



Universidad Autónoma de Querétaro
Facultad de Ingeniería
Doctorado en Mecatrónica



**Diagnóstico de fallos electromecánicos en motores eléctricos
mediante el análisis avanzado del flujo magnético y su
implementación en hardware**

Opción de titulación

Tesis

Que como parte de los requisitos para obtener el título de

Doctor en Mecatrónica

Presenta:

Israel Zamudio Ramírez

Dirigido por:

Dr. Roque Alfredo Osornio Ríos

Co-dirigido por:

Dr. José Alfonso Antonino Daviu

San Juan del Río, Querétaro, Marzo de 2023



Dirección General de Bibliotecas y Servicios Digitales de
Información



Diagnóstico de fallos electromecánicos en motores
eléctricos mediante el análisis avanzado del flujo
magnético y su implementación en hardware

por

Israel Zamudio Ramírez

se distribuye bajo una [Licencia Creative Commons
Atribución-NoComercial-SinDerivadas 4.0 Internacional](https://creativecommons.org/licenses/by-nc-nd/4.0/).

Clave RI: IGDCC-231072-0323-1923



Universidad Autónoma de Querétaro
Facultad de Ingeniería
Doctorado en Mecatrónica

Diagnóstico de fallos electromecánicos en motores eléctricos mediante el análisis avanzado del flujo magnético y su implementación en hardware

TESIS

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

Presenta:

M. en C. Israel Zamudio Ramírez

Dirigido por:

Dr. Roque Alfredo Osornio Ríos

SINODALES

Dr. Roque Alfredo Osornio Ríos
Presidente

Firma

Dr. José Alfonso Antonino Daviu
Secretario

Firma

Dr. Arturo Yosimar Jaen Cuellar
Vocal

Firma

Dr. Miguel Trejo Hernández
Suplente

Firma

Dr. Juan Pablo Amézquita Sánchez
Suplente

Firma

Dr. Manuel Toledano Ayala
Nombre y Firma
Director de la Facultad

Dr. Juan Carlos Jáuregui Correa
Nombre y Firma
Director de Investigación y
Posgrado

Centro Universitario
Querétaro, Qro.
23 de Enero de 2023
México



Dedicatoria

A mi familia por brindarme siempre su apoyo y cariño impulsándome a seguir adelante en cada reto que se me presenta. A mi padre, Gabino Zamudio Godoy, por siempre brindarnos lo mejor y ser un gran ejemplo para sus hijos.

Y con especial dedicatoria, a mi querida madre Bertha Ramírez Arteaga, a quien con gran esfuerzo y entusiasmo dedicó su vida entera para su familia, y que sin ella esto no sería posible.



Agradecimientos

Al Consejo Nacional de Ciencia y Tecnología (CONACyT) por la beca de Doctorado con número de CVU 652815.

A la Universidad Autónoma de Querétaro por la beca de posgrado con número de expediente 231072.

A mi asesor, Dr. Roque Alfredo Osornio Ríos, por brindarme la oportunidad de participar en este proyecto, por sus acertados comentarios y por su invaluable tiempo y dedicación brindado para el asesoramiento y orientación de la presente tesis.

Al Dr. José Alfonso Antonino Daviu, por todo el apoyo brindado en todos los sentidos, por sus acertados comentarios, y por el apoyo para culminar esta nueva etapa de mi vida.



Resumen

Los motores eléctricos son máquinas eléctricas rotatorias que permiten realizar la conversión de energía eléctrica en energía mecánica, misma que resulta de gran utilidad en diversos procesos industriales, principalmente para accionar mecanismos y cadenas cinemáticas complejas que ejecutan alguna tarea en específico. Dentro de los distintos tipos de motores eléctricos, las máquinas de inducción se han utilizado ampliamente en una gran variedad de procesos industriales. Esto se debe principalmente a sus excelentes características y prestaciones, como lo son: robustez, fácil control, simplicidad, confiabilidad, y fácil mantenimiento. Sin embargo, a pesar de su elevada robustez, este tipo de máquinas se encuentran sujetas a esfuerzos mecánicos, térmicos, eléctricos y ambientales bajo diversas condiciones de operación durante su vida útil, lo que de forma inevitable conduce a fallos. Los principales fallos que suelen presentarse en los motores eléctricos de inducción son aquellos relacionados a sus componentes internos como lo son barras de rotor rotas, desgaste en las pistas exterior e interior en los rodamientos, desgaste en la jaula del rodamiento, fallas en el estator (por ejemplo, cortocircuito entre espiras adyacentes), entre otros. Cuando un motor eléctrico se encuentra operando bajo alguna condición de falla su rendimiento puede verse afectado, lo que se traduce en consumos de energía más elevados, causando a su vez costos extras al momento de facturar. En este trabajo de investigación se presenta el desarrollo de una metodología innovadora, capaz de generar un diagnóstico adecuado y de forma automática de la ocurrencia de las fallas más comunes que pueden desarrollarse en los motores eléctricos de inducción bajo diversas condiciones de operación mediante el análisis del flujo magnético de dispersión (que puede ser capturado en la periferia del marco del motor) empleando herramientas de descomposición en tiempo-frecuencia, herramientas de clasificación de datos y parámetros de caracterización de señales. Así entonces, se prueba la validez de técnicas basadas en el análisis del flujo magnético de dispersión para el diagnóstico de distintas fallas electromecánicas en motores de inducción. Los resultados demuestran el excelente desempeño de la metodología de diagnóstico automático propuesta, al ser evaluada en una gran variedad de motores con diversas características constructivas.

Palabras clave: Análisis transitorio, fallos electromecánicos, flujo magnético de dispersión, motores de inducción, procesamiento de señales.



Abstract

Electric motors are rotating electrical machines that allow the conversion of electrical energy into mechanical energy, which is very useful in various industrial processes, mainly to drive mechanisms and complex kinematic chains that perform a specific task. Within the different types of electric motors, induction machines have been widely used in a wide variety of industrial processes. This is mainly due to its excellent features and benefits, such as robustness, easy control, simplicity, reliability, and easy maintenance. However, despite its high robustness, this type of machine is subject to mechanical, thermal, electrical, and environmental stress under various operating conditions during its useful life, which inevitably leads to failures. The main failures that usually occur in electric induction motors are those related to their internal components, such as broken rotor bars, wear on the outer and inner races of the bearings, wear on the bearing cage, stator failures (for example, short circuit between adjacent turns), among others. When an electric motor is operating under some fault condition, its performance may be affected, which translates into higher energy consumption, causing extra costs at the time of billing. This research thesis presents the development of an innovative methodology capable of automatically generating an adequate diagnosis of the occurrence of the most common failures that can develop in electric induction motors under various operating conditions through the analysis of the stray magnetic flux (which can be captured at the periphery of the motor frame). This is performed by using time-frequency decomposition tools, data classification tools, and signal characterization parameters. Thus, the validity of techniques based on the analysis of the stray magnetic flux for the diagnosis of different electromechanical failures in induction motors is tested. The results demonstrate the excellent performance of the proposed automatic diagnosis methodology when evaluated in a wide variety of engines with different construction characteristics.

Keywords: Transient analysis, electromechanical failures, stray magnetic flux, induction motors, signal processing.



Índice general

1. Introducción.....	17
1.1 ANTECEDENTES.....	18
1.2 Hipótesis.....	25
1.3 OBJETIVOS.....	25
1.3.1 Objetivo general:.....	25
1.3.2 Objetivos específicos:.....	25
1.4 Descripción del problema.....	26
1.5 Justificación.....	28
1.5.1 Relevancia científica.....	28
1.5.2 Relevancia social.....	28
2. FUNDAMENTACIÓN TEÓRICA.....	30
2.1 Introducción al motor de inducción.....	30
2.2 Fallas y clasificación de averías en motores eléctricos de inducción.....	31
2.2.1 Fallos en rodamientos.....	31
2.2.2 Barras rotas.....	35
2.2.3 Desalineamientos.....	37
2.2.4 Fallos en engranes.....	39
2.2.5 Fallos en el aislamiento.....	40
2.2.6 Asimetrías en el bobinado del rotor.....	43
3. TÉCNICAS DE PROCESAMIENTO Y CLASIFICACIÓN DE SEÑALES PARA EL DIAGNÓSTICO DE FALLAS EN MÁQUINAS ELÉCTRICAS.....	45
3.1 Análisis en estado permanente.....	45
3.1.1 Transformada de Fourier y algoritmo transformada rápida de Fourier (FFT).....	45
3.1.2 Indicadores estadísticos y no estadísticos.....	47
3.1.3 Indicador de fallo basado en la energía DWT ().....	50
3.1.4 Fractales.....	52
3.1.5 Entropía wavelet.....	53
3.2 Análisis en estado transitorio.....	55



3.2.1 Transformada de Fourier de tiempo corto (STFT).....	59
3.2.2 Algoritmo de clasificación de señales para la estimación del contenido frecuencial de una señal en el tiempo (algoritmo MUSIC).....	60
3.2.3 Transformada wavelet.....	62
3.2.4 Transformada wavelet discreta (DWT).....	63
3.2.5 Principio de incertidumbre transformada wavelet.....	65
3.2.6 Familias wavelet madre.....	65
3.2.7 Transformada wavelet discreta inversa (IDWT).....	68
3.3 Análisis discriminante lineal.....	68
3.4 Clasificación de datos mediante redes neuronales artificiales (RNA).....	69
3.5 Detección automática del arranque del motor y estado estable.....	71
4. ANÁLISIS DEL FLUJO MAGNÉTICO DE DISPERSIÓN PARA EL MONITOREO DE LA CONDICIÓN EN MÁQUINAS ELÉCTRICAS.....	73
4.1 Sensores típicos empleados para la adquisición de señales de flujo magnético.....	74
4.1.1 Sensores de bobina para capturar flujo magnético.....	74
4.1.2 Sensor fluxgate.....	76
4.1.3 Sensores de efecto Hall.....	77
4.2 Sensor triaxial propuesto.....	77
4.3 Diseño digital de sistemas de procesado y adquisición.....	79
4.3.1 Tarjeta de adquisición.....	80
4.3.2 Tarjeta de procesado.....	82
5. METODOLOGÍA.....	85
6. RESULTADOS Y DISCUSIÓN.....	94
6.1 Aplicación de la metodología propuesta para el diagnóstico automático de asimetrías de rotor en motores de inducción de rotor bobinado.....	95
6.1.1 Motivación del caso de estudio.....	95
6.1.2 Puesta en marcha de experimentos.....	96
6.1.3 Resultados y discusión del caso de estudio.....	97
6.2 Aplicación de la metodología propuesta para el diagnóstico automático de fallo de barras rotas y desalineamiento durante el arranque del motor.....	106



6.2.1 Motivación del caso de estudio.....	106
6.2.2 Puesta en marcha de experimentos.....	107
6.2.3 Resultados y discusión del caso de estudio.....	110
6.3 Aplicación de la metodología propuesta para el diagnóstico automático de fallo gradual de pista exterior en rodamientos.....	120
6.3.1 Motivación del caso de estudio.....	120
6.3.2 Puesta en marcha de experimentos.....	123
6.3.3 Resultados y discusión del caso de estudio.....	127
6.4 Aplicación de la metodología propuesta para el diagnóstico de fallo de barras rotas en motores de arranque de corta duración.....	139
6.4.1 Motivación del caso de estudio.....	139
6.4.2 Puesta en marcha de experimentos.....	141
6.4.3 Resultados y discusión del caso de estudio.....	143
6.5 Aplicación de la metodología propuesta para el diagnóstico de desgaste gradual en cajas de engranes.....	149
6.5.1 Motivación del caso de estudio.....	149
6.5.2 Puesta en marcha de experimentos.....	150
6.5.3 Resultados y discusión del caso de estudio.....	153
6.6 Aplicación de la metodología propuesta para el diagnóstico de desgaste de herramientas de corte en máquinas CNC.....	161
6.6.1 Motivación del caso de estudio.....	161
6.6.2 Puesta en marcha de experimentos.....	163
6.6.3 Resultados y discusión del caso de estudio.....	167
7. CONCLUSIONES Y PROSPECTIVAS.....	173
Referencias.....	191



Índice de cuadros

Tabla 1: Efectos en la vida útil del aislamiento al operar bajo temperaturas elevadas (Bonnett & Soukup, 1992).....	41
Tabla 2. Indicadores estadísticos para la caracterización del comportamiento dinámico de una señal capturada en el tiempo.....	48
Tabla 3. Funciones de activación comúnmente empleadas en una red neuronal artificial..	71
Tabla 4. Matriz de pruebas para los diferentes niveles de desgaste del rodamiento.....	125
Tabla 5. Detalle de los subconjuntos seleccionados integrados al considerar combinaciones de tres indicadores estadísticos para el cómputo del puntaje de Fisher cuando el motor operaba a una frecuencia de suministro de energía de 60 Hz y 50 Hz (Zamudio-Ramirez et al., 2021).....	132
Tabla 6. Detalle de los subconjuntos seleccionados integrados al considerar combinaciones de tres indicadores estadísticos para el cómputo del puntaje de Fisher cuando el motor operaba a una frecuencia de suministro de energía de 15 Hz y 5 Hz....	133
Tabla 7. Porcentaje de efectividad de la metodología propuesta (matriz de confusión) al analizar todas las condiciones de rodamiento consideradas para una fuente de alimentación de línea directa a 60 Hz, y para una fuente de alimentación VFD de 60 Hz, 50 Hz y 15 Hz.....	137
Tabla 8. Porcentaje de efectividad de la metodología propuesta (matriz de confusión) al analizar todas las condiciones de rodamiento consideradas para una fuente de alimentación VFD de 5 Hz.....	138
Tabla 9. Valores propios resultantes, varianza individual y acumulativa para los componentes principales.....	154
Tabla 10. Matriz de confusión conseguida por la clasificación individual resultante mediante el clasificador basado en redes neuronales artificiales aquí propuesto.....	156
Tabla 11. Amplitud máxima rastreada para el armónico relacionado con la falla.....	160
Tabla 12. Bandas de frecuencia cubiertas por las señales wavelet más representativas, de acuerdo a la frecuencia de muestreo empleada de 5 kHz.....	167
Tabla 13. Porcentaje de efectividad de la metodología propuesta al analizar el flujo de dispersión axial + radial (matriz de confusión).....	172



Índice de figuras

Figura 1. Distribución de fallos en motores eléctricos con capacidad mayor a 200 hp (Petrov et al., 2017).....	18
Figura 2. Arco eléctrico en un rodamiento metálico: (a) La corriente eléctrica pasa a través de los elementos rodantes. (b) La soldadura por arco se produce entre los elementos rodantes y la pista del rodamiento. (c) El material fundido se solidifica y separa. (d) El exceso de material se elimina debido a la rotación de los elementos rodantes (Zamudio-Ramirez et al., 2021).....	33
Figura 3. Parámetros de rodamientos de bolas (autoría propia).....	34
Figura 4. Tipos de desalineamiento de eje. (a) Desalineamiento angular. (b) Desalineamiento paralelo. (c) Desalineamiento combinado (autoría propia).....	38
Figura 5. Ejemplo de uso de transformada de Fourier: (a) señal en el tiempo, (b) espectro de Fourier.....	47
Figura 6. Cálculo de los indicadores propuestos a partir de una señal capturada en el dominio del tiempo.....	50
Figura 7. Ventana rectangular considerada para calcular el valor del indicador analizando la señal wavelet (Zamudio-Ramirez et al., 2022).....	51
Figura 8. Evoluciones teóricas de los componentes amplificadas por las asimetrías del rotor durante un transitorio de arranque simulado en un motor de inducción (autoría propia).....	58
Figura 9. Transformada de Fourier de tiempo corto con superposición de ventanas sucesivas de una señal en el dominio del tiempo (autoría propia).....	60
Figura 10. Transformada MUSIC de tiempo corto con superposición de ventanas sucesivas de una señal en el dominio del tiempo (autoría propia).....	62
Figura 11. Diagrama a bloques del análisis de filtros (autoría propia).....	64
Figura 12. Diagrama a bloques de banco de filtros de 3 niveles (autoría propia).....	64
Figura 13. Resolución en tiempo y frecuencia para diferentes niveles de descomposición de transformada wavelet.....	65
Figura 14. Coeficientes de filtro para distintas familias wavelet (autoría propia).....	67
Figura 15. Diagrama de bloques transformada wavelet discreta inversa.....	68
Figura 16. Red neuronal artificial: (a) arquitectura de red neuronal feed-forward (FFNN); (b) estructura funcional de una neurona (autoría propia).....	70
Figura 17. Obtención de envolvente superior de señales en el dominio del tiempo.....	72



Figura 18. Obtención de transitorio de arranque a partir de la envolvente de la señal en el tiempo.....	72
Figura 19. Componentes del flujo magnético de dispersión: (a) flujo de dispersión radial; (b) flujo de dispersión axial (Zamudio-Ramírez et al., 2020).....	73
Figura 20. Posiciones alternativas de instalación de sensores tipo bobina para capturar las diferentes componentes del flujo magnético de dispersión en un motor de inducción (Ramirez-Nunez et al., 2018).....	75
Figura 21. Configuración básica de un sensor tipo fluxgate.....	76
Figura 22. Foto de sensor fluxgate comercial modelo DRV425 de Texas Instrument.....	77
Figura 23. Sensor de flujo magnético de dispersión triaxial propuesto: (a) sensor primario de efecto Hall; (b) composición del sensor de flujo magnético de dispersión triaxial; (c) instalación del sensor de flujo magnético de dispersión triaxial (Zamudio-Ramírez et al., 2020).....	78
Figura 24. Etapas de un sistema básico de un procesamiento digital de señales (autoría propia).....	79
Figura 25. Configuración de amplificador operacional no inversor restador,.....	81
Figura 26. Esquema 3D de la tarjeta desarrollada para el acondicionamiento y adquisición de señales del sensor de flujo de dispersión triaxial desarrollado (autoría propia).....	82
Figura 27. Principales componentes de procesador empleado para la implementación de la metodología propuesta.....	83
Figura 28. Tareas principales llevadas a cabo e implementadas a través del procesador principal basado en la plataforma raspberry pi 4 (autoría propia).....	84
Figura 29. Flujo de señal de la metodología propuesta (autoría propia).....	86
Figura 30. Obtención de envolvente superior de señal capturada en el dominio del tiempo (autoría propia).....	88
Figura 31. Obtención de transitorio de arranque a partir de la envolvente de la señal en el tiempo (autoría propia).....	88
Figura 32. División del mapa tiempo-frecuencia STFT en regiones de interés (autoría propia).....	89
Figura 33. Banco de pruebas de laboratorio: (a) osciloscopio registrador de forma de onda y motor de inducción de rotor bobinado probado; (b) reóstato externo para forzar las asimetrías; y (c) sensor de flujo magnético instalado en la posición B (Zamudio-Ramirez, Antonino-Daviu, et al., 2020).....	96



Figura 34. Análisis DWT de la señal durante el arranque del motor (señal roja) con el sensor en las tres posiciones diferentes estudiadas aquí para un motor sano (lado izquierdo) y para un motor con asimetría de rotor (lado derecho) (Zamudio-Ramirez, Antonino-Daviu, et al., 2020)..... 98

Figura 35. Análisis DWT de la señal inducida en el sensor de bobina cuando este se coloca en la posición B: (a) señal total capturada durante el arranque; (b) señal para un motor saludable; (c) señal para un motor con asimetría de rotor nivel dos; y (d) señal para un motor con asimetría de rotor nivel cuatro (Zamudio-Ramirez, Antonino-Daviu, et al., 2020)..... 99

Figura 36. Análisis STFT de las señales del sensor de bobina capturadas durante el arranque del motor para la máquina con asimetría de rotor y para las tres posiciones del sensor (el color denota la densidad de energía en cada punto del mapa de tiempo-frecuencia, el rojo indica la densidad más alta y el azul la densidad más baja) (Zamudio-Ramirez, Antonino-Daviu, et al., 2020)..... 100

Figura 37. Análisis STFT de las señales del sensor de bobina capturadas durante el arranque del motor para la máquina con asimetría de rotor nivel dos de cuatro y motor con asimetría de rotor nivel cuatro de cuatro, para las tres posiciones consideradas del sensor. El motor funciona en condición sin carga (Zamudio-Ramirez, Antonino-Daviu, et al., 2020) 101

Figura 38. Análisis STFT de las señales del sensor de bobina capturadas durante el arranque del motor para la máquina con asimetría de rotor nivel dos de cuatro y motor con asimetría de rotor nivel cuatro de cuatro, para las tres posiciones consideradas del sensor. El motor funciona en condición sin carga (Zamudio-Ramirez, Antonino-Daviu, et al., 2020). 102

Figura 39. Valores del indicador basados en la energía de la señal wavelet d8, para un motor saludable y para cada nivel de asimetría del rotor inducida (Zamudio-Ramirez, Antonino-Daviu, et al., 2020)..... 104

Figura 40. Configuración experimental: (a) banco de pruebas de motor de inducción, (b) vista lateral del banco de pruebas, (c) vista frontal del banco de pruebas (Zamudio-Ramírez et al., 2020)..... 107

Figura 41. Banco de pruebas de motores. (a) Motor alineado. (b) motor desalineado (Zamudio-Ramírez et al., 2020)..... 108

Figura 42. Banco de pruebas de motores. (a) Dos barras de rotor rotas; (b) Una barra de rotor rota (Zamudio-Ramírez et al., 2020)..... 109

Figura 43. Bandas de frecuencia consideradas para los análisis y caracterización de los mapas STFT (autoría propia)..... 110



Figura 44. Análisis de la varianza para los distintos casos de estudio procesando la información de la región 4 del mapa tiempo-frecuencia para las señales de flujo axial +radial (autoría propia)..... 112

Figura 45. Análisis de la varianza para los distintos casos de estudio procesando la información de la región 3 del mapa tiempo-frecuencia para las señales de flujo axial +radial (autoría propia)..... 113

Figura 46. Análisis de la varianza para los distintos casos de estudio procesando la información de la región 2 del mapa tiempo-frecuencia para las señales de flujo axial +radial (autoría propia)..... 114

Figura 47. Análisis de la varianza para los distintos casos de estudio procesando la información de la región 1 del mapa tiempo-frecuencia para las señales de flujo axial +radial (autoría propia)..... 115

Figura 48. Señales en el dominio del tiempo capturadas por el sensor de flujo de dispersión triaxial propuesto: (a) flujo de dispersión axial; (b) combinación del flujo de dispersión axial y radial; (c) flujo de dispersión radial (autoría propia)..... 115

Figura 49. Análisis STFT obtenidos para cada una de las fallas del motor de inducción aquí estudiadas al procesar las señales proporcionadas por el sensor triaxial de flujo dispersión al instalarlo en la posición A: (a) sensor primario 1; (b) sensor primario 2; (c) sensor primario 3 (Zamudio-Ramírez et al., 2020)..... 117

Figura 50. Resultados de clasificación de la metodología propuesta obtenidos para señales de flujo magnético de dispersión (a) Regiones de decisión resultantes modeladas por el clasificador basado en la red neuronal artificial propuesto sobre el espacio bidimensional; (b) Eficacia de clasificación (autoría propia)..... 118

Figura 51. Configuración experimental: (a) Banco de pruebas de cadena cinemática. (b) Vista lateral del banco de pruebas. (c) Vista frontal del banco de pruebas (Zamudio-Ramírez et al., 2020)..... 123

Figura 52. Rodamiento metálico modelo 6203 2RS, utilizado durante la experimentación (Zamudio-Ramírez et al., 2020)..... 125

Figura 53. Rodamientos utilizados durante los experimentos. (a) Rodamiento sano. (b) Rodamiento con daño de 1 mm en la pista exterior. (c) Rodamiento con daño de 2 mm en la pista exterior. (d) Rodamiento con daño de 3 mm en la pista exterior. (e) Rodamiento con daño de 4 mm en la pista exterior. (f) Rodamiento con daño de 5 mm en la pista exterior (Zamudio-Ramírez et al., 2020)..... 125

Figura 54. Funciones de densidad normalizadas que definen las zonas de detectabilidad obtenidas por los diferentes indicadores estadísticos y no estadísticos aquí propuestos



para los diferentes componentes del flujo de dispersión utilizando: (a) Valor medio. (b) valor RMS. (c) valor SMR. (d) valor de (Zamudio-Ramirez et al., 2021)..... 128

Figura 55. Funciones de densidad normalizadas que definen las zonas de detectabilidad obtenidas por los diferentes indicadores estadísticos y no estadísticos aquí propuestos para los diferentes componentes del flujo de dispersión utilizando: (a) valor . (b) Valor . (c) Valor CF. (d) Valor LF (Zamudio-Ramirez et al., 2021)..... 130

Figura 56. Funciones de densidad normalizadas que definen las zonas de detectabilidad obtenidas por los diferentes indicadores estadísticos y no estadísticos aquí propuestos para los diferentes componentes del flujo de dispersión utilizando: (a) valor . (b) Valor . (c) Valor . (d) Valor KFD..... 131

Figura 57. Proyección de las regiones de decisión para la clasificación de fallas múltiples calculada por el clasificador basado en la red neuronal artificial propuesta cuando el motor de inducción funciona a 60 Hz bajo un arranque directo: (a) Vista completa de la proyección. (b) Vista ampliada de la zona del rectángulo negro (Zamudio-Ramirez et al., 2021)..... 133

Figura 58. Proyección de las regiones de decisión para la clasificación de fallas múltiples calculada por el clasificador basado en la red neuronal artificial propuesto cuando el motor de inducción funciona a 60 Hz bajo un arranque empleando un variador de frecuencia: (a) Vista completa de la proyección. (b) Vista ampliada de la zona del rectángulo negro (Zamudio-Ramirez et al., 2021)..... 134

Figura 59. Proyección de las regiones de decisión para la clasificación de fallas múltiples calculada por el clasificador basado en la red neuronal artificial propuesto cuando el motor de inducción funciona a 50 Hz bajo un arranque empleando un variador de frecuencia: (a) Vista completa de la proyección. (b) Vista ampliada de la zona del rectángulo negro (Zamudio-Ramirez et al., 2021)..... 134

Figura 60. Proyección de las regiones de decisión para la clasificación de fallas múltiples calculada por el clasificador basado en la red neuronal artificial propuesto cuando el motor de inducción funciona a 15 Hz bajo un arranque empleando un variador de frecuencia: (a) Vista completa de la proyección. (b) Vista ampliada de la zona del rectángulo negro (Zamudio-Ramirez et al., 2021)..... 135

Figura 61. Proyección de las regiones de decisión para la clasificación de fallas múltiples calculada por el clasificador basado en la red neuronal artificial propuesto cuando el motor de inducción funciona a 5 Hz bajo un arranque empleando un variador de frecuencia: (a) Vista completa de la proyección. (b) Vista ampliada de la zona del rectángulo negro (Zamudio-Ramirez et al., 2021)..... 135

Figura 62. Banco de pruebas de laboratorio (motor 1)..... 141



Figura 63. Dimensiones del sensor de bobina empleado durante los experimentos del presente caso de estudio.....	141
Figura 64. Segundo motor probado durante los experimentos (motor 2): 7,5 kW, 2 pares de polos.....	142
Figura 65. Análisis MUSIC de las señales de capturadas durante el arranque del motor 1 para el sensor en las posiciones A, B y C y para las diferentes condiciones de falla, a saber, motor saludable (con desalineación inherente), motor con una barra rota y motor con dos barras rotas (Zamudio-Ramirez et al., 2020).....	144
Figura 66. Análisis MUSIC de las señales de capturadas por el sensor de bobina durante el arranque del motor 2 para el sensor en las posiciones A, B y C (Zamudio-Ramirez et al., 2020).....	145
Figura 67. Regiones consideradas en los mapas tiempo-frecuencia MUSIC para la automatización de la técnica (Zamudio-Ramirez et al., 2020).....	146
Figura 68. Cálculo de parámetros estadísticos y no estadísticos (entradas de la red neuronal artificial) para las diferentes regiones de los análisis MUSIC de las señales de flujo de dispersión capturadas para las diferentes condiciones de falla (posición B del sensor).....	147
Figura 69. Banco de pruebas de laboratorio basado en una cadena cinemática para la evaluación experimental de diferentes niveles de desgaste en los dientes de engranajes de una caja de cambios (Zamudio-Ramirez et al., 2022).....	151
Figura 70. Engranajes utilizados durante la experimentación: (a) engrane sano, (b) 25 % y (c) 75 % de desgaste uniforme de los dientes (Zamudio-Ramirez et al., 2022).....	152
Figura 71. Representación bidimensional resultante obtenida aplicando la técnica de análisis discriminante lineal a las matrices de indicadores estadísticos para todas las condiciones consideradas (Zamudio-Ramirez et al., 2022).....	154
Figura 72. Regiones de decisión resultantes modeladas por el clasificador basado en redes neuronales artificiales aquí propuesto sobre el espacio bidimensional donde se representan todas las condiciones consideradas (Zamudio-Ramirez et al., 2022).....	156
Figura 73. Análisis MUSIC de las señales de flujo magnético de dispersión capturadas durante el arranque del motor para las diferentes condiciones de falla: engranaje sano y tres condiciones de falla de desgaste uniforme en los dientes del engranaje 25%, 50% y 75% (Zamudio-Ramirez et al., 2022).....	158
Figura 74. Configuración experimental: (a) banco de pruebas de máquinas CNC, (b) vista lateral del banco de pruebas de máquinas CNC y (c) área de trabajo (Zamudio-Ramirez et al., 2022).....	163



Figura 75. Estados de desgaste de la herramienta: (a) herramienta nueva, (b) herramienta desgastada y (c) herramienta rota..... 164

Figura 76. Ciclo de torneado ejecutado durante en los ensayos experimentales.....165

Figura 77. Análisis DWT de las diferentes señales de flujo magnético de dispersión para una profundidad de corte de 1,25 mm y para los tres niveles de desgaste de la herramienta de corte analizados en este trabajo (Zamudio-Ramirez, et al., 2022)..... 168

Figura 78. Análisis FFT para la combinación de flujo de dispersión axial y radial con una profundidad de corte de 1,25 mm para: (a) herramienta nueva, (b) herramienta desgastada y (c) herramienta rota (Zamudio-Ramirez, et al., 2022)..... 169

Figura 79. Valores del indicador para cada condición de desgaste de la herramienta de corte, diversas profundidades de corte, y para cada señal de las diferentes componentes del flujo de dispersión cuando se basa en la energía de la señal wavelet . (a) Flujo de dispersión axial + radial. (b) Flujo de dispersión radial. (c) Flujo de dispersión axial (Zamudio-Ramirez, et al., 2022)..... 170



1. INTRODUCCIÓN

Los motores eléctricos son dispositivos muy importantes para muchos procesos industriales, ya que son ampliamente utilizados como impulsores primarios de la mayoría de las cargas involucradas en esas aplicaciones. Su amplio uso puede representar, en términos de consumo eléctrico, entre el 40% y el 60% del total en cualquier sitio industrial (Abd-el-Malek et al., 2017; Al Badawi et al., 2015). Existen diversos tipos de motores eléctricos con características constructivas distintas (como por ejemplo, motores de inducción tipo jaula de ardilla, motores de inducción de rotor bobinado, motores síncronos, motores síncronos de reluctancia variable, motores de imanes permanentes, entre otros); sin embargo, los motores de inducción están especialmente extendidos por su robustez, fácil mantenimiento, bajo costo y versatilidad (Amezquita-Sanchez et al., 2017). Así entonces, este tipo de motores suelen tener un amplio campo de acción en sistemas mecatrónicos al usarse en la mayoría de tareas dentro del área de producción, por ejemplo, sistemas de inyección de plástico, prensas, bandas transportadoras, plantas de tratamiento de aguas residuales, compresores, bombas, entre muchos otros. Debido a las actuales exigencias en los procesos industriales, es una prioridad mantener en funcionamiento el ciclo de producción sin interrupciones, por lo que, a su vez se convierte en un aspecto de gran relevancia contar con sistemas capaces de monitorear de forma constante el estado de los motores impulsores, que se encuentran involucrados en dichos procesos. De esta manera es posible asumir acciones de mantenimiento adecuadas, lo que evita tiempos de inactividad no programados y reduce los costos de mantenimiento. Adicionalmente, se sabe que motores con falla consumen y desperdician más energía causando costos extras al momento de facturar (García et al., 2019). Así entonces, resulta de gran relevancia estudiar las principales fallas en estos tipos de motores, y más aún generar metodologías adecuadas para el diagnóstico oportuno de las mismas, antes que se conviertan en una falla irreversible.

A pesar de sus excelentes características y elevada robustez ante una posible avería, los motores eléctricos de inducción son susceptibles a fallas. Ello es debido a que este tipo de máquinas deben operar en una gran variedad de procesos (muchos de ellos críticos en las correspondientes factorías en las que se desarrollan) y bajo condiciones que no son óptimas para su desempeño. Durante las últimas décadas se han llevado a cabo diversos estudios para determinar la ocurrencia de las diferentes fallas en motores eléctricos de inducción. En ellos se ha determinado que los fallos más comunes son aquellos que se desarrollan en los rodamientos y en los aislamientos de los devanados del estátor, seguidos por fallos en el rotor. Los porcentajes arrojados de acuerdo a una investigación llevada a cabo en motores eléctricos con capacidad mayor de 200 hp empleados en la industria y en instalaciones comerciales se muestra en la Figura 1. En esta figura, los números localizados en la parte de la derecha muestran la localización física del fallo

correspondiente a la etiqueta señalada en el lado izquierdo de la figura. Así por ejemplo, fallos en rodamientos, siendo la causa número 1 de ocurrencia de averías en motores eléctricos de acuerdo a [Petrov et al. \(2017\)](#), pueden localizarse físicamente en un motor de inducción como lo indica el lado derecho de la Figura 1.

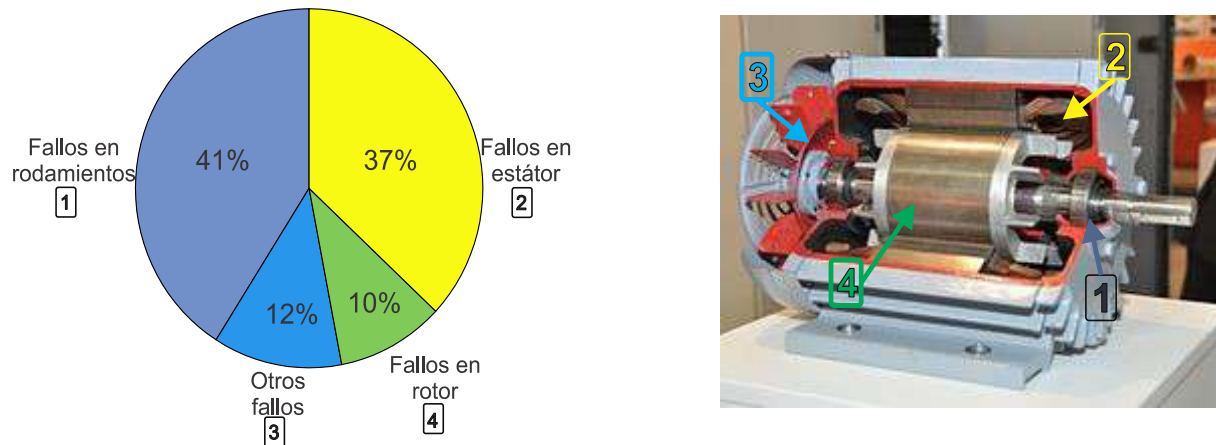


Figura 1. Distribución de fallos en motores eléctricos con capacidad mayor a 200 hp ([Petrov et al., 2017](#)).

1.1 ANTECEDENTES

Los fallos inesperados en motores eléctricos pueden causar interrupciones repentinas en procesos de producción o en servicios críticos (como lo son servicios médicos, servicios de transporte, operaciones militares) a los que se encuentren sirviendo, lo que puede generar elevados costos económicos (costo de reparación o sustitución, interrupción de la producción) como problemas de seguridad personal para el personal que se encuentre operando la máquina (por ejemplo, producción de chispas en un ambiente explosivo, paros en servicios médicos, etc.). Debido a esto, es deseable un diagnóstico oportuno de averías de máquinas de forma general, particularmente de máquinas eléctricas para generar protocolos de reparación o planificación de la sustitución con suficiente antelación, antes de que ocurra un fallo catastrófico de la máquina, causando fallas irreversibles y diversas repercusiones anteriormente mencionadas. Así entonces, esta tarea ha tomado una gran importancia especialmente en el ámbito industrial.

La detección de algunas de las fallas en motores eléctricos se ha basado principalmente en metodologías que realizan el análisis de diversas magnitudes físicas, especialmente de señales eléctricas y mecánicas, como voltajes y corrientes, y señales de vibración. En lo que respecta al análisis de señales de vibración se conocen ciertos inconvenientes



inherentes a la técnica, esto es así debido al hecho de no poder discriminar, en muchos de los casos, entre fallos de origen mecánico y de origen eléctrico o su carácter invasivo debido a la necesidad de instalación de equipamiento de medida específico (acelerómetros, etc.). Por otro lado, una de las técnicas más recurrentes es el conocido análisis espectral de la corriente de estado estable (MCSA, por su abreviatura en inglés Motor Current Signature Analysis) utilizando la transformada rápida de Fourier (FFT, por su abreviatura en inglés Fast Fourier Transform). Este método ha sido ampliamente utilizado a nivel industrial ya que ha permitido el diagnóstico de una gran variedad de averías, como lo son: roturas de barra, excentricidades, cortocircuitos en el estator, entre otras. Esta técnica basa su principio de funcionamiento en evaluar la amplitud de las componentes amplificadas debido a algún fallo, y que son muy específicas (Antonino-Daviu et al., 2018; Bessous et al., 2017; Guo et al., 2018s; Morales-Perez et al., 2018). Cuando una avería está presente en la máquina, la amplitud de sus componentes frecuenciales asociadas es magnificada en el espectro de Fourier, lo cual permite diagnosticar la presencia de alguna falla en la máquina. Así entonces, se sabe que la presencia de barras rotas provoca una distorsión en el campo magnético del entrehierro, lo cual, a su vez induce varias componentes frecuenciales muy particulares en la corriente del estator. Las dos componentes que son de mayor relevancia para el diagnóstico de este fallo se les denomina armónicos laterales y cuyas frecuencias (f_{SH} vienen dadas por la expresión (1), donde f = frecuencia de alimentación de la máquina y s = deslizamiento (Gyftakis et al., 2016).

$f_{SH} = f \cdot (1 \pm 2 \cdot s)$	(1)
--------------------------------------	-----

Así entonces, si existe este fallo en el motor, los armónicos laterales serán visibles en el espectro de Fourier al aplicar la FFT a las señales de la corriente estática en régimen permanente (Gyftakis et al., 2016).

De manera similar, la presencia de excentricidades mixtas (otra avería bastante frecuente en máquinas de inducción), provoca la aparición (en el espectro Fourier de la corriente en régimen permanente) de componentes frecuenciales (f_{ecc} dadas por la expresión (2) donde $f_r = \omega$ frecuencia de rotación del rotor, $k=1,2,3,\dots$

$$f_{ecc} = f \pm k f_r \quad (2)$$



De estas componentes asociadas con la excentricidad, las más relevantes son las que se obtienen para $k=1$, ya que son aquellas que por lo general tienen una mayor amplitud respecto a valores mayores de k .

A pesar de que este método tradicional ha sido utilizado ampliamente en la industria, se pueden citar diversos inconvenientes; por ejemplo, la aplicación de esta técnica resulta ser no adecuada si la máquina bajo análisis se encuentra operando con un bajo nivel de carga ($s \approx 0$), ya que en estas condiciones existe un solapamiento de los armónicos laterales con la componente fundamental en el espectro de Fourier, perdiéndose así el rastro de la firma de la corriente (Antonino-daviu et al., 2014). Además, otro inconveniente de este método se debe al hecho que fenómenos ajenos a la avería, tales como cargas pulsantes, tensiones de suministro oscilantes, tubos axiales de refrigeración, entre otros, pueden introducir en el espectro de Fourier componentes frecuenciales muy similares a las amplificadas por las averías (roturas de barras del rotor o incluso excentricidades mixtas) lo que conlleva a falsos diagnósticos (Choudhary et al., 2019). De manera similar, la reducción de corriente que circula por la jaula en motores de inducción de doble jaula limita el diagnóstico de ciertos casos de roturas de barras no consecutivas (Garcia et al., 2019).

Debido a los problemas e inconvenientes que presenta el método de diagnóstico tradicional, recientemente ha surgido un nuevo enfoque que propone el análisis de las magnitudes características de la máquina durante los procesos transitorios a través de los que ésta puede operar. Este enfoque transitorio se ha centrado principalmente en la corriente demandada por la máquina en régimen transitorio y, más concretamente, durante el arranque del motor, que ha sido el transitorio en cuyo análisis y estudio han ido enfocando su atención un número creciente de autores. Así entonces, en las últimas décadas se comenzó a proponer la aplicación de herramientas de descomposición tiempo-frecuencia (TFD por su abreviatura en inglés, Time-Frequency Decomposition) adecuadas para el análisis de la corriente de arranque. De esta manera, sería posible analizar el patrón o huella específica que deja la componente de fallo única (misma que depende del deslizamiento del motor). La detección de dichos patrones sería pues, un indicador fiable de la presencia de la correspondiente avería, además de muy robusto, ya que la creación de patrones similares debido a otra falla o fenómeno resulta complicada. Todas las técnicas desarrolladas forman parte de un nuevo enfoque, al que se le ha denominado Análisis Transitorio de la Firma de Corriente (TMCSA, por su abreviatura en inglés Transient Motor Current Signature Analysis).

Los resultados obtenidos al aplicar dicha herramienta han sido excelentes, permitiendo el diagnóstico de averías como roturas de barras en el rotor o excentricidades mixtas en máquinas de muy diversos tamaños (desde pocos kW hasta cientos de kW) operando en muy diversas condiciones y con distintas características constructivas (Antonino-Daviu et al., 2018; Kia, 2018; Lo et al., 2018). La herramienta proporciona buenos resultados



incluso en casos en los que el método clásico, basado en la FFT, no era adecuado, ejemplo de ello es el caso de máquinas operando en vacío o bajo condiciones que pudieran interferir o llevar a un diagnóstico erróneo (cargas pulsantes, tensiones de suministro oscilante). Inclusive, dicha técnica se ha aplicado con éxito al diagnóstico de casos en los que diversas averías se encuentran simultáneamente presentes en la máquina o combinadas con otros fenómenos que pueden dificultar el diagnóstico (Antonino-Daviu et al., 2018).

A pesar de las grandes ventajas que representa analizar señales de corriente mediante herramientas de descomposición tiempo-frecuencia, aún existen aplicaciones donde el análisis actual puede no ser concluyente, esto debido a una diversidad de causas, entre otras: amplificación de componentes frecuenciales originada por la influencia de conductos de aire axial bajo ciertas circunstancias, falsos positivos debido a oscilaciones de carga (Nemec et al., 2019), o donde su sensibilidad para la detección de algunas fallas puede ser mejorable (Ramirez-Nunez et al., 2018). Por ejemplo, algunas investigaciones actuales están orientadas a estudiar el potencial del análisis de flujo magnético de dispersión para proporcionar inmunidad a la influencia del conducto de aire axial y las oscilaciones de carga (Frosini et al., 2017). Así entonces, y de forma eventual han surgido nuevas técnicas basadas en el análisis de diferentes magnitudes físicas alternativas a las convencionales (corrientes, voltajes, vibraciones). Entre ellas se puede hacer especial mención al análisis del flujo magnético de dispersión, ya que es una técnica que ha sido retomada en los últimos años. Esto se debe principalmente a los avances en los sensores y las herramientas de procesamiento de señales empleadas para su análisis y extracción de información relevante, y que promete ser una excelente alternativa al convencional análisis de corrientes estáticas por las ventajas inherentes que el uso de ella conlleva, entre otras, confiabilidad, naturaleza no invasiva (el sensor no requiere conexión alguna con la máquina bajo análisis), una espectacular reducción en los costes de sensores necesarios, volúmenes reducidos, alta precisión en la adquisición de datos y una fácil portabilidad. La idea principal del análisis del flujo magnético de dispersión alrededor de la máquina se basa en el hecho que la máquina eléctrica produce un flujo magnético de manera inherente debido a la naturaleza de su construcción, además este flujo está vinculado al estado magnético de la máquina y, por lo tanto, puede verse afectado por la presencia de una falla en la misma. Así entonces, los métodos de detección de fallas que utilizan el análisis del campo magnético externo se basan en la propiedad de que cualquier falla cambia el campo magnético en las inmediaciones de la máquina (Romary et al., 2013).

Diversas investigaciones han demostrado que la efectividad del análisis del flujo magnético, medido a partir de sensores adecuados para la detección de diversas fallas en motores eléctricos es elevada. Con respecto a las fallas del rotor, Romary et al., (2013) demostraron que los componentes en $s \cdot f$ (donde $f = \omega$ frecuencia de alimentación y $s = \omega_r$ deslizamiento) medidas en el campo axial son particularmente sensibles a la presencia de daños en el rotor. Este último componente se debe a la variación de la velocidad angular



en $2 \cdot s \cdot f$ causada por la presencia de barras rotas (Ceban et al., 2012; Romary et al., 2013). El monitoreo de las amplitudes de estos componentes en el espectro FFT del campo magnético externo (especialmente, en la dirección axial) es una opción interesante para detectar daños en el rotor. Sin embargo, los valores de baja frecuencia de estos componentes hacen necesario generar tiempos de adquisición largos, de modo que el análisis FFT pueda distinguirlos correctamente (Ceban et al., 2012; Romary et al., 2013). Algunos autores como Verucchi et al. (2016) han determinado que la presencia de desalineaciones aumenta las amplitudes de los componentes en $f \pm f_r$, (donde $f_r = \dot{\omega}$ frecuencia de rotación del rotor) en el espectro de la corriente del estator. Otros autores como Ishkova et al. (2016) afirman que las excentricidades mixtas conducen a la amplificación de frecuencias similares en el espectro FFT del flujo en estado estable. Esas frecuencias (f_{ecc} vienen dadas por la expresión (3) (p = número de par de polos de la máquina, $m=1,2,3,\dots$

$$f_{ecc} = f \cdot \left(1 \pm \frac{m(1-s)}{p} \right) \quad (3)$$

Extrapolando la idea del análisis transitorio de las corrientes estáticas al caso del análisis de señales de flujo magnético ha propiciado la expansión del uso de esta técnica para el estudio de diferentes averías en motores de inducción como lo son barras rotas, espiras en cortocircuito en el devanado del estator, excentricidad estática y dinámica del rotor y fallas en los cojinetes (Frosini et al., 2015, 2017; Panagiotou et al., 2018, 2019; Ramirez-Nunez et al., 2018; Romary et al., 2013) En todos estos trabajos es primordial la tarea de procesamiento de señal mediante herramientas de descomposición tiempo-frecuencia. Las técnicas mayormente empleadas para este estudio son la transformada wavelet discreta (DWT, por su abreviatura en inglés Discrete Wavelet Transform) y la transformada de Fourier de tiempo corto (STFT, por su abreviatura en inglés Short-Time Fourier Transform). Sin embargo, como es bien sabido, la señal monitoreada presenta características no estacionarias, lo cual provoca disturbios en los resultados al analizarla con estas herramientas (Rivera-Guillen et al., 2018). Se han propuesto algunos trabajos para optimizar el análisis de la señal mediante herramientas de descomposición para señales no estacionarias y no lineales como el presentado por Wu et al., (2018), donde se emplea el método de descomposición de modo empírico (EMD, por su abreviatura en inglés Empirical Mode Decomposition) el cual es intuitivo, no supervisado y autoadaptivo que puede descomponer una señal no estacionaria y no lineal en componentes oscilatorios de banda estrecha llamados funciones de modo intrínseco (IMF, por su abreviatura en inglés Intrinsic Mode Function). Por su parte Lu et al., (2018); Singru et al., (2018) presentan



trabajos en el que emplean un análisis espectral de alta resolución a través del algoritmo de clasificación de señales múltiples (MUSIC, por su abreviatura en inglés MULTiple Signal Classification) y del método de distribución Wigner-Ville, respectivamente para identificar diversas fallas en motores de inducción. Sin embargo, a pesar de las aplicaciones potenciales, la mayoría de los trabajos relacionados con herramientas de descomposición para señales no estacionarias requieren de una computadora personal (PC) aplicado al procesamiento de la señal fuera de línea, y esto se debe a la complejidad de la técnica, así como a su alta carga computacional. De esta manera, algunos autores como [Camarena-Martinez et al., \(2014a\)](#) proponen el empleo de dispositivos de lógica programable como lo es un arreglo de compuertas programable en campo (FPGA, por su abreviatura en inglés Field Programmable Gate Array) para llevar a cabo el procesamiento de señal implementando algoritmos de análisis de señales no estacionarias mediante hardware y, de esta manera diagnosticar fallas de barras rotas en motores de inducción empleando un acelerómetro, demostrando así el potencial que el empleo de estos dispositivos tiene en la tarea de diagnóstico de fallas en máquinas eléctricas.

