alumnos.uaq.mx

Israel Zamudio-Ramirez
Instituto Tecnológico de la Energía
Universitat Politècnica de Valencia
Valencia, Spain
iszara@doctor.upv.es
Facultad de Ingenieria
Universidad Autonoma de Queretaro
Queretaro, Mexico
izamudio13@alumnos.uaq.mx

Jose Alfonso Antonino-Daviu
Instituto Tecnológico de la Energía
Universitat Politècnica de Valencia
Valencia, Spain
joanda@die.upv.es

Roque Alfredo Osornio-Rios
Facultad de Ingenieria
Universidad Autonoma de Queretaro
Queretaro, Mexico
raor@uaq.mx

Abstract—Kinematic chains have a fundamental role in the modern industry thanks to the great variety of applications where they can be found. For this reason the development of new fault detection methods has gained traction in recent years. Different physical signals have been used for the diagnosis of kinematic chains such as electric current, mechanical vibrations, or stray flux; nonetheless, the analysis of temperature signals measured by thermographic cameras has proven to be an effective way to detect certain types of failures complementing the existing work on this area. This paper presents the development of an infrared image processing system for the detection of electromechanical faults (misalignment, unbalance, broken bars, bearing defects, and gearbox wear) on a kinematic chain composed by an induction motor, an output pulley, a plastic transmission band, and an alternator. The system is based on the automatic segmentation of a region of interest associated to the kinematic chain through the implementation of image processing techniques and the calculation of statistical characteristics from the histogram of a thermal image acquired by a low-cost thermographic camera.

Index Terms—image processing, induction motors, fault detection.

I. INTRODUCTION

Kinematic chains in the industrial sector consist of a set of electromechanical elements such as gearboxes, pulleys, couplings, induction motors, and mechanical loads connected in order to accomplish a specific task which are used in a great variety of applications [1]. The main component in any

This work was supported by the Spanish 'Ministerio de Ciencia Innovación y Universidades' and FEDER program in the framework of the 'Proyectos de I+D de Generación de Conocimiento del Programa Estatal de Generación de Conocimiento y Fortalecimiento Científico y Tecnológico del Sistema de I+D+i, Subprograma Estatal de Generación de Conocimiento (ref: PGC2018-095747-B-I00). (Corresponding author: Roque A. Osornio-Rios).

kinematic chain is the induction motor consuming 85 % of the power used in industrial plants [2] which is why ensuring the correct performance of these devices is essential for the productive sector and as such the monitoring of kinematic chains has attracted the attention of many researchers in recent years.

Typically, the faults in a kinematic chain are classified in two main categories: mechanical faults and electrical faults. Among the possible mechanical faults in a kinematic chain the most common ones are broken bars of the induction motor, defective bearings, rotor eccentricities, mechanical unbalance on the pulleys, misalignment of the transmission band, and mechanical defects in components of the kinematic chain such as gearboxes or coupling elements. On the other hand, the main electrical faults are fault in the motor insulation, interturn short circuit, and power failures (phase unbalance, overcurrent, etc.) [3].

Kinematic chain monitoring and fault detection has been approached by measuring different physical variables including electric current, mechanical vibrations, stray flux, and temperature. The analysis of current signals, commonly known as Motor Current Signature Analysis (MCSA), has been used to detect bearing faults in induction motors using signal processing techniques such as Fourier Transform (FT) [4] or Discrete Wavelet Transform (DWT) [5]. Vibration signals, commonly acquired with accelerometers, have been used to detect broken bars faults [6] with frequency analysis techniques like the Fast Fourier Transform (FFT) [7]. The analysis of stray flux signals with techniques such as the Short Time Fourier Transform (STFT) and the extraction of frequency components have de-

tected inter-turn faults [8] and broken bars in induction motors [9]. Temperature signals acquired with infrared thermography technologies have been used with different image processing methods to detect mechanical failures such as unbalance, broken bars, bearing defects [10] as well as gear wear on kinematic chains [11]. The analysis of temperature signals has risen in recent years because thermography is a noninvasive method that allows the monitoring system to be used while the kinematic chain is operating [12], however, this technology still has some disadvantages such as the high cost of the equipment, the closed software environment, as well as the constant need of calibration and assistance of an expert for many infrared cameras [13].

This paper presents the development of an infrared thermal image processing system for the detection of electromechanical faults in kinematic chains. This system is based on the FLIR Lepton 3.5 sensor, a low-cost infrared camera used for thermography applications. The method proposed for the system has a first stage focused on the implementation of Otsu's algorithm for background segmentation on an infrared image, after that there is an automatic object localization stage to locate a region of interest (ROI) associated with the kinematic chain using the SIFT method (*Scale Invariant Feature Transform*), and finally the histogram of the ROI is analyzed to obtain statistical characteristics that can be used to classify different fault states in the kinematic chain. The experiments were made in a kinematic chain integrated with an induction motor, an output pulley, a plastic transmission band, and an alternator as a mechanical load. The fault states considered during the experimentation stage were misalignment, unbalance, broken bars, bearing defect, gearbox wear, as well as the case of a healthy kinematic chain for reference.

II. BACKGROUND

A. Image segmentation

One of the classic methods for image segmentation is Otsu's algorithm [14]. This method uses an automatic algorithm to eliminate the background of an image by dividing the histogram in two classes C_0 and C_1 separated by a threshold value, k . The best value of k is the one that maximizes the inter-class variance expressed by $\sigma_b^2(k)$ in (1):

$$\sigma_b^2(k) = \omega_0(k)\omega_1(k)[\mu_0(k) - \mu_1(k)]^2 \quad (1)$$

$$\omega_0(k) = \sum_{i=0}^{k-1} p(i) \quad (2)$$

$$\omega_1(k) = \sum_{i=k}^{L-1} p(i) \quad (3)$$

$$\mu_0(k) = \frac{\sum_{i=0}^{k-1} k \cdot p(i)}{\omega_0(k)} \quad (4)$$

$$\mu_1(k) = \frac{\sum_{i=k}^{L-1} k \cdot p(i)}{\omega_1(k)} \quad (5)$$

Where $\omega_{0,1}$ is the probability function on class C_0 (2) and C_1 (3), $\mu_{0,1}$ is the mean value of class C_0 (4) and C_1 (5), L is the amount of gray levels in the image, and p is the probability of any given pixel to be in a gray level.

B. Object localization

Lowe's method [15], most commonly known as SIFT (*Scale Invariant Feature Transform*), for the extraction of scale invariant key points is one of the most effective [16] for the localization and segmentation of objects in an image. The method follows four main steps:

1) *Scale-space extrema detection*: The scale-space of an image is calculated using a difference of Gaussian functions (6) to identify potential points invariant to rotation and scale.

$$D(x, y, \sigma) = G(x, y, k\sigma) * I(x, y) - G(x, y, \sigma) * I(x, y) \quad (6)$$

Where $I(x, y)$ is the original image, and σ is the scale or standard deviation for the Gaussian function $G(x, y, \sigma)$ convoluted with the image I .

2) *Key point localization*: Each potential key point is evaluated by an edge-detection and low-contrast model to keep only those key points with more stability in the image.

3) *Orientation assignment*: An orientation is assigned to each key point based on the local gradient properties of the image in order to improve the invariant nature of the key points to scale and rotation, the gradient properties, m and θ are calculated using the equations (7) and (8) respectively:

$$m = \sqrt{(I(x, y) - I(x + 1, y))^2 + (I(x, y) - I(x, y + 1))^2} \quad (7)$$

$$\theta = \tan^{-1} \left[\frac{I(x, y) - I(x, y + 1)}{I(x, y) - I(x + 1, y)} \right] \quad (8)$$

C. Histogram characteristics

The histogram of a thermal image describes the distribution of pixels in a defined number of grey levels. It is possible to extract different statistical characteristics that can be used to condense the information available in a thermal image [17], the following statistics were chosen for this system:

- Mean (10)
- Standard Deviation (11)
- Skewness (12)
- Kurtosis (13)
- Energy (14)
- Entropy (15)

The histogram of an image can also be interpreted as a discrete probability distribution (9), which simplifies the calculations required to obtain all the previously defined statistical characteristics.

1) *Histogram Probability*:

$$P(g) = \frac{N(g)}{M} \quad (9)$$

Where M is the total amount of pixels in image I , $N(g)$ is the number of pixels for each grey level g of the L defined levels.