Como se ha visto en la recopilación de los antecedentes, se han desarrollado diversas herramientas para la detección de fallas en motores eléctricos. Las metodologías desarrolladas para obtener un diagnóstico pertinente han venido mejorando en los últimos años, de tal manera que se han propuesto diferentes variables de detección para dichos fines, cada una sujeta a sus ventajas y desventajas. Así, por ejemplo, el análisis de señales de vibración se sabe que no es capaz de discriminar, en muchos de los casos, entre fallos de origen mecánico y de origen eléctrico. Por su parte, el análisis de corrientes, siendo la metodología que mayormente se ha empleado, especialmente en el campo de la industria sigue presentando algunos inconvenientes, a pesar del uso y desarrollo de técnicas avanzadas de procesamiento de señal como lo son las herramientas de descomposición en tiempo-frecuencia para su análisis, ya que, por ejemplo, la influencia del conducto de aire axial y las oscilaciones de carga pueden generar falsos diagnósticos. Es así, como técnicas emergentes y de reciente creación han sido el foco de atención de diversos investigadores, enfatizando el análisis de señales de flujo magnético, que representa una excelente alternativa a metodologías convencionales debido a las ventajas inherentes que el empleo de esta conlleva, entre otras, confiabilidad, naturaleza no invasiva, una espectacular reducción en los costes de sensores necesarios, volúmenes reducidos, alta precisión en la adquisición de datos, y una fácil portabilidad. Todo ello aunado al avance de los procesadores digitales empleados para manipular dichas señales, mismos que han sido mejorados en las últimas décadas, permiten la implementación de técnicas complejas que requieren una elevada carga computacional. Sin embargo, a pesar de los grandes avances que se tienen en el campo del diagnóstico de fallas en máquinas eléctricas, aún quedan cuestiones por abordar entre otras, es necesario y de gran trascendencia contar con técnicas y metodologías novedosas capaces de generar un diagnóstico oportuno, confiable y de forma automática enfatizando que algunas fallas



pueden convertirse en catastróficas e irreversibles en un corto periodo de tiempo. De la misma manera, es de suma importancia extender este enfoque a otras máquinas rotativas que emplean motores eléctricos como principales impulsores (como máquinas CNC) y condiciones de operación a fin de generalizar el uso de esta herramienta a nivel industrial, además, existe la necesidad de desarrollar estructuras digitales que combinen varias metodologías de procesamiento para dar soluciones en línea a problemas complejos como lo es la detección de fallas en motores eléctricos, es decir, para combinar el análisis de descomposición en tiempo-frecuencia de señales no estacionarias, extraer características esenciales, y clasificar de manera automática las fallas. Así también, es deseable contar con sensores que sean capaces de capturar las diversas componentes del flujo magnético de dispersión desde un mismo punto en la carcasa de la máquina bajo análisis, esto debido a que resulta complicado (bajo términos prácticos) instalar tres sensores de forma simultánea, puesto que no siempre se tiene el acceso a las diferentes posiciones de instalación requeridas. El presente trabajo de investigación desarrolla una metodología innovadora, capaz de generar un diagnóstico adecuado y de forma automática de la ocurrencia de las fallas más comunes que suelen ocurrir en los motores eléctricos de inducción bajo diversas condiciones de operación mediante el análisis del flujo magnético de dispersión. Para ello se emplean herramientas de descomposición en tiempo-frecuencia, herramientas de clasificación de datos y parámetros de caracterización de señales, además se realiza una optimización de los parámetros de estas herramientas a fin de proporcionar generalidad y flexibilidad a la metodología que se aborda en la presente tesis. Así entonces, se prueba la validez de técnicas basadas en el análisis del flujo magnético de dispersión para el diagnóstico de fallas electromecánicas como lo son: barras de rotor rotas, desalineamientos, desgaste gradual de pista exterior en rodamientos de bolas, desgaste uniforme gradual en engranes, entre otros. Los motores analizados son arrancados mediante variador de frecuencia y mediante arranque directo. El trabajo va más allá de la aplicación de técnicas convencionales, basadas en el análisis de datos de flujo en régimen permanente, profundizando en la aplicación de técnicas modernas basadas en análisis transitorio. Por otra parte, se presenta el desarrollo de un sistema en chip portable, económico y muy flexible mediante el cual se efectúa la metodología propuesta en un computador de placa única empleando el lenguaje de programación C. Este sistema en chip portable consiste de una tarjeta de adquisición de señales y un procesador digital que permite realizar operaciones in-situ sobre las señales de flujo magnético de dispersión capturadas. Las arquitecturas desarrolladas son propietarias e implementan las herramientas y técnicas requeridas para ejecutar operaciones de diagnóstico de forma permanente siguiendo la metodología de diagnóstico automático aquí propuesta.



1.2 Hipótesis

A partir del análisis de señales de flujo magnético disperso alrededor de la máquina es posible diagnosticar de manera oportuna la ocurrencia de las averías más comunes en motores de inducción a través de técnicas de procesamiento de señal empleando herramientas de descomposición tiempo-frecuencia y su implementación en un procesador digital.

1.3 OBJETIVOS

1.3.1 Objetivo general:

Desarrollar e implementar una metodología para el diagnóstico de las fallas electromecánicas más comunes en motores eléctricos de inducción (fallas en el estator, fallas en rodamientos, fallas en el rotor) mediante el análisis del flujo magnético de dispersión alrededor de la máquina, tanto durante el transitorio de arranque como en régimen permanente, empleando herramientas matemáticas de descomposición tiempo-frecuencia, y técnicas de clasificación de datos y su implementación en hardware.

1.3.2 Objetivos específicos:

- Documentar las técnicas mayormente empleadas basadas en análisis del flujo magnético de dispersión, haciendo especial énfasis en aquellas basadas en un análisis transitorio mediante lo reportado en la literatura para establecer el enfoque del estudio.
- Determinar la técnica de análisis más idónea a utilizar en el contexto de la presente tesis haciendo especial énfasis en la automatización de la misma.
- Realización de ensayos experimentales para la extensión de la metodología:
 - Extensión a máquinas con otras características constructivas (distinto número de polos, potencia, etc.).
 - Extensión a otras averías (fallos en rodamientos, fallas incipientes en los aislamientos)
- Generar una base de datos con las señales experimentales obtenidas para su posterior análisis mediante técnicas avanzadas de procesamiento de señal.
- Analizar, en base a los resultados, la viabilidad de la técnica para su extensión a otras averías, máquinas, o condiciones.



- Determinar los valores más adecuados para los parámetros que definen las transformadas a utilizar mediante una gran variedad de ensayos empleando la base de datos generada.
- Generar una estructura de red neuronal artificial que mejor se adapte a los fines de la presente tesis con el objetivo de reducir los requisitos computacionales sin afectar su rendimiento para automatizar el diagnóstico final mediante técnicas de teoría de la información como información mutua.
- Desarrollar e implementar los algoritmos de la metodología propuesta mediante un lenguaje de programación en C para su utilización en un procesador de tarjeta única.
- Realizar pruebas de la metodología propuesta en señales seleccionadas, primeramente, a partir de un banco de datos para posteriormente validar la funcionalidad de éstas en máquinas eléctricas de laboratorio y la industria.

1.4 Descripción del problema

Como se muestra en la literatura revisada, es necesario desarrollar una metodología novedosa capaz de diagnosticar las fallas electromecánicas más comunes que se presentan en motores eléctricos de forma oportuna y deseablemente de forma automática y en línea, ya que, en la mayoría de estos fallos el motor continúa operando aparentemente de forma normal, sin embargo, pueden surgir problemas secundarios, que no son visibles a la vista, tales como: gasto energético mayor, las fallas pueden desarrollarse hasta convertirse en un problema irreversible causando gastos económicos elevados, se dañan los mecanismos que se encuentran acoplados al motor (provocando que se detenga el proceso al cual se halla sirviendo), todo ello sin mencionar que se puede poner en riesgo al operario del equipo cuando el motor trabaja de forma anormal. Así mismo, a pesar de los esfuerzos que en las últimas décadas han llevado a cabo los investigadores en el área, aún queda una importante labor pendiente en lo que respecta a la generalización, optimización y automatización de las técnicas ya desarrolladas. La extensión de estos enfoques a otras máquinas diferentes al motor de inducción convencional (como lo son máquinas CNC) y condiciones de operación, la optimización detallada de las herramientas empleadas, así como la automatización de la aplicación de estas técnicas son cuestiones que siguen pendientes de llevarse a cabo y que se han abordado con éxito en la presente tesis mediante el empleo de señales de flujo magnético de dispersión. Se ha demostrado que lecturas de flujo magnético de dispersión representa una excelente alternativa para solucionar problemas de falsos diagnósticos presentes en metodologías convencionales que emplean lecturas de corriente.



De acuerdo a la recopilación de antecedentes, la mayoría de los trabajos reportados requieren de un cierto tiempo de ejecución para realizar el diagnóstico del estado del motor, esto dependiendo de la metodología propuesta, y en ciertos casos la valoración debe ser llevada a cabo por un experto de acuerdo a su experiencia, sin embargo, diversos fallos, como problemas en el sistema del aislamiento eléctrico suelen ocurrir en cortos periodos de tiempo convirtiéndose en una falla irreversible en cuestión de minutos.

La mayoría de las metodologías existentes para realizar el diagnóstico de averías en motores de inducción se basan principalmente en el análisis de señales de corriente, que como se ha reportado en la literatura técnica, tienen el inconveniente de arrojar resultados erróneos bajo ciertas condiciones de operación.

En términos prácticos, es deseable contar con un sensor novedoso, de bajo costo, de tamaño reducido que sea capaz de capturar las diversas componentes del flujo magnético de dispersión desde una misma posición sobre la carcasa del motor bajo análisis.

La mayoría de las metodologías desarrolladas para el diagnóstico de fallas en motores eléctricos, y que son basadas en el análisis de flujo magnético de dispersión emplean técnicas convencionales como la FFT. Sin embargo, debido a problemas intrínsecos de dicha técnica como sensibilidad a la baja relación señal-ruido, superposición de componentes espectrales muy cercanos, no apto para señales no estacionarias, chorreo espectral y pérdida de información relacionada con el tiempo, es necesario el análisis de señales de flujo magnético de dispersión mediante herramientas avanzadas de procesamiento de señales que mitiguen dichos problemas.



1.5 Justificación

1.5.1 Relevancia científica

Debido a que los motores eléctricos de inducción son dispositivos ampliamente utilizados a nivel industrial, estos operan por lo general de manera continua bajo diversas condiciones ambientales y de trabajo, razón por la cual suelen presentar diferentes fallas, tales como: fallos en el estator, fallos en el rotor, fallos en rodamientos, fallos en los aislamientos, entre otros. Los motores que presentan estas fallas suelen operar aparentemente de forma normal, sin embargo, la falla puede provocar un daño irreversible, esto sin mencionar que sistemas y mecanismos acoplados al motor pueden verse afectados además de causar costos y pérdidas económicas que ascienden a cantidades elevadas de dinero. Entonces, es de suma importancia contar con un sistema capaz de diagnosticar de forma automática y oportuna este tipo de fallos.

La mayoría de metodologías propuestas para el diagnóstico de fallas en motores eléctricos y que se basan en el análisis de señales de flujo magnético de dispersión emplean sensores del tipo bobina, por lo que resulta ser poco práctico este tipo de sensores para capturar las diferentes componentes magnéticas del flujo de dispersión, ya que algunas de las ocasiones no se tiene acceso a ciertas zonas de la periferia del motor, o el espacio disponible es muy reducido. Por lo anterior, es necesario el desarrollo de un sensor triaxial que sea capaz de capturar las diversas componentes del flujo magnético de dispersión desde un mismo punto en la carcasa del motor.

Es bien sabido que el empleo de procesadores electrónicos que permiten realizar operaciones en un corto periodo de tiempo, proporciona una excelente alternativa para la ejecución en tareas complejas, mejorando así los tiempos de respuesta, que se vuelve un factor importante en cuanto a detección de fallas se trata. Más aún, este tipo de dispositivos permiten generar sistemas en chip económicos, portables y muy flexibles capaces de ser empleados bajo diversos ambientes de trabajo permitiendo generar un dispositivo electrónico capaz de ejecutar tareas específicas, como lo es el procesamiento de señales.

En este trabajo se aplicarán herramientas y técnicas de análisis avanzado para el tratamiento de señales de flujo magnético de dispersión, y así explotar las características del mismo para la detección y discriminación de fallos en motores eléctricos.

1.5.2 Relevancia social

El desarrollo de la metodología propuesta permite llevar una detección temprana de forma automática de las fallas más comunes que suelen ocurrir en motores eléctricos de inducción, mismos que son ampliamente utilizados en diferentes ámbitos de la sociedad y



a nivel industrial. Una detección temprana de las fallas en motores eléctricos permite generar un mantenimiento adecuado, impactando directamente en la eficiencia de los mismos, ya que un motor que opera bajo alguna falla reducirá su eficiencia y consumirá mayor energía. Al generar una metodología automática de diagnóstico oportuno se puede reducir los tiempos en los cuales el motor opera bajo la influencia de alguna falla, generando así un menor consumo de energía al programar mantenimientos de forma prematura y adecuada. Otro aspecto de gran relevancia, es la reducción de la huella de emisión de dióxido de carbono que se puede lograr como consecuencia de operar un motor siempre bajo niveles óptimos de eficiencia, y sin la influencia de alguna falla.



2. FUNDAMENTACIÓN TEÓRICA.

2.1 Introducción al motor de inducción

Los motores eléctricos son dispositivos que han sido de gran relevancia para impulsar las cadenas cinemáticas involucradas en muchos procesos de diversos sectores (cementero, petroquímico, papelerero, siderúrgico, textil, alimentación, automotriz...), accionando cargas muy diversas (bombas, compresores, ventiladores, soplantes, molinos, etc...) y operando bajo condiciones de funcionamiento muy variadas. Así entonces, en una sola planta industrial puede haber cientos o incluso miles de estas máquinas, cuyo correcto funcionamiento es primordial para garantizar la continuidad de los procesos y la seguridad de máquinas y usuarios. Este tipo de máquinas resultan imprescindibles en otras aplicaciones, como las centrales de generación o en aplicaciones del sector terciario. Además, los motores eléctricos gozan de un protagonismo creciente en algunas aplicaciones que son cruciales para el desarrollo sostenible de las sociedades modernas, como son la generación de energías renovables o los vehículos eléctricos. Dentro de los motores eléctricos industriales, los que más han extendido su uso son los motores asíncronos o motores de inducción y, concretamente, los motores de jaula de ardilla. Estas son máquinas muy robustas, de construcción más simple y, en general, resultan más económicas que otras alternativas. Es por ello que más del 90% de motores eléctricos industriales son máquinas pertenecientes a esta tipología.

Además de los motores tipo jaula de ardilla, dentro de los motores asíncronos, se tienen también los motores de rotor bobinado. Se trata de máquinas que presentan algunas ventajas interesantes, como la posibilidad de acceso al devanado del rotor para la medida de corrientes o para insertar resistencias externas durante el arranque, lo cual permite la modificación de la curva par-velocidad, obteniendo elevados pares de arranque. La posibilidad de inserción de reóstatos externos en estas máquinas también permite la atenuación del pico de corriente demandado por las mismas durante el citado arranque. A pesar de estas interesantes ventajas, que las hacen especialmente interesantes en algunas aplicaciones industriales en las que se requieren pares de arranque elevados (por ejemplo, sector cementero), estas máquinas tienen también notables inconvenientes, fundamentalmente ligados a los problemas de mantenimiento que presenta el sistema de anillos rozantes-escobillas que permite intercalar las resistencias externas, así como al mayor costo y complejidad constructiva que presentan en comparación con las máquinas de rotor de jaula. Otro grupo relevante dentro de los motores eléctricos industriales es el de los motores síncronos. Estas máquinas son mucho menos utilizadas en la modalidad de funcionamiento como motor, en comparación con las máquinas asíncronas. Entre otras razones cabe apuntar la necesidad de sistemas auxiliares que permitan el arranque de las



mismas (arranque mediante motor auxiliar, arranque mediante variador de frecuencia, arranque a través de devanado amortiguador), mayores problemas de mantenimiento (necesidad de sistemas de anillos rozantes-escobillas para alimentar la excitación en algunas variantes), así como mayor costo y complejidad constructiva. Sin embargo, en el rango de potencias muy elevadas, algunas de sus ventajas (mayor rendimiento, posibilidad de regulación del factor de potencia) pueden compensar con creces sus inconvenientes. Es por ello que no resulta extraño encontrar algunos motores síncronos en aplicaciones de potencia muy elevada (>1MW) siendo, por otro lado, máquinas críticas en dichas aplicaciones. En la actualidad, el uso de este tipo de máquinas se está extrapolando en aplicaciones de potencias más bajas, debido fundamentalmente a los mayores rendimientos que presentan, factor que resulta de gran interés en el contexto actual de preocupación por la mejora de la eficiencia energética de procesos industriales.

Debido al uso tan extendido de los motores eléctricos en el ámbito industrial y, en concreto, de los motores asíncronos, su mantenimiento resulta capital. En este sentido, averías repentinas en dichas máquinas pueden acarrear consecuencias nefastas para las empresas (paradas no planificadas de la producción, costos de reparación e inspección, peligro para la seguridad de usuarios y procesos, etc...). Hay que tener en cuenta que estos motores son muchas veces máquinas críticas en aquellos procesos en los que operan, habiéndose reportado pérdidas de hasta varios millones de euros por día como consecuencia de averías intempestivas en algunas de estas máquinas.

2.2 Fallas y clasificación de averías en motores eléctricos de inducción

En esta sección se describen los fallos más comunes que suelen ocurrir en los motores eléctricos rotativos. Debido al gran empleo de los motores de inducción, se pondrá mayor énfasis a este tipo de máquinas. Así entonces, mediante esta sección se dará detalle de las causas más comunes de estos fallos, así como sus repercusiones.

2.2.1 Fallos en rodamientos.

Las fallas en los rodamientos (cojinetes) es una de las averías que suelen ocurrir de manera más frecuente en los motores de inducción. De acuerdo a lo reportado en la literatura, se ha demostrado que la mayoría de las fallas de los motores eléctricos se pueden atribuir a los cojinetes y devanados, siendo hasta aproximadamente el 69 % de la



tasa total de fallas relacionadas con los cojinetes, dependiendo del tipo y tamaño del motor (Bonnert et al., 2008). Unas de las principales causas que pueden desencadenar fallas en los rodamientos son aquellas relacionadas a cargas excesivas, lubricación insuficiente, contaminación externa, instalación incorrecta y arco eléctrico, entre otras (SKF, 2017). Esta situación puede conducir a un rendimiento inaceptable y vibraciones indeseables con una falla inminente a largo plazo, o defectos de componentes individuales, como el elemento rodante, la pista interior y la pista exterior si se trata de rodamientos de bolas. Además, la presencia de fallas en etapas tempranas puede provocar interrupciones inesperadas y pérdidas de producción (Frosini, 2020). Adicionalmente, otra de las principales causas que pueden provocar que un rodamiento sufra daños es debido a excentricidades excesivas. Este tipo de excentricidades tienen diferentes orígenes, pero dentro de los que se han reportado con mayor frecuencia son aquellas debidas a montajes deficientes, rotor o estator deformados, y fuerzas desequilibradas debidas a empuje magnético desequilibrado (UMP, por sus siglas en inglés Unbalance Magnetic Pull) (Guo et al., 2003; Salah et al., 2019). Asimismo, de acuerdo con Oliver et al. (2015), las fallas en la pista exterior son una de las causas más comunes de fallas en los rodamientos, mismas que se pueden convertir en daños irreversibles derivado de arcos eléctricos generados por corrientes parásitas, y que recientemente se ha incrementado la ocurrencia de estas fallas desde la llegada de los variadores de frecuencia (VFD por sus siglas en inglés, Variable Frequency Drive).

2.2.1.1 Fallos en rodamientos debidos a arcos eléctricos en motores eléctricos.

Como se mencionó en el párrafo anterior, las fallas más comunes relacionadas con los rodamientos se deben generalmente a una excesiva carga, lubricación insuficiente, contaminación externa, instalación incorrecta y por descargas eléctricas. Esto último se ha considerado un tema crítico que puede dar lugar a la aparición de averías de mayor gravedad en los rodamientos (Plazenet et al., 2018). Esto se debe principalmente al elevado empleo de variadores de frecuencia para alimentar motores eléctricos de inducción, y de esta manera tener un control sobre la velocidad de operación de este. Así entonces, fallos de rodamientos por descargas eléctricas tiene su origen debido a la presencia de arco eléctrico en los elementos de apoyo de los rodamientos metálicos. Un fenómeno producido por la fuga de corriente, que genera un micro desgaste de las superficies rodantes (Oliver et al., 2015). Esta fuga de corriente puede generar pequeños cráteres en las superficies de apoyo (pistas de rodadura exteriores y/o interiores) a medida que la fuga de corriente viaja a través de los elementos rodantes (bolas de rodamiento) desde la pista exterior hasta la pista interior, como se muestra en la Figura 2a. Esta fuga de corriente puede producir un proceso de soldadura por arco si se genera en una pequeña superficie de contacto caracterizado por la presencia de altas temperaturas como

se muestra en la Figura 2b. En consecuencia, como el material es calentado, puede alcanzar temperaturas de fusión en las que el material derretido puede eliminarse fácilmente y removido debido a la rotación de los elementos rodantes (bolas de rodamiento), ver Figura 2c, d. Como consecuencia, los cráteres producidos en la pista exterior del rodamiento pueden conducir a la generación de superficies de contacto irregulares, provocando un impacto cada vez que los elementos de apoyo pasan a través de ellos.




Figura 2. Arco eléctrico en un rodamiento metálico: (a) La corriente eléctrica pasa a través de los elementos rodantes. (b) La soldadura por arco se produce entre los elementos rodantes y la pista del rodamiento. (c) El material fundido se solidifica y separa. (d) El exceso de material se elimina debido a la rotación de los elementos rodantes (Zamudio-Ramirez et al., 2021).

Así entonces, como se reporta en la literatura, se sabe que los defectos de los rodamientos generan impactos mecánicos producidos por los elementos rodantes sobre la pista del rodamiento. Cuando aparece un defecto superficial en un elemento de apoyo, las fuerzas de impacto, que se manifiestan en la señal de vibración del motor, suelen ser periódicas para cuando la velocidad del eje es constante. Por lo tanto, se produce una interacción periódica entre las pistas y los elementos rodantes. Si la carga del rodamiento es radial, un análisis de frecuencia de la señal de vibración radial destaca una modulación de amplitud, donde el portador es cualquier resonancia mecánica, y la señal de modulación es la frecuencia característica mecánica de la falla en específico (Bellini et al., 2008).

Para el caso particular cuando el defecto del rodamiento se encuentra en la pista exterior, provocará un impulso cada vez que los elementos rodantes contacten con la irregularidad, induciendo un efecto de modulación, que en ocasiones se puede observar en las señales de vibración (Trajin et al., 2010). Esta modulación da lugar a frecuencias características relacionadas con la frecuencia de rotación del rotor (f_r) y la geometría del cojinete, y para el caso de fallas en la pista exterior estas frecuencias (f_{BPOF}) vienen dadas por (3).

$$f_{BPOF} = \frac{f_r}{2} \cdot N_b \cdot \left(1 + \frac{D_B}{D_C} \cos(\beta) \right) \quad (3)$$

donde D_C es el diámetro de la jaula, medido desde el centro de la bola hasta el centro de la bola opuesta, D_B es el diámetro de la bola, N_b es el número de bolas y β es el ángulo de contacto entre las superficies de apoyo, como se puede apreciar en la Figura 3.




Figura 3. Parámetros de rodamientos de bolas (autoría propia).

El efecto de la componente de vibración sobre las señales de corriente de alimentación estática ha sido vinculado y modelado de acuerdo con dos enfoques principales. Por un lado, se considera que la componente vibratoria en una de las frecuencias características de la falla actúa sobre la máquina eléctrica como un rizado de par que, a su vez, produce un rizado en la velocidad. En consecuencia, la vibración se refleja en la corriente como un grupo de componentes frecuenciales laterales (f_{BE}) de la frecuencia de la fuente de alimentación (f_s), cuya frecuencia viene dada por (4) (Bellini, et al., 2008):



$$f_{BE} = f_s \pm k \cdot f_{BPOF} \quad (4)$$

donde k es un entero positivo.

Por otra parte, el efecto de la componente vibratoria sobre las señales de corriente de alimentación estática se ha modelado como una excentricidad estática, que provoca la amplificación de las frecuencias f_{BE} .

2.2.2 Barras rotas

La rotura de barras de rotor es una de las fallas más comunes en los motores eléctricos de inducción tipo jaula de ardilla, especialmente en motores de elevada potencia. Se sabe que los motores eléctricos de este tipo pueden sufrir diferentes fuerzas electromagnéticas y térmicas durante su operación continua debido a diversas causas, pero dentro de las más comunes se tienen fluctuaciones en la carga, arranques directos, entre otras. Este tipo de esfuerzos propicia la aparición de averías en las barras del rotor, mismas que son susceptibles de fallos irreversibles. Este tipo de fallas será dependiente del tipo de construcción del bobinado, de la aplicación del motor, ciclo de operación, geometría del bobinado, materiales de construcción, y particularmente al régimen de arranque directo (Thomson et al., 2016). Por ello es que se pueden distinguir diversas causas que pueden llevar a que las barras puedan sufrir un daño, entre otros: esfuerzos mecánicos, esfuerzos térmicos, combinación de esfuerzos mecánicos y térmicos, como se discute a continuación:

- Esfuerzos mecánicos: Este tipo de esfuerzos resultan de las fuerzas centrífugas causadas durante la operación normal del motor y alcanza su máxima amplitud en el radio de rotación más largo (Thomson et al., 2016). Las dos fuerzas principales que se desarrollan durante el arranque del motor son, por un lado, aquellas relacionadas a fuerzas centrífugas en el rotor y los anillos terminales de las secciones del núcleo del rotor sobre las barras, y por otro lado aquellas relacionadas a fuerzas de reacción, que mantienen las barras en su lugar.
- Esfuerzos térmicos: Este tipo de esfuerzos se desarrollan debido al calor generado en las bobinas del rotor, especialmente se acentúan en cada arranque cuando el motor es operado directamente de la línea ya que una cantidad significativa de calor es producida. La cantidad de calor generada, y así el máximo alcanzado dependerá entre otras cuestiones, de la diferencia encontrada entre las curvas torque-velocidad del motor y de la carga, y de la combinación inercial entre el rotor del



motor y la carga impulsada. Así entonces, entre mayor sea el tiempo en que el motor alcanza el estado estable, mayor será la temperatura alcanzada durante este transitorio (Thomson et al., 2016). La distribución de pérdida de calor de la barra del rotor no uniforme da como resultado una distribución de aumento de temperatura no uniforme asociada, siendo el aumento de temperatura en la parte superior de la barra mayor que en la parte inferior de la barra. Por lo tanto, durante la aceleración, esta distribución de temperatura no uniforme puede dar lugar a un “arqueamiento de la barra” fuera de las ranuras del rotor debido a la expansión térmica diferencial (Thomson et al., 2016). Sin embargo, a medida que el rotor se acelera, la frecuencia de deslizamiento ($f_2 = s \cdot f$) de la corriente del rotor cae y, finalmente, la corriente en las barras se distribuye uniformemente a las velocidades normales de funcionamiento. Los arranques repetitivos durante un período corto de tiempo pueden producir temperaturas excesivas en el devanado del rotor en motores que se usan en sistemas de transmisión de alta inercia, ya que no se habrá disipado todo el calor generado durante los primeros arranques. Por lo tanto, la temperatura del devanado del rotor puede seguir siendo alta desde el primer arranque, cuando el segundo arranque provoca un aumento adicional de la temperatura. Así entonces, si se realizan arranques repetidos, el calentamiento acumulativo del rotor puede conducir a temperaturas de bobinado del rotor indeseablemente altas. Tales problemas de sobrecalentamiento del devanado del rotor son mucho más probables en motores que arrancan directamente mediante equipos accionados por alta inercia (Thomson et al., 2016).

- Combinación de esfuerzos mecánicos y eléctricos. Cada vez que se arranca un motor, las tensiones mecánicas y térmicas actúan en combinación para producir tensiones mecánicas mucho más altas que las que producirían individualmente. Los efectos de estos esfuerzos combinados pueden volverse más serios si se realizan arranques repetitivos sin permitir suficiente tiempo para que el devanado del rotor se enfríe entre cada arranque. Tales tensiones pueden hacer que tanto las barras del rotor como los anillos terminales se agrieten y finalmente fallen (Thomson et al., 2016).

Así entonces, cuando ocurre una rotura de barra, debido a cualquiera de las causas anteriormente descritas, se produce una distorsión en el campo del entrehierro (Antonino-Daviu et al., 2006). Como resultado, cuando existe un daño en el rotor, se pierde la simetría de la máquina, y de acuerdo con el Teorema de Fortescue (Fortescue, 1918), además del campo que gira en el sentido de las agujas del reloj, se produce un campo magnético de rotación inversa debido a las corrientes del rotor desequilibradas, que dan lugar a una componente de frecuencia localizada en $-s \cdot f$. Posteriormente, esta secuencia



inversa se refleja en el lado del estator produciendo el conocido armónico de banda lateral inferior (LSH por su abreviatura en inglés, Lower Side-band Harmonic), dando lugar a la amplificación de la componente frecuencial (f_{LSH}) de fallo dada por (5):

$$f_{LSH} = (1 - 2 \cdot s) \cdot f \quad (5)$$

Esta variación de corriente cíclica implica una oscilación de velocidad y una pulsación de par al doble de la frecuencia de deslizamiento ($2 \cdot s \cdot f_s$). Esta oscilación de velocidad induce, en el devanado del estator, una componente superior en $f_{USH} = (1 + 2 \cdot s) \cdot f_s$. Brevemente, las barras rotas del rotor inducen en el devanado del estator componentes adicionales a frecuencias f_{ksr} dadas por la expresión (6):

$$f_{ksr} = (1 \pm 2 \cdot k \cdot s) \cdot f \quad (6)$$
$$k = 0, 1, 2, \dots$$

2.2.3 Desalineamientos

Durante el proceso de transmisión de potencia entre el motor y la carga impulsada se pueden generar problemas debidos a desalineamientos. Se pueden distinguir dos tipos de desalineamientos: angular (ver Figura 4a), y paralelo (como se muestra en la Figura 4b), este último también conocido como desalineamiento radial; adicionalmente, se puede dar el caso en que ambos desalineamientos se encuentren presentes de forma simultánea, como se muestra en la Figura 4c. La desalineación angular ocurre cuando hay una desviación angular entre el eje del motor y la carga. Esta situación se ilustra en la Figura 4a. El grado de desalineación está representado por el ángulo α entre los dos ejes. Cuando los ejes están perfectamente paralelos entre sí, pero no en la misma línea, se produce una desalineación paralela. Esta situación se puede observar en la Figura 4b. La desalineación radial es más grave cuanto mayor es la distancia entre los dos ejes de rotación. Dicha distancia se indica como d en la Figura 4b.




Figura 4. Tipos de desalineamiento de eje. (a) Desalineamiento angular. (b) Desalineamiento paralelo. (c) Desalineamiento combinado (autoría propia).

Dependiendo de su tipo, el fenómeno de desalineación puede producir y/o aumentar vibraciones a diferentes frecuencias. En particular, la desalineación angular provoca vibraciones en la frecuencia de rotación ($1x$) y su segundo armónico ($2x$). Sin embargo, esto depende en gran medida del tipo de acoplamiento (Piotrowski et al., 1989). Para máquinas accionadas por motores eléctricos, la desalineación muestra tener influencia en el espectro de corriente del estator, ya que afecta el comportamiento dinámico del motor (Bossio et al., 2009). Esto produce en consecuencia un aumento en la amplitud de las componentes que están asociadas a la excentricidad estática y dinámica del entrehierro (Obaid et al., 2003). Tanto la excentricidad dinámica del entrehierro como el desbalance y desalineamiento mecánico del rotor producen componentes en el espectro de corriente a frecuencias f_{DES} dadas por la expresión (7), lo que permite detectar estos fenómenos. Sin embargo, dado que todos ellos producen componentes similares, su diagnóstico sigue siendo difícil.

$$f_{DES} = f \pm n \cdot f_r \quad (7)$$



donde n es un número entero, y f_r es la frecuencia de rotación del eje.

2.2.4 Fallos en engranes

Las cajas de engranajes se han utilizado ampliamente en muchas aplicaciones de diferentes campos a nivel industrial para la transmisión de potencia y par en maquinaria rotativa. Diferentes campos de la industria se han beneficiado del excelente desempeño que estos dispositivos mecánicos ofrecen, entre muchos otros: industria aeroespacial, de trabajo pesado, turbinas eólicas, máquinas herramienta en industrias manufactureras (Praveenkumar et al., 2017; Salameh et al., 2018). Recientemente, se han utilizado masivamente como sistemas de transmisión en vehículos eléctricos, mismos que han tenido un auge espectacular en los últimos años (Praveenkumar et al., 2017). Su alta eficiencia de transmisión y su fuerte capacidad de carga explican su uso generalizado. Durante su vida útil, los reductores mediante cajas de engranajes están sometidos a esfuerzos constantes que provocan un desgaste inminente y gradual del engranaje dentado. Esta situación puede conducir a un rendimiento inaceptable, vibraciones indeseables y mucho ruido. Además, la presencia de fallas incipientes puede provocar interrupciones inesperadas y pérdidas de producción (Azamfar et al., 2020).

Las vibraciones mecánicas de la maquinaria rotatoria con engranajes son inherentes a su funcionamiento ya que son creadas por el juego o la excitación de las fuerzas dinámicas inducidas cuando los dientes del engranaje hacen contacto (Saucedo-Dorantes et al., 2016). De esta forma, a mayor juego mecánico, se espera que la amplitud de la vibración sea mayor, produciendo que se amplifique una frecuencia de impacto denominada frecuencia de malla (f_{malla}), y frecuencias relacionadas con la malla ($f_{Gr1malla}$) que se pueden observar en el espectro de vibración y torque. Estas frecuencias pueden ser estimadas de acuerdo a la ecuación (8) (Kuang et al., 2003).

$$\begin{aligned} f_{malla} &= N_{r1} \cdot f_{r1} = N_{r2} \cdot f_{r2} \\ f_{Gr1malla} &= N_{r1} \cdot f_{r1} \pm f_{r1} \end{aligned} \quad (8)$$

donde N_{r1} y N_{r2} son el número de dientes del engranaje de entrada y salida, respectivamente, y f_{r1} y f_{r2} son la frecuencia de rotación de entrada y salida, respectivamente.

Cuando se presenta un fallo en la caja de engranes, que puede ser producido por una irregularidad en el diente del engranaje (es decir, diente roto o diente fracturado), se



espera una influencia en el par de carga y un aumento de la vibración (Kar et al., 2006). Además, en el trabajo presentado por Kia et al., (2007) se muestra que, en presencia de fallas en la caja de engranajes, cualquier vibración torsional en el rotor introducirá familias de armónicos de bandas laterales provocadas ya sea por la rotación del engranaje de entrada (f_{Gr1}), la rotación del engranaje de salida (f_{Gr2}), o la variación de rigidez del contacto de los dientes del engranaje (f_{Gmalla}). Además, la combinación de componentes asociados a los engranajes de entrada y salida, f_{Gr1} y f_{Gr2} también pueden aparecer produciendo la amplificación de sus armónicos relacionados ($f_{Gr1-Gr2}$). De forma similar, la aparición de componentes de frecuencia característicos que son asociados con el engranaje de entrada y la frecuencia de malla ($f_{Gr1-malla}$), y aquellos relacionados con el engranaje de salida y la frecuencia de malla ($f_{Gr1-Gr2-malla}$) pueden ser amplificados. Tales armónicos de bandas laterales se pueden observar alrededor de la frecuencia de alimentación (f_s) de la corriente del estator, y su ubicación frecuencial está dada por las ecuaciones (9) a (15):

$$f_{Gr1} = f_s \pm m \cdot f_{r1} \quad (9)$$

$$f_{Gr2} = f_s \pm n \cdot f_{r2} \quad (10)$$

$$f_{Gmalla} = f_s \pm p \cdot f_{mesh} \quad (11)$$

$$f_{Gr1-r2} = f_s \pm m \cdot f_{r1} \pm n \cdot f_{r2} \quad (12)$$

$$f_{Gr1-malla} = f_s \pm m \cdot f_{r1} \pm p \cdot f_{malla} \quad (13)$$

$$f_{Gr2-malla} = f_s \pm n \cdot f_{r2} \pm p \cdot f_{malla} \quad (14)$$

$$f_{Gr1-r2-malla} = f_s \pm m \cdot f_{r1} \pm n \cdot f_{r2} \pm p \cdot f_{malla} \quad (15)$$

donde m , n y p representan un número entero positivo que puede tomar valores iguales a 1,2,3,... y que permite calcular los armónicos correspondientes de las componentes fundamentales f_{Gr1} , f_{Gr2} y f_{malla} , respectivamente, en un espectro de frecuencia.

2.2.5 Fallos en el aislamiento.



Diversas investigaciones han mostrado que aproximadamente entre 30% y 40% de fallos en motores de inducción son producidos debido a problemas relacionados al aislamiento (Donnell et al., 1987). Aunque el modo de falla final puede ser la ruptura eléctrica de un componente dieléctrico, el mecanismo subyacente que provoca la ruptura puede ser debido esencialmente a 4 tipos de esfuerzos: térmico, eléctrico, mecánico, y ambientales (Bonnett et al., 1992; Siddique et al., 2005). Eventualmente, dichos esfuerzos debilitarán tanto el aislamiento que se perforará y el conductor se conectará a tierra.

1. Esfuerzos térmicos:

Una de las causas principales y conocidas que originan una aceleración en el deterioro de los aislamientos es provocada por aumentos en la temperatura de operación del motor. Estos aumentos originan que el proceso de envejecimiento sea más rápido y, por lo tanto, se reduzca la vida útil del aislamiento de una manera significativa. De forma general, un aumento en 10 °C en la temperatura de operación del motor disminuye la vida del aislamiento hasta por un 50 %. En condiciones normales de funcionamiento, el proceso de envejecimiento en sí mismo no causa una falla, pero hace que el aislamiento sea más vulnerable a otras tensiones, que luego producen el fallo real. Otro esfuerzo térmico que tiene un efecto negativo en la vida útil del aislamiento es la sobrecarga térmica, que ocurre debido a variaciones de voltaje, voltajes de fase desequilibrados, sobrecarga, ventilación obstruida o temperatura ambiente. Como regla de pulgar, la temperatura en la fase con la corriente más alta aumentará en un 25 % por un desequilibrio de voltaje de 3.5 % por fase. La Tabla 1 muestra los efectos en la vida útil del aislamiento cuando éste opera bajo temperaturas ambientales mayores de 40 ° C (Bonnett et al., 1992).

Tabla 1: Efectos en la vida útil del aislamiento al operar bajo temperaturas elevadas (Bonnett & Soukup, 1992).

Temperatura ambiente ° C	Horas de vida útil del aislamiento
30°	250000
40°	125000
50°	60000
60°	30000



2. Esfuerzos eléctricos:

Existen diferentes razones por las cuales las tensiones eléctricas conducen a la falla del aislamiento del estátor. Estos generalmente se pueden dañar debido a problemas con el material dieléctrico, por efectos corona y voltajes transitorios a los que está expuesta una máquina de esta índole. El tipo de material dieléctrico que se utiliza para el aislamiento fase a tierra, fase a fase y espira a espira, así como los esfuerzos debidos a tensiones aplicadas a los materiales aislantes, influyen significativamente en la vida útil del aislamiento. Otro de los agentes causantes del deterioro del aislamiento y que se ha observado recientemente es debido a stados transitorios de suministro eléctrico en la máquina. Estos transitorios pueden incluso causar fallas de espira a tierra. Las principales causas que originan estos transitorios se deben a fallas en el suministro de energía, ya sea por fusibles limitadores de corriente, transferencia rápida de bus, apertura y cierre de interruptores automáticos, conmutación de capacitores, entre otros. Recientemente, con la utilización de variadores de frecuencia, se ha observado una elevada cantidad de fallas en los aislamientos debido a los permanentes transitorios que estos generan, situación que se ve influenciada por el uso de convertidores electrónicos, que causan nuevos esfuerzos sobre dicho aislamiento, derivados de las elevadas velocidades de conmutación de los semiconductores de potencia y pulsaciones de alta frecuencia. Adicionalmente, durante el proceso de arranque y parada pueden ocurrir transitorios de alta tensión ([Bonnett et al., 1992](#)).

3. Esfuerzos mecánicos:

Las principales causas de fallas de aislamiento debido a esfuerzos mecánicos son el movimiento de la bobina y los golpes del rotor. La fuerza sobre las bobinas es proporcional al cuadrado de la corriente del motor y alcanza su valor máximo durante el arranque del motor. Esta fuerza hace que las bobinas se muevan y vibren. El movimiento de las bobinas puede causar daños severos al aislamiento de la bobina o al conductor. Existen diferentes motivos que provocan que el rotor golpee al estátor, siendo las más comunes fallas en los cojinetes, deflexión del eje y desalineación del rotor ([Bonnett et al., 1992](#)).

4. Esfuerzos ambientales:



Los esfuerzos ambientales son ocasionados principalmente por la presencia de materiales contaminantes ajenos que reducen las capacidades de disipación de calor, producen fallas prematuras en los rodamientos e inclusive rupturas en el aislamiento al causar cortocircuitos. Es por esta razón que este tipo de máquinas se deben de mantener en condiciones limpias y permanecer secos tanto internamente como externamente en la medida de lo posible, todo ello para evitar la influencia de químicos y partículas ajenas sobre las condiciones del aislamiento (Bonnett et al., 1992).

2.2.6 Asimetrías en el bobinado del rotor.

Cuando el motor de inducción de rotor bobinado se encuentra en condiciones óptimas de operación, es decir, sin ninguna falla, las impedancias del estator y del rotor están idealmente distribuidas simétricamente y las corrientes están balanceadas. En este caso particular, el sistema de corriente trifásica equilibrada produce un campo magnético giratorio fundamental en el sentido de las agujas del reloj en el entrehierro del motor. Este campo induce una corriente en el devanado del rotor con una frecuencia proporcional al deslizamiento del rotor. Así entonces, el devanado del rotor genera un campo en el sentido de las agujas del reloj que gira a una frecuencia equivalente a $f \cdot s$. Sin embargo, cuando existe un daño en el rotor, se pierde la simetría de la máquina, y de acuerdo con el Teorema de Fortescue (Fortescue, 1918), además del campo que gira en el sentido de las agujas del reloj, se produce un campo magnético de rotación inversa debido a las corrientes del rotor desequilibradas, que dan lugar a una componente de frecuencia localizada en $-s \cdot f$. Posteriormente, esta secuencia inversa se refleja en el lado del estator produciendo el conocido armónico de banda lateral inferior (LSH por su abreviatura en inglés, Lower Side-band Harmonic), dando lugar a la componente frecuencial de fallo dada por (16):

$$f_{LSH} = (1 - 2 \cdot s) \cdot f \quad (16)$$

Como se reporta en algunas investigaciones (Ceban et al., 2012; Gritli et al., 2013), es posible asociar a este campo antihorario un sistema de corriente de secuencia negativa con amplitud I_{ccw} , el cual se suma al sistema de corriente de secuencia positiva con amplitud I_{cc} , provocando un par pulsante y una oscilación de velocidad (Ceban et al., 2012). Además, es bien sabido que esta oscilación de velocidad también genera una componente adicional de densidad de flujo en el entrehierro, denominada armónico de



banda lateral superior (USH por su abreviatura en inglés, Upper Side-band Harmonic) y cuya frecuencia característica viene dada por la ecuación (17) (Alberto et al., 2000).

$$(1+2 \cdot s) \cdot f \quad (17)$$

Como consecuencia, en el espectro de las corrientes estáticas aparece un conjunto de nuevas componentes frecuenciales f_{ksr} , que pueden ser estimadas mediante la ecuación (18):

$$f_{ksr} = (1 \pm 2 \cdot k \cdot s) \cdot f \quad (18)$$
$$k = 0, 1, 2, \dots$$

Adicionalmente, aparece un conjunto de nuevas componentes frecuenciales f_{krr} en el espectro de corrientes del rotor, mismas que se reflejan en el campo magnético externo (Filippetti et al., 1998; Gritli et al., 2013; Romary et al., 2013). Estas frecuencias pueden ser estimadas de acuerdo a la ecuación (19).

$$f_{krr} = \pm (1 + 2 \cdot k) \cdot s \cdot f \quad (19)$$

Conjuntamente de estos armónicos relacionados con fallas de asimetría en el rotor, Vedreño, (2013) demuestra que mediante la ecuación (20) es posible estimar los componentes de frecuencia amplificados en las corrientes del rotor causadas por la asimetría del rotor.

$$f_{asym} = \left[\frac{k}{p} \cdot (1 - s) \pm s \right] \cdot f \quad (20)$$



3. TÉCNICAS DE PROCESAMIENTO Y CLASIFICACIÓN DE SEÑALES PARA EL DIAGNÓSTICO DE FALLAS EN MÁQUINAS ELÉCTRICAS

Como se revisó en secciones anteriores, cuando un motor eléctrico de inducción se encuentra operando bajo una falla específica, diversas magnitudes electromecánicas relacionadas a sus condiciones naturales de operación pueden verse alteradas, tales como corrientes, vibraciones, ruido, torque, entre otras. Así entonces, un adecuado análisis de estas magnitudes físicas puede ayudar a diagnosticar la presencia de la falla correspondiente. En este sentido, las diferentes técnicas que se han desarrollado y reportado en la literatura durante las últimas décadas se basan en el análisis, y extracción de información relevante a partir cantidades específicas de la máquina. El empleo de técnicas de procesamiento de señales ha permitido llevar a cabo esta tarea con excelentes resultados ya que permite extraer características relacionadas con el comportamiento dinámico de la señal capturada. En este contexto, se pueden distinguir dos enfoques principales de procesamiento de señales para el diagnóstico de fallas en máquinas eléctricas: 1) análisis de estado estable mediante el uso convencional de la transformada rápida de Fourier (FFT), así como indicadores estadísticos y no estadísticos, y 2) diagnóstico basado en transitorios mediante la aplicación de herramientas matemáticas de descomposición de tiempo-frecuencia (TFD, por su abreviatura en inglés Time-Frequency Decomposition).

3.1 Análisis en estado permanente

3.1.1 Transformada de Fourier y algoritmo transformada rápida de Fourier (FFT)

La transformada de Fourier (FT por su abreviatura en inglés Fourier Transform) es una herramienta matemática que descompone una función del tiempo (una señal) en las frecuencias que lo integran. La transformada de Fourier de una función del tiempo se



expresa matemáticamente mediante la ecuación (21) y se denomina representación del dominio de frecuencia de la señal original. Concretamente, esto significa que cualquier sistema lineal invariable en el tiempo, tal como un filtro aplicado a una señal, se puede expresar de forma relativamente simple como una operación en frecuencias.

$$x(f) = \int_{-\infty}^{\infty} x(t) * e^{-2j\pi f(t)} dt \quad (21)$$

Donde: $t = \hat{i}$ tiempo, $f = \hat{i}$ frecuencia, $x = \hat{i}$ Señal en función del tiempo, $j = \hat{i}$ parte imaginaria de un número complejo.

Para realizar el cálculo de la transformada de Fourier en un dominio discreto, se emplea la transformada Discreta de Fourier (DFT, Discrete Fourier Transform por sus siglas en inglés). La DFT toma una secuencia de datos N muestreados de una señal y calcula el contenido de frecuencia de ésta representando estos datos en el dominio de la frecuencia de forma discreta $X[k]$ al multiplicar la señal en tiempo discreto $x[n]$ por el kernel de multiplicación. La DFT para señales en tiempo discreto se representa matemáticamente mediante la ecuación (22).

$$X[k] = \sum_0^{N-1} x[n] e^{\frac{j2\pi}{N}kn}, 0 \leq k \leq N-1 \quad (22)$$

Donde j indica la parte imaginaria de un número complejo.