2) Mean:

$$\mu_g = \sum_{i=0}^{L-1} i \cdot P(i) \quad (10)$$

3) Standard Deviation:

$$\sigma_g = \sqrt{\sum_{i=0}^{L-1} (i - \mu_g)^2 \cdot P(i)} \quad (11)$$

4) Skewness:

$$S = \frac{1}{\sigma_g^3} \sum_{i=0}^{L-1} (i - \mu_g)^3 \cdot P(i) \quad (12)$$

5) Kurtosis:

$$K = \frac{1}{\sigma_g^4} \sum_{i=0}^{L-1} (i - \mu_g)^4 \cdot P(i) \quad (13)$$

6) Energy:

$$E = \sum_{i=0}^{L-1} [P(i)]^2 \quad (14)$$

7) Entropy:

$$H = - \sum_{i=0}^{L-1} P(i) \cdot \log_2[P(i)] \quad (15)$$

III. THERMOGRAPHY SYSTEM DEVELOPMENT

The development of the thermal image processing system as a method for electromechanical fault detection in kinematic chains was designed following the block diagram shown in figure 1. The method proposed in this paper is based on the capture of thermal images by means of a low-cost thermal sensor and the implementation of four image processing steps: pre-processing, background segmentation, automatic location of a region of interest (ROI), and extraction of statistical characteristics from the image histogram.

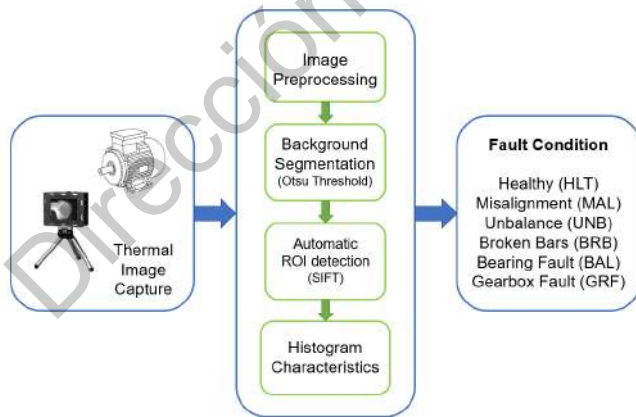


Fig. 1: Block diagram for the thermography system

A. Thermal Image Capture

The low-cost infrared sensor FLIR Lepton 3.5 was used to capture the thermal images analyzed by the system. This camera provides an auto-calibrated output image of 160×120 pixels in data packets of 14 bits that are acquired by a Raspberry Pi 4 board by establishing a SPI communication protocol between devices [8]. This infrared sensor allows for an easy and full data manipulation without restrictions imposed by typical commercial infrared sensors, which facilitates its implementation to proprietary systems and enables to develop efficient and novel methods in a diverse number of applications.

B. Image Preprocessing

The image received in data packets of 14 bits through the communication port of the Raspberry Pi 4 board require a pre-processing stage to remap the pixel values of the thermal image to data packets of 8 bits, i.e. remap the pixel values from an initial range of 0-16383 to an objective range of 0-255. After that, the image is resized using a bilinear interpolation to get a new image of 520×360 pixels in order to increase the information available in the image and thus improving the possible results obtained by the segmentation techniques.

C. Background Segmentation

A background segmentation stage is required so as to reduce the computational load and improve the performance of the localization algorithm, this segmentation of the background is accomplished by implementing Otsu's method following equations (1) to (5). This allows the system to eliminate the low-temperature zones from the image which are considered irrelevant for the detection of training key points.

D. ROI Detection

The Region of Interest (ROI) associated with the induction motor of the kinematic chain is located automatically using the SIFT method. The implementation of this method using equations (6) to (8) takes two stages: a training stage and a pairing stage. The training stage consists of taking the thermal image without background and calculate its invariant key points which are saved in the memory of the system. The coordinates for a rectangle covering the induction motor of the kinematic chain are also saved so as to use them as a reference in the next stage. In the pairing stage a new thermal image is taken and its invariant key points are calculated, then the homography between the two set of key points is found which allows the system to locate automatically the training ROI in the pairing image. The training stage can be executed only once for each kinematic chain examined, this makes it possible for the system to efficiently locate the ROI on different images of the same kinematic chain.

E. Histogram Characteristics

Finally, the statistical characteristics are obtained from the histogram of the localized ROI in the thermal image. These characteristics are used to analyze the current state of the

kinematic chain: mean (10), standard deviation (11), skewness (12), kurtosis (13), energy (14), and entropy (15).

IV. EXPERIMENTS

A. Experimental Setup

The experiments designed for the acquisition of thermal images were made using the kinematic chain shown in figure 2. The components in the configuration of the kinematic chain are: a) induction motor, b) output pulley, c) transmission band, d) alternator as mechanical load. The three phase induction motor is a model WEG 3F A.E. 00136AP3E48TCT, with a supply voltage of 208-230 / 460 V, frequency of 60 Hz, nominal speed of 3355 rpm, and power of 0.74 kW (1 HP). The infrared camera used for the acquisition of images was located 0.80 m away from the kinematic chain in all the experiments.




Fig. 2: Kinematic chain used in the experimentation. a) induction motor, b) output pulley, c) transmission band, d) alternator as mechanical load

B. Study Cases

Each experiment considers only one of the seven specified study cases presented in table I. Every test was initiated by cold starting the induction motor and keeping the kinematic chain running for 90 minutes, the thermography system was capturing six thermal images per minute.

TABLE I: Faults studied on the kinematic chain

Case	Description
Healthy(HLT)	Healthy case, without faults.
Misalignment (MAL)	Misalignment on the transmission band.
Unbalance (UNB)	Mechanical unbalance in the pulley.
1 Broken Bar (IBRB)	1 broken bar in the rotor of the induction motor.
2 Broken Bars (2BRB)	2 broken bars in the rotor of the induction motor.
Bearing Fault (BAL)	5 mm hole on the bearing of the induction motor.
Gearbox Fault (GRF)	75 % wear of teeth on the gearbox.

V. RESULTS AND DISCUSSION

After the implementation of the method presented in figure 1 for the development of a thermography system and the experimentation considering the study cases in table I, a total of 3780 grey scale thermal images were acquired (Fig. 3) which shows the evolution of the kinematic chain temperature during each test. The results presented in this paper only used 1260 thermal images associated with the final 30 minutes of each experiment assuming that the kinematic chain temperature reached a steady state condition after 60 minutes.



Fig. 3: Thermal image in grey scale

The automatic location of the kinematic chain on a thermal image through the pairing of key points obtained by the SIFT algorithm can be observed in figure 4, the ROI associated to the kinematic chain is automatically segmented and saved by the system as presented in figure 5. The histogram obtained from the segmented ROI describes the distribution of temperature measured by the infrared sensor and is expressed using kelvin on figure 6, this plot can be explained as the number of pixels counted by the system in the segmented ROI associated with a defined temperature and as such is expected that the statistical characteristics change according to the state of the kinematic chain. These characteristics, described by equations (10) to (15), are calculated for every histogram obtained by the thermography system.

The statistical characteristics of the images captured are manually separated according to the state of the kinematic chain during the experimentation stage, i.e., a database is created for each study case considered in this paper. The mean values of each statistic is calculated and then organized in the matrix presented in table II. The plots in figure 7 show a graphic representation of the relationship between the different statistical characteristics obtained from the histogram. The entropy (15) was chosen as the common characteristic on all three plots because its normalized variance is the greatest among the considered statistics. It can be observed in plot 7a (skewness vs entropy) that the different study cases are clearly separated from each other but the distribution of the points is not uniform. A different case can be observed in plot 7b (standard deviation vs entropy) where the distribution of

points is not uniform and the distant between cases makes it difficult to separate the study cases, e.g., the HLT and UNB points are overlapping. Finally, it can be seen in plot 7c (energy vs entropy) that the study case points are separated from each other and although the distribution of the points is not uniform, it seems to follow a linear or logarithmic trend.