Para visualizar un ejemplo de la interpretación del cálculo del espectro de Fourier de una señal en función del tiempo, la Figura 5a muestra la señal $x(t) = \cos(2\pi * 5t) + \cos(2\pi * 10t) + \cos(2\pi * 20t) + \cos(2\pi * 50t)$ y su descomposición en las frecuencias que la integran (Figura 5b), es decir 5 Hz, 10 Hz, 20 Hz, y 50 Hz a través de la transformada rápida de Fourier. En dicha figura se puede observar que las amplitudes de las frecuencias que integran la señal son significativas y son las únicas representativas. Por otro lado, debido a que la señal tratada en este ejemplo es del tipo estacionaria, es decir sus componentes frecuenciales no cambian con el tiempo, el espectro de Fourier es ideal y solo aparecen las componentes esperadas, sin embargo, la transformada de Fourier aplicada a señales no estacionarias permite extraer las componentes frecuenciales

presente en la señal, pero no indica el tiempo de aparición de cada una de ellas, es decir, se pierde la información temporal.

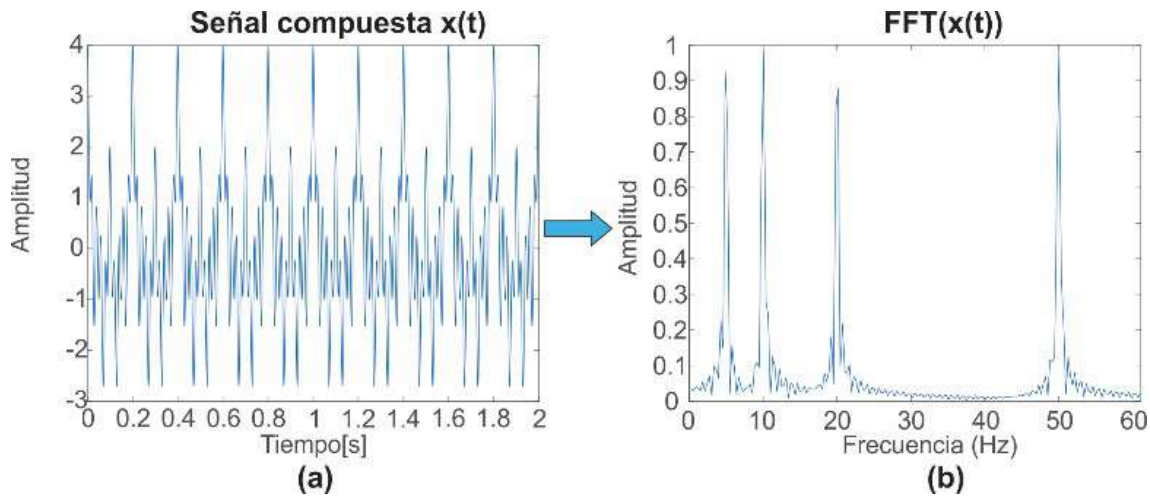


Figura 5. Ejemplo de uso de transformada de Fourier: (a) señal en el tiempo, (b) espectro de Fourier.

3.1.2 Indicadores estadísticos y no estadísticos.

El objetivo principal de los indicadores estadísticos en el dominio del tiempo es obtener información relevante sobre el comportamiento de un sistema por medio de una señal capturada en el tiempo. Dado que un sistema con diferentes condiciones de operación tiene señales con parámetros estadísticos variados, se espera que un estado de falla se vea reflejado en dichas características o indicadores (Caesarendra et al., 2017). En este sentido, la idea principal de emplear y extraer indicadores y características de cualquier magnitud física (adquirida a partir de un sistema bajo estudio) para la detección de fallas en el mismo es obtener parámetros que puedan reflejar correctamente la condición de trabajo del sistema y, en consecuencia, identificar sus patrones de falla (Huerta-Rosales et al., 2021). Los índices estadísticos en el dominio del tiempo como la media, la raíz cuadrada media (RMS), la desviación estándar, la variación, el factor de impulso, el factor de forma, entre otros, se han utilizado con éxito para el diagnóstico de fallas en motores de inducción (Caesarendra et al., 2017; Mao et al., 2019; Saucedo-Dorantes et al., 2018). Las ecuaciones que describen cada uno de estos indicadores, y que son empleados en la presente tesis se encuentran descritas en la Tabla 2. Estos indicadores son elegidos por sus diversas ventajas que presentan, mismas que han permitido su proliferación para esquemas de diagnóstico destinados al diagnóstico en línea y su implementación en hardware (Huerta-Rosales et al., 2021), entre otras: la baja carga de cómputo y los



recursos de memoria mínimos utilizados para calcularlos, la capacidad de extraer información sobre tendencias generales y su simplicidad.

Con el fin de mantener solo los indicadores más representativos, es decir, aquellos que más significado tienen sobre los resultados, y minimizar los problemas de redundancia, se realiza una etapa de preprocesamiento posterior mediante la aplicación de técnicas como la puntuación de Fisher. Este método puede interpretarse como una medida relativa que representa la distancia entre diferentes clases y la dispersión entre puntos de datos pertenecientes a cada clase. De esta manera, un puntaje de Fisher (FS por su abreviatura en inglés Fischer Score) pequeño implica una capacidad discriminatoria deficiente, mientras que un puntaje de Fisher más alto vincula una mejor característica discriminatoria. Considerando esto, la selección de características se realiza bajo un enfoque combinatorio donde los puntajes de Fisher se obtienen al realizar combinaciones entre todas las características estadísticas disponibles. Por lo tanto, las capacidades de discriminación se evalúan considerando diferentes subconjuntos de características. Luego, después de evaluar la puntuación de Fisher de cada subconjunto de características estadísticas, el primer subconjunto clasificado se considera el más relevante y discriminatorio. El FS^j de la función j está dado por (23) (Huerta-Rosales et al., 2021).

$$FS^j = \frac{\sum_{i=1}^c n_i (\mu_i^j - \mu^j)^2}{\sum_{i=1}^c n_i (\sigma_i^j)^2} \quad (23)$$

donde μ_i^j , σ_i^j , y n_i son la media, la desviación estándar y el tamaño de la i -ésima clase c de la j -ésima función, respectivamente, μ_j es la media de todo el conjunto de datos de la j -ésima función.

Tabla 2. Indicadores estadísticos para la caracterización del comportamiento dinámico de una señal capturada en el tiempo.

Indicador	Ecuación matemática
Media aritmética	$T_1 = \frac{1}{N} \cdot \sum_{i=1}^N x_i $ (24)
Valor máximo	$T_2 = \max(x)$ (25)

Media cuadrática	$T_3 = \sqrt{\frac{1}{N} \cdot \sum_{i=1}^N (x_i)^2}$	(26)
Raíz cuadrada media	$T_4 = \left(\frac{1}{N} \cdot \sum_{i=1}^N \sqrt{ x_i } \right)^2$	(27)
Desviación estándar	$T_5 = \sqrt{\frac{1}{N} \cdot \sum_{i=1}^N (x_i - T_1)^2}$	(28)
Varianza	$T_6 = \frac{1}{N} \cdot \sum_{i=1}^n (x_i - T_1)^2$	(29)
Factor de forma RMS	$T_7 = \frac{T_3}{\frac{1}{N} \cdot \sum_{i=1}^N x_i }$	(30)
Factor de forma SRM	$T_8 = \frac{T_4}{\frac{1}{N} \cdot \sum_{i=1}^N x_i }$	(31)
Factor cresta	$T_9 = \frac{T_2}{T_3}$	(32)
Factor de latitud	$T_{10} = \frac{T_2}{T_4}$	(33)
Factor de impulso	$T_{11} = \frac{T_2}{\frac{1}{N} \cdot \sum_{i=1}^N x_i }$	(34)
Oblicuidad	$T_{12} = \frac{\sum [(x_i - T_1)^3]}{T_5^3}$	(35)
Curtosis	$T_{13} = \frac{\sum [(x_i - T_1)^4]}{T_5^4}$	(36)
Quinto momento	$T_{14} = \frac{\sum [(x_i - T_1)^5]}{T_5^5}$	(37)
Sexto momento	$T_{15} = \frac{\sum [(x_i - T_1)^6]}{T_5^6}$	(38)

La Figura 6 muestra un ejemplo de la forma de obtener los indicadores aquí propuestos. Como se puede observar, se trata de una señal capturada en el tiempo, en la que es necesario generar ventanas cuadradas deslizantes con o sin superposición entre ventanas. El tamaño de la ventana es previamente seleccionado; sin embargo, para los fines de este trabajo de investigación se emplea un tamaño de ventana de 1s, con el fin de evitar lo más posible procesar disturbios en la señal capturada. Finalmente, por cada ventana de puntos se calcula cada uno de los indicadores aquí propuestos calculando las expresiones (24) a (38).

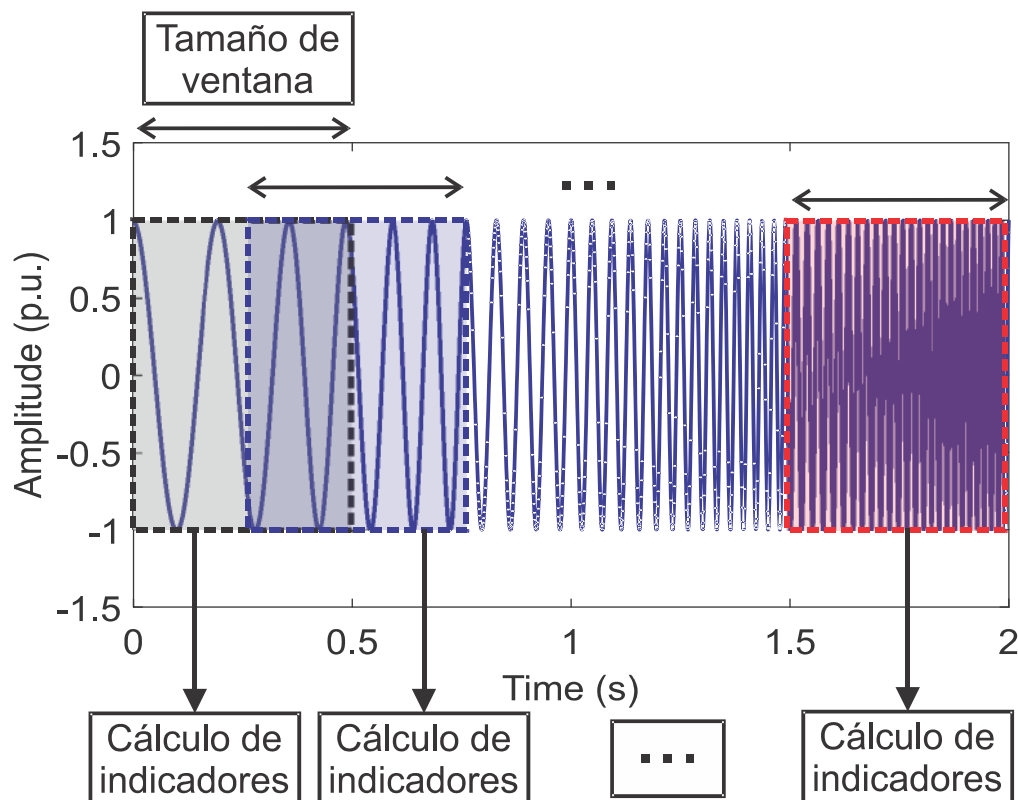


Figura 6. Cálculo de los indicadores propuestos a partir de una señal capturada en el dominio del tiempo.

3.1.3 Indicador de fallo basado en la energía DWT (γ_{DWT}).

La energía basada en la transformada wavelet discreta (γ_{DWT}), es un indicador normalizado que proporciona una idea general de los cambios de energía en una señal dada. Este indicador ha sido ampliamente aplicado con gran éxito al diagnóstico de fallas en motores eléctricos debido a su alta capacidad para evaluar la energía de una banda de frecuencia



específica. Este indicador es adecuado para medir las amplitudes en una banda de frecuencia limitada en la que aparece una componente de falla, y su uso está basado en el hecho que energías de la componente wavelet que contiene la banda de frecuencia donde aparece el fallo aumentan a medida que la severidad de la falla estudiada se agrava, y para el caso en que se analiza una señal capturada en el dominio del tiempo a partir de una magnitud física (como corrientes, sonido, vibraciones, etc.) relaciona esta señal (capturada por el sensor correspondiente) con el de la señal wavelet que contiene la mayor parte de la componente de frecuencia de falla (d_n). Este indicador ha sido sugerido en trabajos previos para la detección de algunas fallas en motores eléctricos como problemas en el rotor (Riera-Guasp et al., 2008), y se adapta aquí para los propósitos de este trabajo de tesis. Este indicador normalizado viene dado por la ecuación (39) (donde N_b es la posición de la primera muestra a considerar y N_s es la última muestra que cubre el intervalo de tiempo considerado).

Dado que este indicador requiere el análisis de los datos derivados de una ventana rectangular extraída de las bandas de frecuencia DWT, se recomienda una ventana de tiempo de 1 s como tamaño mínimo para reducir el efecto del ruido de procesamiento producido por fuentes externas. La Figura 7 muestra un ejemplo de una ventana de tiempo considerada para los análisis de una señal wavelet d_5 para calcular el índice γ_{DWT} .

$$\gamma_{DWT}(dB) = 10 \cdot \log \left[\frac{\sum_{j=N_b}^{N_s} \phi_j^2}{\sum_{j=N_b}^{N_s} [d_n(j)]^2} \right] \quad (39)$$




Figura 7. Ventana rectangular considerada para calcular el valor del indicador γ_{DWT} analizando la señal wavelet d_5 (Zamudio-Ramirez et al., 2022).



3.1.4 Fractales.

El análisis de dimensión fractal (FD por sus siglas en inglés, Fractal Dimension) es un concepto de la teoría del caos, que intenta medir la cantidad de autosimilitud o patrones repetidos que están presentes en una señal (Amezquita-Sanchez et al., 2017). La caracterización fractal puede ser especialmente útil para analizar y comparar formas de onda complejas (Katz, 1988). De esta forma, un análisis de dimensión fractal puede usarse para evaluar la consistencia de una señal en el dominio del tiempo, lo que implica inherentemente que dicho análisis puede arrojar información relacionada con las variaciones que modifican la regularidad de una señal. Por lo tanto, extrapolando estas ideas para el caso de fallas en motores eléctricos, se espera una alteración en la señal medida debido a una falla (aumento de amplitud de las frecuencias relacionadas con la falla o características transitorias en la señal medida), que puede variar según la gravedad del daño, dicho cambio puede caracterizarse por un índice fractal. Las dimensiones fractales de una señal en el dominio del tiempo pueden oscilar entre 1.0 para líneas rectas y 2.0 según la complejidad y la autosimilitud (Katz, 1988). De acuerdo a lo reportado en la literatura, existen diferentes implementaciones de la dimensión fractal, dentro de las más comunes se encuentran la dimensión fractal de Katz (Katz, 1988), la dimensión fractal de Higuchi (Higuchi, 1988), y la dimensión fractal de caja (Wang, 2005). Debido a sus excelentes características, su fácil implementación, y sus bajos recursos computacionales requeridos para calcularlo, la dimensión fractal de Katz resulta ser óptimo para implementarse en procesadores para esquemas de cálculo en línea. Así entonces, la dimensión fractal de Katz mide la fractalidad de una señal de serie temporal x por medio de la distancia euclidiana de puntos de datos sucesivos.

El procedimiento matemático para obtener la dimensión fractal de Katz es el siguiente:

1. Encontrar la distancia euclidiana máxima d entre la primera muestra x_1 y la muestra x_k (para $k=1, \dots, N$), donde N representa el número de muestras total de la señal en el dominio del tiempo x .
2. Obtener la suma aritmética de las distancias euclidianas (L) entre muestras sucesivas de la señal en el dominio del tiempo x , para posteriormente calcular su promedio (a) de acuerdo a la ecuación (40).

$$L = \sum_{k=2}^N \text{distancia}(x_k - x_{k-1}) \quad (40)$$



$$a = \frac{L}{N - 1}$$

3. Calcular la dimensión fractal de Katz, KFD, de la señal de la serie en el dominio del tiempo de acuerdo con la ecuación (41).

$$KFD = \frac{\log\left(\frac{L}{a}\right)}{\log\left(\frac{d}{a}\right)} \quad (41)$$

3.1.5 Entropía wavelet.

Debido al principio de incertidumbre inherente en algunas transformaciones tiempo-frecuencia, aparece una limitación crítica cuando se aplica una ventana específica a una serie de datos, como en el caso de la transformada wavelet; si la ventana es demasiado estrecha, la resolución de la frecuencia será pobre; por lo contrario, si la ventana es demasiado ancha, la localización del tiempo será menos precisa. Esta limitación se vuelve un punto crítico y de gran relevancia cuando la señal bajo análisis tiene componentes transitorios localizados en el tiempo, como los componentes en la mayoría de señales reales (Rosso et al., 2001).

Para superar estas limitaciones, se ha definido un parámetro basado en la entropía de una señal a partir de una representación tiempo-frecuencia de la misma proporcionada por la transformada wavelet (Quiroga et al., 2001). La transformada wavelet discreta ortogonal no hace suposiciones sobre estacionariedad de señales y la única entrada necesaria es la serie temporal. En este caso, la evolución temporal de los patrones de frecuencia puede seguirse con una resolución óptima de tiempo-frecuencia. Por lo tanto, mientras que la entropía basada en la transformada wavelet refleja el grado de orden / desorden de la señal, puede proporcionar información adicional sobre el proceso dinámico subyacente asociado con la señal (Rosso et al., 2001). La entropía wavelet se ha empleado satisfactoriamente en diferentes campos de investigación teniendo una gran variedad de aplicaciones, incluyendo aquellas relacionadas al análisis de señales eléctricas del cerebro (Siket et al., 2017). Esto se logra combinando la información de todas las bandas de información wavelet, ya que los datos entre señales de ondículas adyacentes se toman y combinan en un índice para evitar enfocarse en una sola banda wavelet que tiene su



propia resolución de tiempo-frecuencia. La entropía wavelet total (S_{WT}) se encuentra definida por la ecuación (42) (Blanco et al., 1998).

$$S_{WT} \equiv S_{WT}(p) = - \sum_{i=m}^n p_i \ln(p_i) \quad (42)$$

donde m y n son el primer y último nivel de descomposición wavelet considerados para el análisis, respectivamente, y p_i representa los valores normalizados de energía de onda relativa, que se pueden calcular de acuerdo a la ecuación (43):

$$p_i = \frac{E_i}{E_{tot}} \quad (43)$$

donde E_i y E_{tot} , definidos por la ecuación (44) y la ecuación (45) respectivamente, representan la energía de la descomposición del nivel de wavelet i y la energía total de todas las descomposiciones del nivel de wavelet considerados, respectivamente.

$$E_i = \sum_k |C_i(k)|^2 \quad (44)$$

$$E_{tot} = \sum_i E_i \quad (45)$$

donde $C_i(k)$ es la muestra k del nivel de descomposición i obtenido a partir del cómputo de la transformada wavelet discreta.



3.2 Análisis en estado transitorio.

Como se revisó en secciones anteriores, cuando un motor de inducción se encuentra operando bajo condiciones de falla (barras rotas, excentricidades, desalineamientos, fallas en los rodamientos de bolas, entre otras), diversas magnitudes físicas relacionadas al mismo motor (corrientes de alimentación estatórica, vibraciones, gradiente de temperatura, flujo magnético del entrehierro, flujo magnético de dispersión, entre otras) se ven afectadas, modificando así su comportamiento dinámico. Estos cambios en las diversas magnitudes físicas suelen verse reflejados mediante la amplificación de frecuencias específicas, mismas que pueden ser distintas dependiendo del fallo, como se abordó en la sección 2.2 de este trabajo. Así entonces, como se ha reportado en la literatura técnica, estas frecuencias se encuentran bien identificadas y fundamentadas, por lo que se sabe que la gran mayoría de ellas están relacionadas con el deslizamiento del motor, para el caso de motores eléctricos de inducción. Debido a esta relación que guardan las frecuencias amplificadas por algún fallo con el deslizamiento, se espera que durante algún transitorio en el estado de operación del motor, ya sea debido por una carga oscilante, variaciones en los niveles de tensión, transitorio de arranque, entre otros, se genere un cambio en la frecuencia específica del fallo. Considerando esto, diversas metodologías se han basado en el desarrollo de técnicas capaces de rastrear y evaluar la evolución del armónico amplificado por el fallo en un mapa tiempo-frecuencia habitualmente, mismo que permite una visualización clara del fallo con respecto a variaciones en el deslizamiento.

De esta manera, se espera que, durante el transitorio de arranque, situación en la que el deslizamiento sufre un cambio sustancial siguiendo un perfil específico, al pasar de un valor de 1 (cuando la máquina se encuentra detenida) hasta aproximarse a un valor cercano a 0 (cuando la máquina alcanza el estado estable) se observe un patrón muy específico y bien definido. Este tipo de análisis representa diversas ventajas sobre metodologías convencionales que se basan únicamente en la evaluación de amplitudes de frecuencias específicas, y que son amplificadas por el fallo, ya que como se ha reportado en diversas publicaciones en los últimos años, es posible generar falsos diagnósticos, evidentemente indeseados ([Lee et al., 2020](#); [Park et al., 2019](#); [Lee, et al., 2020](#); [Shin et al., 2021](#)). Estos falsos diagnósticos pueden ser causados principalmente por fenómenos que no guardan relación alguna respecto a la avería de los componentes de la máquina, esto es por ejemplo, falsos diagnósticos debido a características constructivas de la máquina como es el caso de la influencia de conductos axiales de aire, oscilaciones de carga de baja frecuencia cuya frecuencia puede coincidir perfectamente con alguna relacionada a fallos (por ejemplo, coincidencia de bajas frecuencias de oscilación con la amplificación de frecuencias debidas a barras de rotor rotas), anisotropía magnética, vibración de frecuencia de paso de pala, porosidades en el rotor, rotura de barras no adyacentes,



estimación incorrecta de la velocidad de operación, entre otras (Lee et al., 2020). En este sentido, se puede concluir que aquellas técnicas basadas en la evaluación de amplitudes de frecuencias específicas, como la técnica MCSA, solo es estrictamente adecuado su empleo bajo condiciones estacionarias de operación del motor, que son por otro lado, bastante inusuales en el entorno industrial, donde la carga de la máquina cambia continuamente (plantas de tratamiento de aguas residuales, compresores, etc.), y las aplicaciones de velocidad variable (bombas, máquinas herramienta, cintas transportadoras, etc.) son bastante frecuentes. Por lo anterior, en los últimos años se ha prestado especial atención al diagnóstico de fallas en motores de inducción mediante técnicas basadas en transitorios, más frecuentemente y específicamente durante el transitorio de arranque. Para ello, se han empleado diversas herramientas de descomposición tiempo-frecuencia, mismas que permiten una visualización de la evolución (en caso de presencia de alguna falla que se manifieste mediante la amplificación de frecuencias específicas) durante el transitorio de arranque. Algunas de las técnicas que se han empleado y reportado con mayor frecuencia son, entre otras: la transformada de Fourier de tiempo corto (STFT, por su abreviatura en inglés Short-Time Fourier Transform), transformada wavelet continua (CWT, por su abreviatura en inglés Continuous Wavelet Transform), transformada discreta wavelet (DWT, por su abreviatura en inglés Discrete Wavelet Transform), distribución Wigner-Ville, entre otros (Fernandez-Cavero et al., 2017; Pons et al., 2014). Debido a la gran diversidad de técnicas de descomposición tiempo-frecuencia que han sido desarrolladas y reportadas durante las últimas décadas, es posible contar con un elevado número de herramientas a disposición; por lo anterior, no se discutirán todas ellas en este trabajo de tesis, sino exclusivamente aquellas empleadas y que son indispensables para llevar a cabo la propuesta del presente trabajo. En este sentido, información más detallada y comparaciones más puntuales sobre técnicas y herramientas de descomposición tiempo-frecuencia ampliamente utilizadas para tareas de diagnóstico de fallas en máquinas eléctricas durante estados transitorios pueden encontrarse y consultarse en el trabajo reportado por Pons et al. (2014).

Para mostrar de forma más clara la idea base de metodologías basadas en análisis tiempo-frecuencia de la evolución y trayectoria seguida por armónicos amplificados debidos a fallas en motores eléctricos de inducción, a continuación, se plantea a base de ejemplo la revisión teórica de los patrones producidos por fallas de asimetría en motores de inducción de rotor bobinado. Para ello, se debe tomar bajo consideración que, debido al fenómeno físico bajo análisis, la asimetría de rotor en motores de inducción de rotor bobinado produce la amplificación de frecuencias específicas, mismas que se encuentran relacionadas con el deslizamiento del motor como se revisó en la sección 2.2.6 de este trabajo de tesis. Entonces, se sabe que mediante la expresión (20) es posible estimar dichas frecuencias. Como puede inferirse a partir de dicha ecuación, cuando el motor opera bajo esta falla se dará origen a la amplificación de una familia de armónicos “ k ”. Bajo el supuesto que se tiene registrado el perfil de velocidad angular del eje del motor durante



el arranque, la Figura 8 muestra la trayectoria teórica seguida por dichas familias de armónicos de fallo, y que se describen a continuación:

- Componentes radiales: dados por la expresión (20). Estos corresponden a una familia de armónicos amplificadas por la asimetría del devanado del rotor en motores de inducción de rotor bobinado. Para cada valor de k/p , la expresión (20) produce un par de armónicos de falla que evolucionan hacia sus respectivas frecuencias en estado estable que caen cerca del armónico de devanado correspondiente (3° , 5° , 7° ... armónico de devanado). Más específicamente, para cada valor de k/p , la frecuencia de uno de los componentes (componente indirecto) cae a cero antes de ascender nuevamente hacia su valor de estado estable (p. ej., $f \cdot (3 - 4 \cdot s)$, $f \cdot (5 - 6 \cdot s)$, $f \cdot (7 - 8 \cdot s)$, etc.), mientras que la frecuencia del otro componente (componente directo) aumenta directamente desde su valor inicial (f) hasta su valor de estado estacionario (p. ej., $f \cdot (3 - 2 \cdot s)$, $f \cdot (5 - 4 \cdot s)$, $f \cdot (7 - 6 \cdot s)$, etc.).
- Componentes axiales: son principalmente los armónicos de baja frecuencia en $s \cdot f$ y $3 \cdot s \cdot f$. Su amplitud también puede verse amplificada por otras fallas como excentricidades, como se ha reportado en la literatura (Ceban et al., 2012; Romary et al., 2013). La frecuencia del componente $s \cdot f$ comienza en f cuando la máquina es conectada y termina cerca de 0 en estado estable, mientras que la frecuencia del componente $3 \cdot s \cdot f$ comienza en $3 \cdot f$ y termina cerca de 0 Hz, como se muestra en la Figura 8.
- Componentes de frecuencia de rotación: componentes en $f \pm fr$, que se ven amplificadas por excentricidades o, en menor medida, por desalineaciones o problemas de carga. Como informan algunos autores, sus amplitudes también se amplifican cuando hay asimetrías en el rotor (Gyftakis et al., 2020). Ambos componentes cambian sus frecuencias desde su valor inicial (f en ambos casos) hacia sus respectivas frecuencias de estado estacionario ($f + fr$ o $f - fr$, respectivamente), como se muestra en la Figura 8.

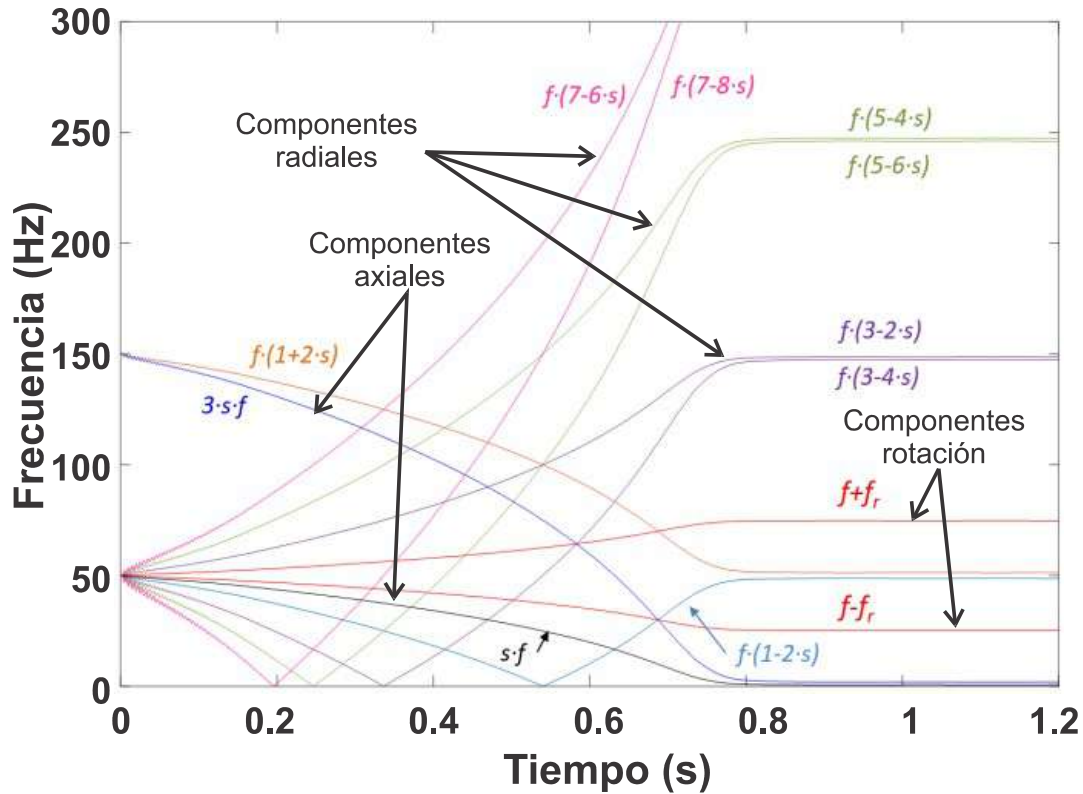


Figura 8. Evoluciones teóricas de los componentes amplificados por las asimetrías del rotor durante un transitorio de arranque simulado en un motor de inducción (autoría propia).

De esta manera, es posible generar un diagnóstico mediante el análisis de la trayectoria de armónicos amplificados en caso de fallo. Lo que sucede normalmente es que se requiere de un experto capaz de descifrar dichos patrones, para así generar un diagnóstico final. Sin embargo, esto no siempre es posible y en ciertas fallas, un daño irreversible puede suceder en cuestión de segundos, por lo que lo más recomendable y deseable es contar con metodologías capaces de generar un diagnóstico oportuno y automático, mismo que puede ser obtenido con un elevado grado de confiabilidad a partir de mapas tiempo-frecuencia y el análisis de la evolución de armónicos amplificados por alguna falla en específico. En los párrafos siguientes se revisa con mayor detalle las principales técnicas de descomposición tiempo-frecuencia que son de indispensable utilidad en el presente trabajo.



3.2.1 Transformada de Fourier de tiempo corto (STFT)

La transformada de Fourier de tiempo corto es una técnica de procesamiento de señales que permite la descomposición de una señal en el dominio del tiempo en sus componentes de tiempo-frecuencia. Para ello, se secciona la señal en el dominio del tiempo a través de ventanas temporales de igual tamaño, y posteriormente se obtiene el contenido frecuencial de cada una de estas ventanas mediante la transformada rápida de Fourier (FFT). Entonces, el tamaño de la ventana de tiempo define la resolución de tiempo y frecuencia, es decir, a mayor ventana de tiempo, mayor resolución de frecuencia, pero menor resolución de tiempo, y viceversa.

Matemáticamente, la STFT de una señal de longitud N se puede calcular mediante la ecuación (46):

$$X_{STFT}[m, k] = \sum_{n=0}^{N-1} x[n]g[mL - n]e^{-j\left(\frac{2\pi kn}{N}\right)} \quad (46)$$

Donde $x[n]$ es la señal de tiempo discreto, n es el índice de dominio de tiempo, $k=0, \dots, N-1, m=0, \dots, \left[\left(\frac{N}{L}\right)-1\right]$, g es la función de la ventana en el tiempo (misma que puede ser del tipo ventana cuadrada, ventana Hamming, ventana Hanning, entre otras). L determina la separación de tiempo entre ventanas sucesivas.

La Figura 9 muestra la forma más sencilla de obtener el mapa de tiempo-frecuencia de una señal a lo largo del tiempo utilizando la STFT, con una ventana cuadrada. Como se puede observar en dicha figura, la señal capturada mediante algún sensor en el dominio del tiempo es subdividida en ventanas $m=1, 2, 3, \dots, \left[\left(\frac{N}{L}\right)-1\right]$. Estas ventanas pueden tener un cierto porcentaje de solapamiento, dependiendo de las necesidades específicas de carga computacional, memoria del dispositivo con el que se obtiene el mapa tiempo-frecuencia, y tiempo de procesamiento. Posteriormente se consigue una representación en el dominio de la frecuencia por cada una de estas ventanas mediante la aplicación de la transformada rápida de Fourier. Finalmente, se generará un mapa tiempo-frecuencia de la señal en el tiempo, conservando así información correspondiente a diferentes intervalos de tiempo, y el contenido frecuencial en ese intervalo de tiempo.

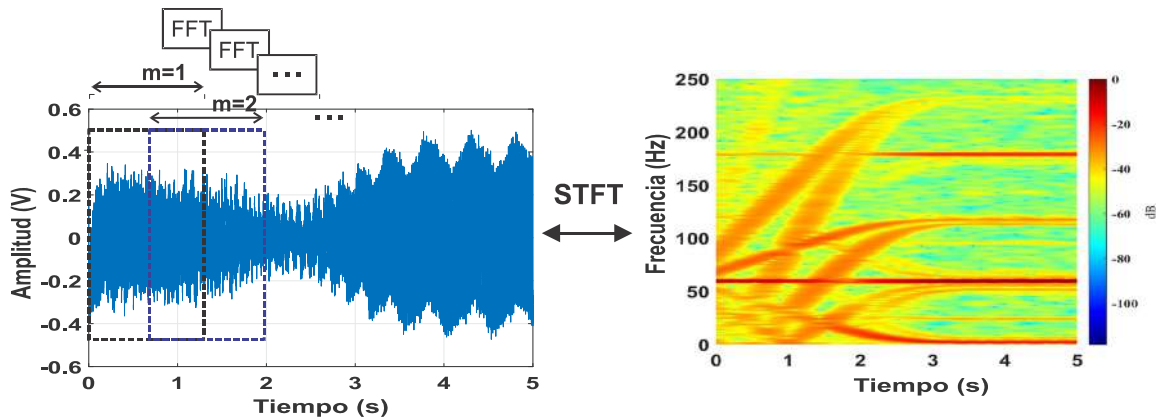


Figura 9. Transformada de Fourier de tiempo corto con superposición de ventanas sucesivas de una señal en el dominio del tiempo (autoría propia).

3.2.2 Algoritmo de clasificación de señales para la estimación del contenido frecuencial de una señal en el tiempo (algoritmo MUSIC)

El algoritmo de clasificación de señales múltiples (MUSIC, por su abreviatura en inglés MULTiple Signal Classification) es una técnica de estimación de frecuencia que fue introducido por primera vez por [Schmidt \(1986\)](#). Este algoritmo pertenece a la familia de métodos basados en la descomposición del espacio de observación en subespacios de señal y ruido. MUSIC es especialmente adecuado para detectar componentes de baja amplitud en señales con una baja relación señal/ruido (alto nivel de ruido en la señal). Además, ofrece una excelente resolución con señales no estacionarias mientras que solo requiere una pequeña ventana de tiempo para poder realizar el cómputo del mismo. Este tipo de técnicas de procesamiento de señales suelen ser denominadas del tipo super resolución, debido a que, con pocas muestras de la señal bajo análisis se puede obtener una representación frecuencial con una alta resolución. Esta característica resulta ser de especial utilidad para analizar señales que tienen componentes frecuenciales adyacentes de gran amplitud, mismas que pueden encontrarse solapadas en caso que no se tenga una buena resolución en frecuencia de la técnica empleada. Así entonces, el uso de técnicas de alta resolución como MUSIC proporciona superficies más regulares, mitiga los efectos del ruido, y evidencia solo componentes de frecuencia más grandes, lo que la convierte en una herramienta útil para el análisis de señales ruidosas con frecuencias de cambio de tiempo ([Chavez et al., 2016](#)).



En este algoritmo se asume que la señal de tiempo discreto $x[n]$ puede representarse como una suma de P sinusoides complejas en el ruido $\omega[n]$ como se muestra en la ecuación (47) Schmidt (1986):

$$x[n] = \sum_{k=1}^P A_k e^{j2\pi f_k t + \varphi_k} + \omega[n], n=0,1,2,\dots,N-1 \quad (47)$$

donde A_k es la amplitud, f_k es la frecuencia, φ_k es la fase del k -ésimo vector espacial, $\omega(t)$ es el ruido blanco y P se conoce como orden MUSIC. La amplitud y la frecuencia de la sinusoide no son aleatorias ni desconocidas. Las fases de las sinusoides son variables aleatorias no correlacionadas, distribuidas uniformemente en el intervalo $[-\pi, \pi]$.

El espectro de potencia de $x[n]$ consiste en un conjunto de P impulsos de área $2\pi \nu A_k \nu$ a frecuencias f_k para $k=1,2,\dots,P$, más el espectro de potencia del ruido aditivo $\omega[n]$. Basado en la ortogonalidad de los subespacios de señal y ruido, el pseudoespectro P_{MUSIC} de MUSIC de la señal actual viene dado por la función de estimación de frecuencia dada por la ecuación (48):

$$P_{MUSIC}(f) = \frac{1}{\sum_{i=P+1}^M |e_i^{-H} \bar{v}_i|^2} \quad (48)$$

donde \bar{v}_i es el vector propio de ruido y e_i^{-H} es el vector de señal definido como $e_i^{-H}(f_i) = [1, e^{-j2\pi f_i}, \dots, e^{-j2\pi f_i(M-1)}]$. La expresión (48) muestra un máximo cuando, para un cierto valor f_k que está realmente presente en la señal, las proyecciones de los subespacios de señal y ruido son cero.

El procedimiento para obtener un mapa tiempo-frecuencia a partir del algoritmo ST-MUSIC es muy similar al procedimiento descrito en la sección anterior para obtener un mapa tiempo-frecuencia a través de la técnica STFT; sin embargo, en lugar de obtener la información frecuencial por cada ventana de tiempo empleando la técnica de transformada rápida de Fourier, se obtiene un pseudoespectro mediante el algoritmo MUSIC (mismo que contendrá una estimación del contenido frecuencial en el intervalo de tiempo respectivo a la ventana bajo análisis) como se observa en la Figura 10.

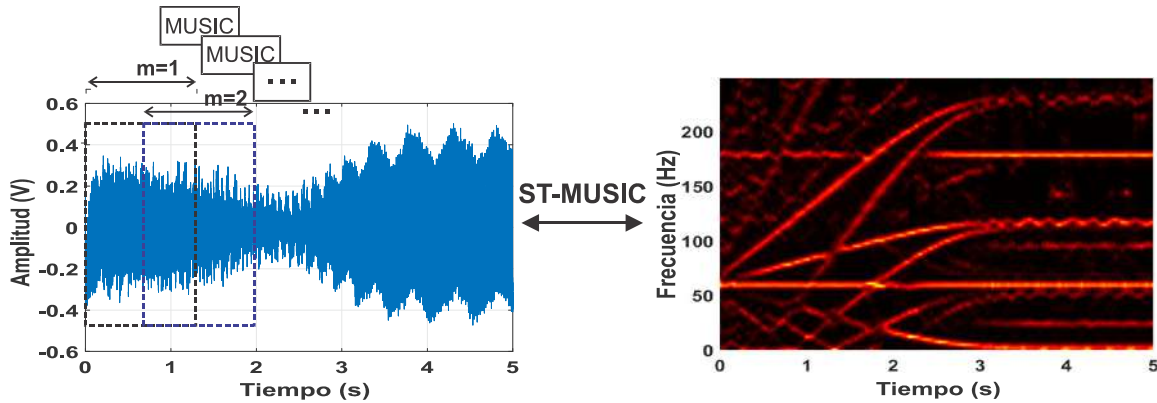


Figura 10. Transformada MUSIC de tiempo corto con superposición de ventanas sucesivas de una señal en el dominio del tiempo (autoría propia).

3.2.3 Transformada wavelet

Las wavelets son una clase de funciones utilizadas para localizar una función dada tanto en el tiempo como en la escala (frecuencia) (Escudero et al., 2017). Una familia de wavelets puede construirse a partir de una función $\psi(x)$, a veces conocida como una “wavelet madre”, que está confinada en un intervalo finito. Las “wavelets hija”, expresadas matemáticamente mediante la ecuación (49), son entonces formadas por la traslación (b) y la contracción (a). De esta manera, la transformada wavelet, definida mediante la ecuación (50), proporciona información del tiempo en que ocurren o se presentan ciertas señales con sus respectivas frecuencias. Así por ejemplo, una función estacionaria (mismo contenido frecuencial a lo largo del tiempo) puede ser detectada de manera íntegra a través de la transformada de Fourier, pero si se trata de una señal no estacionaria, es decir, una señal cuyo contenido frecuencial puede cambiar con respecto al tiempo, la transformada de Fourier solo indica cuáles son las principales frecuencias que componen dicha señal sin proporcionar información del tiempo en que se presentaron, perdiendo así información que puede ser de gran relevancia para ciertas aplicaciones que así lo requieran.

Una wavelet individual puede ser definida por la ecuación (49) mientras que la transformada wavelet viene dada por la ecuación (50):

$$\psi^{ab}(x) = |a|^{-\frac{1}{2}} \psi\left(\frac{x-b}{a}\right) \quad (49)$$



$$W_{\psi}(f)(a,b)=\frac{1}{\sqrt{a}}\int_{-\infty}^{\infty}f(t)\psi\left(\frac{t-b}{a}\right)dt \quad (50)$$

donde: $a=\hat{c}$ Contracción, $b=\hat{c}$ Traslación.

3.2.4 Transformada wavelet discreta (DWT).

Una transformada wavelet discreta (DWT por su abreviatura en inglés, Discrete Wavelet Transform) es aquella transformación de una señal en el dominio del tiempo a un dominio tiempo-frecuencia, para la cual las señales wavelet se muestrean discretamente. Al igual que con otras transformadas wavelets, una ventaja clave que tiene sobre las transformadas de Fourier es la resolución temporal: captura tanto la información de frecuencia como la ubicación (en el tiempo) de una señal digital utilizando técnicas de filtrado digital. Los filtros de diferentes frecuencias de corte se utilizan para analizar la señal a diferentes escalas. La DWT de una señal $x[n]$ se puede calcular empleando el algoritmo propuesto por Mallat (1989), que consiste en aplicar una serie de filtros a la señal de entrada x de paso alto para analizar las frecuencias altas, y de manera simultánea por una serie de filtros de paso bajo para analizar las bajas frecuencias. Los coeficientes de dichos filtros son determinados mediante la selección de una wavelet madre de acuerdo a la aplicación. En primer lugar, las muestras de la señal x se pasan a través de un filtro pasa altas con respuesta de impulso $h[n]$ y que contiene N coeficientes. Dicho filtrado se define mediante una operación de convolución de las dos señales de acuerdo a la ecuación (51):

$$D[n]=(x * h)[n]=\sum_{k=0}^N x[k]h[n-k]=\sum_{k=-\infty}^{\infty} h[k]x[n-k] \quad (51)$$

Adicionalmente, la señal $x[n]$ se descompone simultáneamente usando un filtro de pasa bajas $g[n]$ de acuerdo a la ecuación (52).

$$A[n]=(x * g)[n]=\sum_{k=0}^N x[k]g[n-k]=\sum_{k=-\infty}^{\infty} g[k]x[n-k] \quad (52)$$

Las salidas de dichas operaciones resultan en los coeficientes de detalle ($D[n]$, filtro pasa altas) y los coeficientes de aproximación ($A[n]$, filtro pasa bajas) respectivamente. Se debe

de tener en cuenta que dichos filtros deben de estar relacionados, y deben de cumplir con las características de un filtro de espejo en cuadratura. Por otro lado, debido a que la mitad del contenido frecuencial de la señal ya ha sido filtrado (teóricamente removido), la mitad de las muestras se pueden descartar según la regla de Nyquist. La salida del filtro de paso bajo $A[n]$ se submuestra por 2 y se procesa nuevamente aplicando el filtro pasa bajas $g[n]$ y un filtro pasa altas $h[n]$ con la mitad de la frecuencia de corte de la anterior como se muestra en la Figura 11. Esta descomposición reduce a la mitad la resolución temporal, ya que solo la mitad de cada salida de filtro caracteriza la señal. Sin embargo, cada salida tiene la mitad de la banda de frecuencia de la entrada, por lo que la resolución de frecuencia se ha duplicado.




Figura 11. Diagrama a bloques del análisis de filtros (autoría propia).

Dicha descomposición se repite para aumentar aún más la resolución de frecuencia, y los coeficientes de aproximación anteriormente descompuestos con filtros de paso alto y de paso bajo son submuestreados. Esto se representa como un árbol binario con nodos que representan un subespacio con una localización de tiempo-frecuencia diferente tal y como se observa en la Figura 12, donde f es el rango de frecuencia esperada en dicho nodo, mientras que f_s es la frecuencia de muestreo de la señal $x[n]$. El árbol se conoce como banco de filtros y cada señal wavelet (aproximación o detalle) está asociada a una determinada banda de frecuencias.

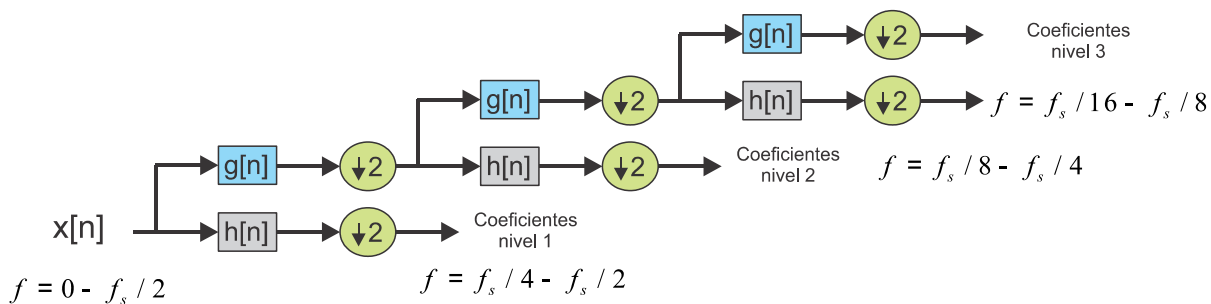


Figura 12. Diagrama a bloques de banco de filtros de 3 niveles (autoría propia).



3.2.5 Principio de incertidumbre transformada wavelet.

Es de notar que la resolución en tiempo y frecuencia es diferente en el plano tiempo-frecuencia en una transformada wavelet, o lo que es igual, el tamaño de ventana es variable dependiendo de la región o nodo bajo análisis. El principio de incertidumbre de Heisenberg para el análisis de señales mediante la transformada wavelet indica que, para altas frecuencias, la resolución en tiempo es mejor que para bajas frecuencias, es decir, se puede localizar en el tiempo con menor incertidumbre el contenido de altas frecuencias de una señal mediante la DWT. Por otro lado, la localización en el tiempo para bandas de baja frecuencia de una señal descompuesta mediante la DWT implica un mayor grado de incertidumbre, sin embargo, la resolución en frecuencia es mejor.

La Figura 13 muestra mediante un esquema el hecho descrito anteriormente, en el que se puede apreciar con claridad la distribución de la resolución obtenida mediante esta técnica a lo largo de la dimensión temporal y frecuencial. Así entonces, bajas frecuencias se encuentran localizadas con buena resolución el contenido frecuencial de la señal, sin embargo, su localización en el tiempo es limitada. Por el contrario, a mayor frecuencia de análisis, la localización en el tiempo de ese contenido frecuencial es más precisa, sin embargo, el ancho de banda es mayor.




Figura 13. Resolución en tiempo y frecuencia para diferentes niveles de descomposición de transformada wavelet.