Fig. 4: Key point identification and pairing with SIFT method



Fig. 5: ROI associated to the kinematic chain

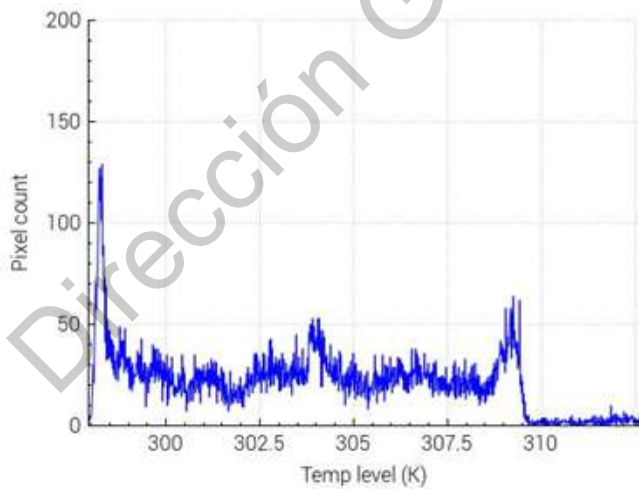

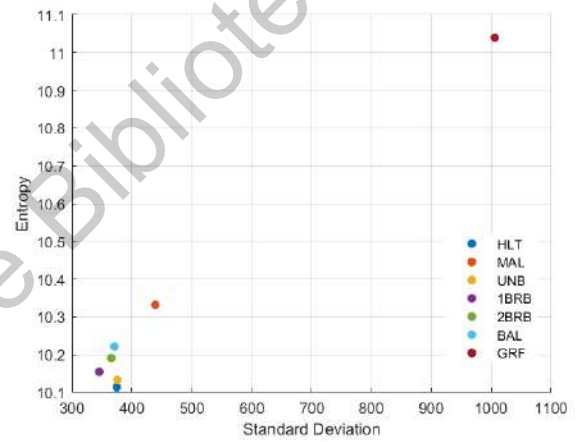



Fig. 6: Histogram of segmented ROI from the thermal image



(a) Skewness-Entropy



(b) Standard Deviation-Entropy



(c) Energy-Entropy

Fig. 7: Relationship between different statistical characteristics obtained from the histogram. a) Skewness-Entropy, b) Standard Deviation-Entropy, c) Energy-Entropy

TABLE II: Mean values of statistical characteristics

STUDY CASE	STATISTICAL CHARACTERISTIC					
	Mean	Std. Deviation	Skewness	Kurtosis	Energy	Entropy
HLT	585.403336	374.9721873	0.26727356	1.89973234	0.00110237	10.1134114
MAL	678.049178	439.433141	0.12222769	2.09085222	0.00091138	10.331588
UNB	549.080591	375.9819163	0.21737771	1.89750058	0.00108876	10.1325868
1BRB	612.528911	345.9004352	0.09076439	2.14800858	0.00099785	10.1542834
2BRB	649.428551	365.8696882	0.02104321	1.9790289	0.0009639	10.1906724
BAL	743.69652	371.0111118	0.13339617	1.94669719	0.00096166	10.2212555
GRF	1094.88914	1005.831974	1.37353915	3.75574524	0.00062724	11.0394564

VI. CONCLUSIONS

In this paper an infrared image processing system was developed to detect electromechanical faults in a kinematic chain considering seven different study cases during the experimentation: healthy, misalignment, unbalance, one and two broken bars, bearing defects, and gearbox wear. The methodology presented effectively captured and processed thermal images through the automatic segmentation of a region of interest associated to the kinematic chain.

The algorithm used on the thermal image processing system allows it to be invariant to geometric transformations of the objects in a picture such as rotation, translation, or resizing which is really useful in an industrial environment. This situation demonstrates the effectiveness of the proposed method, which allows for an online final diagnosis with capabilities for an easy and permanent installation of the required sensors, enabling for a constant healthiness state monitoring of the analyzed kinematic chain (a very valuable aspect in industrial applications with time-critical operations). Moreover, the training stage required by the proposed method can be done only once for each study case without affecting the performance of the system.

The results presented in this paper are preliminary in the creation of new methods and techniques for fault detection on kinematic chains. Our future work will be to validate the developed system on different kinematic chains and increasing the number of study cases considered during the experiments. Furthermore, in order to establish a framework for different fault schemes (which does not require preliminary real kinematic chain data for training), numerical simulations describing thermal patterns of an electromechanical system are recommended.

In addition to that, we will consider the use of dimensionality reduction techniques on the statistical characteristics in order to reduce the computational load for future analysis. Finally, we will evaluate different classification methods such as decision trees or artificial neural networks to get a precise and automatic diagnosis and fault detection on any kinematic chain.

REFERENCES

[1] Garcia-Ramirez, A. G., Morales-Hernandez, L. A., Osornio-Rios, R. A., Benitez-Rangel, J. P., Garcia-Perez, A., and Romero-Troncoso, R. D. J. (2014). Fault detection in induction motors and the impact on the kinematic chain through thermographic analysis. *Electric Power Systems Research*, 114, 1–9.