3.2.6 Familias wavelet madre.

Como se vio en el capítulo 3.2.4 del presente documento, es necesario conocer los coeficientes del filtro pasa bajas $g[n]$ y los coeficientes de filtro pasa altas $h[n]$ para poder



aplicar la operación de convolución a la señal bajo análisis x . Se debe de tener en cuenta que dichos filtros deben de estar relacionados, y deben de cumplir con las características de un filtro de espejo en cuadratura. Así entonces, existen diversas familias de filtros que cumplen con estas características, pero que cada uno de ellos resulta en una respuesta distinta por lo que es de suma importancia elegir la familia wavelet más adecuada dependiendo la aplicación, para así obtener resultados significativos. Algunos de los criterios que se deben de tomar a consideración para elegir una wavelet madre adecuada para el análisis de series temporales es la suavidad, una característica que queda definida por la regularidad, es decir, los puntos en los que la función es derivable y la autosimilitud (Daubechies, 1990). Los coeficientes de los filtros empleados para el cálculo de la transformada wavelet discreta de una señal son obtenidos a partir de diferentes familias de wavelet madre que se encuentran bien definidas y que satisfacen con la característica de ser un filtro espejo en cuadratura, es decir, si se tienen dos filtros $g[n]$ y $h[n]$, su relación debe ser tal que se cumpla la propiedad enmarcada por la ecuación (53):

$$g[L - 1 - n] = (-1)^n \cdot h[n] \quad (53)$$

donde $0 \leq n < L$.

Entre las familias de wavelet madre empleadas comúnmente se encuentran la familia Daubechies, Symlet, dmeyer, Coiflet, entre otros. La Figura 14 muestra los filtros de paso bajo y de paso alto para las familias de wavelet madre anteriormente mencionadas.

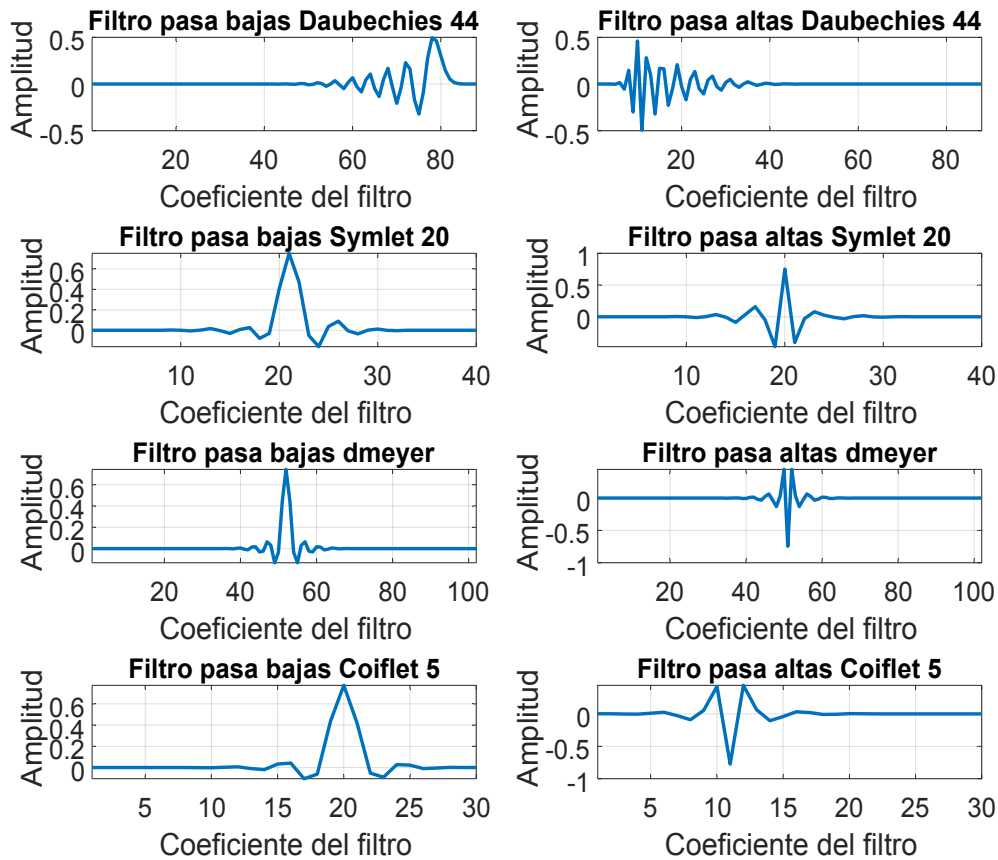


Figura 14. Coeficientes de filtro para distintas familias wavelet (autoría propia).

Es común aplicar la familia Daubechies en el análisis de tendencias y es recomendable realizar el cómputo de la transformada wavelet discreta empleando una wavelet madre de orden superior, es decir, que el filtro asociado contenga un elevado número de coeficientes puesto que el filtrado suele ser menos ideal en otros casos. Además, si el orden de la wavelet madre empleado contine menos coeficientes, es posible que surjan problemas debido a un filtrado menos ideal. Esto se traduce en que existe la posibilidad de un traslape entre bandas adyacentes (Antonino-Daviu et al., 2006) empeorando la respuesta en frecuencia, resultando en un filtro menos ideal, lo que puede dar lugar a que componentes frecuenciales de alta amplitud se vean reflejadas en bandas de frecuencia adyacentes.

3.2.7 Transformada wavelet discreta inversa (IDWT).

Para obtener la transformada wavelet discreta inversa a partir de los coeficientes de aproximación y detalle en el nivel j , cA_j y cD_j respectivamente, la transformada wavelet discreta inversa reconstruye cA_{j-1} , invirtiendo los pasos de descomposición insertando ceros (sobremuestreo diádico) y ejecutando la operación característica de convolución de los resultados con los filtros de reconstrucción correspondientes pasa bajas (Lo_R) y pasa altas (Hi_R) como se muestra en la Figura 15.




Figura 15. Diagrama de bloques transformada wavelet discreta inversa.

3.3 Análisis discriminante lineal.

El análisis discriminante lineal (LDA, por su abreviatura en inglés Linear Discriminant Analysis) es una técnica de reducción de dimensionalidad supervisada que es comúnmente empleada como un paso de preprocesamiento para aplicaciones de aprendizaje automático y clasificación de patrones. El objetivo principal de esta técnica de clasificador se centra en proyectar un conjunto de datos de vectores d -dimensionales en un subespacio más pequeño s (donde $s \leq d$) maximizando la separabilidad lineal entre datos de diferentes clases encontrando un mapeo lineal (Song et al., 2015). Esta técnica se ha aplicado ampliamente en los enfoques clásicos de reducción de características para obtener un nuevo conjunto no redundante de menos características, de manera que se lleva a cabo una combinación de información relevante proporcionada por diferentes índices. Por lo tanto, a pesar de que una característica específica no proporcione información significativa por sí misma; puede proporcionar información relevante mediante su combinación con otros (Saucedo-Dorantes et al., 2016). El procedimiento matemático para realizar un LDA se describe en resumen a continuación y se puede encontrar en detalle en diferentes publicaciones como en (Wen et al., 2019):



1. Calcular la media de los vectores de dimensión d de la matriz de entrada.
2. Calcular la matriz entre clases y la matriz de dispersión dentro de la clase.
3. Calcular vectores propios y valores propios.
4. Seleccionar discriminantes lineales para el nuevo subespacio de características y formar una matriz de vectores propios.
5. Utilizar la matriz de vectores propios para transformar los vectores en el nuevo espacio dimensional inferior.
6. Maximizar la matriz entre clases y minimizar la matriz de dispersión dentro de la clase.

3.4 Clasificación de datos mediante redes neuronales artificiales (RNA).

Una red neuronal artificial (RNA) es un conjunto de unidades de procesamiento elementales llamadas neuronas o nodos, cuya capacidad de procesamiento se almacena en las conexiones mediante pesos sinápticos, y cuya adaptación depende del aprendizaje. Así entonces, una red neuronal artificial se puede concebir como un modelo computacional capaz de resolver problemas de clasificación y reconocimiento de patrones a través de estructuras algorítmicas completas ([Camarena-Martinez et al., 2014b](#)). La técnica de redes neuronales se usa para reconocer y clasificar patrones de fallas complejas sin la necesidad de contar con mucho conocimiento sobre el proceso, las señales usadas o los propios patrones de fallas. Así entonces, las ventajas de emplear redes neuronales para la clasificación de datos son variadas y algunas de ellas se enumeran a continuación ([Bacha et al., 2008](#)):

1. En términos computacionales, las redes neuronales son muy rápidas de calcular. Esto es útil cuando un sistema de diagnóstico debe ejecutarse en tiempo real y debe manejar muchas señales.
2. Poco o nada de conocimiento del proceso es requerido para el uso de redes neuronales. Una ventaja especial es que no se requiere conocimiento sobre patrones de fallas.
3. Una red neuronal es robusta, especialmente con respecto al ruido.

Entre las arquitecturas de redes neuronales más comunes, las redes neuronales feed-forward (FFNN, por su abreviatura en inglés Feed-Forward Neural Network) han sido ampliamente utilizadas ya que este modelo computacional es muy simple y práctico, y en términos computacionales, su cálculo representa una carga muy baja. Además, esta estructura de red neuronal facilita la posibilidad de generar resultados automatizados al generalizar adecuadamente sobre los datos con los que se entrena. Las redes neuronales

feed-forward han encontrado aplicaciones para resolver problemas de clasificación y aproximar funciones de valor real. La estructura más general de red neuronal feed-forward está compuesta por una arquitectura en capas que tiene esencialmente una capa de entrada (cuya tarea es asignar valores de entrada), una o más capas ocultas (cuya tarea es realizar operaciones) y una capa de salida (cuya tarea es realizar operaciones y comparar los valores con el objetivo o los de referencia), como se muestra en la Figura 16a, donde I_i son las entradas de la red neuronal y O_i corresponden a las salidas del modelo. Cada capa tiene una o más unidades elementales denominadas neuronas, cuya capacidad de procesamiento se almacena en las conexiones mediante pesos sinápticos, y cuya adaptación depende del aprendizaje (Antolines, 2014), como se puede observar en la Figura 16b. El modelo matemático de cada neurona viene dado por la ecuación (54), donde y es la salida de la neurona, w_i son los pesos sinápticos, x_i son las entradas de la neurona, b es el sesgo, $f(\cdot)$ es la función de activación, y n es el número total de entradas a la red neuronal.

$$y = f(u) = f\left(\sum_{i=1}^n w_i x_i + b\right) \quad (54)$$

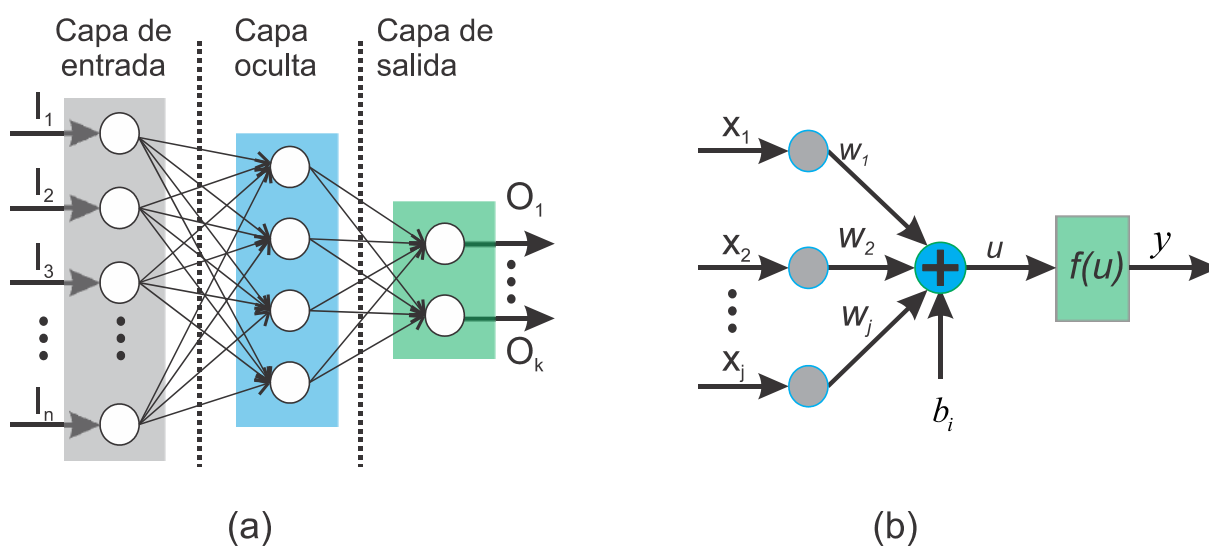


Figura 16. Red neuronal artificial: (a) arquitectura de red neuronal feed-forward (FFNN); (b) estructura funcional de una neurona (autoría propia).

Existen diferentes funciones de activación $f(\cdot)$, sin embargo, aquellas que suelen emplearse comúnmente en las tareas de solución de problemas de clasificación y reconocimiento de patrones se enlistan en la Tabla 3.



Tabla 3. Funciones de activación comúnmente empleadas en una red neuronal artificial.

Función escalón unitaria	$f(u) = \begin{cases} 1, & \text{si } u > 0 \\ 0, & \text{de otra manera} \end{cases}$
Función lineal	$f(u) = u$
Función sigmoide	$f(u) = \frac{a}{1 + \exp(-u)}$
Función tangente hiperbólica	$f(u) = \frac{e^u - e^{-u}}{e^u + e^{-u}}$

3.5 Detección automática del arranque del motor y estado estable.

Como se ha reportado en la literatura, algunas de las fallas más comunes en los motores eléctricos de inducción se ven reflejadas en diferentes señales de la propia máquina (vibración, corrientes de alimentación estatórica, sonido, etc.) mediante la amplificación de frecuencias específicas (que dependen la gran mayoría del deslizamiento s del motor). Debido a este hecho, es posible ver un patrón durante el transitorio de arranque o, dicho de otra manera, la evolución de la componente frecuencial debida a algún fallo específico durante el transitorio de arranque (cuando el deslizamiento vale 1, caso cuando el motor se encuentra detenido, y se aproxima a cero conforme el motor alcanza el estado estable de operación) permite distinguir con cierto grado e certidumbre el estado del motor bajo análisis, permitiendo así distinguir cuando el motor se encuentra operando bajo una avería. Así entonces, para metodologías en las que se requiere realizar un diagnóstico automático y oportuno, es imprescindible realizar la detección y, en su caso, el aislamiento automático de la señal correspondiente al transitorio de arranque de aquella correspondiente al motor bajo operación en estado estable. Para estos fines, en la presente tesis se propone un método simple para aislar el transitorio de arranque mediante un algoritmo sencillo, y que no demanda mucha carga computacional, tal como se describe a continuación:

1. Obtener la envolvente superior de la señal en el dominio del tiempo, como se muestra en la Figura 17. Para ello se puede seguir el procedimiento propuesto por Jarne (2018).

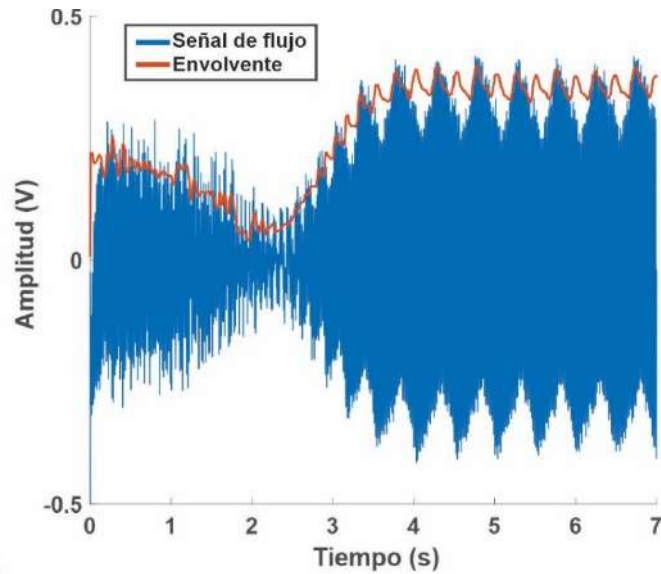


Figura 17. Obtención de envolvente superior de señales en el dominio del tiempo.

2. Establecer un valor límite (obtenido a través de las últimas muestras) igual al promedio de la amplitud de la envolvente en estado estable. La intersección de este valor límite con el eje del tiempo será casi el final del transitorio de arranque. Este hecho se puede observar en la Figura 18.




Figura 18. Obtención de transitorio de arranque a partir de la envolvente de la señal en el tiempo.

4. ANÁLISIS DEL FLUJO MAGNÉTICO DE DISPERSIÓN PARA EL MONITOREO DE LA CONDICIÓN EN MÁQUINAS ELÉCTRICAS

El flujo magnético que se localiza disperso a los alrededores de una máquina eléctrica de inducción es un efecto residual e indeseable debido a que éste no participa en el proceso de generar par de salida. Así entonces, el flujo magnético de dispersión es el flujo magnético que irradia fuera del marco de la máquina y es inducido por las corrientes del estator y del rotor (Bellini et al., 2006). Estas corrientes (y por lo tanto, el flujo de dispersión) se ven afectadas cuando el motor eléctrico funciona en condiciones de falla o en condiciones que no son óptimas de operación. Según lo reportado por Romary et al. (2009), el flujo de dispersión se puede analizar a través de sus dos componentes magnéticas: flujo de dispersión axial y flujo de dispersión radial. De acuerdo a lo reportado en la literatura, es posible capturar por separado los componentes de flujo de dispersión axial y radial e incluso la combinación de ambos instalando sensores adecuados en el marco del motor en posiciones específicas. La Figura 19 muestra la circulación estimada de las líneas de campo de los flujos dispersos axiales y radiales, y las posiciones alternativas en las que se pueden instalar sensores basados en bobinas para capturarlos. El flujo de dispersión axial se puede adquirir al instalar un sensor como se muestra en la posición A de la Figura 19. Por su parte, es posible adquirir las señales de flujo de dispersión radial mediante la instalación de un sensor adecuado de acuerdo a la posición C mostrada en la Figura 19. Finalmente, si se instala un sensor como en la posición B mostrada en la Figura 19 es posible capturar la combinación del flujo de dispersión axial y radial.




Figura 19. Componentes del flujo magnético de dispersión: (a) flujo de dispersión radial; (b) flujo de dispersión axial (Zamudio-Ramírez et al., 2020).



Por su parte, los métodos basados en el análisis del flujo de dispersión se fundamentan en que la presencia de determinados fallos en las diferentes máquinas eléctricas modifican el flujo magnético en su entorno (Ceban et al., 2012; Henao et al., 2003; Penman et al., 1994). Así entonces, en una máquina simétrica sana, las corrientes del estator y del rotor están equilibradas en los devanados finales y por consecuencia el flujo de dispersión es insignificante. Por el contrario, cuando existe alguna falla o daño en algunos componentes del motor eléctrico bajo análisis (como por ejemplo una avería en el rotor), esta puede generar una asimetría, lo que puede dar lugar a un campo magnético de rotación inversa debido a las corrientes desequilibradas del rotor.

4.1 Sensores típicos empleados para la adquisición de señales de flujo magnético.

4.1.1 Sensores de bobina para capturar flujo magnético.

Los sensores basados en una bobina de alambre generalmente tienen formas circulares e incorporan bobinados de alambre (con o sin núcleo ferromagnético), basados en un bajo número de vueltas, comúnmente entre 10 y 3000 dependiendo de la aplicación (medición de flujo magnético de dispersión o entrehierro) y dimensiones (Lee et al., 2021; Pusca et al., 2010; Zamudio-Ramirez et al., 2020). Una gran ventaja de los sensores basados en bobinas es su construcción simple, lo que permite su fácil fabricación. En los trabajos reportados por Irhoumah et al. (2020) y Tian et al. (2020), los autores muestran un análisis del impacto del número de hilos y el diámetro, y el tipo de núcleo sobre la señal de flujo magnético capturada. Ahí se muestra que es preferible emplear sensores que tienen un gran número de vueltas con diámetros más pequeños ya que se puede obtener una disminución en amplitud y un desplazamiento hacia frecuencias altas de la frecuencia resonante (F_0). Además, como lo señalan Shaikh et al. (2021), el comportamiento no lineal del hierro debido a la permeabilidad, saturación, histéresis o corrientes de Foucault no afecta a la detección de fallas, mientras que se obtiene una tensión inducida de amplitud significativamente mayor para la misma cantidad de flujo magnético de dispersión (una característica importante en ambientes ruidosos). Esta situación revela que los sensores de flujo con núcleo de hierro parecen ofrecer ventajas sobre los sensores con núcleo de aire cuando adquieren señales de flujo de dispersión.

Las principales limitaciones de los sensores basados en bobinas para el monitoreo de condición de máquinas eléctricas son las siguientes:

- La señal de salida depende de la frecuencia del campo magnético, que por lo tanto limita el ancho de banda de frecuencia por resonancia de la bobina.

- Para lograr una alta sensibilidad, el sensor debe ser bastante grande, ya que la sensibilidad depende en gran medida de las dimensiones de la bobina (Tian et al., 2020).
- Desde un punto de vista práctico, las bobinas suelen ser difíciles de instalar en la posición correcta (para asegurar la adquisición de una señal fiable), ya que el diseño de la máquina y su carcasa a veces no lo permiten.

La Figura 20 muestra formas alternativas de instalación de sensores tipo bobina para capturar de forma independiente las diferentes componentes de flujo magnético de dispersión en un motor de inducción. Como se puede apreciar en dicha figura, se requieren tres distintos sensores instalados en diferentes posiciones del motor para lograr capturar de forma simultánea las diferentes componentes de flujo magnético. Esto representa una clara desventaja ya que, en términos prácticos es complicado conseguir el espacio necesario para poder instalar todos los sensores, especialmente en espacios reducidos, además que puede resultar complejo tener acceso a todas las posiciones del motor.




Figura 20. Posiciones alternativas de instalación de sensores tipo bobina para capturar las diferentes componentes del flujo magnético de dispersión en un motor de inducción (Ramirez-Nunez et al., 2018).

4.1.2 Sensor fluxgate

Los sensores del tipo fluxgate son dispositivos de estado sólido empleados para medir la magnitud y la dirección de un campo magnético de corriente continua o de baja frecuencia en el rango de 10^{-10} a 10^{-4} T. La configuración básica del sensor se puede observar en la Figura 21. El campo de excitación satura periódicamente el material magnético del núcleo del sensor, que es producido por la corriente de excitación I . Por lo tanto, la permeabilidad del núcleo cambia y el flujo magnético de corriente continua causado por el campo magnético B_0 es modulado. Así entonces, se induce un voltaje V_{ind} proporcional a la intensidad de campo medida en la bobina de detección (recogida) en el segundo armónico (y también armónicos más altos) de la frecuencia de excitación. En la Figura 21 se muestra uno de los sensores tipo fluxgate que han sido reportados en trabajos para el diagnóstico de fallas en máquinas eléctricas con resultados favorables (Goktas et al., 2017; Ripka, 2003). Este tipo de sensor es del tipo comercial y puede ser adquirido a un bajo costo en tiendas de electrónica, siendo el modelo DRV425 de la marca Texas Instrument uno de los comúnmente empleados. Sus características principales, como lo son rango de detección de alta precisión de ± 2 mT con un ancho de banda de medición de hasta 47 kHz, compensación baja, deriva de compensación, y ruido del sensor, combinados con la ganancia precisa, la deriva de ganancia baja y la no linealidad muy baja proporcionada por la bobina de compensación interna, dan como resultado una precisión de medición de campo magnético suficiente. La salida del DRV425 es una señal analógica proporcional al campo magnético detectado. El DRV425 ofrece un conjunto completo de funciones, incluido un amplificador diferencial interno, referencia de precisión en el chip y funciones de diagnóstico para minimizar el recuento de componentes y el costo a nivel del sistema. La Figura 22 muestra una foto de dicho dispositivo.




Figura 21. Configuración básica de un sensor tipo fluxgate.




Figura 22. Foto de sensor fluxgate comercial modelo DRV425 de Texas Instrument.

4.1.3 Sensores de efecto Hall

Los sensores de efecto Hall se han utilizado e instalado ampliamente en numerosas máquinas eléctricas para control de movimiento, estimación de la posición inicial del rotor, y detección y diagnóstico de fallas. Los sensores de efecto Hall son dispositivos de bajo costo y pequeño tamaño (lo que permite instalarlos en lugares con espacio reducido). Tienen la capacidad de adquirir flujos magnéticos constantes y variantes con medidas absolutas y lineales sobre un campo muy grande. Dado que los sensores de efecto Hall no requieren elementos grandes (como piezas ferromagnéticas), es posible generar esquemas no invasivos para adquirir señales de flujo magnético. Sin embargo, la principal desventaja de este tipo de sensor es su sensibilidad, ya que el ruido ambiental puede perturbar fácilmente las mediciones, aunque estos efectos pueden disminuirse o anularse mediante el uso de circuitos electrónicos adecuados.

4.2 Sensor triaxial propuesto

Debido a las limitaciones encontradas en los sensores convencionales y mayormente empleados para capturar las diferentes componentes del flujo magnético de dispersión, en el presente trabajo se propone una nueva arquitectura de sensor triaxial para capturar el flujo magnético de dispersión en motores eléctricos desde un solo punto en la carcasa del motor bajo análisis. Así entonces, el sensor de flujo magnético de dispersión triaxial propuesto se compone esencialmente de la integración de tres sensores primarios de efecto Hall individuales, como el que se muestra en la Figura 23a. Cada uno de los

sensores primarios son microsistemas marca ALLEGRO™, modelo A1325, teniendo una sensibilidad de 5 mV/G. Este sensor mide 3.02 mm de ancho por 4.1 mm de alto, tiene un voltaje de salida proporcional a la densidad de flujo magnético, salida de bajo ruido, amplio rango de temperatura ambiente: $-40\text{ }^{\circ}\text{C}$ a $150\text{ }^{\circ}\text{C}$, es inmune al esfuerzo mecánico y cumple con otras características indicadas por el fabricante en su respectiva ficha técnica. Los sensores primarios están ubicados en un eje perpendicular entre sí para capturar los componentes de flujo de dispersión axial, radial y la combinación de axial y radial, independientemente de su ubicación relativa a la estructura del motor. La Figura 23b muestra una vista esquemática del sensor de flujo de dispersión triaxial propuesto aquí. Se pueden observar las posiciones relativas de los tres sensores primarios. En este sentido, si los sensores están instalados en la posición A, que se muestra en la Figura 23c, el sensor primario 1 captura principalmente el flujo axial, el sensor primario 2 captura la combinación del flujo axial y radial, mientras que el sensor primario 3 captura el flujo radial. De manera similar, si los sensores se instalan en la posición B que se muestra en la Figura 23c, el sensor primario 1 captura principalmente la combinación del flujo de dispersión axial y radial, el sensor primario 2 captura el flujo axial y el sensor primario 3 captura principalmente el flujo de dispersión radial. La principal ventaja de este sensor es que se puede ubicar virtualmente en cualquier parte del marco de la máquina de tal manera que aún podrá capturar los diferentes componentes del flujo magnético de dispersión.




Figura 23. Sensor de flujo magnético de dispersión triaxial propuesto: (a) sensor primario de efecto Hall; (b) composición del sensor de flujo magnético de dispersión triaxial; (c) instalación del sensor de flujo magnético de dispersión triaxial (Zamudio-Ramírez et al., 2020).

4.3 Diseño digital de sistemas de procesamiento y adquisición

El procesamiento digital de señales es la manipulación matemática de una señal física con el propósito de mejorarla o extraer información y características relevantes para caracterizarla dentro de un proceso. Dicha señal o magnitud física debe ser medida por medio de un sensor y convertida a una representación en el dominio discreto mediante un convertidor analógico a digital, la Figura 24 muestra el sistema básico de un procesamiento digital de señales.




Figura 24. Etapas de un sistema básico de un procesamiento digital de señales (autoría propia).

El procesamiento digital de señales agrupa un conjunto de operaciones que se aplican sobre señales discretas, estas operaciones se describen como transformaciones matemáticas. Los objetivos de realizar un procesamiento digital de señales son, entre otros, proveer una mejor aproximación del análisis o estimación del contenido de la información, analizar, representar, transformar, manipular señales y el contenido de la información. Procesar señales digitalmente tiene muchas ventajas sobre su contraparte analógica, esto debido a que existen procesos que son muy difíciles o casi imposibles de analizar y realizar de manera analógica, además, el procesamiento analógico se realiza mediante resistores, capacitores, inductores, etc., elementos que muestran un desempeño minimizado al afectarse por cambios de temperatura, cambios de voltaje y vibraciones mecánicas, entre otros. Por su parte el procesamiento digital de señales supone diversas ventajas ya que este tipo de procesamiento reduce la susceptibilidad al ruido, la cantidad de elementos empleados para la ejecución de operaciones, el tiempo de desarrollo, los costos, el consumo de potencia, entre otros.

Debido a la índole del presente trabajo de tesis, en la que se propone una metodología para el diagnóstico de fallos electromecánicos en motores eléctricos mediante el análisis avanzado del flujo magnético y su implementación en un dispositivo de procesamiento



digital, es indispensable la utilización de dispositivos electrónicos capaces de realizar diversas tareas relacionadas con la adquisición, acondicionamiento, y procesamiento de señales de flujo magnético de dispersión. Para ello, se propone el uso de un procesador con las capacidades suficientes para adquirir, almacenar, y procesar las señales que la presente propuesta demanda. Por lo anterior se propone el uso de un procesador basado en una computadora de placa única (SBC, por su abreviatura en inglés Single Board Computer), mismo que puede realizar el cálculo de la STFT, extracción de características de parámetros estadísticos, reducción de dimensionalidad de análisis discriminante lineal y clasificación mediante una red neuronal artificial. El procesador SBC utilizado en este trabajo está basado en una raspberry pi model 3 que cuenta con un procesador 4× ARM Cortex-A53 y que basa su funcionamiento en una frecuencia de 1.2GHz, con un consumo de corriente promedio de 800 mA en conjunto con la pantalla táctil raspberry.

4.3.1 Tarjeta de adquisición

Para adquirir de forma adecuada las señales provenientes del sensor triaxial desarrollado es indispensable contar con una etapa de acondicionamiento de señal y un convertidor analógico a digital (ADC, por su abreviatura en inglés Analog to digital Converter). Así entonces, en el presente trabajo de tesis se realizó la integración del hardware necesario para llevar a cabo esta etapa. Primeramente, se diseñó una tarjeta de circuito impreso (PCB, por su abreviatura en inglés Printed Circuit Board). La tarjeta desarrollada para adquirir adecuadamente las señales del sensor triaxial de flujo disperso consta de una etapa de acondicionamiento de la señal en la que se realiza un filtro anti-aliasing por medio de amplificadores operacionales, seguido de una etapa de digitalización de la señal realizada a través de un microcontrolador Texas Instrument marca MSP432P401R, que incluye un ADC con precisión de 14 bits, hasta 24 canales de entrada y hasta 1 Millón de muestras por segundo (MSPs), suficiente para los fines de este trabajo. La Figura 26 muestra el esquemático en 3D de dicha tarjeta. En ella se pueden observar los componentes principales que la integran, donde se pueden distinguir por una parte el microcontrolador modelo MSP432 encargado de convertir las señales análogas a digitales mediante el convertidor ADC que tiene integrado, por otra parte los conectores especiales para alojar dichas señales análogas, y finalmente los amplificadores operacionales (encargados de realizar el acondicionamiento de la señal a niveles de tensión adecuados para el convertidor analógico digital). A este respecto, para llevar a cabo la etapa de acondicionamiento de la señal del sensor de flujo magnético de dispersión triaxial, se emplea una etapa de restador no inversor de dos señales. El objetivo de esta etapa es eliminar el offset de corriente continua que presenta dicho sensor, y al mismo tiempo generar una amplificación considerable de la salida del sensor de efecto Hall empleado. La Figura 25 muestra la conexión / configuración de dicha etapa de acondicionamiento



mediante el empleo de amplificadores operacionales típicos. Por su parte, la expresión (55) proporciona el comportamiento de dicha etapa de acondicionamiento. Donde V_1 corresponde al voltaje del sensor de flujo triaxial, V_2 corresponde al voltaje equivalente al offset de los sensores de efecto Hall empleados, que en este caso y de acuerdo a la hoja de datos del fabricante corresponde a 2.5 V aproximadamente.

$$V_{out} = (V_2 - V_1) \cdot \frac{R_3}{R_1} \quad (55)$$




Figura 25. Configuración de amplificador operacional no inversor restador,

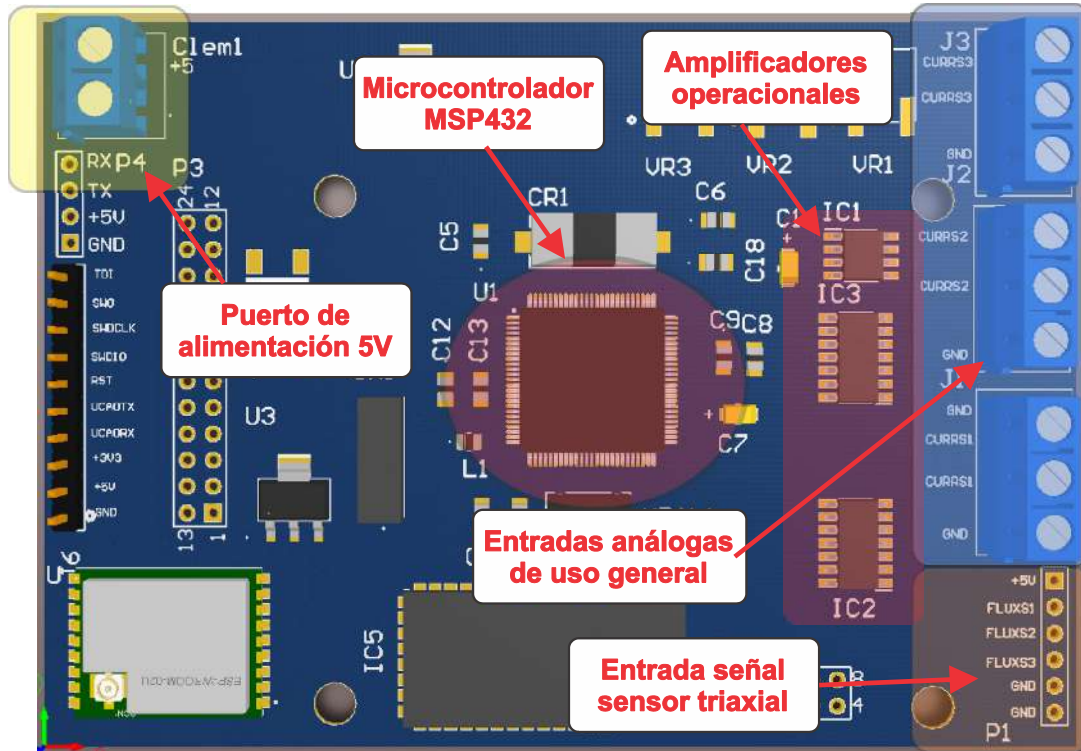


Figura 26. Esquema 3D de la tarjeta desarrollada para el acondicionamiento y adquisición de señales del sensor de flujo de dispersión triaxial desarrollado (autoría propia).

4.3.2 Tarjeta de procesamiento

La tarjeta de procesamiento tiene por objetivo almacenar y procesar las señales digitales provenientes de la etapa de acondicionamiento descrita en la sección 4.3.1. Esta tarjeta es del tipo procesador basado en computadora de placa única, y puede realizar el cálculo de la STFT, DWT, ST-MUSIC, extracción de características de parámetros estadísticos, reducción de dimensionalidad de análisis discriminante lineal y clasificación mediante una red neuronal artificial, como se describe en la sección 3 de este trabajo de tesis. El procesador SBC utilizado está basado en una raspberry pi modelo 4 que cuenta con un procesador 4× ARM Cortex-A53 y que basa su funcionamiento en una frecuencia de 1.2GHz, con un consumo de corriente promedio de 800 mA en conjunto con la pantalla táctil raspberry. Adicionalmente, esta tarjeta cuenta con 2 GB de memoria RAM, más que suficiente para almacenar de forma dinámica la información intermedia para llevar a cabo las tareas de adquisición, almacenamiento y procesamiento de señales que el presente trabajo de tesis demanda. La Figura 27 muestra la tarjeta modelo raspberry pi 4 y sus principales componentes. Esta tarjeta cuenta con protocolos estandar de comunicación y conectividad gracias a su puerto de expansión de entradas y salidas de propósito general integrado en las que se implementa distintos protocolos de comunicación industriales y

estandarizados como lo son protocolo de comunicación I2C, SPI, UART, entre otros. Adicionalmente, esta tarjeta cuenta con conectividad inalámbrica LAN 2.4 GHz and 5.0 GHz IEEE 802.11b/g/n/ac, Bluetooth 5.0, BLE Gigabit Ethernet 2 × puertos USB 3.0, 2 × puertos USB 2.0.




Figura 27. Principales componentes de procesador empleado para la implementación de la metodología propuesta.

Por otra parte, la Figura 28 muestra las principales técnicas implementadas en la tarjeta raspberry pi, mismas que permiten realizar los cálculos necesarios para un diagnóstico continuo de la máquina bajo análisis empleando la metodología propuesta. Así entonces, se pueden distinguir cuatro tareas esenciales, tal y como se describe a continuación:

1. Adquisición de señales: En esta tarea se implementa la interfaz de comunicación entre el módulo de acondicionamiento y adquisición de señales, y el procesador principal basado en plataforma raspberry pi 4. La comunicación se lleva a cabo entre el microcontrolador modelo MSP432 (que contiene la tarjeta de acondicionamiento y adquisición de señales) y el procesador principal de la tarjeta raspberry pi 4. Para implementar dicha comunicación e intercambio de información se hace uso del protocolo de comunicación estandarizado UART, mismo que lo contienen ambos procesadores mencionados anteriormente.
2. Herramientas de procesamiento de señales. Aquí se implementan los cálculos matemáticos básicos que se requieren para posteriormente llevar a cabo tareas de procesamiento más complejas como lo es el cálculo de la DWT, STFT, MUSIC. Estos cálculos corresponden con aquellos descritos en la sección 3 de este trabajo de tesis, y que se enumeran a continuación:
 - Implementación de filtro digital pasa bajas, y filtro digital promedio.

- Implementación de operación convolución de señales. Empleado para el cálculo de la DWT, como se describe en la sección 3.2.4.
- Implementación de operador multiplicación-acumulación. Empleado para el cálculo de la transformada discreta de Fourier, como se describe en la expresión (22).
- Implementación de cálculo de indicadores estadísticos y no estadísticos de acuerdo a las ecuaciones (24) a (38).

3. Implementación de herramientas de descomposición tiempo-frecuencia (STFT; DWT, ST-MUSIC, FFT). En esta tarea se implementan las operaciones matemáticas que permiten llevar a cabo el cómputo de las herramientas de descomposición tiempo-frecuencia, como se describe en la sección 3.

4. Implementación de técnicas de agrupamiento y clasificación de datos. Aquí se lleva a cabo la etapa de automatización del proceso de clasificación de la falla mediante la implementación de herramientas de inteligencia artificial como lo son redes neuronales artificiales (RNA), análisis discriminante lineal (LDA), y análisis de componente principal (PCA). Esta tarea se lleva a cabo mediante la implementación de las expresiones matemáticas descritas en la sección 3.4.

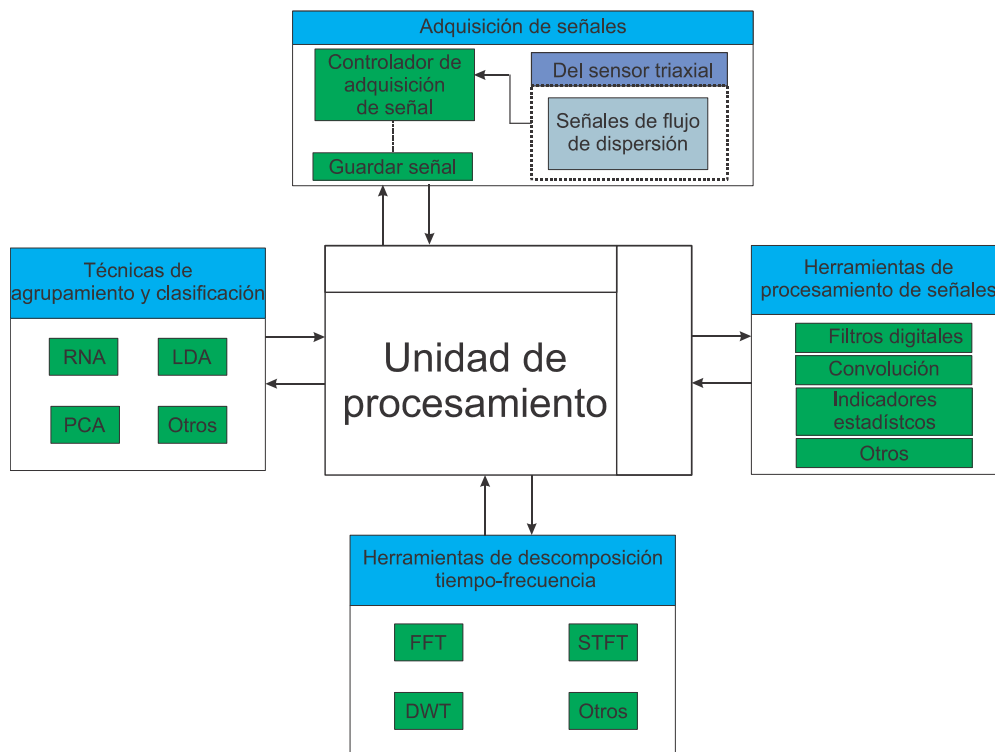


Figura 28. Tareas principales llevadas a cabo e implementadas a través del procesador principal basado en la plataforma raspberry pi 4 (autoría propia).



5. METODOLOGÍA

En el siguiente apartado se describe a detalle la metodología propuesta en este trabajo de tesis. Primeramente, se da detalle de los fundamentos teóricos que sustentan la metodología propuesta, posteriormente se introduce el esquemático de la metodología. Mediante este esquemático se muestra el flujo de las señales y las etapas de procesamiento propuestas para lograr un diagnóstico oportuno y automático de las diversas fallas electromecánicas que suelen ocurrir en motores eléctricos de inducción, a saber: barras de rotor rotas, excentricidades, desalineamientos, engranes desgastados, asimetrías de rotor en motores de inducción de rotor bobinado, fallas de pista exterior en rodamientos de bolas, entre otras. Finalmente se describen con detalle, y paso a paso las etapas que componen la metodología propuesta.

En este contexto, y como se abordó en secciones anteriores, la gran mayoría de fallas que suelen ocurrir en los motores eléctricos, en este caso, motores eléctricos de inducción generarán un cambio en el comportamiento dinámico de las magnitudes físicas asociadas al propio motor, como lo pueden ser corrientes estatóricas de alimentación, señales de vibración del marco del motor, señales acústicas, cambios de temperatura, flujo magnético de dispersión, entre otros. De esta manera, se sabe que es posible observar cambios, tales como aumentos en la amplitud de frecuencias específicas y que son relacionadas al fallo, cambios en el gradiente de temperatura, cambios en la amplitud las señales de vibración, de emisión sonora, entre otros. Por lo anterior, la idea principal de la metodología propuesta es caracterizar esos cambios y comportamientos dinámicos de las señales de flujo de dispersión magnética (que es capturado en la periferia del marco del motor) cuando ocurre una falla específica respecto al estado base, esto es, cuando el motor se encuentra en estado saludable. Así entonces, se propone el empleo de indicadores estadísticos y no estadísticos obtenidos a partir de la señal normalizada (capturada en el dominio del tiempo) del flujo magnético de dispersión, de la densidad de energía de zonas específicas a partir de mapas tiempo-frecuencia (obtenidos mediante la aplicación de herramientas de descomposición tiempo-frecuencia como lo son STFT, y ST-MUSIC), y a partir de indicadores normalizados (γ_{DWT}) obtenidos a partir de la DWT. Todos estos indicadores permiten caracterizar claramente el comportamiento dinámico de dicha señal, y a su vez identificar cambios debidos a fallas específicas. Finalmente, sabiendo la relevancia de poder generar un diagnóstico automático y oportuno, se propone el empleo de técnicas de inteligencia artificial como lo es redes neuronales artificiales, y análisis discriminante lineal (LDA) para el manejo de los indicadores anteriormente mencionados. De esta manera es posible generar agrupaciones de datos que comparten características similares, maximizar la distancia entre grupos y minimizar la dispersión dentro de los grupos. Estos grupos hacen referencia precisamente a los diferentes fallos que se



estudian en este trabajo de tesis. Por último, una vez agrupados y caracterizados los diferentes fallos que suelen ocurrir en los motores eléctricos de inducción, estos son identificados de forma automática por la red neuronal artificial. A continuación, se detallan las etapas de dicha propuesta.

La Figura 29 muestra el diagrama de flujo de la metodología propuesta. Como se puede observar, la propuesta se compone esencialmente de 5 etapas de procesamiento como se detalla a continuación:

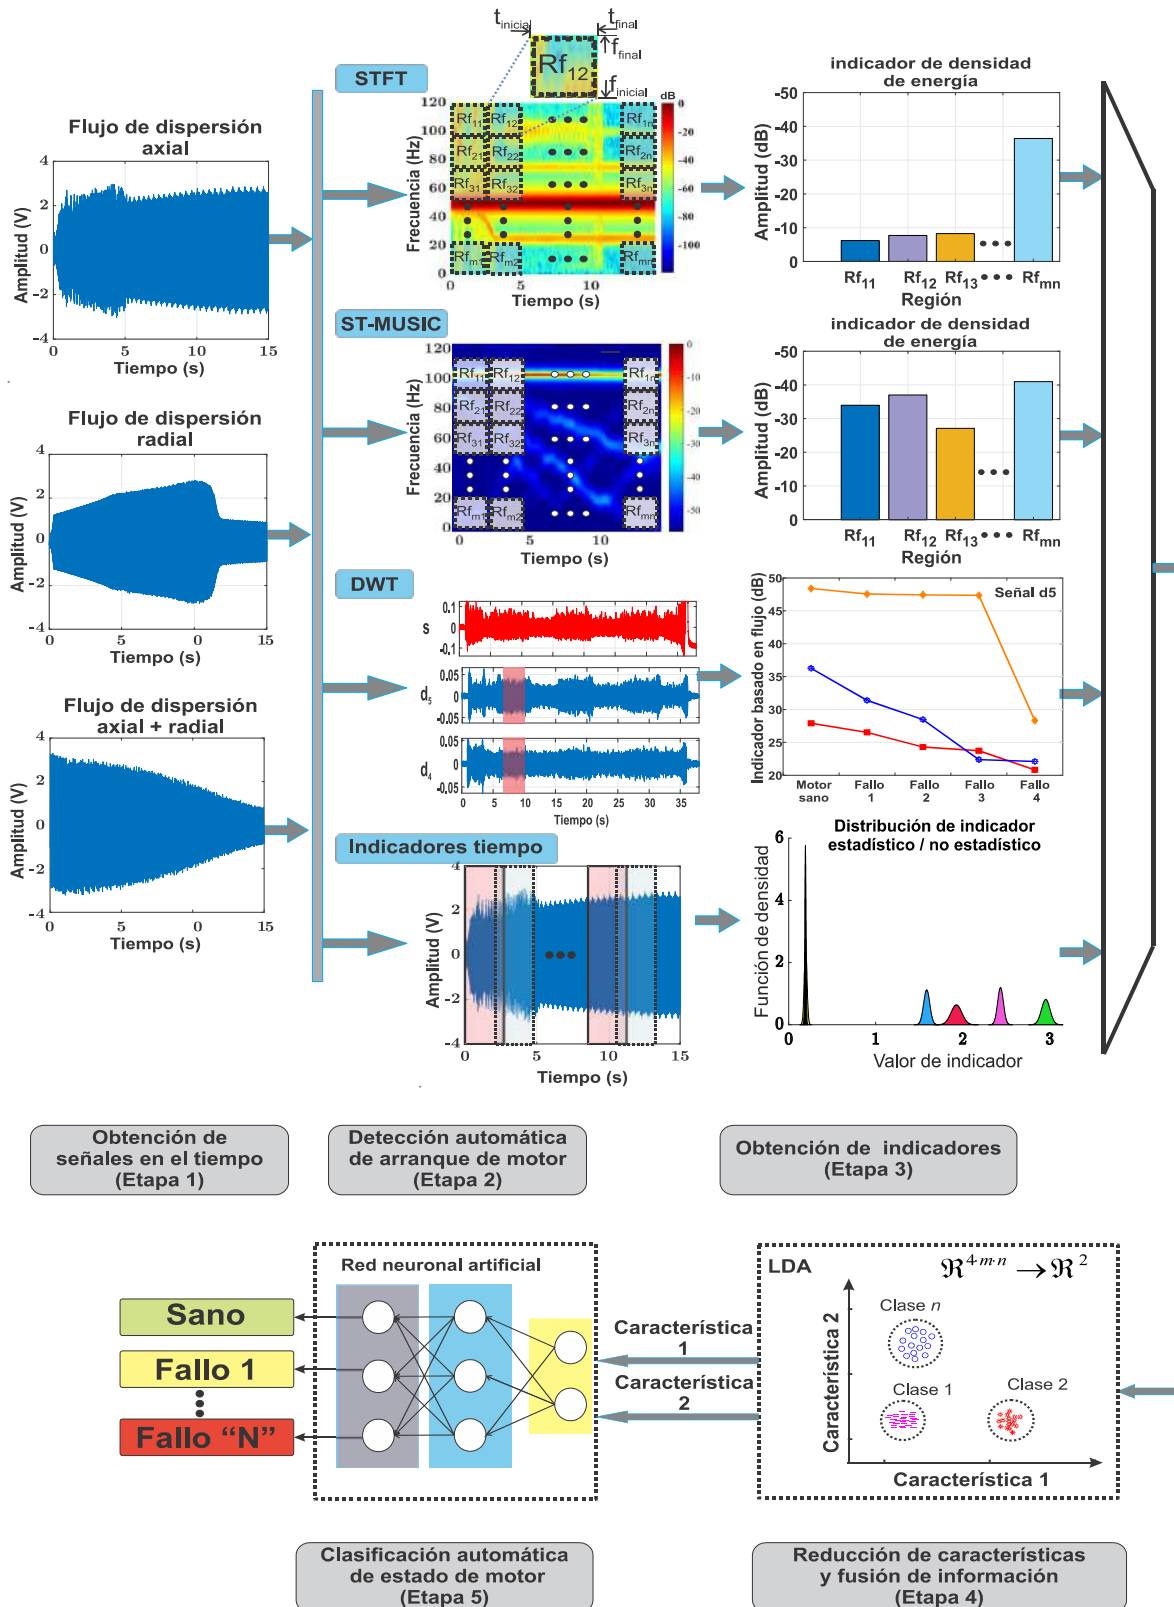


Figura 29. Flujo de señal de la metodología propuesta (autoría propia).