[2] Rangel-Magdaleno, J., Ramirez-Cortes, J., and 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*, x, 825–829.

[3] Choudhary, A., Goyal, D., Shimi, S. L., and Akula, A. (2019). Condition Monitoring and Fault Diagnosis of Induction Motors: A Review. *Archives of Computational Methods in Engineering*, 26(4), 1221–1238.

[4] Toma, R. N., Prosvirin, A. E., and Kim, J. M. (2020). Bearing fault diagnosis of induction motors using a genetic algorithm and machine learning classifiers. *Sensors (Switzerland)*, 20(7).

[5] Deekshit Kompella, K. C., Venu Gopala Rao, M., and Srinivasa Rao, R. (2018). Bearing fault detection in a 3 phase induction motor using stator current frequency spectral subtraction with various wavelet decomposition techniques. *Ain Shams Engineering Journal*, 9(4), 2427–2439.

[6] Glowacz, A., Glowacz, W., Kozik, J., Piech, K., Gutten, M., Caesarendra, W., Liu, H., Brumerick, F., Irfan, M., and Faizal Khan, Z. (2019). Detection of Deterioration of Three-phase Induction Motor using Vibration Signals. *Measurement Science Review*, 19(6), 241–249.

[7] Sakhalkar, N. P., and Korde, P. (2018). Fault detection in induction motors based on motor current signature analysis and accelerometer. *2017 International Conference on Energy, Communication, Data Analytics and Soft Computing, ICECDS 2017*, 363–367.

[8] Ewert, P. (2017). Use of axial flux in the detection of electrical faults in induction motors. *2017 International Symposium on Electrical Machines, SME 2017*.

[9] Panagiotou, P. A., Arvanitakis, I., Lophitis, N., Antonino-Daviu, J. A., and Gyftakis, K. N. (2019). A New Approach for Broken Rotor Bar Detection in Induction Motors Using Frequency Extraction in Stray Flux Signals. *IEEE Transactions on Industry Applications*, 55(4), 3501–3511.

[10] Glowacz, A., and Glowacz, Z. (2017). Diagnosis of the three-phase induction motor using thermal imaging. *Infrared Physics and Technology*, 81, 7–16.

[11] Resendiz-Ochoa, E., Saucedo-Dorantes, J. J., Benitez-Rangel, J. P., Osornio-Rios, R. A., and Morales-Hernandez, L. A. (2020). Novel methodology for condition monitoring of gear wear using supervised learning and infrared thermography. *Applied Sciences (Switzerland)*, 10(2), 1–18.

[12] Singh, G., Anil Kumar, T. C., and Naikan, V. N. A. (2016). Induction motor inter turn fault detection using infrared thermographic analysis. *Infrared Physics and Technology*, 77, 277–282.

[13] Resendiz-Ochoa, E., Osornio-Rios, R. A., Benitez-Rangel, J. P., Romero-Troncoso, R. D. J., and Morales-Hernandez, L. A. (2018). Induction Motor Failure Analysis: An Automatic Methodology Based on Infrared Imaging. *IEEE Access*, 6, 76993–77003.

[14] Otsu, N. (1979). A threshold selection method from gray-level histograms. *IEEE transactions on systems, man, and cybernetics*, 9(1), 62–66.

[15] Lowe, D. G. (2004). Distinctive image features from scale-invariant keypoints. *International Journal of Computer Vision*, 60(2), 91–110.

[16] Karvelis, P., Georgoulas, G., Stylios, C. D., Tsoumas, I. P., Antonino-Daviu, J. A., Rodenas, M. J. P., and Climente-Alarcon, V. (2014). An automated thermographic image segmentation method for induction motor fault diagnosis. *IECON Proceedings (Industrial Electronics Conference)*, 3396–3402.

[17] Tran, V. T., Yang, B. S., Gu, F., and Ball, A. (2013). Thermal image enhancement using bi-dimensional empirical mode decomposition in combination with relevance vector machine for rotating machinery fault diagnosis. *Mechanical Systems and Signal Processing*, 38(2), 601–614.

[18] FLIR. (2018). Specifications General FLIR Lepton 3 and 3.5. FLIR Systems, Inc. <https://www.flir.com/globalassets/imported-assets/document/lepton-3-3.5-datasheet.pdf>