1. **Adquisición de señales del flujo magnético de dispersión** (flujo de dispersión axial, radial, y axial + radial). Para adquirir las diferentes componentes del flujo magnético de dispersión se propone el empleo y la instalación del sensor de flujo de dispersión triaxial propuesto en la presente tesis, y que se detalla en la sección 4.2. Este sensor puede ser instalado en la periferia de la carcasa, como se muestra en la Figura 23. Se plantea el empleo de este sensor debido a las ventajas que representa sobre algunas otras alternativas (como los convencionales sensores tipo bobina), ya que permite capturar las diferentes componentes magnéticas del flujo de dispersión desde un mismo punto en la periferia de la carcasa del motor, permite capturar inclusive flujos magnéticos constantes, es de reducido tamaño lo que posibilita su instalación inclusive en lugares donde es complicado acceder en la máquina bajo análisis (es decir en lugares reducidos), y es un sensor de muy bajo costo. Por otro lado, también es posible emplear sensores tipo bobina, como el que se describe en la sección 4.1.1; sin embargo, para capturar simultáneamente las diferentes componentes magnéticas del flujo de dispersión es necesario instalar tres sensores en tres posiciones diferentes de la carcasa del motor (como se muestra en la Figura 20), lo cual en términos prácticos no siempre es posible. Para adquirir estas señales es necesario contar con un grabador de señales como lo es un osciloscopio, o un sistema de adquisición de señales (DAS, por su abreviatura en inglés Data Acquisition System) adecuado para ello.

2. **Detección automática del arranque del motor.** Debido a que algunos de los indicadores propuestos aquí se basan en la densidad de energía de diferentes zonas de interés del mapa tiempo-frecuencia (obtenido de las señales capturadas durante el arranque del motor) es indispensable contar con una metodología capaz de garantizar de forma automática que la señal capturada corresponde exclusivamente al arranque del motor. Para ello, en este trabajo de tesis se plantea un método simple para aislar el transitorio de arranque mediante un algoritmo sencillo, y que no demanda mucha carga computacional, tal como se describe a continuación (y que se proporciona más detalle en la sección 3.5):
 - i. Obtener la envolvente superior de la señal en el dominio del tiempo, como se muestra en la Figura 30. Para ello se puede seguir el procedimiento propuesto por [Jarne \(2018\)](#).

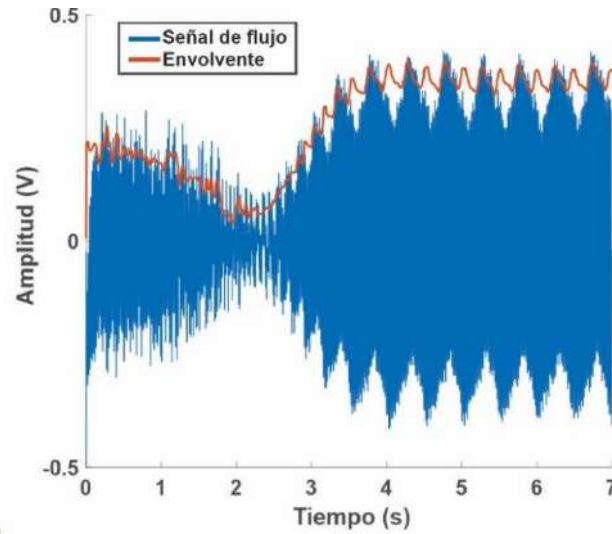


Figura 30. Obtención de envolvente superior de señal capturada en el dominio del tiempo (autoría propia).

- ii. Establecer un valor límite (obtenido a través de las últimas muestras). Este valor límite es igual al promedio de la amplitud de la envolvente en estado estable, y cuya intersección con el eje del tiempo será prácticamente el final del transitorio de arranque. Este hecho se puede observar en la Figura 31.

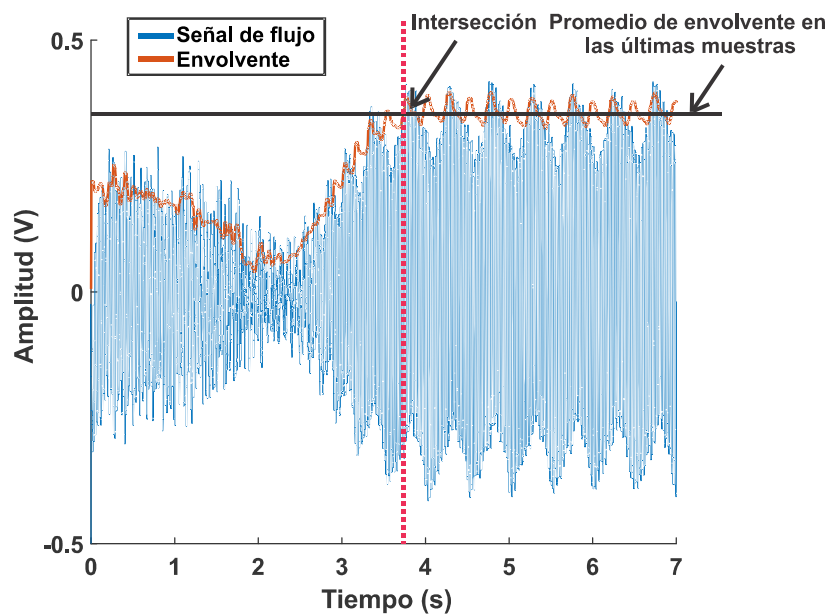


Figura 31. Obtención de transitorio de arranque a partir de la envolvente de la señal en el tiempo (autoría propia).

3. **Obtención de indicadores estadísticos y no estadísticos.** Esta es una de las etapas críticas de la metodología propuesta, ya que aquí es donde se realiza la caracterización de la señal mediante distintos indicadores estadísticos, y no estadísticos. Como puede apreciarse en la Figura 29, es posible distinguir cuatro posibles alternativas de indicadores, como se detallan a continuación:

- i. Indicadores basados en la densidad de energía de zonas específicas de interés en el mapa tiempo-frecuencia obtenido mediante la técnica STFT. En este caso particular, la idea principal es caracterizar los patrones y trazas de la evolución de los armónicos que son amplificadas debido a un fallo en específico. Estos patrones son visibles durante el transitorio de arranque, ya que como se abordó en secciones anteriores, la mayoría de estos armónicos de fallo son dependientes del deslizamiento del motor que, recordando, dicho deslizamiento tiene un valor de 1 cuando el motor se encuentra detenido, y se aproxima a un valor cercano a cero cuando alcanza el estado estable. Estas evoluciones se identifican mediante el uso de algunos indicadores, que corresponden a la media aritmética y la energía máxima de regiones específicas del mapa tiempo-frecuencia (representadas como áreas sombreadas en la Figura 29), y que se muestra de forma ampliada en la Figura 32 para mayor claridad. Dichos indicadores se pueden calcular mediante (56) y (57) para la energía media y máxima, respectivamente.

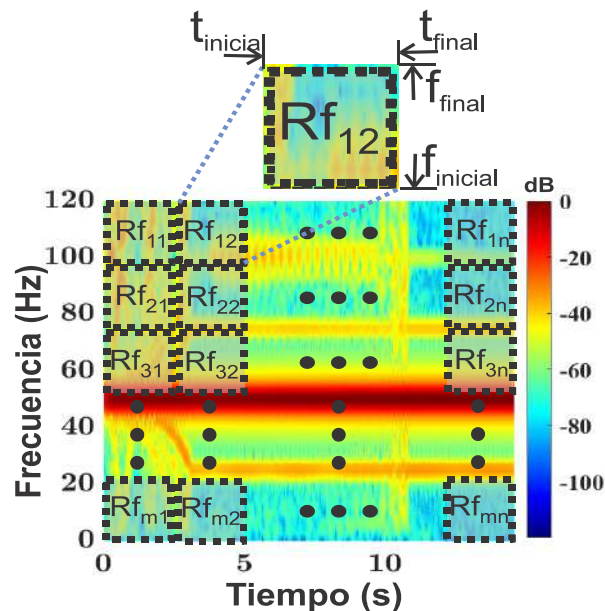


Figura 32. División del mapa tiempo-frecuencia STFT en regiones de interés $Rf_{11}, Rf_{12} \dots Rf_{mn}$ (autoría propia).



$$\text{mean}(RF_{ij}) = \frac{1}{N_{dp}} \left(\sum_{k=t_{inicial}}^{t_{final}} \sum_{l=f_{inicial}}^{f_{final}} (E_{k,l})_{RF_{ij}} \right) \quad (56)$$

$$\text{max}(RF_{ij}) = \text{max} \left(\sum_{k=t_{inicial}}^{t_{final}} \sum_{l=f_{inicial}}^{f_{final}} (E_{k,l})_{RF_{ij}} \right) \quad (57)$$

donde $E_{k,l}$ es la densidad de energía normalizada (sobre el componente de frecuencia fundamental) en la coordenada (k,l) de la región del mapa tiempo–frecuencia bajo consideración (es decir, $RF_{i,j}$), $f_{inicial}$ y f_{final} son, respectivamente, las muestras de frecuencia inicial y final que definen la región tiempo–frecuencia considerada, $t_{inicial}$ y t_{final} son, respectivamente, las muestras de tiempo inicial y final que definen la región tiempo–frecuencia analizada, y N_{dp} es igual al número total de puntos de datos encerrados por la región procesada.

- ii. Indicadores basados en la densidad de energía de zonas específicas de interés en el mapa tiempo-frecuencia obtenido mediante la técnica ST-MUSIC. Este es un caso similar al del punto abordado anteriormente; sin embargo, en lugar de emplear la técnica STFT, se hace uso de una técnica de alta resolución como lo es el algoritmo MUSIC, mismo que se describe con mayor detalle en la sección 3.2.2 de este trabajo. Se propone el empleo de esta técnica para los casos donde el arranque del motor es de muy corta duración (menor a 1 s), ya que las ventajas de esta técnica permiten distinguir la evolución de armónicos que se desarrollan muy cercanos entre sí, como lo son aquellos cuya trayectoria es cercana a la componente fundamental, y que debido a su gran amplitud dificultan, o en el peor de los casos imposibilitan la distinción de los armónicos amplificadas por un fallo. Cabe recalcar que, debido a sus características, la aplicación de la técnica ST-MUSIC es especialmente adecuado para detectar componentes de baja amplitud en señales con una baja relación señal/ruido (alto nivel de ruido en la señal).
- iii. Indicadores basados en la técnica DWT. En este caso se obtiene un indicador basado en la energía de una banda frecuencial previamente seleccionada, y que correspondiente a aquella en la que se estima que el armónico de fallo evolucionará en algún momento durante su trayectoria durante el arranque del motor. Para obtener este indicador se propone el empleo de la energía γ_{DWT} , mismo que se proporciona información más



detallada en la sección 3.1.3 de este trabajo. Este indicador es adecuado para medir las amplitudes en una banda de frecuencia limitada en la que aparece una componente de falla, y su uso está basado en el hecho que las energías de la componente wavelet, que contiene la banda de frecuencia donde aparece el fallo, aumentan a medida que aumenta la severidad de la falla estudiada, y para el caso en que se analiza una señal capturada en el tiempo a partir de una magnitud física (como corrientes, sonido, vibraciones, etc.) relaciona esta señal (capturada por el sensor correspondiente) con el de la señal wavelet que contiene la mayor parte de la componente de frecuencia de falla.

- iv. Indicadores estadísticos y no estadísticos a partir de la señal en el dominio del tiempo. Mediante el cómputo de indicadores estadísticos y no estadísticos de una señal del dominio del tiempo, como se indica en la sección 3.1.2, es posible obtener información relevante sobre el comportamiento de un sistema. Esto debido a que un sistema con diferentes condiciones de operación tiene señales con parámetros estadísticos variados, por lo que se espera que un estado de falla se vea reflejado en dichas características o indicadores (Caesarendra et al., 2017). En este sentido, la idea principal de emplear y extraer indicadores y características de cualquier magnitud física (adquirida a partir de un sistema bajo estudio) para la detección de fallas en el mismo es obtener parámetros que puedan reflejar correctamente la condición de trabajo de un sistema y, en consecuencia, identificar sus patrones de falla (Caesarendra et al., 2017).

4. Reducción de características aplicando un análisis discriminante lineal, LDA.

De esta manera es posible combinar la información más relevante proporcionada por las características más discriminatorias y obtener una transformación a 2 características finales (Característica 1 y Característica 2). Luego de eso, se obtiene una proyección bidimensional, donde se maximiza la distancia euclidiana entre diferentes severidades de falla. Esta proyección permite observar la agrupación de datos entre diferentes severidades de fallas, ya que el eje de proyección principal se selecciona para ser la Característica 1 y la Característica 2, respectivamente.

5. **Clasificación automática del estado de la máquina bajo análisis mediante técnicas de inteligencia artificial.** Para los objetivos de este trabajo, se utiliza una red neuronal artificial con funciones de activación tangente hiperbólica y lineal en las capas oculta y de salida, respectivamente, lo que permite un fácil aprendizaje



(Feng et al., 2019). Se selecciona esta arquitectura debido a su sencillez, alto rendimiento como clasificador automático y los bajos recursos de cómputo demandados para su procesamiento. Las características obtenidas después del análisis discriminante lineal se alimentan al clasificador basado en la red neuronal artificial, que está entrenado para clasificar entre las diferentes fallas estudiadas.



6. RESULTADOS Y DISCUSIÓN.

En esta sección se presentan los resultados obtenidos al aplicar la metodología propuesta a diversos casos de estudio, sobre distintos bancos de motores con diferentes características constructivas. Por cada caso de estudio se pone en contexto la relevancia de su aplicación mediante una subsección denominada motivación del caso de estudio. Como puede apreciarse a continuación, por cada caso de estudio se expone la necesidad, las ventajas, y la pertinencia de contar con una metodología de diagnóstico automático como la que se propone en este trabajo de tesis. Debido a que se estudian diversas fallas electromecánicas que suelen ocurrir en motores eléctricos de inducción, a saber: barras de rotor rotas, excentricidades, desalineamientos, engranes desgastados, asimetrías de rotor en motores de inducción de rotor bobinado, fallas de pista exterior en rodamientos de bolas, entre otras, una gran diversidad de bancos de motores, y asimismo motores con diversas características fueron probados, por lo que se ha puesto a disposición una subsección exclusiva para dar detalle del banco de motores empleado, las señales capturadas, la forma de instalar el sensor de flujo de dispersión, la forma de capturar las señales, la forma de inducir el fallo, entre otra información de gran relevancia con el fin que el lector disponga de los elementos necesarios para poder analizar y replicar los resultados aquí encontrados y discutidos. Adicionalmente se da detalle de los parámetros específicos y de la técnica empleada en cada caso de estudio. Finalmente, se examina con detalle los resultados obtenidos mediante la discusión de los diversos análisis llevados a cabo.

Debido a que la metodología propuesta se encuentra enfocada principalmente en caracterizar el comportamiento dinámico de las diversas señales del flujo magnético de dispersión capturado en el marco del motor bajo análisis, el alcance de la misma es muy extenso, de tal manera que como caso de estudio, tras una amplia revisión de la literatura se propuso el análisis de señales de flujo magnético de dispersión mediante la metodología propuesta para el diagnóstico de desgaste de herramientas de corte en máquinas de control numérico computarizado (máquinas CNC). Por lo anterior, primeramente, se abordan los casos de estudio relacionados al diagnóstico de diversas fallas electromecánicas en motores eléctricos de inducción (sección 6.1 a sección 6.5), y posteriormente se aborda el caso de estudio relacionado al diagnóstico de desgaste de herramientas en máquinas CNC (sección 6.6).



6.1 Aplicación de la metodología propuesta para el diagnóstico automático de asimetrías de rotor en motores de inducción de rotor bobinado.

6.1.1 Motivación del caso de estudio

Los motores de inducción de rotor bobinado pueden desarrollar pares de arranque elevados con corrientes de arranque más bajas, lo que los hace adecuados para aplicaciones industriales como molinos de bolas, grúas, bombas, ventiladores y sopladores, cintas transportadoras, astilladoras o montacargas (Technology, 1997; Toliyat et al., 2018). Recientemente, se han utilizado masivamente como generadores en unidades de turbinas eólicas. Uno de los inconvenientes de los motores de rotor bobinado (WRIM por su abreviatura en inglés, Wound Rotor Induction Motor), en comparación con sus contrapartes de rotor de jaula de ardilla, es su mantenimiento más delicado debido a la complejidad de configuración del circuito del rotor, lo que implica el uso de sistemas de anillos colectores/escobillas para acceder al devanado del rotor. Estos sistemas son propensos a sufrir diferentes tipos de fallas debido a contactos defectuosos entre los anillos colectores y las escobillas, desgaste desigual de las escobillas en las tres fases, juntas de alta resistividad y apriete inadecuado o desigual de los resortes. De hecho, algunos estudios han demostrado que la mayoría de las fallas de los motores eléctricos se pueden atribuir a los cojinetes y devanados (Bonnett et al., 2008). Las asimetrías en el devanado del rotor pueden tener consecuencias muy negativas, provocando sistemas desequilibrados de corrientes de rotor con pares parásitos posteriores y también pueden causar vibraciones excesivas y disipaciones de alta energía (Bellini, et al., 2008). Estos pueden conducir a un funcionamiento anormal del motor e incluso a daños irreparables en el aislamiento, causando pérdidas notables para las empresas involucradas (Grande-Barreto et al., 2017). A continuación, se muestran los resultados obtenidos al aplicar la metodología propuesta para la detección de fallas de asimetría en el rotor de un motor de inducción de rotor bobinado. El procedimiento de diagnóstico propuesto fue validado en el laboratorio en un motor de inducción de rotor bobinado de 4P, 400 V, 11 kW. Los devanados del rotor se ubicaron en 24 ranuras y la resistencia por fase fue de 0.335 Ω (Zamudio-Ramirez, Antonino-Daviu, et al., 2020). Se realizaron varios experimentos tanto para el motor en condiciones sanas como para el motor con hasta cuatro niveles de asimetrías inducidas en el rotor. Así entonces, mediante este caso de estudio se prueba la validez de la metodología para el diagnóstico automático de diferentes niveles de gravedad de fallo en los motores tipo WRIM, lo que aporta a la literatura, puesto que no se



había propuesto ninguna metodología que analice el transitorio de arranque para el diagnóstico de estas fallas mediante señales de flujo magnético de dispersión, y más aún, proponer un indicador de gravedad de fallo.

6.1.2 Puesta en marcha de experimentos

El nivel de falla inducida en el motor se controló mediante un reóstato externo insertado en serie con uno de los devanados del rotor. Así entonces, al variar la resistencia del reóstato se lograron diferentes niveles de asimetría del rotor. El reóstato consiste en una resistencia variable con diez niveles diferentes de impedancia, mismos que pueden ser seleccionados por el usuario mediante una perilla. Este hecho se puede apreciar en la parte superior derecha de la Figura 33. El nivel máximo de resistencia de fase a fase fue de $11,6 \Omega$ (paso 10) y el mínimo de $0,14 \Omega$ (paso 1). Además, para obtener los componentes de flujo axial y radial, se instaló un sensor de flujo en la carcasa del motor en las tres posiciones A, B y C (revisadas anteriormente en la Figura 19). El sensor de flujo magnético fue elaborado a partir de una bobina circular construida a partir de alambre de cobre esmaltado con 1000 espiras. El diámetro exterior de dicho sensor es de 80 mm , mientras que el diámetro interior es de 39 mm . Las señales de fuerza electromotriz (*fem*) inducidas se capturaron durante el arranque del motor, y en estado estable conectando el sensor de bobina a un osciloscopio capaz de registrar la forma de onda en forma digital, mismo dispositivo donde se almacenaron los datos medidos. Se fijó una frecuencia de muestreo $f_s = 5 \text{ kHz}$ y un tiempo de adquisición de 60 s , suficiente para capturar el estado transitorio y estable del motor. La Figura 33 muestra el motor de inducción de rotor bobinado probado, el sistema de adquisición de señales, el reóstato externo y una de las posiciones consideradas del sensor de flujo magnético tipo bobina (Posición B). Los experimentos se desarrollaron bajo diferentes niveles de carga (sin carga, carga parcial y carga nominal). La condición sin carga es una situación más crítica para detectar los componentes relacionados con fallas en las señales de flujo magnético de dispersión, debido al valor reducido del deslizamiento s . Bajo esta condición, los métodos clásicos de estado estacionario pueden tener dificultades para detectar los componentes $f \cdot (1 \pm 2 \cdot s)$, ya que estos pueden superponerse con la frecuencia de suministro f debido al bajo valor de deslizamiento. El método basado en transitorios de arranque propuesto evita este problema, ya que los patrones de falla están claramente presentes durante el arranque, independientemente del nivel de carga.

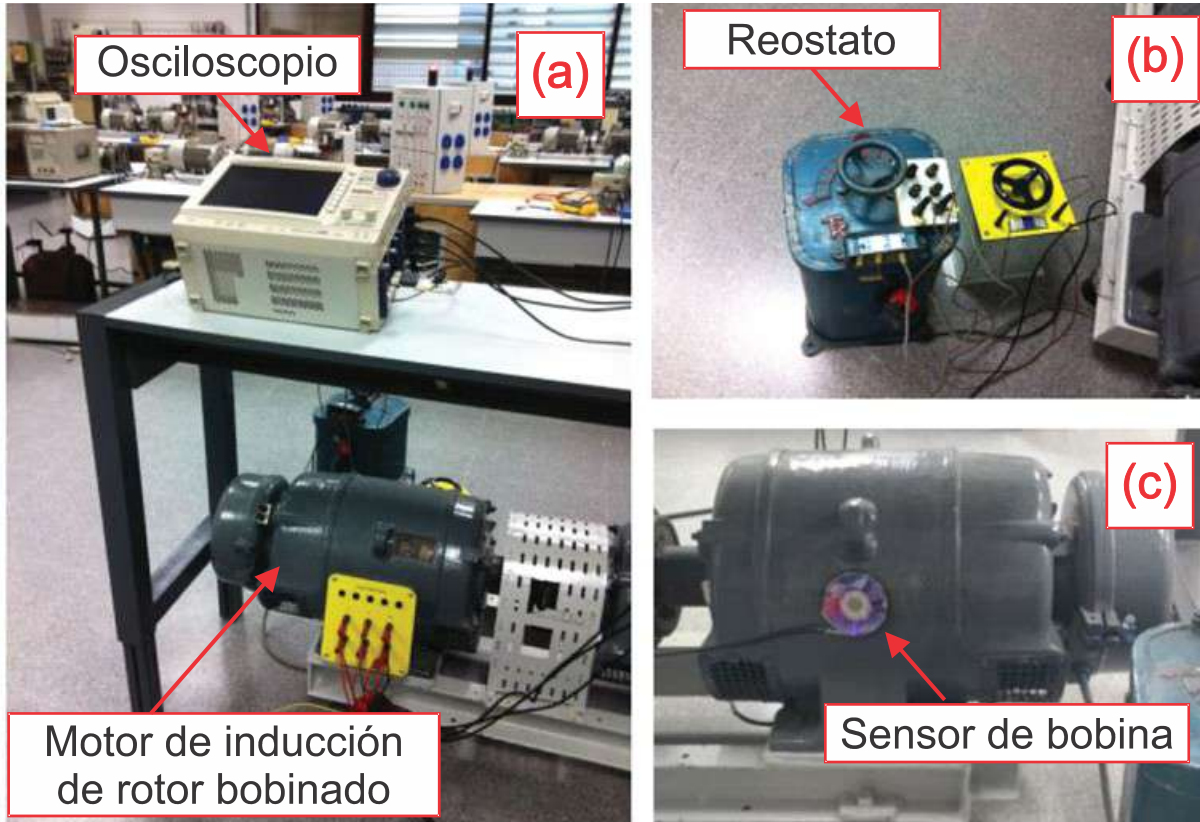


Figura 33. Banco de pruebas de laboratorio: (a) osciloscopio registrador de forma de onda y motor de inducción de rotor bobinado probado; (b) reóstato externo para forzar las asimetrías; y (c) sensor de flujo magnético instalado en la posición B (Zamudio-Ramirez, Antonino-Daviu, et al., 2020).

6.1.3 Resultados y discusión del caso de estudio.

Para realizar el análisis de las señales correspondientes, los datos medidos se transfirieron a una computadora donde se aplican técnicas adecuadas de procesamiento de señales digitales. Debido a que el análisis presentado aquí se centra en una banda de frecuencia específica por debajo de 150 Hz , ya que la frecuencia de suministro es igual a 50 Hz (para este caso particular) y la frecuencia máxima de la componente amplificada por el fallo corresponde a 3 veces la frecuencia de suministro cuando el deslizamiento es 1, la señal de interés se filtra mediante un filtro Butterworth de cuarto orden con una frecuencia de corte de 150 Hz . Luego, para los análisis de tiempo-frecuencia, se aplicaron dos herramientas diferentes a las señales capturadas mediante el sensor de bobina y almacenadas durante el transitorio de arranque. Por un lado, la STFT se usa para rastrear la evolución de los componentes de falla durante el transitorio de arranque del motor. En condiciones saludables, se espera que solo se encuentre presente la componente



fundamental de alimentación del motor; debe aparecer como una línea horizontal en la frecuencia de suministro (50 Hz para este caso de estudio). Bajo la presencia de asimetría del rotor, se estima que la componente fundamental esté acompañada por los patrones característicos tiempo-frecuencia causados por la evolución de los componentes amplificados debidos a la falla estudiada. La segunda técnica de procesamiento de señales utilizada es la DWT. Una buena selección de la señal wavelet es fundamental para que el diagnóstico sea fiable, por lo que esta señal wavelet debe cubrir parte de la banda de frecuencia donde evoluciona la componente de fallo considerada que, como se vio en la sección 2.2.6 (para el caso de fallas de asimetría en motores de rotor bobinado) corresponde en la banda de frecuencias cubierta por el incremento de la componente $f \cdot (1 - 2 \cdot s)$ durante el arranque del motor. Esto hace que sea posible captar los cambios de amplitud en los niveles de energía que se producen cuando la falla se encuentra presente, ya que estos armónicos desaparecen junto con la falla. Para este propósito, la Figura 34 muestra los análisis DWT de las señales f_{em} inducidas en el sensor de bobina en las posiciones A, B y C durante el arranque del motor (se usó $db\ 44$ como wavelet madre para los análisis). En esta figura se puede apreciar los diferentes niveles de descomposición wavelet para los casos cuando el motor está en buen estado (ver lado izquierdo de la Figura 34) en contraste a las del motor con presencia de asimetría en el rotor (ver lado derecho de la Figura 34). La forma de onda superior (en color rojo) es la señal f_{em} analizada. Las formas de onda que se muestran a continuación corresponden a las señales wavelet que son más relevantes para los propósitos descritos en este caso de estudio, a saber, $d6$, $d7$, $d8$ y $a8$, mismas que cubren una banda de frecuencias desde los 0 Hz hasta los 78.12 Hz.

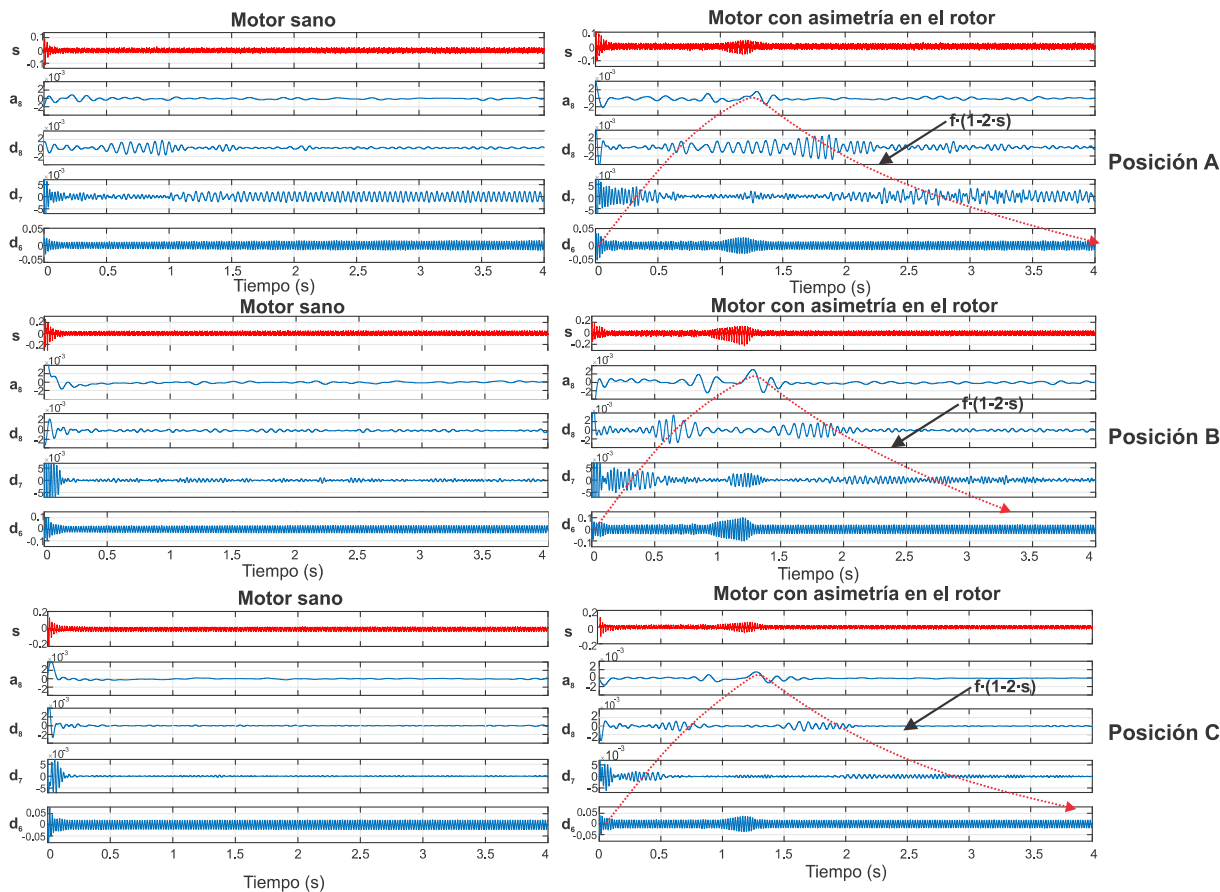


Figura 34. Análisis DWT de la señal fem durante el arranque del motor (señal roja) con el sensor en las tres posiciones diferentes estudiadas aquí para un motor sano (lado izquierdo) y para un motor con asimetría de rotor (lado derecho) (Zamudio-Ramirez, Antonino-Daviu, et al., 2020).

Es de destacar que las señales $d7$, $d8$ y $a8$ tienen amplitudes de oscilaciones muy bajas cuando el motor está sano. Por otro lado, cuando el motor tiene presencia de fallas de asimetría de rotor, aparecen oscilaciones muy claras con amplitudes mayores en las señales $d7$, $d8$ y $a8$ (ver el lado derecho de la Figura 34). Esto se atribuye principalmente a que la energía de estas señales se ve afectada por la evolución temporal de la componente $f \cdot (1 - 2 \cdot s)$ creada por la falla del rotor, de tal forma que cuando el motor está conectado y comienza su aceleración, la componente de falla aparece partiendo de la componente frecuencial fundamental (señal $d6$), y luego evoluciona a través de las señales $d7$, $d8$ y $a8$, mismas que cubren las bandas de frecuencia por debajo de 50 Hz siguiendo un patrón específico. Posteriormente, el deslizamiento es aproximadamente cero, como se indica en los gráficos correspondientes por las flechas punteadas de color rojo. Obsérvese que también hay otras oscilaciones menores en estas señales causadas por la evolución de otros componentes relacionados con fallas (por ejemplo, en $s \cdot f$). Considerando esto, se propone emplear la información proporcionada por la señal wavelet $d8$, que cubre el rango de frecuencias [10-20 Hz], debido a que la frecuencia de muestreo

utilizada es de 5 kHz, por lo que se analiza una parte de la mencionada y deseada banda de frecuencias. La Figura 35 ilustra las diferencias en las amplitudes de las oscilaciones que aparecen en la señal d_8 , para el sensor colocado en la Posición B. Obsérvese que, cuanto mayor es la gravedad de la falla, mayor es la amplitud de estas oscilaciones, lo que demuestra que la energía de estas señales se ve afectada por las fallas de asimetría del rotor en el WRIM. En la misma figura, las áreas resaltadas en rojo son las áreas utilizadas para el cálculo del indicador de flujo γ_{DWT} , mismo que se describe en la sección 3.1.3. Estas áreas corresponden precisamente al intervalo de tiempo en el que la evolución de la falla penetra la señal d_8 .




Figura 35. Análisis DWT de la señal fem inducida en el sensor de bobina cuando este se coloca en la posición B: (a) señal fem total capturada durante el arranque; (b) señal d_8 para un motor saludable; (c) señal d_8 para un motor con asimetría de rotor nivel dos; y (d) señal d_8 para un motor con asimetría de rotor nivel cuatro (Zamudio-Ramirez, Antonino-Daviu, et al., 2020).

Por otro lado, la Figura 36 muestra los análisis de las señales del sensor de la bobina en las tres posiciones (A, B y C) utilizando la STFT cuando el motor tiene fallas de asimetría en el rotor. Esta herramienta permite una visualización más clara del contenido del mapa tiempo-frecuencia. Al respecto, nótese la aparición de las componentes de falla caracterizadas de acuerdo la ecuación (1): por un lado, la componente $(1+2 \cdot s) \cdot f$, que parte de una frecuencia de 150 Hz y va decreciendo hasta aproximarse a la frecuencia fundamental, y, por otro lado, la componente de falla $(1-2 \cdot s) \cdot f$, que evoluciona siguiendo el patrón en forma de “V” comentado anteriormente. Obsérvese también la presencia de la citada componente en $s \cdot f$, de carácter axial, que también se ve amplificada por la asimetría del rotor. Finalmente, también se detecta la evolución de un componente (f_{ecc}) que se debe a la presencia de cierto nivel de desalineación entre motor y carga y que está presente en todas las pruebas. Esta componente viene dada por $f_{ecc} = f - f_r$ y evoluciona desde la frecuencia fundamental ($f = 50 \text{ Hz}$) hasta cerca de $f/2$, ya que la máquina ensayada tiene dos pares de polos.




Figura 36. Análisis STFT de las señales del sensor de bobina capturadas durante el arranque del motor para la máquina con asimetría de rotor y para las tres posiciones del sensor (el color denota la densidad de energía en cada punto del mapa de tiempo-frecuencia, el rojo indica la densidad más alta y el azul la densidad más baja) (Zamudio-Ramirez, Antonino-Daviu, et al., 2020).

De forma similar, la Figura 37 muestra el análisis tiempo-frecuencia utilizando la STFT de las señales de *emf* capturadas durante el transitorio de arranque en tres condiciones diferentes del motor, correspondientes al motor en una condición saludable, con un nivel de severidad de falla dos (resistencia agregada $R_{add}=1.6R_R$ con R_R = resistencia del rotor), y el caso en que el motor estaba operando bajo una falla grave correspondiente a un nivel de severidad de falla cuatro (resistencia añadida $R_{add}=1.9R_R$). Es de resaltar que el motor estaba operando sin carga, esto con la finalidad de demostrar que la propuesta es inmune a problemas de solapamiento de la componente fundamental (que es de gran amplitud) con las componentes frecuenciales amplificadas debido a un fallo de asimetría en el rotor, lo que podría resultar en un falso diagnóstico. Este tipo de falsos diagnósticos suelen ser muy comunes bajo esquemas de detección de falla que se basan en la evaluación de amplitudes de componentes frecuenciales únicas y específicas, como el método convencional MCSA. La Figura 38 es equivalente a la Figura 37 pero para condiciones de carga parcial (3/4 de la carga nominal) y se incluye aquí para demostrar que los resultados también son válidos para la máquina en condiciones de carga. A primera vista, se hace evidente que existen claras diferencias entre las tres condiciones de falla, ya que se visualizan amplitudes mayores en la evolución de la componente frecuencial relacionada al fallo a medida que empeora la asimetría del rotor. En este sentido, las componentes de falla en $f \cdot (1 - 2 \cdot s)$ (radial) y $s \cdot f$ (axial) están presentes en todos los casos de falla, pero sus intensidades mayores o menores dependen de la posición considerada del sensor, como se puede observar claramente en la Figura 37 y Figura 38.

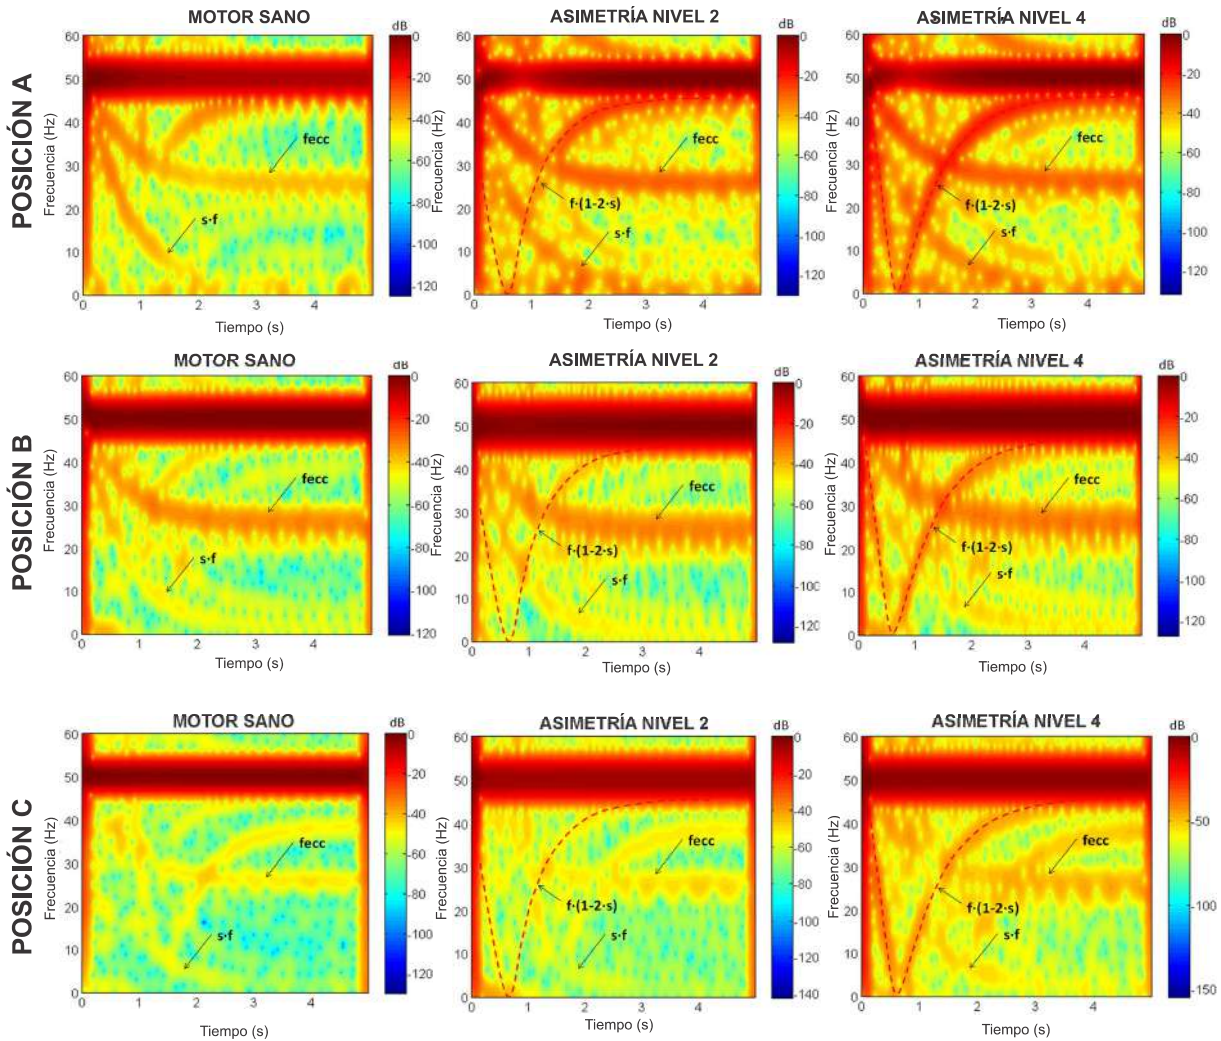


Figura 37. Análisis STFT de las señales del sensor de bobina capturadas durante el arranque del motor para la máquina con asimetría de rotor nivel dos de cuatro y motor con asimetría de rotor nivel cuatro de cuatro, para las tres posiciones consideradas del sensor. El motor funciona en condición sin carga (Zamudio-Ramirez, Antonino-Daviu, et al., 2020)

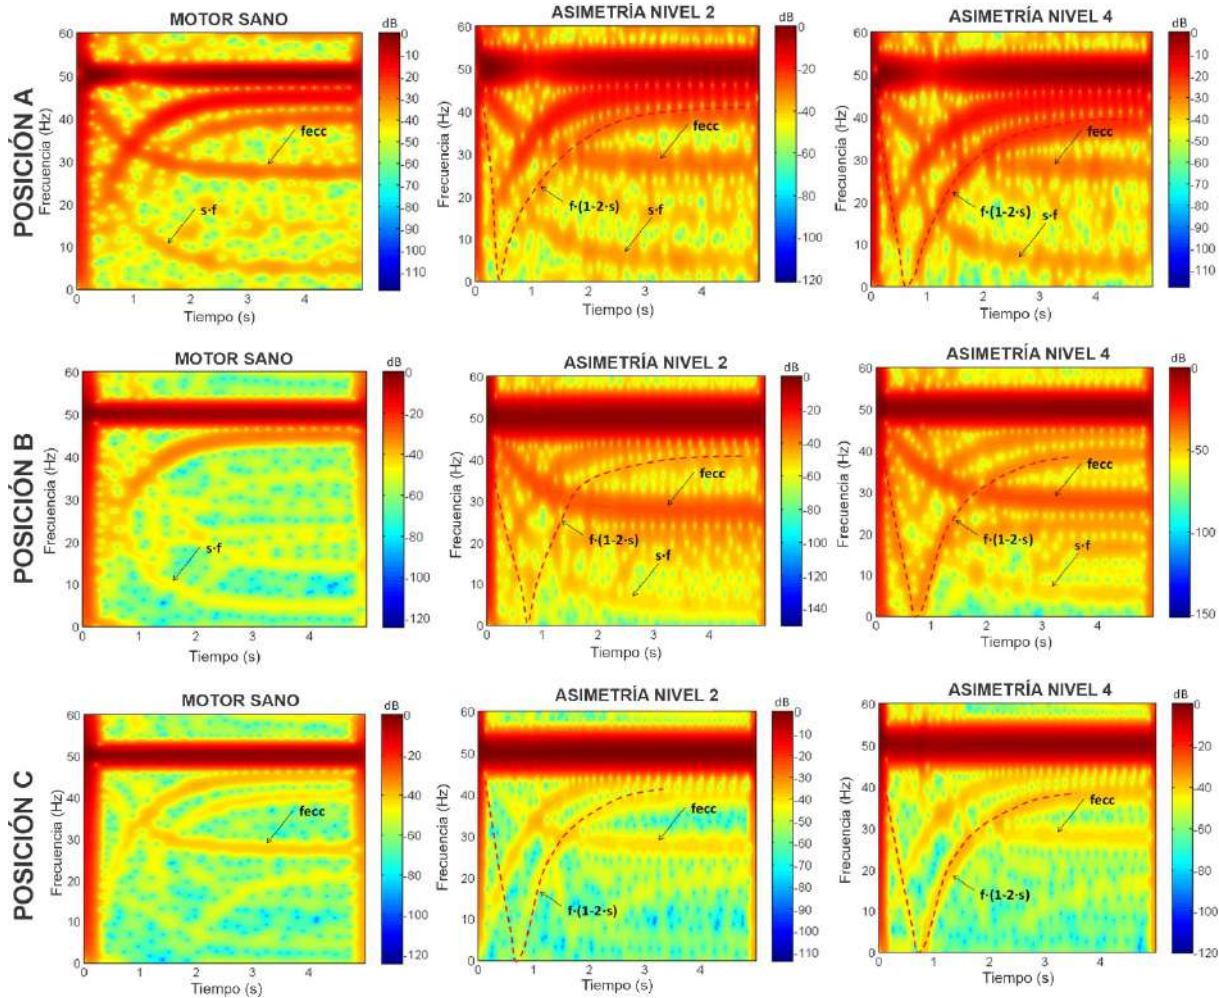


Figura 38. Análisis STFT de las señales del sensor de bobina capturadas durante el arranque del motor para la máquina con asimetría de rotor nivel dos de cuatro y motor con asimetría de rotor nivel cuatro de cuatro, para las tres posiciones consideradas del sensor. El motor funciona en condición sin carga (Zamudio-Ramirez, Antonino-Daviu, et al., 2020).

Más concretamente, tras un cuidadoso análisis del gráfico se pueden obtener las siguientes conclusiones:

1. Con respecto a la componente en $f \cdot (1 - 2 \cdot s)$, su evolución es claramente discernible para cada condición de falla en cada posición del sensor. Además, su intensidad aumenta a medida que empeora la asimetría del devanado del rotor (aparece con muy baja intensidad en los casos sanos). Esto indica que este componente es un muy buen candidato para detectar la presencia de la asimetría y cuantificar su severidad, razón por la cual el indicador propuesto en este trabajo de tesis se basa en este componente específico. Por otro lado, aunque esta componente tiene una naturaleza predominantemente radial (Ramirez-Nunez et al., 2018), su evolución se observa para todas las posiciones del sensor, probablemente debido a su amplitud



predominante y porque para cada posición del sensor se capturó una cierta porción del flujo radial.

2. Por otro lado, también se observa claramente la evolución de la componente axial en $s \cdot f$. Este componente es más perceptible en la Posición A, ya que en esta posición del sensor el flujo capturado es principalmente axial. Por lo tanto, esta componente frecuencial (amplificada por la falla) tiene mucha más amplitud para esta posición del sensor, mientras que muestra menos amplitud para la Posición B y, especialmente, para la Posición C. Por otro lado, observe cómo, para cada posición específica del sensor, a pesar de que este componente aumenta su intensidad a medida que aumenta la gravedad de la falla, es claramente observable incluso en condiciones saludables. Esto se debe a que, como se informó en trabajos anteriores, la amplitud de la componente $s \cdot f$ también se ve incrementada por la presencia de desalineaciones/excentricidades. Dado que el motor probado estuvo operando bajo cierto nivel de desalineación en todas las pruebas, esto conduce a un incremento en la amplitud de este componente, incluso para las pruebas correspondientes a la condición saludable del devanado del rotor.

Además, para mostrar el potencial de la metodología propuesta para generar un diagnóstico automático de fallas de asimetría en WRIM, la Figura 39 muestra los resultados obtenidos cuando el indicador de flujo es calculado aplicando la ecuación (39) a la señal wavelet $d8$ obtenida usando la técnica DWT. Estos resultados se obtienen usando el sensor del tipo bobina instalado en las tres diferentes posiciones definidas en la sección 4 de este trabajo (posiciones A, B y C de acuerdo con la Figura 19). En ellos se muestra que es posible detectar la gravedad de las fallas de asimetría del rotor en un WRIM por medio de lecturas de fem de un sensor de bobina externa conectado al motor. Además, como se puede observar, el valor del indicador para el caso en que el motor está sano indica niveles más altos, mientras que cuando la severidad de la falla es cada vez mayor, el indicador arroja valores cada vez más bajos en dB, siguiendo una clara tendencia decreciente cuando el nivel de asimetría es mayor. En efecto, la diferencia entre el motor en buen estado y el motor con mayor severidad de falla considerada es ciertamente amplia, hecho que demuestra la efectividad del indicador. Esta situación se atribuye a que la señal wavelet considerada ($d8$) tiene baja amplitud cuando el motor está en buen estado, mientras que su energía comienza su aumento cuando aparece la componente debida a la falla.




Figura 39. Valores del indicador γ_{DWT} basados en la energía de la señal wavelet d8, para un motor saludable y para cada nivel de asimetría del rotor inducida (Zamudio-Ramirez, Antonino-Daviu, et al., 2020).



6.2 Aplicación de la metodología propuesta para el diagnóstico automático de fallo de barras rotas y desalineamiento durante el arranque del motor.

6.2.1 Motivación del caso de estudio.

Los motores de inducción son componentes esenciales y ampliamente utilizados en muchos procesos industriales. Aunque estas máquinas son muy robustas, son propensas a fallar. Hoy en día es una tarea primordial obtener un diagnóstico fiable y preciso del estado de los motores eléctricos, de forma que se logre una reducción posterior de los tiempos requeridos y costos de reparación. Los enfoques más comunes para llevar a cabo esta tarea se basan en el análisis de corrientes, lo que tiene algunos inconvenientes bien conocidos que pueden conducir a falsos diagnósticos. Con los nuevos desarrollos en el campo de la tecnología de sensores y procesamiento de señales, se debe explorar la posibilidad de combinar la información obtenida del análisis de diferentes magnitudes, con el fin de lograr conclusiones diagnósticas más confiables, antes de que la falla pueda convertirse en un daño irreversible. Las roturas en las barras del rotor en motores de inducción tipo jaula de ardilla pueden ocurrir en las propias barras, en los anillos terminales, o en las uniones entre estas dos partes. De acuerdo a lo reportado en la literatura, se sabe que las fallas del rotor son causadas principalmente por una combinación de diferentes esfuerzos que se presentan en el rotor debido a aspectos electromagnéticos, térmicos, dinámicos, ambientales y mecánicos, como los que se mencionan a continuación ([Hassan et al., 2018](#)):

- Esfuerzos térmicos durante el arranque directo en línea (DOL por su abreviatura en inglés, Direct OnLine) o sobrecarga que causan sobrecalentamiento de la jaula del rotor.
- Tensiones magnéticas debidas a fuerzas electromagnéticas, tirones magnéticos desequilibrados, ruido electromagnético y vibraciones.
- Esfuerzos dinámicos como resultado de cargas mecánicas pulsantes (fluctuaciones de voltaje, oscilación del par del eje y fuerzas centrífugas).
- Esfuerzos mecánicos debido a laminación suelta, piezas fatigadas, y fallas en los rodamientos.
- Estrés ambiental por contaminación y abrasión del material del rotor debido a productos químicos o exposición a la humedad.

Así entonces, resulta de gran relevancia el diagnóstico oportuno y preferentemente de forma automática de barras rotas en motores eléctricos de inducción debido a las diversas repercusiones que una falla de este tipo puede tener, entre otras: si no se atiende a



tiempo, los esfuerzos térmicos provocados por la ausencia de la barra rota en las barras adyacentes puede generar un desgaste mayor e incrementa la rapidez de la evolución, si se llega a desprender una barra puede generar un contacto con el bobinado del estator lo que a su vez puede finalizar en un cortocircuito catastrófico con fallas irreversibles.

En este caso de estudio se explora el análisis ponderado de diversas componentes de flujo magnético de dispersión capturado en la periferia del marco del motor bajo análisis (flujo de dispersión radial, axial y combinación de flujo dispersión axial y radial) mediante el sensor de flujo dispersión triaxial propuesto. Este sensor es compacto, no invasivo, y de bajo costo, mismo que se describe en la sección 4.2. Las señales son capturadas durante el arranque del motor y son analizadas a través de la transformada de Fourier de tiempo corto (STFT). Posteriormente se caracterizan los patrones específicos que aparecen cuando el motor se encuentra operando bajo una falla utilizando parámetros estadísticos y no estadísticos que alimentan un análisis discriminante lineal de reducción de características (LDA) y luego una red neuronal de retro propagación para fines de clasificación, abriendo la posibilidad de ofrecer un esquema de diagnóstico automático de fallas in-situ. Así entonces, mediante este caso de estudio se analiza la pertinencia del sensor de flujo magnético de dispersión triaxial propuesto para capturar de forma simultánea las distintas componentes magnéticas del flujo, proporcionando un avance en los sensores empleados para capturar dichas señales.

6.2.2 Puesta en marcha de experimentos.

La validación de la propuesta se realiza mediante el análisis de varias señales adquiridas de un banco de pruebas de motores de inducción, en el que se estudian algunos de los fallos electromecánicos más comunes que aparecen en este tipo de motores (fallos de barras rotas, y problemas de desalineamiento entre el motor y la carga). La configuración experimental utilizada se muestra en la Figura 40a. El motor de inducción trifásico analizado (modelo WEG 00136APE48T) tiene dos polos, 28 barras en el rotor, potencia nominal de 0.74 KW, factor de potencia de 0,87 y corriente nominal de 2,9A. Se alimenta con 220 Vac a 60Hz. La carga mecánica la proporciona un alternador ordinario que representa aproximadamente el 25% de la carga nominal del motor. Las señales magnéticas del flujo de dispersión (localizado en la periferia de la carcasa del motor) se adquieren usando el sensor triaxial de flujo magnético propuesto en el presente trabajo y descrito en la sección 4.2. Este sensor es colocado junto a la placa de datos (posición A) como se muestra en la Figura 40b. El sistema de adquisición de datos (DAS por su abreviatura en inglés, Data Acquisition System) es fijado a una frecuencia de muestreo de 5 kHz dentro de un período de 30 segundos, que es suficiente para capturar el transitorio de arranque del motor. Así entonces, en primer lugar, el motor de inducción se prueba en

condiciones saludables para establecer una referencia para las consiguientes condiciones de fallos. Posteriormente, se induce una desalineación mecánica muy leve, ya que esta es una falla muy común y que suele generarse inherentemente en la mayoría de los acoplamientos mecánicos, pero que repercute en el desgaste entre el motor y la carga, principalmente. Además, con el fin de ampliar el uso y las capacidades de la metodología propuesta, se indujeron y combinaron una barra de rotor rota (1 BRB) y dos barras de rotor rotas (2 BRB) con desalineaciones (MAL), lo que permitió estudiar dos esquemas de falla combinados diferentes: 1 BRB + MAL y 2 BRB + MAL.




Figura 40. Configuración experimental: (a) banco de pruebas de motor de inducción, (b) vista lateral del banco de pruebas, (c) vista frontal del banco de pruebas (Zamudio-Ramírez et al., 2020).

Para tener una referencia en los diferentes casos aquí estudiados, primero se analizó el motor en estado saludable. Posteriormente, se indujo una desalineación muy leve entre el motor y la carga. La prueba de desalineación se llevó a cabo desplazando hacia adelante

la banda en la polea del motor, de modo que los ejes transversales de rotación del motor y su carga no estuvieran alineados formando un ángulo de separación β como se muestra en la Figura 41b. Esta condición se puede ver claramente comparando el motor alineado (Figura 41a) y el motor desalineado (Figura 41b).




Figura 41. Banco de pruebas de motores. (a) Motor alineado. (b) motor desalineado (Zamudio-Ramírez et al., 2020).

Como segunda falla estudiada, se indujeron barras de rotor rotas en el motor y se combinaron simultáneamente con desalineación. En primer lugar, se analizó el motor con dos barras de rotor rotas y desalineación. Posteriormente, para demostrar que también se pueden diagnosticar fallas de menor gravedad, se indujo una barra de rotor rota en combinación con desalineación. Para producir una condición de barra de rotor rota artificialmente, se perforó un orificio de 2,0 mm de diámetro en una y dos barras del rotor sin dañar el eje del rotor. La Figura 42a muestra el rotor con dos barras de rotor rotas, mientras que la Figura 42b muestra una barra de rotor rota inducida en un segundo rotor que se utilizó durante la prueba.




Figura 42. Banco de pruebas de motores. (a) Dos barras de rotor rotas; (b) Una barra de rotor rota (Zamudio-Ramírez et al., 2020).

6.2.3 Resultados y discusión del caso de estudio.

En la primera etapa del procesamiento de la señal, los flujos magnéticos de dispersión axial, radial y, axial + radial se obtienen a través del sensor de flujo de dispersión triaxial aquí propuesto. Posteriormente, los mapas tiempo-frecuencia obtenidos en un análisis del transitorio de arranque se calculan utilizando la STFT con una ventana del tipo Hamming con una longitud de tiempo de 1024 puntos de datos, que a la frecuencia de muestreo utilizada (5 kHz) representa un ancho de 0.2048 s, el tamaño de salto utilizado entre ventanas consecutivas es de 256 puntos de datos lo que representa un 75% de superposición, y se utilizaron 1024 puntos para el cálculo de la FFT para cada ventana. Esto da una resolución de frecuencia de aproximadamente 4,88 Hz y una resolución de tiempo de 51,2 ms. Estos parámetros se eligen con el fin de tener una buena resolución en el tiempo ya que el transitorio de arranque en motores eléctricos es un parámetro variable que depende en gran medida de la carga del motor. Una vez obtenidos estos mapas, se subdividen en cuatro regiones de interés, que cubren un ancho de banda por debajo de la componente fundamental de alimentación (60 Hz) ya que en esta región evolucionan la mayoría de los armónicos de mayor interés (ligados a las fallas consideradas). Se han considerado las siguientes bandas o regiones de frecuencia: región 1 (~ [0-13] Hz), región 2 (~ [13-26] Hz), región 3 (~ [26-39] Hz) y región 4 (~ [39-52] Hz) como se muestra en la Figura 43.


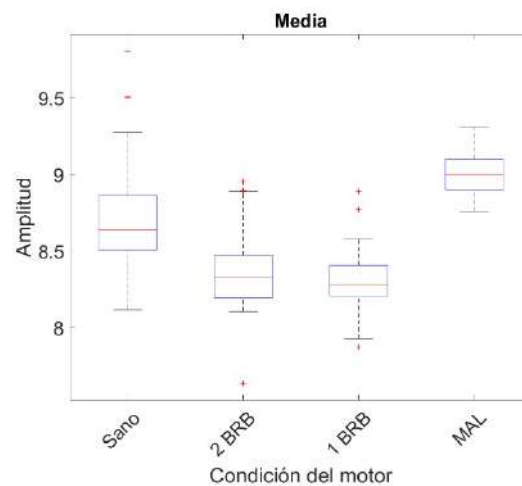



Figura 43. Bandas de frecuencia consideradas para los análisis y caracterización de los mapas STFT (autoría propia).

Una vez desglosados estos mapas de tiempo-frecuencia, se obtienen varios parámetros estadísticos y no estadísticos de cada una de estas regiones para caracterizarlas. Se han considerado los siguientes diez parámetros: (1) energía de la señal, (2) desviación estándar, (3) media estadística, (4) mediana estadística, (5) curtosis, (6) asimetría, (7) raíz cuadrática media, (8) Relación pico-promedio, (9) factor de forma y (10) factor de cresta. Se puede consultar la Tabla 2 que incluye una descripción matemática de cada uno de estos parámetros y la forma en que se pueden calcular. Estos parámetros se eligen debido a su capacidad para proporcionar información relevante sobre cambios y tendencias en las señales al invertir un costo muy bajo en carga computacional. Una vez obtenidos esos parámetros, se genera una matriz de entrada para la reducción de características a través del LDA. Después de eso, el número de parámetros de entrada al LDA es 120: 10 (parámetros estadísticos) \times 4 (bandas de frecuencia) \times 3 (sensores), que se reducen a 3 características significativas (F1, F2, F3) ya que esta reducción permite obtener una representación visual de las diferentes condiciones de falla estudiadas aquí. Luego, la FFNN es entrenada para separar entre clases de las fallas estudiadas. Este módulo se entrena primero a través del algoritmo de Levenberg-Marquardt para identificar una condición HLT en el motor de inducción o la presencia de múltiples fallas. Para ello se capturan cuarenta señales reales muestreadas bajo cada condición de motor, dando como resultado un total de 160 muestras. De las 40 pruebas obtenidas para cada caso de estudio, 32 de fueron utilizadas para el entrenamiento de la FFNN y 8 para la validación de la misma. El entrenamiento de la red neuronal se realizó mediante el uso de un software especializado. La arquitectura final de la red neuronal artificial tiene 3 entradas (número de



parámetros después de la reducción de características de LDA), 2 y 10 neuronas en las capas ocultas y 4 salidas (una por cada condición), que funcionan como indicadores de la condición del motor de inducción. Las figuras Error: Reference source not found-Error: Reference source not found muestran los resultados obtenidos al realizar un análisis de la varianza (ANOVA) de los indicadores más representativos aquí propuestos para todas las muestras conseguidas del flujo axial + radial sobre las diferentes regiones previamente definidas de los mapas tiempo-frecuencia (regiones 1 a la 4, ver Figura 43), es decir, aquellos que muestran una menor superposición para los diferentes casos de estudio considerados (HLT, 1 BRB, 2 BRB, MAL). Como puede apreciarse en dichas figuras, es posible distinguir entre los diferentes fallos al analizar los distintos indicadores aquí mostrados, ya que, en la distribución de estos, no se encuentra superpuestos. Esto permite emplear una técnica de inteligencia artificial (como lo es redes neuronales artificiales) para realizar la combinación de la información proporcionada por todos los indicadores, y así proporcionar un diagnóstico final (clasificación del estado del motor: sano, BRB, 2 BRB, MAL) de forma automática.




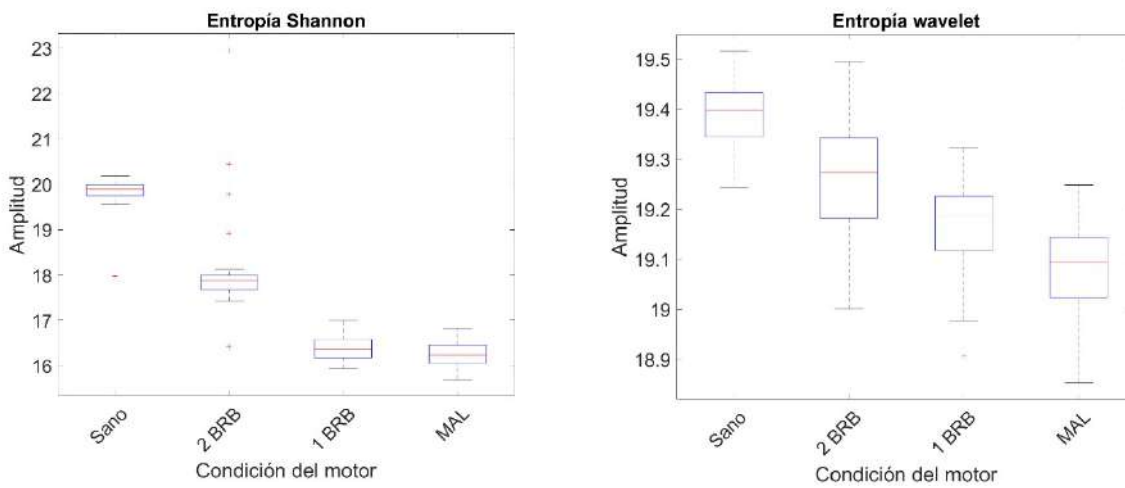


Figura 44. Análisis de la varianza para los distintos casos de estudio procesando la información de la región 4 del mapa tiempo-frecuencia para las señales de flujo axial +radial (autoría propia).







Figura 45. Análisis de la varianza para los distintos casos de estudio procesando la información de la región 3 del mapa tiempo-frecuencia para las señales de flujo axial +radial (autoría propia)..







Figura 46. Análisis de la varianza para los distintos casos de estudio procesando la información de la región 2 del mapa tiempo-frecuencia para las señales de flujo axial +radial (autoría propia).






Figura 47. Análisis de la varianza para los distintos casos de estudio procesando la información de la región 1 del mapa tiempo-frecuencia para las señales de flujo axial +radial (autoría propia).

Debido a que en este caso de estudio se empleó por primera vez el sensor triaxial propuesto (descrito en la sección 4.2) para capturar las diferentes componentes magnéticas del flujo de dispersión desde un solo punto, la

Error: Reference source not found muestra una gráfica de dichas señales en el dominio del tiempo para el caso del motor con dos barras rotas.




Figura 48. Señales en el dominio del tiempo capturadas por el sensor de flujo de dispersión triaxial propuesto: (a) flujo de dispersión axial; (b) combinación del flujo de dispersión axial y radial; (c) flujo de dispersión radial (autoría propia).

Los mapas tiempo-frecuencia obtenidos mediante la técnica STFT al procesar las señales proporcionadas por el sensor triaxial de flujo propuesto y para cada una de las fallas del



motor de inducción estudiadas en el presente caso de estudio: HLT, MAL, 1 BRB + MAL, 2 BRB + MAL se muestran en la Figura 49. De esta figura se puede observar la aparición y evolución de las componentes de falla descritas por la teoría:

- Por un lado, la componente axial en $s \cdot f$ es claramente visible, especialmente cuando se analizan las señales proporcionadas por el sensor primario 1 y 2, que capturan el flujo magnético de dispersión axial, y combinación de flujos de dispersión axial y radial, respectivamente,
- Por otro lado, la componente frecuencial armónica amplificada por el fallo $f \cdot (1 - 2 \cdot s)$ es especialmente visible en el sensor primario 3, que captura principalmente el flujo de dispersión radial.

A través del sensor de flujo magnético de dispersión triaxial propuesto, es posible capturar la evolución de los armónicos de falla del motor de inducción utilizando herramientas especializadas de descomposición tiempo-frecuencia de manera concisa, con la ventaja de poder adquirir estas evoluciones desde una sola posición en la periferia de la carcasa del motor. Los mapas tiempo-frecuencia demuestran este hecho. En estos mapas, se puede ver claramente la aparición de patrones muy característicos, especialmente cuando el motor está operando en una condición de falla. Por el contrario, cuando el motor está en un estado saludable, no se observa un patrón específico. La Figura 49a, muestra los mapas de tiempo-frecuencia obtenidos al analizar la señal proporcionada por el sensor primario 1, el cual captura esencialmente el flujo de dispersión axial. En estos mapas se nota la aparición del armónico $s \cdot f$ (amplificado por fallas de desalineación) y el armónico $f \cdot (1 - 2 \cdot s)$ que es amplificado por barras rotas del rotor. De igual forma, la Figura 49b muestra los mapas tiempo-frecuencia obtenidos al analizar la señal captada por el sensor primario 2, cuyas lecturas corresponden a la adquisición simultánea de los flujos magnéticos de dispersión axial y radial. En comparación con los mapas obtenidos a través del flujo de dispersión axial, es evidente la presencia del armónico $f \cdot (1 - 2 \cdot s)$ aun cuando el motor opera bajo 1 BRB + MAL. Por otro lado, la Figura 49c muestra los mapas de tiempo-frecuencia obtenidos al procesar la señal proporcionada por el sensor primario 3 que corresponde esencialmente a lecturas de flujo de dispersión radial. En estos mapas se evidencia la amplificación del armónico $f \cdot (1 - 2 \cdot s)$ con mayor intensidad (en comparación a los mapas obtenidos a través del flujo axial y la combinación de flujos dispersos axiales y radiales) cuando el motor está operando bajo 2 BRB + MAL, e incluso cuando el motor tiene 1 BRB + MAL.

Así entonces, se puede observar que el sensor triaxial propuesto es capaz de capturar las componentes de falla de forma adecuada, lo que permite realizar el diagnóstico de una forma muy práctica, en cuanto a la instalación de sensores y adquisición de señales se trata, ya que desde un mismo punto en la periferia de la carcasa del motor bajo análisis es

posible adquirir las diferentes componentes de flujo magnético de dispersión de forma simultánea.

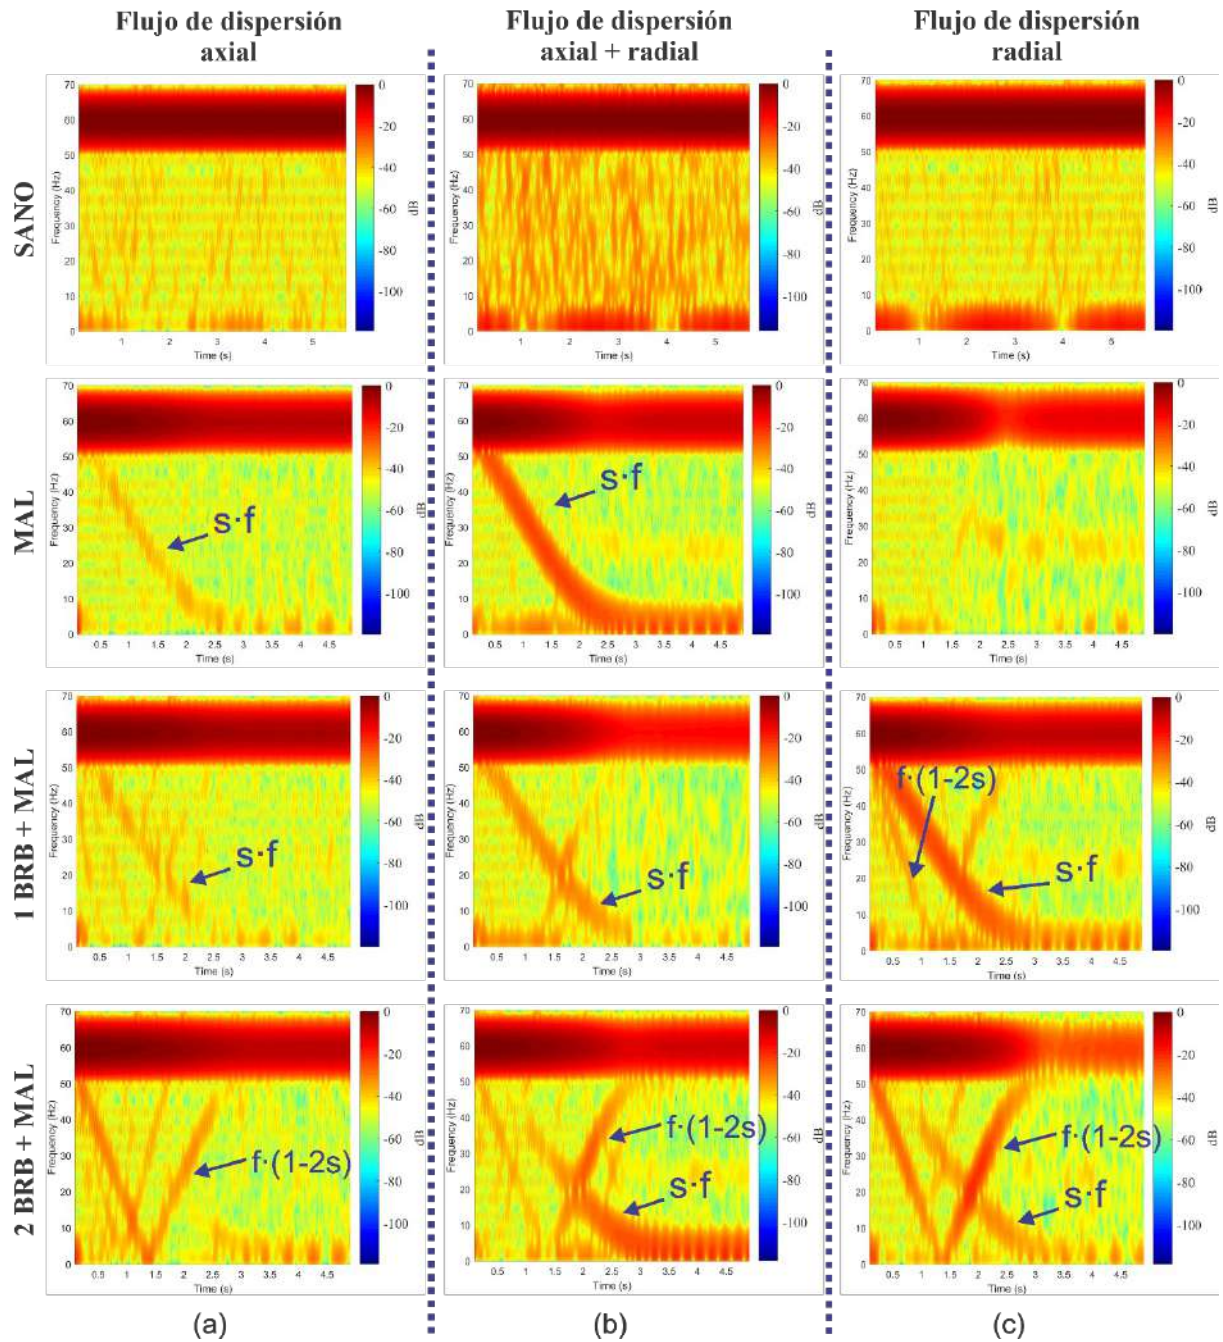



Figura 49. Análisis STFT obtenidos para cada una de las fallas del motor de inducción aquí estudiadas al procesar las señales proporcionadas por el sensor triaxial de flujo dispersión al instalarlo en la posición A: (a) sensor primario 1; (b) sensor primario 2; (c) sensor primario 3 (Zamudio-Ramírez et al., 2020).

La Figura 50 muestra los resultados obtenidos al seguir la metodología propuesta para la identificación del estado del motor de inducción. Se ejecutaron un total de 32 pruebas consecutivas para cada caso de estudio en condiciones reales de operación de la máquina con el fin de mostrar la efectividad de su clasificación y sus capacidades para generar un diagnóstico oportuno en línea. Los resultados incluyen la identificación de una condición saludable, desalineación leve y la combinación de una y dos barras de rotor rotas con una desalineación leve. En este sentido, la Figura 50a muestra las regiones de decisión resultantes modeladas por el clasificador basado en la red neuronal artificial propuesto sobre el espacio bidimensional. Por su parte, la Figura 50b muestra los rendimientos de clasificación resultantes alcanzados durante el entrenamiento y la prueba del clasificador. Las clasificaciones correctas se encuentran en la diagonal de la matriz de confusión mostrada en la Figura 50b. A través de la metodología propuesta es posible clasificar correctamente los diferentes niveles de desgaste aquí estudiados con una efectividad superior al 81,3% (cuando el motor se encontraba trabajando bajo una falla incipiente de una barra rota), teniendo una efectividad del 96.9% para cuando el motor se encuentra operando bajo óptimas condiciones (motor sano). La efectividad, por estado de condición del motor analizado, se obtiene a través del cálculo del índice de tasa de detección de fallas (FDR por su abreviatura en inglés, Fault Detection Rate) al dividir el número de clasificaciones correctas entre el número total de muestras (32 muestras totales por estado de condición).



(a)

Matriz de confusión

	Sano	1 BRB	2 BRB	MAL	
Sano	31 24.2%	0 0.0%	0 0.0%	2 1.6%	93.9% 6.1%
1 BRB	0 0.0%	26 20.3%	0 0.0%	0 0.0%	100% 0.0%
2 BRB	1 0.8%	6 4.7%	31 24.2%	0 0.0%	81.6% 18.4%
MAL	0 0.0%	0 0.0%	1 0.8%	30 23.4%	96.8% 3.2%
	96.9% 3.1%	81.3% 18.8%	96.9% 3.1%	93.8% 6.3%	92.2% 7.8%
	Sano	1 BRB	2 BRB	MAL	

Clase objetivo

(b)

Figura 50. Resultados de clasificación de la metodología propuesta obtenidos para señales de flujo magnético de dispersión (a) Regiones de decisión resultantes modeladas por el clasificador basado en la red neuronal artificial propuesto sobre el espacio bidimensional; (b) Eficacia de clasificación (autoría propia).



6.3 Aplicación de la metodología propuesta para el diagnóstico automático de fallo gradual de pista exterior en rodamientos.

6.3.1 Motivación del caso de estudio

Como se ha revisado en secciones anteriores de este trabajo, los motores de inducción han sido ampliamente utilizados, principalmente debido a sus bondadosas características al ser máquinas de bajo costo, fáciles de mantener, altamente resistentes y fáciles de controlar. Sin embargo, a pesar de su elevada robustez, este tipo de máquinas son susceptibles de fallas debidas principalmente a condiciones inherentes de operación, ya que son sometidas a esfuerzos mecánicos inevitables. Así entonces, los motores de inducción son propensos a sufrir fallas en etapas tempranas (es decir, cuando la falla está comenzando a desarrollarse), principalmente debido a circunstancias operativas inherentes, como tensiones térmicas, eléctricas, mecánicas o ambientales. Algunos estudios han demostrado que la mayoría de las fallas de los motores eléctricos se pueden atribuir a los cojinetes/rodamientos y devanados, siendo aproximadamente el 69 % de la tasa total de fallas relacionadas con los cojinetes (Bonnert et al., 2008). Las fallas más comunes relacionadas con los rodamientos generalmente se deben a cargas excesivas, lubricación insuficiente, contaminación externa, instalación incorrecta y arco eléctrico. Esta situación puede conducir a un rendimiento inaceptable y vibraciones indeseables con una falla inminente o defectos de componentes individuales, como elemento rodante, pista interior y pista exterior. Además, la presencia de fallas en etapas tempranas puede provocar interrupciones inesperadas y pérdidas de producción (Saucedo-Dorantes et al., 2016). De acuerdo con Oliver et al. (2017), el desgaste en la pista exterior es una de las causas más comunes de fallas en los rodamientos, debido principalmente a arcos eléctricos que son generados por corrientes parásitas, y que recientemente se han incrementado desde la llegada de los variadores de frecuencia (VFD) como se explica en la sección 2.2.1 del presente trabajo. Así entonces, diversos son los trabajos que se han reportado en la literatura con el fin de generar un diagnóstico oportuno de fallos en las diferentes partes de los rodamientos de bolas (pista exterior, pista interior, elementos rodantes, caja). Para ello, estos trabajos se han valido de la información proporcionada por diversas magnitudes físicas capturadas a partir del motor bajo análisis. Dentro de las más empleadas para este tipo de fallos que se consideran de origen mecánico se ha empleado el análisis de señales de vibración, corrientes de alimentación, estática, y recientemente señales de flujo dispersión, algunos de ellos bajo esquemas clásicos de detección (por ejemplo, mediante el análisis de firma de corriente del motor MCSA), como se discute a continuación.



Las metodologías convencionales se basan en la evaluación de las amplitudes máximas a frecuencias específicas mediante una representación en el dominio de la frecuencia mediante la aplicación de la transformada rápida de Fourier (FFT). Estas frecuencias, que dependen de las dimensiones geométricas de los rodamientos y del deslizamiento del motor (como se describe en la sección 2.2.1.1 de este trabajo), se amplifican cuando hay una falla (Bediaga et al., 2013). La estimación de dichas frecuencias se realiza principalmente mediante información del fabricante, dimensiones geométricas del rodamiento y datos de velocidad de rotación (Zhang et al., 2020). A pesar de sus grandes ventajas y la amplia aplicación de señales de vibración para el monitoreo de fallas en rodamientos, la efectividad de estas técnicas depende en gran medida de la precisión de la estimación de la frecuencia relacionada con la falla. Además, en el entorno industrial real, tales amplitudes de frecuencia específicas son principalmente bajas y borrosas en señales ruidosas (Zhang et al., 2020). Dado que las frecuencias características de las fallas de los rodamientos dependen del deslizamiento, algunos trabajos han propuesto el análisis de las señales de vibración mediante una herramienta adecuada de descomposición de frecuencia de tiempo (TFD) durante el transitorio de arranque de la máquina, como se describe en (Delgado-Arredondo et al., 2015). Este mapa t-f permitió diferenciar entre un rodamiento sano y una pista exterior con una falla que tenía un diámetro de orificio de 1,191 mm. Sin embargo, en términos prácticos existe un inconveniente principal en este tipo de enfoques ya que las representaciones de las vibraciones mediante mapas tiempo-frecuencia suelen no ser claras, siendo además borrosas debido a las señales ruidosas, hecho que compromete el diagnóstico final y puede generar falsas indicaciones no deseadas. Además, algunas herramientas de descomposición tiempo-frecuencia de alta resolución como MUSIC demandan una gran cantidad de tiempo y recursos computacionales para obtener un mapa multidimensional, situación que complica su aplicación a esquemas en línea (Zamudio-Ramirez, Osornio-Rios, et al., 2022). Alternativamente, algunos autores han propuesto el estudio de las señales de corriente (Saucedo-Dorantes et al., 2016). El análisis de corrientes resulta ser una técnica no invasiva en la que los efectos vibratorios de fallas en rodamientos son reflejados y observados como la amplificación de frecuencias eléctricas (Bellini, et al., 2008). Por otra parte, el análisis de señales de corriente para el diagnóstico de fallas en motores eléctricos puede generar diagnósticos falsos debido a oscilaciones de par bajo de carga, conductos de aire axiales del rotor, anisotropía magnética, entre otros (Lee et al., 2020). En este sentido, algunos autores han adoptado el análisis de señales de flujo magnético debido a las excelentes características y ventajas de esta técnica, como la naturaleza no invasiva, el bajo costo requerido de sensores, mayor eficiencia y confiabilidad en los casos en que los enfoques convencionales producen indicaciones falsas (Frosini et al., 2015; Vitek et al., 2011) Los métodos típicos basados en el análisis de señales de flujo magnético se basan en la identificación y cuantificación de la magnitud de frecuencias específicas relacionadas con fallas en el espectro de Fourier. Por ejemplo,



Vitek et al. (2011) evaluó la diferencia de amplitud a frecuencias específicas usando la FFT para la identificación de una falla en la pista interna de 6 mm. No obstante, como se indica en el trabajo de Vitek et al. (2011), las amplitudes de dichos componentes son muy bajas, lo que ciertamente hace que el diagnóstico sea una tarea desafiante, ya que además las frecuencias de interés suelen ser de baja amplitud, y a veces cercanas a la amplitud del nivel del ruido.

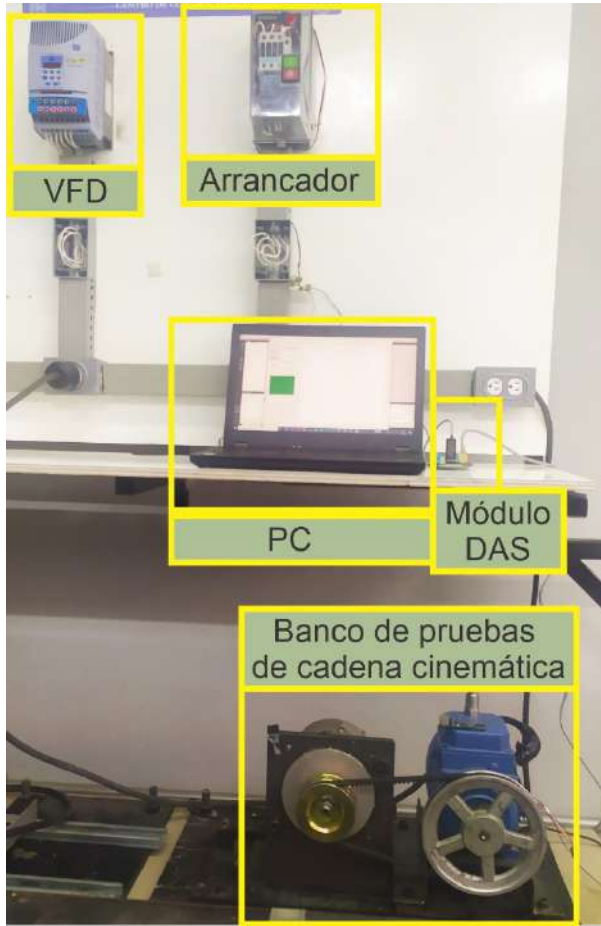
Como se discute en los párrafos anteriores, a pesar de ser una falla muy frecuente (especialmente con la llegada de VFD), las fallas de la pista exterior en rodamientos de bolas han sido estudiadas en etapas muy avanzadas, especialmente debido a que las señales obtenidas, y que son relacionadas con la falla, son generalmente de baja amplitud, siendo inclusive imperceptibles de distinguir para fallas incipientes. Esto dificulta la detección de fallas que comienzan a desarrollarse convirtiendo el diagnóstico en una tarea desafiante. Por otro lado, se sabe que algunas de las metodologías propuestas hasta el momento (principalmente aquellas basadas en la evaluación de amplitudes de frecuencias específicas) requieren el conocimiento de ciertas características de los rodamientos bajo análisis. Esta información, en términos prácticos (en muchas de las ocasiones) es muy complicado obtener, ya que por lo general se obtiene a partir de información proporcionada por el fabricante mediante contacto directo con el (que no siempre se encuentra disponible), o se requiere desmontar una muestra a partir del motor bajo análisis. Además, según el mejor conocimiento del autor, no existe una metodología o estudio reportado capaz de diagnosticar con precisión un desgaste gradual en la pista exterior de los rodamientos, especialmente mediante enfoques no invasivos, que no requieren información previa del rodamiento. La capacidad de diagnosticar este tipo de fallas en etapas incipientes con una advertencia del nivel de severidad es muy deseable ya que puede permitir lograr acciones de mantenimiento adecuadas, lo que puede evitar paradas no programadas y reducir los costos de reparación. En este caso de estudio, se evalúa el desempeño de la metodología aquí propuesta para el diagnóstico del desgaste gradual de fallas en la pista exterior de rodamientos metálicos de bolas. Se muestra una de las capacidades de la metodología propuesta para clasificar la severidad de la falla (diámetro del agujero de la pista exterior) a través de un análisis de las diferentes señales de flujo de dispersión magnética encontradas alrededor del motor impulsor. El análisis y caracterización de la respuesta de la cadena cinemática se realiza mediante indicadores estadísticos y no estadísticos en el dominio del tiempo. Posteriormente, se realiza un diagnóstico final de severidad de la falla mediante la aplicación de un análisis discriminante lineal (LDA) a las diversas características temporales obtenidas. Finalmente, se realiza una indicación automática mediante una FFNN. Esta propuesta se basa en el hecho (según lo informado por la literatura, y como se describe en la sección 2.2.1.1) que los efectos de vibración de las fallas de los rodamientos se reflejan y observan como la amplificación de las frecuencias eléctricas en las señales de corriente del estator, modificando así el flujo perdido a su alrededor. Las diferentes componentes magnéticas




del flujo de dispersión (axial, radial y combinación de axial y radial) se capturan a través del sensor de flujo de dispersión triaxial aquí propuesto (consultar sección 4.2 para más detalle acerca del mismo).

6.3.2 Puesta en marcha de experimentos.


La validación de esta capacidad de la metodología propuesta para el diagnóstico automático de fallo gradual de pista exterior en rodamientos se realiza mediante el análisis de varias señales adquiridas de un banco de pruebas de cadenas cinemáticas. La cadena cinemática utilizada está compuesta por un motor de inducción, un sistema de transmisión de correas y poleas, y una carga mecánica proporcionada por un alternador, que representa el 25% de la carga nominal aproximadamente (ver Figura 51c). El motor de inducción trifásico analizado (modelo WEG 00136APE48T) tiene 2 polos, 28 bares y una potencia nominal de 0,746 KW. Se alimenta con 220 Vac a 60 Hz mediante un arranque directo a través de un arrancador, como se muestra en la Figura 51a. Adicionalmente, con el fin de validar el método propuesto para diferentes frecuencias de alimentación, se controla la velocidad de rotación por medio de un variador de frecuencia modelo WEG CFW08, el cual se puede observar en la Figura 51a. Las señales de flujo de dispersión se capturan mediante el sensor triaxial aquí propuesto (que se compone esencialmente por tres transductores de efecto Hall individuales ubicados en ejes perpendiculares entre sí) instalado en la placa de datos, como se muestra en la Figura 51b. Las señales de flujo perdido se adquieren mediante un módulo de sistema de adquisición de datos (DAS, por su abreviatura en inglés Data Acquisition System) propietario y luego se almacenan en una computadora personal (PC, por su abreviatura en inglés Personal Computer) para su procesamiento. El módulo DAS utiliza un convertidor analógico / digital de 14 bits, la frecuencia de muestreo se establece en 5 kHz y las señales se adquieren en un período de 30 s, que es suficiente para capturar el arranque transitorio y al menos 20 s de estado estable. Con el fin de obtener un número significativo de pruebas, se obtuvieron 7 señales diferentes para cada caso de estudio, como se indica en la Tabla 4. En este sentido, se recolectan un total de 210 muestras durante las pruebas.



(a)



(b)



(c)

Figura 51. Configuración experimental: (a) Banco de pruebas de cadena cinemática. (b) Vista lateral del banco de pruebas. (c) Vista frontal del banco de pruebas (Zamudio-Ramírez et al., 2020).



Tabla 4. Matriz de pruebas para los diferentes niveles de desgaste del rodamiento.

Severidad del fallo en el rodamiento	Frecuencia de alimentación	Número de repeticiones	Número total de pruebas ejecutadas
Rodamiento sano	5 Hz VFD	7	35
	15 Hz VFD	7	
	50 Hz VFD	7	
	60 Hz VFD	7	
	60 Hz arranque directo	7	
1 mm	5 Hz VFD	7	35
	15 Hz VFD	7	
	50 Hz VFD	7	
	60 Hz VFD	7	
	60 Hz arranque directo	7	
2 mm	5 Hz VFD	7	35
	15 Hz VFD	7	
	50 Hz VFD	7	
	60 Hz VFD	7	
	60 Hz arranque directo	7	
3 mm	5 Hz VFD	7	35
	15 Hz VFD	7	
	50 Hz VFD	7	
	60 Hz VFD	7	
	60 Hz arranque directo	7	
4 mm	5 Hz VFD	7	35
	15 Hz VFD	7	
	50 Hz VFD	7	
	60 Hz VFD	7	
	60 Hz arranque directo	7	
5 mm	5 Hz VFD	7	35
	15 Hz VFD	7	
	50 Hz VFD	7	
	60 Hz VFD	7	
	60 Hz arranque directo	7	
Total = 210 pruebas			

Los diferentes experimentos se realizan instalando distintos rodamientos tipo metálicos modelo 6203 2RS como el que se muestra en la Figura 52. Este rodamiento tiene 8 bolas, 40 mm de diámetro exterior (D) y 17 mm de diámetro interior (d). La falla del rodamiento de la pista exterior se induce a través de un proceso de fresado al perforar un orificio en la pista exterior de los diferentes rodamientos con una broca de tungsteno. De esta forma, se induce un desgaste gradual de la pista exterior para los diferentes diámetros de orificio de la siguiente manera: 1 mm, 2 mm, 3 mm, 4 mm y 5 mm (ver Figura 53). En todas las averías consideradas, los experimentos se realizan sustituyendo el rodamiento sano por cada uno de los rodamientos dañados, así entonces el único elemento del motor que es intercambiado por caso de estudio es el rodamiento, mientras se cuida que el motor quede perfectamente alineado cada que se desinstala.




Figura 52. Rodamiento metálico modelo 6203 2RS, utilizado durante la experimentación (Zamudio-Ramírez et al., 2020).




Figura 53. Rodamientos utilizados durante los experimentos. (a) Rodamiento sano. (b) Rodamiento con daño de 1 mm en la pista exterior. (c) Rodamiento con daño de 2 mm en la pista exterior. (d) Rodamiento con daño de 3 mm en la pista exterior. (e) Rodamiento con daño de 4 mm en la pista exterior. (f) Rodamiento con daño de 5 mm en la pista exterior (Zamudio-Ramírez et al., 2020).





6.3.3 Resultados y discusión del caso de estudio.

Siguiendo la metodología propuesta, se analizan las respuestas de las señales de flujo magnético de dispersión para cada condición de rodamiento (es decir, rodamiento saludable, 1 mm, 2 mm, 3 mm, 4 mm y 5 mm de diámetro en la perforación inducida en la pista exterior). Adicionalmente, la metodología propuesta es validada para diferentes frecuencias de alimentación proporcionadas por el variador de frecuencia y directamente de la red de suministro (es decir, arranque en línea directa a 60 Hz, y conexión VFD de 60 Hz, 50 Hz, 15 Hz y 5 Hz). La Figura 54 muestra gráficamente las funciones de densidad normalizadas que definen las zonas de detectabilidad obtenidas por los distintos indicadores calculados: valor medio, RMS , SMR , y σ para el caso en que el motor propulsor se alimenta a 60 Hz bajo una conexión de línea directa. De esta forma, la Figura 54a revela que el valor medio no proporciona ningún dato discriminativo ya que las diferentes severidades de la falla exhiben una superposición entre ellas, lo que evidentemente muestra que no existe alguna relación de la falla con estos indicadores. De manera similar, la Figura 54b–d demuestra que los indicadores RMS , SMR , y σ pueden brindar información discriminativa relevante para las diferentes severidades de falla (ya que hay poca superposición entre ellas). Por otro lado, la Figura 54 muestra que por medio de las características de dominio de tiempo RMS , SMR , σ es posible discriminar individualmente entre severidades de fallo para rodamiento sano, de 1 mm, 2 mm y 5 mm ya que hay casi una superposición nula en todos estos casos (al analizar el flujo de dispersión axial). Además, la Figura 55a–d indica el bajo desempeño discriminativo que se obtiene mediante los indicadores SF_{RMS} , SF_{SRM} , CF , LF , IF cuando se analizan de forma individual (esto es sin aplicar alguna técnica de inteligencia artificial que permita la fusión de datos como lo son redes neuronales artificiales o alguna otra técnica específica para ello), ya que existe una superposición en todos los casos. Finalmente, la Error: Reference source not found, c indica que hay datos discriminativos casi nulos en los indicadores del dominio de tiempo S_k y $5_{th}M$ cuando el motor impulsor se alimenta a 60 Hz bajo una conexión de línea directa. No obstante, la Error: Reference source not found demuestra la relevancia de incluir o analizar el indicador fractal de Katz KFD (especialmente para la señal de flujo de dispersión axial), ya que muestra una baja superposición entre las diferentes severidades de falla. En este sentido, cabe señalar que no se puede realizar un diagnóstico final y confiable mediante la evaluación directa de un solo indicador estadístico y/o no estadístico, ya que se puede obtener una falsa indicación no deseada al obtenerse una superposición entre diferentes severidades de falla. Esto pone en manifiesto la relevancia y la necesidad de alguna técnica que permita la combinación/fusión de la información proveniente de distintos indicadores relacionados a la falla bajo estudio. Por otra parte, es de notar que no todos los indicadores muestran un valor discriminativo que permita distinguir entre las diversas severidades de la falla, por lo que resulta indispensable seleccionar aquellos




indicadores que no estén correlacionados entre ellos, y que además proporcionen información relevante que permita distinguir entre los diferentes niveles de fallo estudiados. Así entonces, para seleccionar el conjunto de indicadores más discriminatorio, se genera un subconjunto de combinación de tres de estos para cada caso de estudio (la misma combinación de subconjunto de tres características se considera para las diferentes señales de flujo de dispersión, así posteriormente se concatenan los mismos tres indicadores para el flujo de dispersión axial, radial y axial +radial). Posteriormente, estos subconjuntos se evalúan a través del puntaje de Fisher, que se calcula aplicando (23), y se selecciona la mejor combinación, es decir, el subconjunto con los valores de puntaje de Fisher más altos. La resume los subconjuntos de indicadores calculados y el indicador de dimensión fractal de Katz con los valores más altos del puntaje de Fisher. Se puede ver claramente que la combinación de σ , k , KFD , SF_{RMS} , SF_{SRM} , $5_{th}M$, $6_{th}M$ y SMR funciona mejor para discriminar las fallas cuando el motor impulsor se alimenta a 60 Hz bajo una conexión de línea directa. De manera similar, la mejor combinación de características para diagnosticar fallas en los rodamientos de la pista exterior cuando el motor impulsor es alimentado a 60 Hz por un variador de frecuencia se encuentra compuesto por los indicadores RMS , SRM , σ , SF_{RMS} , SF_{SRM} , KFD , y media aritmética. Por otro lado, se encuentra que el mejor rendimiento discriminativo bajo una conexión VFD de 50 Hz está vinculado a los indicadores RMS , SRM , k , SF_{RMS} , SF_{SRM} y KFD como se indica en la . De manera similar, la Error: Reference source not found recompila los mejores conjuntos de indicadores que proporcionan información más discriminatoria para el diagnóstico de fallas en los rodamientos cuando se alimenta el motor a 15 Hz y 5 Hz.






(b)




(c)




(b)


Figura 54. Funciones de densidad normalizadas que definen las zonas de detectabilidad obtenidas por los diferentes indicadores estadísticos y no estadísticos aquí propuestos para los diferentes componentes del flujo de dispersión utilizando: (a) Valor medio. (b) valor RMS. (c) valor SMR. (d) valor de σ (Zamudio-Ramirez et al., 2021).




(a)



(b)

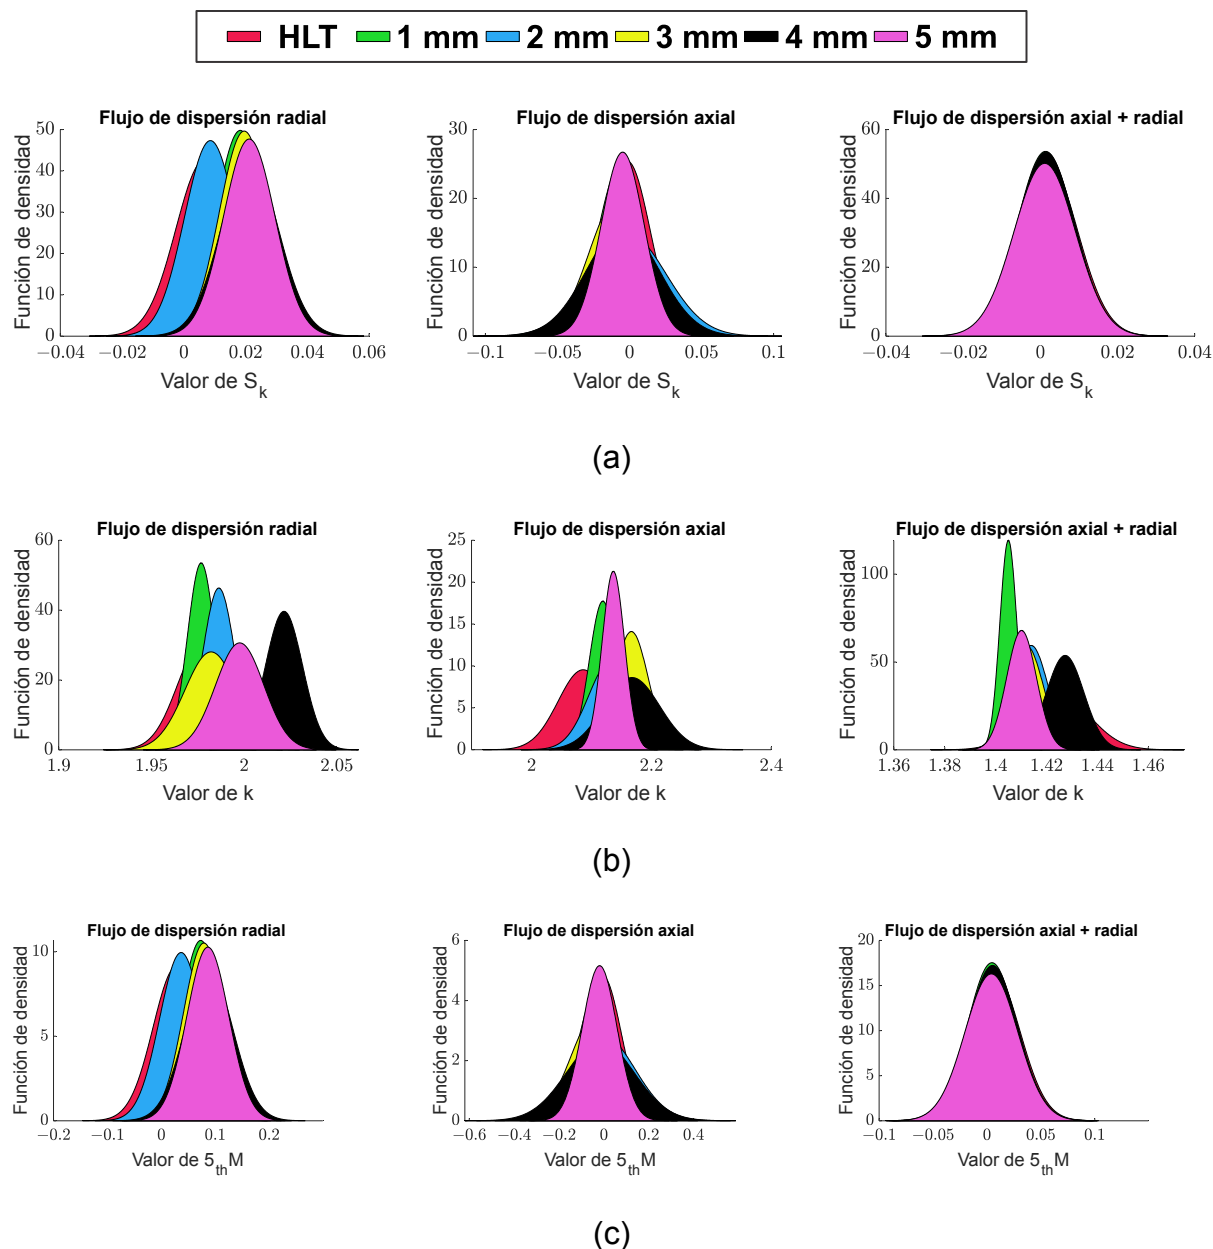



(c)



(d)

Figura 55. Funciones de densidad normalizadas que definen las zonas de detectabilidad obtenidas por los diferentes indicadores estadísticos y no estadísticos aquí propuestos para los diferentes componentes del flujo de dispersión utilizando: (a) valor $S F_{RMS}$. (b) Valor $S F_{SRM}$. (c) Valor CF. (d) Valor LF (Zamudio-Ramirez et al., 2021).





(d)

Figura 56. Funciones de densidad normalizadas que definen las zonas de detectabilidad obtenidas por los diferentes indicadores estadísticos y no estadísticos aquí propuestos para los diferentes componentes del flujo de dispersión utilizando: (a) valor S_k . (b) Valor k . (c) Valor $5_{th}M$. (d) Valor KFD.

Tabla 5. Detalle de los subconjuntos seleccionados integrados al considerar combinaciones de tres indicadores estadísticos para el cómputo del puntaje de Fisher cuando el motor operaba a una frecuencia de suministro de energía de 60 Hz y 50 Hz (Zamudio-Ramirez et al., 2021).

Severidad de fallo en el rodamiento	Frecuencia de operación					
	60 Hz arranque directo		60 Hz VFD		50 Hz VFD	
	Subconjunto seleccionado de características	Puntuación de Fisher calculada	Subconjunto seleccionado de características	Puntuación de Fisher calculada	Subconjunto seleccionado de características	Puntuación de Fisher calculada
1 mm	σ, k, KFD	7.16	RMS, SRM, σ	21.63	RMS, SRM, k	817.19
2 mm	SF_{RMS}, SF_{SRM}, KFD	4.34	SF_{RMS}, SF_{SRM}, KFD	47.60	SF_{RMS}, SF_{SRM}, KFD	80.42
3 mm	$\sigma, 6_{th}M, KFD$	178.91	RMS, KFD, σ	157.68	SF_{RMS}, SF_{SRM}, KFD	37.14
4 mm	σ, KFD, SMR	161.51	RMS, KFD, σ	104.54	SF_{RMS}, SF_{SRM}, KFD	77.83
5 mm	σ, SF_{RMS}, KFD	4.31	Media, RMS, σ^2	15.23	SF_{RMS}, SF_{SRM}, KFD	160.14



Tabla 6. Detalle de los subconjuntos seleccionados integrados al considerar combinaciones de tres indicadores estadísticos para el cómputo del puntaje de Fisher cuando el motor operaba a una frecuencia de suministro de energía de 15 Hz y 5 Hz.

Severidad de fallo en el rodamiento	Frecuencia de operación			
	15 Hz VFD		5 Hz VFD	
	Subconjunto seleccionado de características	Puntuación de Fisher calculada	Subconjunto seleccionado de características	Puntuación de Fisher calculada
1 mm	RMS, SRM, σ	90.50	RMS, SRM, σ	87.86
2 mm	SF_{RMS}, SF_{SRM}, KFD	19.84	SF_{RMS}, SF_{SRM}, KFD	24.03
3 mm	RMS, SRM, σ	78.66	RMS, SRM, σ	63.85
4 mm	RMS, SRM, σ	62.62	RMS, SRM, σ	56.24
5 mm	SRM, σ , KFD	27.58	SRM, k , KFD	16.95

Posteriormente, en la última etapa de la metodología propuesta, se realiza una reducción de características mediante la técnica LDA. A través de esta técnica todos los indicadores estadísticos seleccionados se proyectan en un pequeño subconjunto para maximizar la separación lineal entre diferentes clases mediante la combinación de información proporcionada por los diferentes valores de los indicadores seleccionados. En consecuencia, el conjunto de características extraído se proyecta en un espacio bidimensional (Indicador 1, e indicador 2) para obtener una representación visual de todas las condiciones consideradas. En este sentido, la Figura 57a muestra las regiones de decisión para la clasificación resultantes, y que son obtenidos durante el entrenamiento y la prueba del clasificador basado en una red neuronal para los diferentes daños en los rodamientos cuando el motor de accionamiento se alimenta a 60 Hz bajo una conexión de línea directa. Además, la Figura 57b proporciona una vista ampliada de una zona crítica (donde la separación entre clases es menor). A partir de esta figura, se puede observar claramente que la dispersión obtenida para las diferentes severidades de falla es mínima, y la separación entre clases es grande. De manera similar, la Figura 58a muestra las clasificaciones y límites correctos obtenidos automáticamente por medio del entrenamiento de la red neuronal artificial para el caso en que el motor bajo análisis es alimentado por un VFD a 60 Hz. Además, la Figura 58b (que es una vista ampliada de la zona del rectángulo negro que se encuentra en la Figura 11a) revela que no hay superposición ni clasificación

errónea entre fallas de 3 mm y 4 mm de gravedad a pesar de estar en una región cercana. Resultados similares se pueden apreciar en la Figura 59 y Figura 60. Con respecto a los límites de decisión y la proyección obtenida cuando el motor impulsor se alimenta a 5 Hz, la Figura 61 muestra que existe una clasificación errónea entre el rodamiento sano y el rodamiento defectuoso con una perforación de 2 mm en la pista exterior, ya que los datos proyectados resultan estar en regiones muy cercanas entre sí. Sin embargo, ambos casos están separados con una elevada precisión. El comportamiento no lineal obtenido en los resultados se puede atribuir principalmente a las características temporales utilizadas para caracterizar la cadena cinemática bajo estudio, ya que brindan información relevante sobre los cambios y tendencias encontradas en las señales analizadas. Se encuentra que tales cambios no son lineales a la severidad de la falla. Además, se encuentra a partir de los resultados obtenidos, que diferentes subconjuntos de características en el dominio del tiempo brindan información discriminadora relevante para diagnosticar fallas en los rodamientos de acuerdo con las diferentes frecuencias de suministro de energía estudiadas aquí. Sin embargo, las características totales utilizadas para discriminar todas las severidades de las fallas de los rodamientos bajo diferentes frecuencias de suministro de energía se limitan a los siguientes indicadores: σ , k , KFD , SFS_{RM} , SF_{RMS} , $5_{th}M$, $6_{th}M$, SMR , RMS y σ^2 , tal como se indica en la Tabla 7 y Tabla 8. Adicionalmente, la información mostrada en las Tablas y Error: Reference source not found revela que la dimensión fractal de Katz y σ resultan indispensables para una correcta clasificación de la severidad de la falla, ya que estos indicadores se encuentran en casi todos los subconjuntos que tienen mayores valores en la puntuación de Fisher.

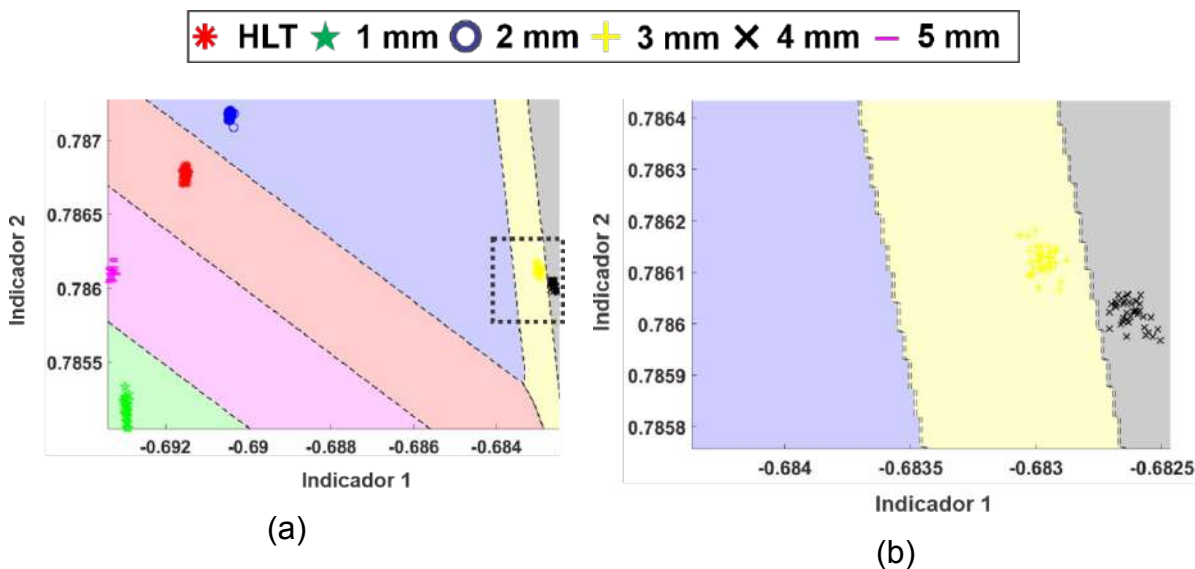


Figura 57. Proyección de las regiones de decisión para la clasificación de fallas múltiples calculada por el clasificador basado en la red neuronal artificial propuesta cuando el motor de inducción funciona a 60 Hz bajo un arranque directo: (a) Vista completa de la proyección. (b) Vista ampliada de la zona del rectángulo negro (Zamudio-Ramirez et al., 2021).

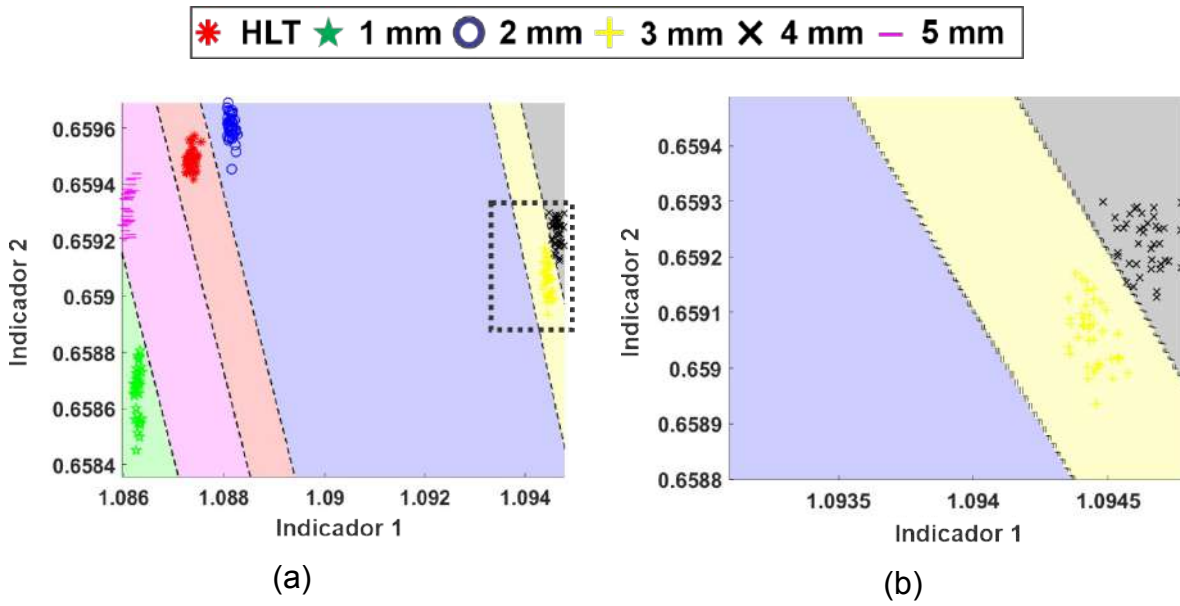


Figura 58. Proyección de las regiones de decisión para la clasificación de fallas múltiples calculada por el clasificador basado en la red neuronal artificial propuesta cuando el motor de inducción funciona a 60 Hz bajo un arranque empleando un variador de frecuencia: (a) Vista completa de la proyección. (b) Vista ampliada de la zona del rectángulo negro (Zamudio-Ramirez et al., 2021).

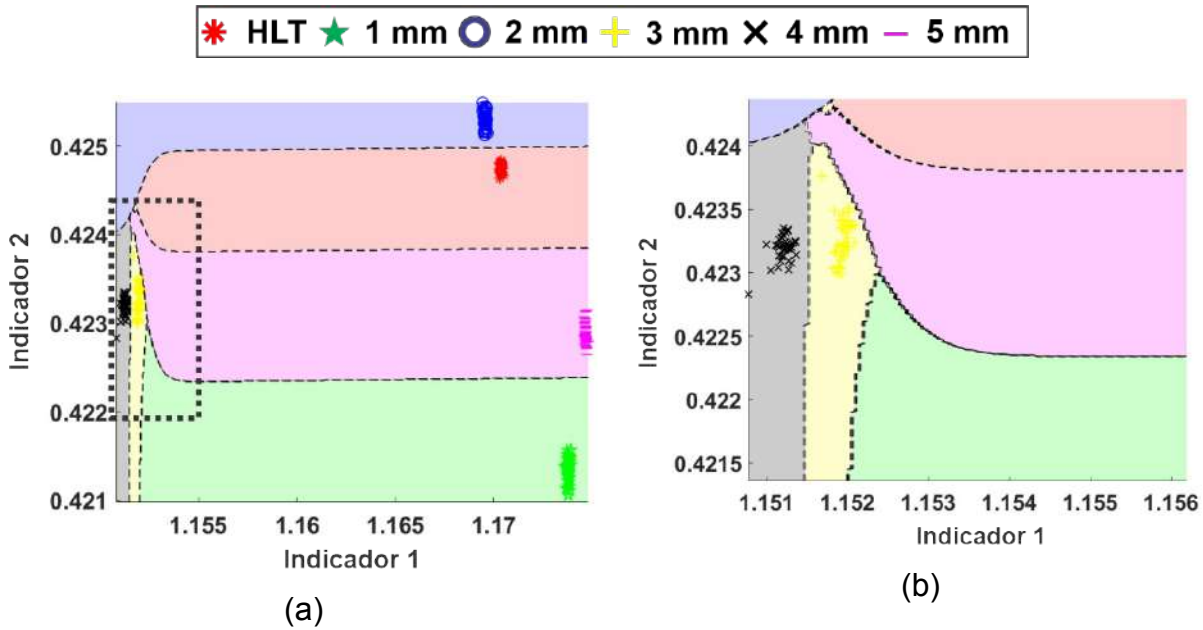


Figura 59. Proyección de las regiones de decisión para la clasificación de fallas múltiples calculada por el clasificador basado en la red neuronal artificial propuesta cuando el motor de inducción funciona a 50 Hz bajo un arranque empleando un variador de frecuencia: (a) Vista completa de la proyección. (b) Vista ampliada de la zona del rectángulo negro (Zamudio-Ramirez et al., 2021).

* HLT
 ★ 1 mm
 ○ 2 mm
 + 3 mm
 × 4 mm
 - 5 mm




Figura 60. Proyección de las regiones de decisión para la clasificación de fallas múltiples calculada por el clasificador basado en la red neuronal artificial propuesto cuando el motor de inducción funciona a 15 Hz bajo un arranque empleando un variador de frecuencia: (a) Vista completa de la proyección. (b) Vista ampliada de la zona del rectángulo negro (Zamudio-Ramirez et al., 2021).

* HLT
 ★ 1 mm
 ○ 2 mm
 + 3 mm
 × 4 mm
 - 5 mm

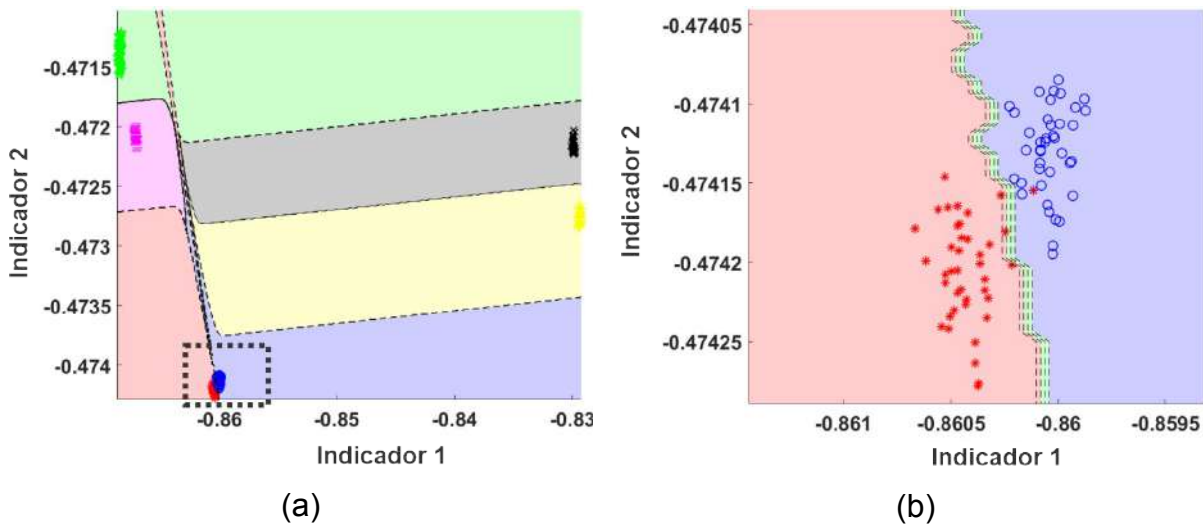


Figura 61. Proyección de las regiones de decisión para la clasificación de fallas múltiples calculada por el clasificador basado en la red neuronal artificial propuesto cuando el motor de inducción funciona a 5 Hz bajo un arranque empleando un variador de frecuencia: (a) Vista completa de la proyección. (b) Vista ampliada de la zona del rectángulo negro (Zamudio-Ramirez et al., 2021).



En la Tabla 7 se muestran los resultados de la clasificación, así como el porcentaje de efectividad de la metodología propuesta cuando el motor impulsor es alimentado a 60 Hz (línea directa), 60 Hz VFD, 50 Hz VFD, y 15 Hz VFD. Las clasificaciones correctas se encuentran en la diagonal de la Tabla (resaltadas en negrita). La efectividad, por estado del rodamiento, se obtiene mediante el cálculo del índice de FDR al dividir el número de clasificaciones correctas entre el número total de muestras. Estos resultados demuestran la pertinencia de la propuesta ya que se obtiene un 100% de clasificación correcta de la severidad de la falla, incluso para fallas incipientes. De igual manera, la Tabla 8 muestra la matriz de confusión obtenida para el caso en que el motor impulsor es alimentado por un VFD a 5 Hz. Este caso especial revela que la propuesta tiene una efectividad del 97.5%, incluso cuando la velocidad de rotación del rotor es muy lenta. La clasificación y diagnóstico de fallas a velocidades de rotación del rotor muy lentas mediante técnicas convencionales resulta muy difícil, ya que el armónico fundamental (que tiene una gran amplitud) se superpone a los componentes adyacentes. A partir de estos resultados, se evidencia que la propuesta es una metodología adecuada y confiable para la detección automática de daños en rodamientos por desgaste gradual. Además, el diagnóstico final no se ve afectado por señales de baja amplitud, una de las principales limitaciones que se encuentran en algunos métodos. La propuesta puede encontrar una amplia aplicabilidad en esquemas en línea con la capacidad de detectar fallas incipientes. La principal limitante de la propuesta es el requerimiento de datos suficientes para los diferentes casos de estudio con el fin de realizar un adecuado entrenamiento del método.

Tabla 7. Porcentaje de efectividad de la metodología propuesta (matriz de confusión) al analizar todas las condiciones de rodamiento consideradas para una fuente de alimentación de línea directa a 60 Hz, y para una fuente de alimentación VFD de 60 Hz, 50 Hz y 15 Hz.

Clase asignada	Clase verdadera						Efectividad (%)
	Sano	1 mm	2 mm	3 mm	4 mm	5 mm	
Sano	40	0	0	0	0	0	100
1 mm	0	40	0	0	0	0	100
2 mm	0	0	40	0	0	0	100
3 mm	0	0	0	40	0	0	100
4 mm	0	0	0	0	40	0	100
5 mm	0	0	0	0	0	40	100



Tabla 8. Porcentaje de efectividad de la metodología propuesta (matriz de confusión) al analizar todas las condiciones de rodamiento consideradas para una fuente de alimentación VFD de 5 Hz.

Clase asignada	Clase verdadera						Efectividad (%)
	Sano	1 mm	2 mm	3 mm	4 mm	5 mm	
Sano	39	0	0	0	0	0	97.5
1 mm	0	40	0	0	0	0	100
2 mm	1	0	40	0	0	0	100
3 mm	0	0	0	40	0	0	100
4 mm	0	0	0	0	40	0	100
5 mm	0	0	0	0	0	40	100



6.4 Aplicación de la metodología propuesta para el diagnóstico de fallo de barras rotas en motores de arranque de corta duración

6.4.1 Motivación del caso de estudio

Como ya se discutió en la sección 6.2.2, es de gran relevancia el diagnóstico oportuno y preferentemente de forma automática de barras rotas en motores eléctricos de inducción debido a las diversas repercusiones que una falla de este tipo puede tener, entre otras: si no se atiende a tiempo, los esfuerzos térmicos provocados por la ausencia de la barra rota en las barras adyacentes puede generar un desgaste mayor y con mayor rapidez, si se llega a desprender una barra puede generar un contacto con el bobinado del estator lo que a su vez puede finalizar en un cortocircuito catastrófico con fallas irreversibles.

A pesar de que se han realizado diversas propuestas y metodologías para el diagnóstico de este tipo de fallas, no se ha propuesto una metodología que genere un diagnóstico automático, especialmente basado en el transitorio de arranque del motor. Se ha demostrado que mediante el análisis de señales capturadas durante el transitorio de arranque es posible generar un diagnóstico más confiable, con la posibilidad de evitar falsos diagnósticos, ya que como se revisó en secciones anteriores, las metodologías convencionales basan el diagnóstico final en la amplitud de frecuencias específicas desarrolladas por el fallo. Sin embargo, se ha demostrado que ciertas frecuencias amplificadas por fallas específicas en la máquina bajo análisis también pueden ser amplificadas o canceladas por fenómenos no relacionados al fallo, como por ejemplo: presencia de barras rotas no adyacentes, influencia de los conductos de aire axiales del rotor, variaciones en la carga, entre otros (Park et al., 2020; Park et al., 2020; Shin et al., 2021). De esta manera, mediante el análisis tiempo-frecuencia de señales capturadas a partir del motor es posible generar un diagnóstico fiable ya que este tipo de metodologías se basan en la identificación de patrones específicos debidos a la evolución de la frecuencia amplificada durante el arranque del motor, mismos que son generalmente dependientes del deslizamiento del motor. Para ello se han de emplear herramientas de descomposición tiempo-frecuencia óptimas para un diagnóstico oportuno. De acuerdo a lo reportado en la literatura, mayormente se ha empleado la técnica STFT debido a sus diversas ventajas, como se discute en la sección 3.2. Sin embargo, la aplicación de este tipo de técnicas tiene un fuerte inconveniente en lo que respecta a la resolución tiempo-frecuencia obtenida, ya que el tamaño de ventana empleado define dicha resolución. Este inconveniente tiene una especial relevancia cuando las frecuencias de interés se



encuentran muy cercanas entre sí, más especialmente este problema es evidente cuando se trata de diferenciar/analizar la amplitud de componentes frecuenciales adyacentes a la frecuencia fundamental. Este problema se debe a que, dependiendo el deslizamiento del motor (principalmente para deslizamientos muy bajos) se puede generar una superposición de frecuencias relacionadas al fallo con la componente fundamental (que es de gran amplitud) lo que imposibilita generar diagnóstico alguno. Otro problema común sucede cuando el motor bajo análisis tiene un arranque muy rápido (especialmente menor a 1 segundo) ya que no permite distinguir la evolución de la componente de interés, puesto que la resolución no es suficiente en estos casos. Así entonces, ante estos inconvenientes presentes en metodologías de diagnóstico convencionales, en el presente trabajo se propone el empleo de técnicas de descomposición tiempo-frecuencia en alta resolución para señales en el tiempo, como lo es el algoritmo MUSIC de tiempo corto (ver sección 3.2.2 de este trabajo para más detalles sobre esta técnica). Esta herramienta permite evidenciar solo componentes de frecuencia de mayor amplitud, y además mitiga los efectos del procesamiento de señales ruidosas, un inconveniente común de las metodologías convencionales.

En este caso de estudio se aplica la metodología aquí propuesta para la caracterización del comportamiento dinámico de señales de flujo de dispersión capturadas en el marco del motor bajo análisis cuando este opera bajo fallas de barras rotas, y cuyo transitorio de arranque es muy corto (menor a 1.5 s). En el presente caso de estudio se aplica la metodología propuesta, basada en la combinación del algoritmo MUSIC de tiempo corto y redes neuronales artificiales para un diagnóstico oportuno, confiable, y automático. Su principal ventaja es mejorar la visualización de los armónicos causados por diferentes fallas del motor en las señales del flujo magnético de dispersión. Además, el algoritmo inteligente permite el cálculo automático de indicadores de severidad de fallas basados en la combinación de varias características de los resultados de MUSIC. Estas características cruciales mejoran significativamente el algoritmo en comparación con la versión preliminar presentada en ([Ramirez-Nunez et al., 2019](#)), convirtiéndolo en una opción ideal para ser incorporado en sistemas autónomos que se basan en el análisis de datos de flujo magnético de dispersión.



6.4.2 Puesta en marcha de experimentos

Se llevaron a cabo diferentes pruebas en el laboratorio utilizando un motor tipo jaula de ardilla de 1,1 kW de potencia (motor 1) con 2 pares de polos. El motor impulsaba un generador de corriente continua que permitía cambiar el nivel de carga (ver Figura 62). Se le instaló un sensor del tipo bobina en el marco del motor en diferentes posiciones del mismo. Este sensor consiste de un arrollamiento de alambre esmaltado con 1000 vueltas, cuyas dimensiones se muestran en la Figura 63. Las tres posiciones consideradas del sensor fueron las representadas en la Figura 19 (pos. A, pos B y pos C). Se probaron motores con diferentes niveles de daño en el rotor (motor sano, una barra rota y dos barras rotas). Dado que el motor no estaba correctamente alineado con la carga accionada, un cierto nivel de desalineación era inevitable, aunque, como se demostró en trabajos recientes ([Park et al., 2020](#)), esto tiene un efecto menor en las señales de flujo magnético de dispersión. En cada prueba, la señal de fuerza electromotriz inducida en el sensor de la bobina externa se registró tanto en el arranque como durante 30 segundos del régimen de estado estable posterior utilizando un osciloscopio YOKOGAWA DL-850. Se utilizó una frecuencia de muestreo de 5 kHz para la adquisición de las señales. Las señales capturadas fueron posteriormente transferidas a una computadora donde se procedió a su análisis.

Por otro lado, se realizaron pruebas adicionales en un motor de inducción tipo jaula de ardilla más grande que el motor 1 (motor 2), que era análogo a los utilizados en aplicaciones industriales reales (ver Figura 64). A priori se desconocía el estado exacto de este motor, por lo que sirvió para validar si la aplicación de la metodología funcionaba bien al momento de diagnosticar su estado. Las principales características de este motor eran: potencia nominal=7,5 kW, tensión nominal=380 V, corriente nominal=15,2 A, velocidad nominal=1435 rpm, número de pares de polos=2.




Figura 62. Banco de pruebas de laboratorio (motor 1)




Figura 63. Dimensiones del sensor de bobina empleado durante los experimentos del presente caso de estudio.



Figura 64. Segundo motor probado durante los experimentos (motor 2): 7,5 kW, 2 pares de polos

6.4.3 Resultados y discusión del caso de estudio.

La Figura 65 muestra los análisis MUSIC de la fuerza electromotriz (f_{em}) capturada a partir de las tres posiciones del sensor (Pos. A, Pos. B. y Pos. C) y para las tres condiciones del motor consideradas, a saber, motor sano, motor con una barra rota y motor con dos barras rotas. En cada nivel de falla (incluso en estado saludable), el motor tenía una cierta desalineación con respecto a la carga impulsada. En primer lugar, se debe tener en cuenta que cuando la máquina está en buen estado, solo se detectan ligeras huellas de las evoluciones de dos componentes en cada posición del sensor: el componente $f - f_r$ y $s \cdot f$. El primero de estos componentes es causado por la existencia de la desalineación entre el motor y la carga accionada que produce cierta amplitud de este armónico. En trabajos recientes (Park et al., 2020), se ha demostrado que la existencia de desalineaciones mecánicas entre el motor y la carga tiene una repercusión mucho menor en las señales de flujo magnético de dispersión (en comparación con los efectos sobre la señal de corriente de arranque) pero, aun así son detectables ciertas trazas de esta componente. Por otro lado, la componente $s \cdot f$ presenta una pequeña amplitud; su presencia se atribuye a la existencia de un cierto nivel de asimetría inherente al rotor, incluso en condiciones saludables. Este componente es claramente perceptible en la Pos. A del sensor tipo bobina, en el que el flujo axial es predominantemente capturado.

El efecto de los daños en el rotor (barras rotas del rotor) es claramente detectable a través de la amplificación de diferentes componentes en los mapas tiempo-frecuencia:



- Por un lado, se puede observar que la componente axial en $s \cdot f$ se amplifica en cada posición del sensor cuando está presente la falla del rotor. La amplificación es especialmente evidente en la Pos. A y Pos. B. En trabajos recientes ([Park et al., 2020](#)), se ha demostrado que la existencia de desalineación tiene una repercusión mucho menor en las señales de flujo magnético de dispersión (en comparación con los efectos sobre la señal de corriente de arranque) pero aun así, son detectables ciertas trazas de esta componente. Por otro lado, la componente $s \cdot f$ presenta una pequeña amplitud; su presencia se atribuye a la existencia de un cierto nivel de asimetría inherente al rotor incluso en condiciones saludables. Este componente es claramente perceptible en Pos. A, en el que el flujo axial es predominantemente capturado.
- Por otro lado, la componente en $f - f_r$ también se amplifica claramente cuando la falla está presente. Esto ocurre en todas las posiciones del sensor. Además, este incremento es más evidente cuando el nivel de falla empeora (comparar una y dos barras rotas). El aumento de la amplitud de esta componente (y por tanto de su firma en el mapa tiempo-frecuencia) está en concordancia con las recientes conclusiones de otros autores ([Gyftakis et al., 2019](#)). Este aumento en su amplitud es una segunda evidencia de la presencia de la falla del rotor.
- Finalmente, el componente de evolución en $f \cdot (1 - 2 \cdot s)$ también es perceptible en los resultados de MUSIC. El patrón en V característico causado por la evolución de este componente es más evidente en aquellas posiciones del sensor que capturan una mayor porción de flujo radial (Pos. B. y Pos. C). Este patrón se ha enfatizado en el gráfico de la Figura 65. La detección de dicho patrón no es tan clara en la posición B, debido al elevado contenido armónico de la región de frecuencia por debajo de la fundamental en la que evolucionan diferentes armónicos bajo el arranque (p. ej. $f - f_r$ y $s \cdot f$). Se debe tener en cuenta que, en esta posición el sensor captura no solo el flujo radial sino también el axial, por lo que muchos componentes están contenidos en la señal capturada.

En cualquier caso, los análisis MUSIC de las señales de fem capturadas durante el transitorio arranque son muy útiles para el diagnóstico, presentando dos ventajas muy interesantes en comparación con otros enfoques:

- 1) El diagnóstico de la avería se basa en la evolución de múltiples armónicos de falla (por ejemplo, $s \cdot f$, $f - f_r$ y $f \cdot (1 - 2 \cdot s)$) y no solamente en un armónico de forma individual, hecho que confiere una alta fiabilidad en el diagnóstico.
- 2) El contenido armónico en los análisis de las señales del flujo magnético de dispersión durante el transitorio de arranque es mucho más completo que el del análisis de la corriente de arranque, en el que se visualizan menos armónicos de falla. Esto también confiere un mayor potencial a la técnica, en comparación con otras alternativas.

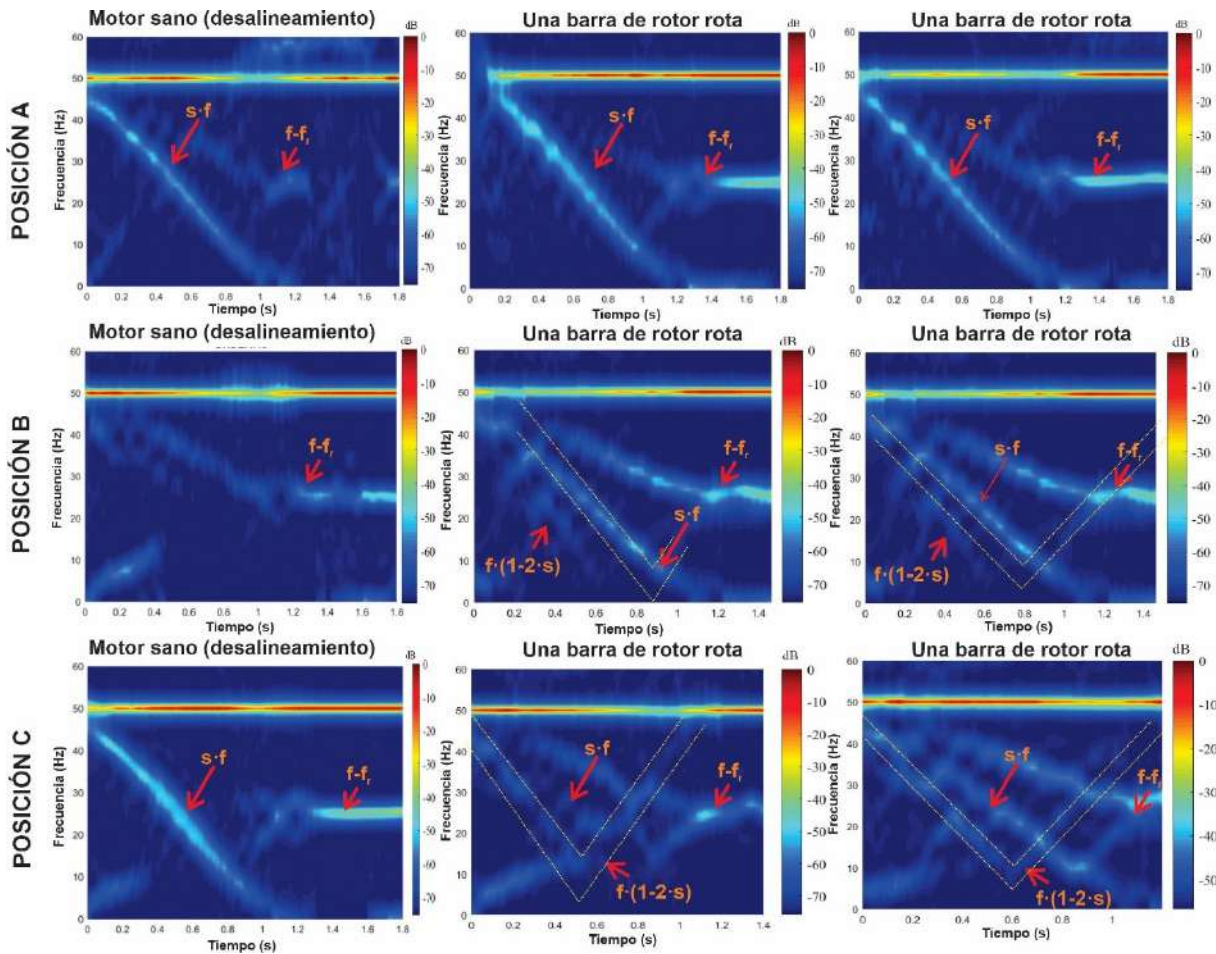


Figura 65. Análisis MUSIC de las señales de f_{em} capturadas durante el arranque del motor 1 para el sensor en las posiciones A, B y C y para las diferentes condiciones de falla, a saber, motor saludable (con desalineación inherente), motor con una barra rota y motor con dos barras rotas (Zamudio-Ramirez et al., 2020).

Para validar la generalidad de la metodología, se aplicó a un motor diferente (motor 2), que era de mayor potencia y tamaño que el motor 1, y tenía características constructivas diferentes. Inicialmente su estado era incierto por lo que la idea fue aplicar la metodología y verificar si era posible diagnosticar de forma correcta el estado de este motor. Los resultados de la aplicación del método MUSIC a este motor se muestran en la Figura 66. Se puede observar que, en todas las posiciones del sensor, el único componente perceptible es $f - f_r$. No se detectaron rastros de la componente de falla $f \cdot (1 - 2 \cdot s)$ y solo ligeros rastros de $s \cdot f$. Esto es indicativo de dos hechos:

- 1) No había evidencia de daños en el rotor del motor (ya que las evoluciones de $s \cdot f$ y $3 \cdot f \cdot s$ no eran observables).

2) Había síntomas claros de excentricidades / desalineación en la máquina (ya que la componente frecuencial a $f - f_r$ estaba presente).

Estas conclusiones diagnósticas proporcionadas por el método demostraron ser válidas posteriormente al inspeccionar la máquina; se corroboró que el rotor estaba sano y que presentaba un nivel importante de desalineación (medido a través de un reloj comparador).

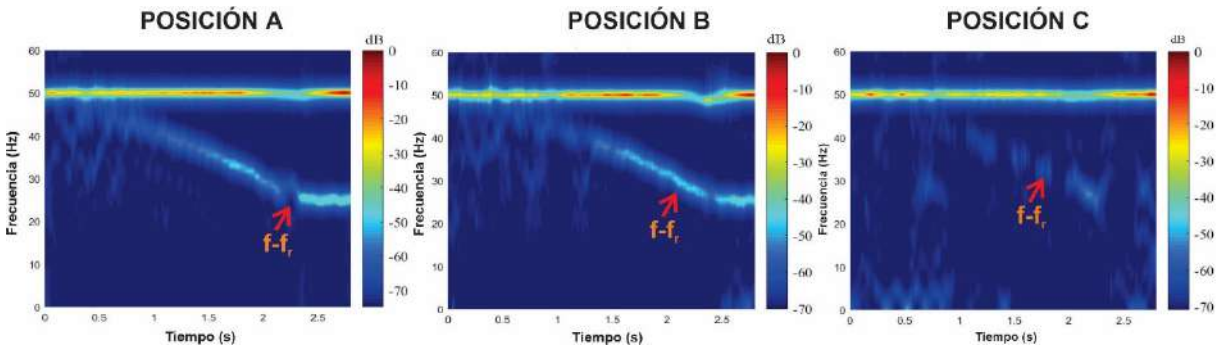


Figura 66. Análisis MUSIC de las señales de f_{em} capturadas por el sensor de bobina durante el arranque del motor 2 para el sensor en las posiciones A, B y C (Zamudio-Ramirez et al., 2020).

Posteriormente se realizó el análisis de los resultados obtenidos durante la automatización de la técnica como se describe a continuación. Para ello se procedió como se señala en la metodología propuesta, para el caso de análisis de mapas tiempo-frecuencia mediante la técnica ST-MUSIC. Así entonces, se dividió el mapa tiempo-frecuencia en regiones de interés. En este caso de estudio se han considerado cuatro regiones, mismas que se encuentran en una zona frecuencial por debajo de la frecuencia fundamental, esto es así ya que los armónicos de interés y que son amplificadas por tipo de fallo en este caso de estudio se desarrollan por debajo de la frecuencia fundamental: región 1 ($\sim [0-11]$ Hz), región 2 ($\sim [11-22]$ Hz), región 3 ($\sim [22-33]$ Hz) y la región 4 ($\sim [33-44]$ Hz). Estas regiones se pueden observar en la Figura 67.

Como siguiente paso se obtienen parámetros estadísticos y no estadísticos para caracterizar las regiones (bandas de frecuencia). Se han considerado los siguientes doce parámetros: (1) Entropía Wavelet no normalizada, (2) Entropía Shannon, (3) Energía de la señal, (4) Desviación estándar, (5) Media, (6) Mediana, (7) Kurtosis, (8) asimetría, (9) RMS, (10) RSSQ, (11) relación pico a promedio, (12) factor de forma y (13) factor de cresta.




Figura 67. Regiones consideradas en los mapas tiempo-frecuencia MUSIC para la automatización de la técnica (Zamudio-Ramirez et al., 2020).

La Figura 68 ilustra los resultados de aplicar el procedimiento descrito a los datos de flujo magnético de dispersión capturados durante el arranque del motor para una posición específica del sensor (posición B) y para las diferentes condiciones de falla. Esta figura muestra el valor de los indicadores estadísticos y no estadísticos antes mencionados (1 a 13), que son las entradas de la red neuronal artificial después de ser computadas para las cuatro regiones de tiempo-frecuencia bajo interés. Una simple observación de esta figura revela que la mayoría de estos indicadores (basados en MUSIC) muestran valores más altos cuando la gravedad de la falla es mayor.

Estos parámetros corresponden a las entradas de la red neuronal artificial propuesta que se basa en una red neuronal retroalimentada con tres capas ocultas (10, 6 y 4 neuronas en cada capa oculta) y que utiliza el algoritmo de entrenamiento de propagación resiliente. Para entrenar la red neuronal, se utiliza el algoritmo de propagación resiliente para identificar una condición saludable en el motor de inducción o la presencia de barras rotas en el rotor. Para ello se capturan 38 señales reales bajo cada condición del motor analizado (sano, una barra rota, dos barras rotas) dando como resultado un total de 114 muestras. De las 38 pruebas obtenidas para cada caso de estudio, 19 fueron utilizadas para el entrenamiento de la red neuronal y 19 para la validación. Las entradas a la red neuronal corresponden a los 12 parámetros estadísticos y no estadísticos extraídos de los mapas tiempo-frecuencia de MUSIC y los objetivos utilizados para el entrenamiento son los tres casos de estudio (motor saludable, una barra de rotor rota, y dos barras de rotor rotas). Después del entrenamiento y la validación, los pesos y sesgos finales de cada capa neuronal se utilizan para implementar el diagnóstico automático propuesto. La red

neuronal mostró una tasa de éxito del 100% para los casos de máquina sana y máquina con una barra rota, y un porcentaje del 84,2% para el caso de dos barras rotas. Se debe tomar en cuenta que, en esta última situación los casos de dos barras rotas no adyacentes se consideraron junto con los casos en los que las barras rotas eran adyacentes. Se ha demostrado que la ocurrencia de la falla en posiciones no adyacentes causa problemas en la determinación del nivel de falla (Riera-Guasp et al., 2010). A pesar de ello, la tasa de éxito obtenida fue muy satisfactoria para ese caso como lo muestran los resultados obtenidos.

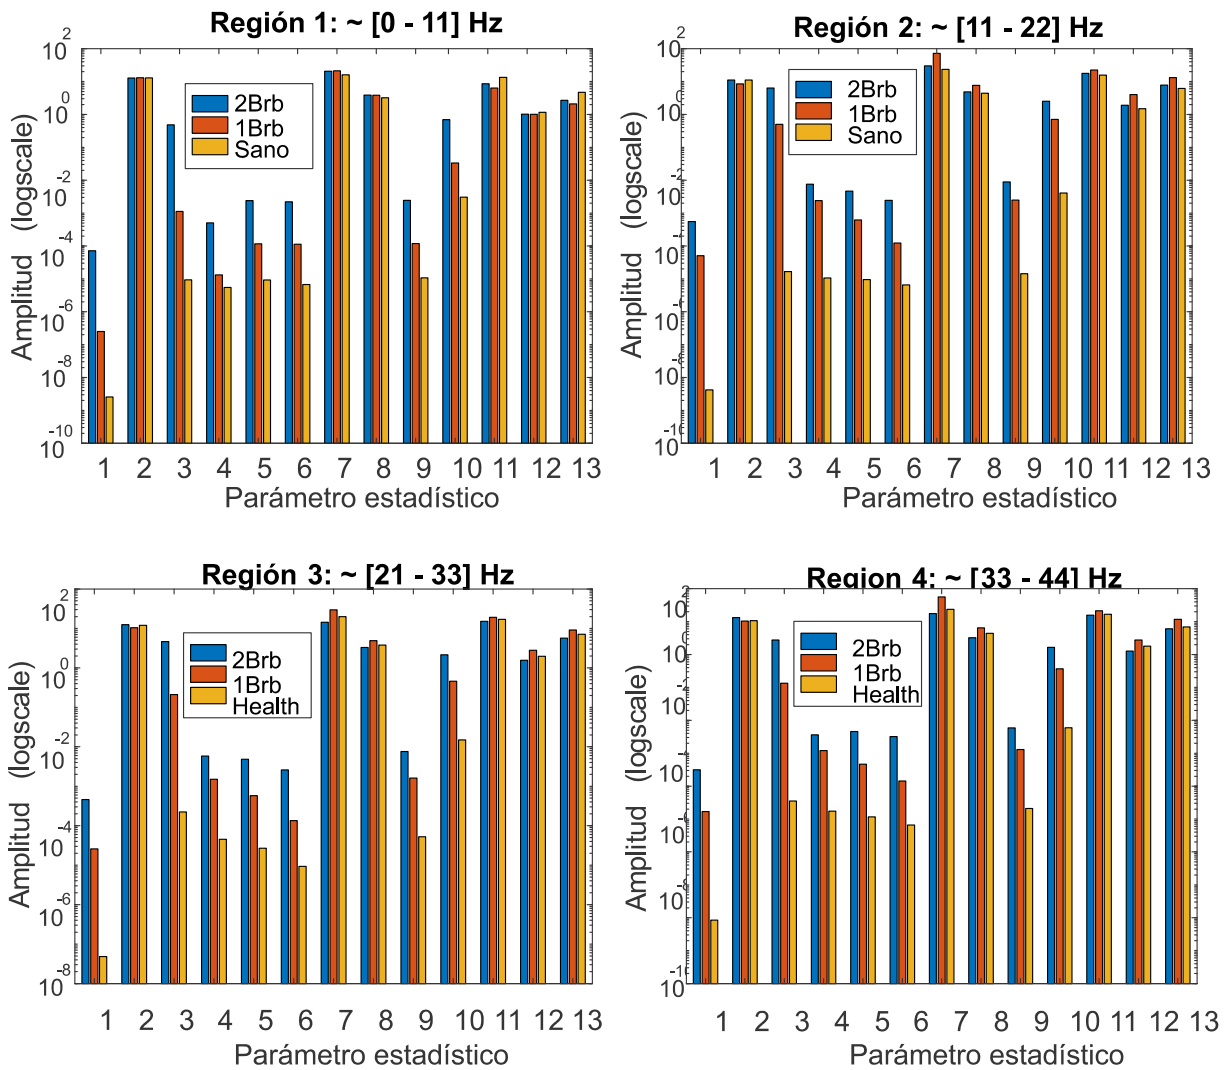


Figura 68. Cálculo de parámetros estadísticos y no estadísticos (entradas de la red neuronal artificial) para las diferentes regiones de los análisis MUSIC de las señales de flujo de dispersión capturadas para las diferentes condiciones de falla (posición B del sensor).



6.5 Aplicación de la metodología propuesta para el diagnóstico de desgaste gradual en cajas de engranes.

6.5.1 Motivación del caso de estudio

El monitoreo de condición y el diagnóstico de fallas de los sistemas rotativos mecánicos son temas muy importantes en las aplicaciones industriales ([Saucedo-Dorantes et al., 2016](#)). Las cajas de engranes son componentes esenciales en la transmisión de potencia mecánica. Estos elementos se utilizan ampliamente en muchas aplicaciones industriales en la producción aeroespacial, automotriz y de trabajo pesado, principalmente debido a su alta eficiencia de transmisión y gran capacidad de carga. Durante su vida útil, los reductores mediante engranes están sometidos a esfuerzos constantes que provocan un desgaste inminente y gradual del engranaje dentado. Esta situación puede conducir a un rendimiento inaceptable, vibraciones indeseables y mucho ruido. Además, la presencia de fallas incipientes puede provocar interrupciones inesperadas y pérdidas de producción ([Saucedo-Dorantes et al., 2016](#)).

Debido a todos estos hechos, se ha realizado un intenso esfuerzo hacia la búsqueda de metodologías confiables para el diagnóstico de fallas de la caja de engranes. La mayoría de las investigaciones en monitoreo de condición sobre cajas de engranajes se enfocan en la detección de fallas discretas como dientes rotos o astillados. De esta forma, diferentes magnitudes físicas tales como vibración, corrientes del estator, y señales de sonido han sido propuestas principalmente para el monitoreo de condición de estos elementos mecánicos ([Salameh et al., 2018](#); [Saucedo-Dorantes et al., 2016](#)). La mayoría de estos trabajos se basan en la característica de armónicos de falla específicos. Sin embargo, sus respectivas representaciones de tiempo-frecuencia (t-f) y espectro de potencia se ven borrosas debido a las señales ruidosas dentro de entornos hostiles con fuertes ruidos e interferencias, lo que compromete el diagnóstico final. Por otro lado, pocos trabajos han propuesto el uso de señales de flujo magnético de dispersión para el diagnóstico de fallas de la caja de engranajes ([Rastegar et al., 2008](#)). Los resultados obtenidos en estas investigaciones han demostrado la relevancia de analizar las señales de flujo magnético de dispersión para el estudio de fallas en cajas de engranajes. Estos trabajos se han centrado en un análisis de estado estacionario, que se basa en la magnitud de componentes armónicos de falla específicos; sin embargo, los inconvenientes de tales metodologías son bien conocidos y limitan su viabilidad en casos específicos que pueden conducir a falsos diagnósticos indeseables. Desafortunadamente, pocos trabajos están relacionados con el diagnóstico y la identificación de fallas en etapas tempranas como lo es el desgaste uniforme de los dientes.



Mediante este caso de estudio en el que se aplica la metodología propuesta, se demuestra la eficacia de esta para diagnosticar fallas incipientes en la caja de engranajes, como el desgaste uniforme de los dientes. Estas señales son capturadas durante el transitorio de arranque del motor. La propuesta se basa en la detección de patrones armónicos de falla característicos que aparecen en los mapas de tiempo-frecuencia bajo el transitorio de arranque al analizar las diferentes componentes magnéticas del flujo de dispersión (axial/radial) mediante una herramienta adecuada de descomposición de tiempo-frecuencia. En este caso de estudio se utiliza el algoritmo MUSIC de tiempo corto ya que esta herramienta permite evidenciar solo componentes de frecuencia de mayor amplitud, y además mitiga los efectos del procesamiento de señales ruidosas, un inconveniente común de las metodologías convencionales. Adicionalmente, se realiza una comparación del desempeño al caracterizar el comportamiento dinámico, y la forma en que repercute el desgaste uniforme de engranes en las señales de flujo magnético de dispersión, mediante el algoritmo MUSIC de tiempo corto, y la caracterización de dicho comportamiento mediante estadísticos en el dominio del tiempo. Los casos de estudio consisten en una caja de engranajes con engranes sano, un engranaje con un desgaste de dientes uniforme del 25 %, un engranaje con un desgaste de dientes uniforme del 50 %, y un engranaje con un desgaste de dientes uniforme del 75 %. Los resultados obtenidos son prometedores y demuestran la efectividad de la propuesta para convertirse en una excelente alternativa a los enfoques clásicos. Así entonces, mediante este caso de estudio se analiza la pertinencia de la metodología propuesta para el diagnóstico de desgaste gradual en dientes de cajas de engranes, lo que ciertamente resulta ser un caso complejo debido a la baja amplitud de las señales capturadas.

6.5.2 Puesta en marcha de experimentos.

El método propuesto se evalúa mediante un conjunto de datos experimentales que fueron recolectados en un banco de pruebas de laboratorio. Dicho banco de pruebas se basa en una cadena cinemática que comprende un motor de inducción de 2 polos, potencia de 1 hp, 220 V (WEG 00236ET3E145T-W22), una caja de engranes con relación 4:1 (BALDOR GCF4X01AA) y un alternador automotriz que se utiliza como una carga. La velocidad del motor de inducción está controlada por un variador de frecuencia; el arranque se establece en un perfil lineal basado en la variación de la frecuencia de suministro de 0 Hz a 60 Hz en 5 segundos. Las cuatro condiciones de falla consideradas (estado saludable y tres niveles diferentes de desgaste uniforme en los dientes del engranaje) se prueban sucesivamente utilizando la caja de engranes de relación 4:1 especificada. El alternador automotriz que actúa como carga mecánica se configuró para que el motor de inducción opere al 10% de su carga nominal, para los resultados que se muestran en este trabajo. La cadena cinemática de laboratorio utilizada durante la experimentación se muestra en la Figura 70.



Las señales de flujo magnético de dispersión se adquieren a través de un sensor triaxial que es capaz de capturar los diferentes componentes magnéticos del flujo de dispersión desde una misma posición en la carcasa del motor. Este sensor triaxial permite una fácil instalación ya que los diferentes componentes magnéticos del flujo de dispersión (es decir, flujo de dispersión axial, flujo de dispersión radial y flujo de dispersión axial + radial) se adquieren simultáneamente en un solo punto de la estructura del motor. Las señales se adquieren a través de un módulo de sistema de adquisición de datos (DAS) propietario (que tiene un convertidor analógico / digital de 14 bits) con una frecuencia de muestreo de 5 kHz durante un intervalo de 30 segundos que comprende tanto el arranque del motor como el estado estable posterior al régimen transitorio. La condición de falla considerada se basa en un desgaste uniforme en el engranaje que es una falla incipiente, y que ha recibido poca atención en la literatura previa en el área. De esta forma, se consideran cuatro condiciones: engranaje sano y engranaje con tres diferentes niveles de desgaste uniforme en los dientes (25%, 50% y 75%); cada una de estas cuatro condiciones se puede observar en la Figura 70a a la Figura 70d, respectivamente. Los niveles uniformes de desgaste de los dientes fueron inducidos artificialmente durante la fabricación de los engranes.

Así entonces, las condiciones consideradas se prueban experimentalmente en la cadena cinemática reemplazando el engranaje sano por cada uno de los engranajes desgastados. Posteriormente, para cada condición evaluada, las señales de flujo magnético de dispersión se adquieren continuamente durante la operación de trabajo del motor de inducción, mientras se alimenta a través del variador de frecuencia, con 60 Hz como frecuencia de suministro. Cada uno de los experimentos se realizó varias veces para adquirir diferentes señales que permitieran verificar la repetibilidad de los resultados; de esta manera, se consiguió capturar al menos 175 segundos de datos para cada condición evaluada.






Figura 69. Banco de pruebas de laboratorio basado en una cadena cinemática para la evaluación experimental de diferentes niveles de desgaste en los dientes de engranajes de una caja de cambios (Zamudio-Ramirez et al., 2022).



(a)



(b)



(c)

Figura 70. Engranés utilizados durante la experimentación: (a) engrane sano, (b) 25 % y (c) 75 % de desgaste uniforme de los dientes (Zamudio-Ramirez et al., 2022).

6.5.3 Resultados y discusión del caso de estudio.

A continuación, se muestran los resultados obtenidos al aplicar la metodología propuesta para caracterizar el desgaste uniforme de dientes en cajas de engranes mediante señales de flujo de dispersión magnética.

Primeramente, se realizó un análisis preliminar de los componentes principales, esto es, se evalúa la varianza individual y acumulada de los principales indicadores estadísticos que se calcularon (ver Tabla 2). Así entonces, se analiza la distribución de los datos para todas las condiciones evaluadas. La Tabla 9 resume los valores propios alcanzados, la varianza individual y la varianza acumulada para los primeros siete componentes principales (CP); se debe tener en cuenta que, si se seleccionan los dos primeros componentes para representar el espacio de indicadores original, se logrará una representación en un espacio bidimensional mediante la retención de una variación acumulada igual al 98,791 % del espacio de indicadores original. Esto representa una elevada representación con solo dos indicadores, de tal manera que gran porcentaje de la variación es retenida.



Tabla 9. Valores propios resultantes, varianza individual y acumulativa para los componentes principales.

Número de componente principal	Valores propios	Varianza individual (%)	Varianza acumulada (%)
CP1	1911.1	94.542	94.542
CP2	85.891	4.248	98.791
CP3	21.184	1.047	98.839
CP4	2.024	0.100	99.939
CP5	0.064	0.056	99.9953
CP6	0.016	0.003	99.998
CP7	0.012	8.33×10^{-4}	>99.999

En consecuencia, las matrices de indicadores estimadas para todas las condiciones abordadas, se someten al procedimiento de reducción de dimensionalidad por medio de la técnica de discriminante lineal (ver sección 3.3) y el espacio de indicadores original de 15 dimensiones se transforma y se proyecta en un espacio de 2 dimensiones para obtener una representación visual de las condiciones evaluadas. En este sentido, cabe destacar que la información más representativa y discriminativa la retiene la el análisis discriminante lineal llevado a cabo, ya que persigue la maximización de la separación lineal entre las condiciones estudiadas. La proyección bidimensional obtenida se muestra en la Figura 71; se debe tener en cuenta que las cuatro condiciones consideradas están claramente separadas entre sí. La separación entre las condiciones evaluadas se debe a que la proyección resultante pertenece a la combinación lineal de diferentes pesos de los indicadores estadísticos; aquellos indicadores estadísticos con pesos más altos se consideran como los más discriminativos, es decir, contienen la información más significativa que conduce a una separación lineal entre las condiciones analizadas.




Figura 71. Representación bidimensional resultante obtenida aplicando la técnica de análisis discriminante lineal a las matrices de indicadores estadísticos para todas las condiciones consideradas (Zamudio-Ramirez et al., 2022).

Siguiendo la metodología de diagnóstico propuesta para la caracterización de las señales de flujo magnético de dispersión mediante indicadores estadísticos y no estadísticos, el último paso se basa en el diagnóstico automático de fallas a través de un clasificador basado en redes neuronales artificiales. Por lo tanto, el clasificador considerado tiene tres capas; la capa de entrada consta de dos neuronas en las que cada neurona representa cada una de las características extraídas por la técnica LDA, es decir, la característica 1 y la característica 2. La capa oculta es una sola capa basada en diez neuronas. Finalmente, la capa de salida se basa en cuatro neuronas que representan cada una de las condiciones evaluadas. Así, las muestras del conjunto bidimensional de características extraídas se dividen en dos partes; el primero (con 140 muestras por condición) mismo que se usa durante el procedimiento de entrenamiento y el segundo (con 35 muestras por condición) que se usa durante la prueba y validación. El clasificador propuesto se entrena durante 70 épocas y se utiliza como método de activación el algoritmo de retropropagación con la función de activación sigmoide (ver sección 3.4). Durante el entrenamiento y la prueba, el clasificador basado en redes neuronales artificiales propuesto alcanza valores de 99,8 % y 100 % como índices de clasificación global, respectivamente. Estos índices son obtenidos mediante el cálculo del FDR, al dividir el número de clasificaciones correctas entre el número total de muestras por clase. En particular, los resultados individuales alcanzados para cada una de las condiciones evaluadas se resumen mediante la matriz de confusión en la Tabla 10, donde la clase verdadera indica el estado real de la máquina, y la clase asignada indica el estado predicho por la red neuronal empleando la metodología



propuesta. Se debe considerar que solo se produce un error de clasificación durante el procedimiento de entrenamiento, mientras que el procedimiento de prueba ajusta todas las muestras a su clase correspondiente. Estos resultados de alto rendimiento demuestran que la consideración de las etapas de cálculo y reducción de características conduce a lograr una caracterización adecuada de la señal de las condiciones evaluadas.

Tabla 10. Matriz de confusión conseguida por la clasificación individual resultante mediante el clasificador basado en redes neuronales artificiales aquí propuesto.

		Clase verdadera							
		Entrenamiento				Prueba			
		Sano	25%	50%	75%	Sano	25%	50%	75%
Clase asignada	Sano	140	0	1	0	35	0	0	0
	25%	0	140	0	0	0	35	0	0
	50%	0	0	139	0	0	0	35	0
	75%	0	0	0	140	0	0	0	35

Además, la consideración del clasificador basado en redes neuronales artificiales aquí propuesto también permite obtener las regiones de decisión que se modelan sobre la proyección bidimensional donde se representan todas las condiciones abordadas. En este sentido, la Figura 72 muestra las regiones de decisión resultantes que son modeladas por el clasificador para cada condición considerada durante el procedimiento de entrenamiento. Incluso si una sola muestra de la condición relacionada con el 50% del desgaste uniforme se clasifica incorrectamente, por medio de la función de porcentaje predicha de pertenencia, se puede reevaluar y dicho error de clasificación incorrecta se puede asignar a su clase verdadera correspondiente.




Figura 72. Regiones de decisión resultantes modeladas por el clasificador basado en redes neuronales artificiales aquí propuesto sobre el espacio bidimensional donde se representan todas las condiciones consideradas (Zamudio-Ramirez et al., 2022).

Finalmente, se realiza un análisis comparativo analizando los mapas de tiempo-frecuencia de las tres señales adquiridas de flujo magnético de dispersión correspondientes a la condición considerada. La comparación consiste en la evaluación de indicadores basados en la densidad de energía obtenidos a partir de los mapas tiempo-frecuencia proporcionados por el algoritmo ST-MUSIC descrito en la sección 3.2.2 de este trabajo. Estos indicadores se basan en la evaluación de la densidad de energía de los armónicos relacionados con el fallo bajo estudio (en su evolución durante el arranque del motor), que son aquellos descritos en la sección 2.2 de este trabajo y que han sido reportados en diferentes trabajos de investigación localizados en la literatura, bajo diferentes esquemas de evaluación. De esta manera se muestran las bondades de la metodología propuesta, y las capacidades de la misma para caracterizar las señales de flujo de dispersión para el diagnóstico de diversas fallas que suelen ocurrir en motores de inducción, dependiendo de las necesidades y características del fallo bajo estudio. Así entonces, en este caso particular, en el que el comportamiento dinámico de las señales de flujo magnético de dispersión suele ser modificado por el fallo de engranes con una amplitud muy baja se sugiere emplear técnicas aptas para ello. Por una parte, técnicas de procesamiento de señales como lo son el algoritmo ST-MUSIC que permite detectar componentes de baja amplitud en señales con una baja relación señal/ruido (alto nivel de ruido en la señal). Además, este algoritmo ofrece una excelente resolución con señales no estacionarias mientras que solo requiere una pequeña ventana de tiempo para poder realizar el cómputo del mismo. Esta característica resulta ser de especial utilidad para analizar señales en las



que se tienen componentes frecuenciales adyacentes de gran amplitud, mismas que pueden encontrarse solapadas en caso de que no se tenga una buena resolución en frecuencia de la técnica empleada. Así entonces, el uso de técnicas de alta resolución como MUSIC proporciona superficies más regulares, mitiga los efectos del ruido y evidencia solo componentes de frecuencia más grandes (Chavez et al., 2016). Por otro lado, técnicas basadas en el análisis de señales en el tiempo, como lo es el empleo de indicadores estadísticos y no estadísticos, ya que, como se ha reportado en la literatura, los armónicos relacionados a fallos en engranes suelen tener una muy baja amplitud en el espectro de Fourier para señales de flujo de dispersión, lo que fácilmente puede conducir a un falso diagnóstico.

Para este fin, Figura 73 muestra los mapas de tiempo-frecuencia resultantes donde es posible observar los patrones de evolución, obtenidos al analizar las señales capturadas durante el arranque del motor, de los armónicos amplificadas por la falla de engranes, y que son predichos en la teoría. En particular, al analizar el mapa t-f que corresponde a la señal de flujo magnético de dispersión axial + radial, es claramente visible la evolución durante el transitorio de arranque de la componente de frecuencia de falla $f_{Gr2} = f_s \pm n \cdot f_{r2}$ con $n=1$, para los casos cuando la cadena cinemática está trabajando bajo las condiciones de desgaste uniforme (es decir, 25%, 50% y 75% de desgaste uniforme en los dientes del engrane). Por el contrario, cuando la caja de engranes se encuentra en buen estado, no aparece el componente característico relacionado con la falla. Además, la Figura 73 muestra que no hay un patrón específico relacionado con un componente de falla en el flujo de dispersión axial, mientras que el flujo de dispersión radial muestra una cierta amplitud de evolución de la falla f_{Gr2} . Adicionalmente, la Tabla 11 muestra la amplitud máxima alcanzada para el armónico relacionado con la falla f_{Gr2} y para los diferentes casos estudiados. Se debe tener en cuenta que el componente de frecuencia f_{Gr2} obtenido al analizar el flujo de dispersión radial muestra una amplitud de -43.80 dB para un engranaje en buen estado; por el contrario, la misma componente de frecuencia para un 75 % de desgaste uniforme de los dientes del engrane tiene una amplitud máxima alcanzada de -32.97 dB. Asimismo, analizando el flujo de dispersión axial + radial se obtiene una amplitud máxima de f_{Gr2} de -42.165 dB para un engranaje sano, -37.648 dB para un 25% de desgaste uniforme, -34.30 dB para un 50% de desgaste uniforme y -31.77 dB para un 75 % de desgaste uniforme en el engranaje dentado. Esta situación permite discriminar entre un desgaste incipiente en el engranaje y un engranaje sano comparando la amplitud máxima del armónico relacionado con la falla f_{Gr2} durante el arranque. Además, esta condición muestra que las fallas de la caja de engranes afectan principalmente el flujo radial. Por otro lado, la amplitud máxima rastreada mediante el análisis de las señales de flujo magnético de dispersión axial muestra una diferencia mínima entre las diferentes condiciones de desgaste estudiadas. Si bien a través del análisis de los mapas t-f es posible identificar la ocurrencia de fallas en la caja de engranajes, como el desgaste

uniforme en los dientes del engranaje, la evaluación de la condición se limita a realizarse como un procedimiento manual, en el que se analizan los componentes de frecuencia característicos relacionados con la falla.

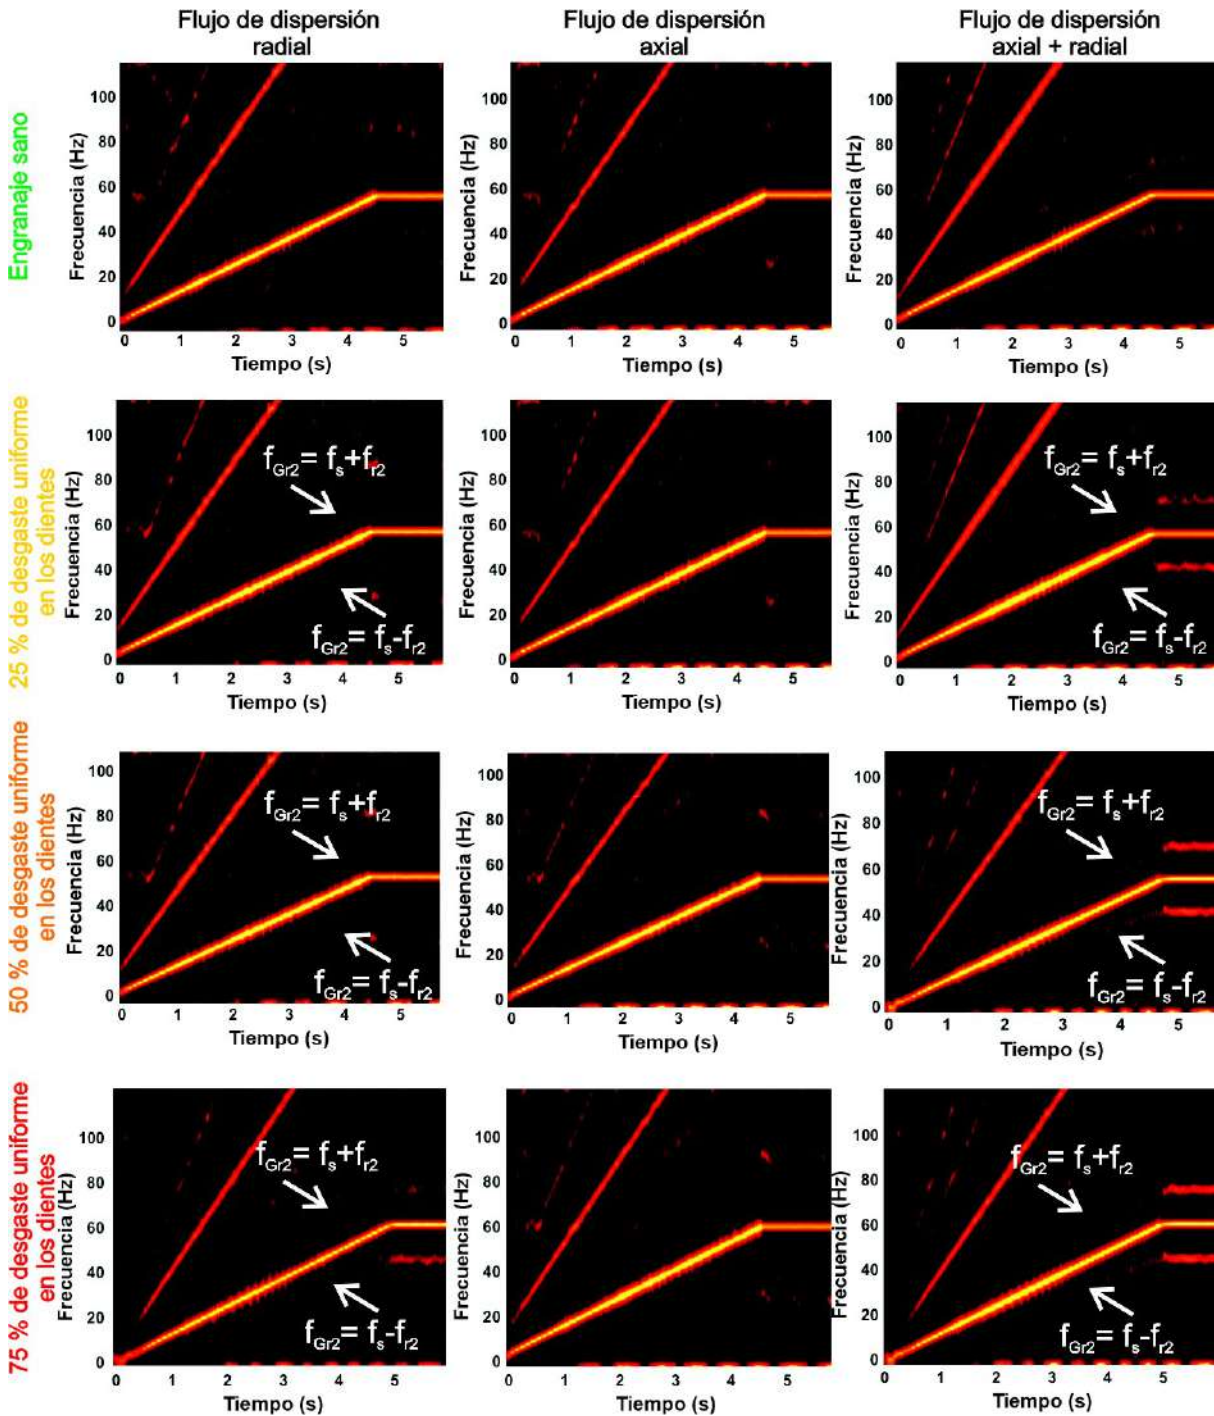


Figura 73. Análisis MUSIC de las señales de flujo magnético de dispersión capturadas durante el arranque del motor para las diferentes condiciones de falla: engranaje sano y tres condiciones de falla de desgaste uniforme en los dientes del engranaje 25%, 50% y 75% (Zamudio-Ramirez et al., 2022).



Tabla 11. Amplitud máxima rastreada para el armónico relacionado con la falla f_{Gr2}

Estado del engranaje dentado	f_{Gr2} maximum amplitude tracked (dB)		
	<i>Flujo de dispersión radial</i>	<i>Flujo de dispersión axial</i>	<i>Flujo de dispersión axial+radial</i>
Engranaje sano	-43.80	-49.890	-42.165
25 % de desgaste uniforme	-42.21	-46.450	-37.648
50 % de desgaste uniforme	-41.58	-48.60	-34.30
75 % de desgaste uniforme	-32.97	-47.300	-31.77

Finalmente, se pueden resaltar tres aspectos importantes del enfoque propuesto; en primer lugar, la propuesta de evaluación del estado que conduce a la identificación de una falla incipiente como es el desgaste uniforme en los dientes del engranaje muestra superioridad en comparación con otros trabajos relacionados en los que se han analizado fallas discretas, es decir, dientes astillados o completamente rotos en un engranaje. En segundo lugar, el análisis de las señales de flujo de dispersión y su caracterización a través de la estimación de un conjunto significativo de características estadísticas basadas en el dominio del tiempo que conducen a una identificación de patrones de las diferentes condiciones evaluadas. En tercer lugar, el análisis del conjunto de características estimado a través de PCA, que facilita determinar el número mínimo de dimensiones que se requieren para representar el espacio de características original con cualquier pérdida de información, además. Finalmente, la reducción de características a través de LDA facilita la tarea de clasificación para la estructura clásica propuesta del clasificador basado en redes neuronales artificiales; de hecho, la proporción de clasificación global lograda por el clasificador basado en redes neuronales artificiales es superior al 99,8%.



6.6 Aplicación de la metodología propuesta para el diagnóstico de desgaste de herramientas de corte en máquinas CNC

6.6.1 Motivación del caso de estudio

La industria manufacturera representa un sector de gran relevancia en el desarrollo económico de muchos países ([Haraguchi et al., 2017](#)). La optimización de los procesos de fabricación es un aspecto importante a tener en cuenta para las empresas involucradas ya que puede representar grandes beneficios económicos, siendo este uno de los principales objetivos perseguidos junto con el aumento de la calidad del producto fabricado. Los costos de las herramientas de corte, los costos de electricidad, la eficiencia del mecanizado y la calidad de la superficie mecanizada se encuentran entre los principales factores que pueden influir fuertemente en los gastos de fabricación ([Luan et al., 2018](#)). Durante un proceso de mecanizado en una máquina de Control Numérico Computarizado (CNC, por su abreviatura en inglés Computer Numeric Control), la herramienta de corte está sometida a esfuerzos constantes, lo que provoca un desgaste inminente y paulatino. De acuerdo a [Weckenmann et al. \(2003\)](#), los costes de mecanizado y sustitución de la herramienta de corte pueden representar hasta un 12% de los costos totales de producción, e incluso, la reducción del tiempo de inactividad de la máquina herramienta de corte mejora significativamente la tasa de producción ([Dutta et al., 2013](#)). En este contexto, es evidente el uso indispensable de herramientas de corte en excelentes condiciones sin reemplazarlas innecesariamente. A estos efectos, es fundamental desarrollar sistemas de monitorización del estado de la herramienta (TCM, por su abreviatura en inglés Tool Condition Monitoring) capaces de diagnosticar de forma eficaz el estado de salud de las herramientas de corte a partir de la información obtenida del proceso de mecanizado y sus diferentes elementos. Básicamente, una máquina CNC puede equiparse con dos tipos de motores eléctricos para su correcto funcionamiento: un servomotor por eje móvil y un motor de inducción para proporcionar par al husillo. Actualmente, la mayoría de las metodologías de monitorización del estado de la herramienta han extraído información de diferentes magnitudes físicas, entre otras: corriente de alimentación del servomotor, fuerzas de corte, emisiones acústicas, imágenes infrarrojas y vibraciones de la estructura mecánica. Sin embargo, muy pocos trabajos se han centrado en el motor del husillo, a pesar de que este es un elemento en conexión directa con la herramienta de corte y, en consecuencia, se puede extraer información relevante ([Lin et al., 2017](#)). Hasta este punto, aunque las técnicas de monitorización del estado de la herramienta no es un tema nuevo,



sigue siendo el foco de diversos estudios de investigación debido a su gran relevancia, ya que las metodologías actuales aún tienen algunas limitaciones y desafíos, que inherentemente limitan su viabilidad en aplicaciones industriales reales (Wong et al., 2020). Generalmente, el uso indispensable de sensores instalados cerca del área de trabajo, que indirectamente afectan los resultados finales, representa una de las principales limitaciones de las metodologías indirectas. Además, en términos prácticos, no siempre es posible instalar sensores cerca de esta zona debido a su alta invasividad en los procesos de mecanizado. Por tanto, resulta de gran relevancia explorar técnicas emergentes no invasivas mediante fuentes alternativas de información para superar los inconvenientes que persisten en las metodologías convencionales. En este contexto, el análisis del flujo magnético ha demostrado producir resultados comparables a los de métodos bien establecidos con alta confiabilidad (Ramirez-Nunez et al., 2018). Hasta el momento de la realización de esta parte de la metodología no se habían realizado investigaciones bajo la premisa de estudiar el impacto que tiene el desgaste de las herramientas de corte sobre el flujo magnético de dispersión capturado alrededor del motor del husillo en máquinas CNC, esto según lo reportado en la literatura técnica. Por lo tanto, resultó de gran relevancia explorar esta cantidad y extrapolar la metodología propuesta para el diagnóstico de desgaste en herramientas de corte.

Así entonces, en este caso de estudio se demuestra que, mediante la metodología propuesta, con la gran ventaja y excelente característica de ser una técnica no invasiva (libre de sensores cerca del área de trabajo) es posible clasificar el estado de desgaste de la herramienta de corte en máquinas CNC a través de un análisis de las señales de flujo de dispersión capturadas en la periferia del motor del husillo. Esta propuesta se basa en el hecho (como lo reporta la literatura) que la fuerza, y por ende la energía requerida para realizar el corte (suministrada por el motor del husillo) se ve alterada cuando la herramienta de corte no está en óptimas condiciones, generando así un cambio en la corriente demandada por el motor del husillo, y por tanto modificando el flujo magnético de dispersión a su alrededor. Las diferentes componentes magnéticas del flujo de dispersión (axial, radial y combinación de axial y radial) se capturan a través del sensor de flujo de dispersión triaxial propuesto en este trabajo (construido a partir de tres sensores primarios de efecto Hall colocados en ejes relativamente perpendiculares) instalado en el marco del motor del husillo de la máquina. El análisis de estas señales se realiza mediante la transformada wavelet discreta (DWT). Además, dada la relevancia de clasificar de forma automática el desgaste de la herramienta de corte en el proceso de mecanizado, se define un indicador de nivel de fallo en base a los resultados obtenidos mediante el análisis tiempo-frecuencia de las señales del flujo magnético de dispersión y luego es utilizado por una red neuronal artificial para establecer un diagnóstico final automático. Los experimentos se realizan bajo un torno CNC modelo Fanuc Oi mate considerando tres diferentes estados de desgaste de la herramienta de corte: herramienta de corte nueva, herramienta de corte desgastada y herramienta de corte rota y diversas profundidades de



corte. Los resultados obtenidos a través de un análisis de rendimiento de la propuesta de clasificación del desgaste de la herramienta de corte, independientemente de la profundidad de corte demuestran la pertinencia de utilizar el flujo magnético de dispersión del motor del husillo como fuente de información, que es capaz de arrojar datos muy relevantes para determinar la presencia de cualquiera de las fallas consideradas en este trabajo.

6.6.2 Puesta en marcha de experimentos.

El procedimiento de diagnóstico propuesto en este trabajo de tesis fue aplicado a un torno CNC Fanuc Oi mate utilizando el banco de pruebas que se muestra en la Figura 74a. Los experimentos se llevaron a cabo bajo las condiciones de herramienta de corte en base a las recomendaciones generales para torneado de acuerdo a [Kalpakjian et al. \(2014\)](#) y de acuerdo con el material base de la pieza y las herramientas de corte seleccionadas para diferentes profundidades de corte. La pieza de trabajo es una aleación de aluminio 6061 y la herramienta de corte es un inserto de carburo sin recubrimiento. Para adquirir las diferentes señales de los componentes magnéticos del flujo de dispersión, se instala el sensor de flujo de dispersión triaxial aquí propuesto (ver sección 4.2) en el marco del motor del husillo, como se muestra en la Figura 74b. Estas señales se capturan y almacenan utilizando un módulo de adquisición de señales propietario, basado en un convertidor analógico / digital marca Texas Instrument de resolución de 12 bits a una frecuencia de muestreo $f_s=5kHz$, y luego se analizan en una computadora personal. El motor de husillo instalado en el torno Fanuc Oi mate es un motor de inducción trifásico (modelo realland smart motors P96AR06D4152704) de 4 polos, de una potencia nominal de 3,7 kW y alimentado con variador de frecuencia a 220 VAC.

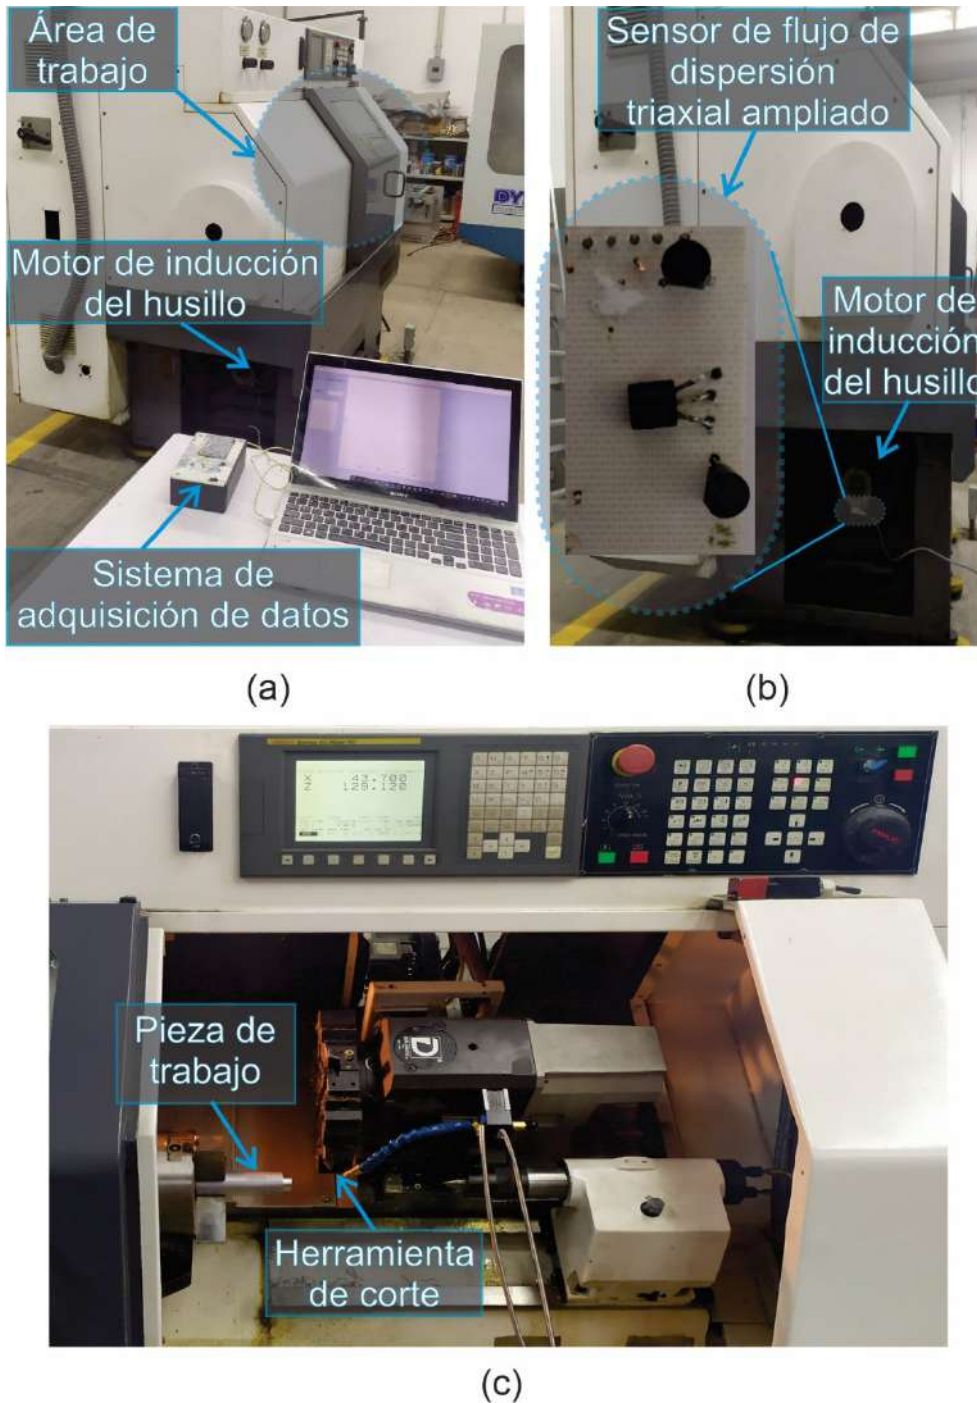


Figura 74. Configuración experimental: (a) banco de pruebas de máquinas CNC, (b) vista lateral del banco de pruebas de máquinas CNC y (c) área de trabajo (Zamudio-Ramirez et al., 2022).

Los diferentes estados de desgaste de la herramienta considerados en este caso de estudio se pueden observar en la Figura 75, a saber: herramienta de corte nueva (Figura 75a), herramienta de corte desgastada con un valor de área de desgaste de herramienta de $A_f=0.3149\text{ mm}^2$ (Figura 75b), y herramienta de corte rota con $A_f=1.7589\text{ mm}^2$, que

incluye una pequeña formación de borde acumulado y una viruta derretida sobre la herramienta de corte debido a la alta temperatura en la interfaz de la pieza de trabajo de la herramienta durante los procesos de mecanizado (ver Figura 75c).




Figura 75. Estados de desgaste de la herramienta: (a) herramienta nueva, (b) herramienta desgastada y (c) herramienta rota.

La Figura 76 muestra el proceso de corte realizado para cada uno de los casos de estudio de desgaste de herramienta de este trabajo. El ciclo de mecanizado consta de tres cortes continuos considerando una velocidad de corte de $V=200\text{ m/min}$ y un avance $f_z=0,08\text{ mm/rev}$ resultando un avance de corte $V_f=133,673\text{ mm/min}$ y 2500 rpm para el husillo. Estos parámetros se tomaron en consideración para programar un ciclo de torneado G90 en un torno CNC Fanuc Oi mate. Todos los experimentos se llevaron a cabo sin líquido refrigerante. Las variaciones de profundidad de corte consideradas en este trabajo son de $t_0=0,25\text{ mm}$ a $t_0=2,25\text{ mm}$, con un incremento $\Delta=0,5\text{ mm}$.




Figura 76. Ciclo de torneado ejecutado durante en los ensayos experimentales.

La red neuronal artificial se entrena a través del algoritmo de Levenberg-Marquardt para identificar una herramienta de corte nueva (condiciones óptimas), una herramienta de corte desgastada o una herramienta de corte rota. Para ello se extraen un total de 450 muestras a partir de ventanas cuadradas obtenidas de las señales en el tiempo del flujo magnético de dispersión axial + radial capturadas durante los ensayos experimentales, esto es: 5 (profundidades de corte) por 3 (niveles de desgaste) por 30 (señales de ventana). Cada señal de ventana se toma de una ventana cuadrada de tiempo de 1,5s cuando la herramienta de corte está realizando un corte. De las 150 señales obtenidas para cada nivel de desgaste (objetivo de clasificación), 105 se utilizan para el entrenamiento de la red neuronal artificial y 45 para la validación. La red neuronal artificial tiene una arquitectura muy simple compuesta por 2 neuronas de entradas (estas son: el indicador γ_{DWT} y profundidad de corte t_0), 4 y 8 neuronas en las capas ocultas y 3 neuronas en la capa de salida, correspondientes por cada condición de desgaste de la herramienta de corte. El número de 4 y 8 neuronas se elige por prueba y error para obtener el mínimo error de clasificación general como se sugiere en (Camarena-Martinez et al., 2014a). El número de capas ocultas se selecciona para obtener una buena precisión manteniendo un tamaño de red pequeño (Heo et al., 2018). La decisión se toma de acuerdo con la neurona de salida correspondiente con el valor de salida más alto y, debido a un entrenamiento realizado anteriormente, dicho valor debe ser cercano a 1.



6.6.3 Resultados y discusión del caso de estudio.

Para realizar el análisis de las señales de flujo magnético de dispersión se calcula el parámetro γ_{DWT} como se explica en la sección 3.1.3 y se obtiene una descomposición tiempo-frecuencia de las señales. Para estos fines, la descomposición tiempo-frecuencia mediante la técnica DWT se realiza a través del software MATLAB utilizando las funciones predefinidas 'wavedec' y 'wrccoef' que permiten obtener una descomposición y reconstrucción de coeficientes de wavelet específicos, respectivamente, y se ejecuta en seis niveles utilizando una wavelet madre *db44* debido a la excelente respuesta de frecuencia y máxima concentración de energía de esta familia wavelet como se ha mencionado y probado en trabajos previos (Rafiee et al., 2009). La banda de frecuencia cubierta por cada señal wavelet se especifica en la Tabla 12 (solo se muestran las señales más relevantes para los análisis considerados).

Tabla 12. Bandas de frecuencia cubiertas por las señales wavelet más representativas, de acuerdo a la frecuencia de muestreo empleada de 5 kHz.

Wavelet signal	Covered frequency band
d6	~ [39-78] Hz
d5	~ [78-156] Hz
d4	~ [156-312] Hz
d3	~ [312-625] Hz

La Figura 77 muestra los resultados obtenidos al usar la técnica de descomposición tiempo-frecuencia DWT para analizar los tres estados diferentes de la herramienta de corte y los tres componentes del flujo magnético de dispersión para los cortes a una profundidad $t_0=1.25\text{ mm}$. Cada período de tiempo (corte 1, corte 2 y corte 3) denota el intervalo de tiempo en el que se realiza un corte durante los experimentos. A partir de esta figura, es posible apreciar una mayor amplitud en la banda de frecuencias cubierta por la señal wavelet d_5 , especialmente este hecho se puede verificar comparando las amplitudes en la señal wavelet d_5 cuando la herramienta está rota en contraste con aquellas cuando la herramienta está en condiciones de óptimo estado. Este hecho se puede atribuir a los esfuerzos que sufre el motor del husillo debido a algún desgaste en la herramienta de corte, de tal forma que cuando una herramienta tenga un nivel de desgaste más severo, las fuerzas y potencias demandadas por el proceso de mecanizado serán mayores y, en



consecuencia, la potencia entregada por el motor del husillo será mayor. Asimismo, al contrastar la sensibilidad de los diferentes componentes del flujo magnético de dispersión, se puede observar una mayor sensibilidad para el desgaste de la herramienta de corte al analizar la combinación del de flujo dispersión axial + radial, mientras que el flujo de dispersión axial no presenta mayor sensibilidad, esto comparando los resultados obtenidos por los otros dos componentes magnéticos.

Por otro lado, la Figura 78 muestra los resultados de FFT obtenidos en condiciones de mínima carga variable al procesar las señales de flujo de dispersión axial +radial para cortes a una profundidad de corte de 1,25 mm. Los análisis se llevan a cabo utilizando una ventana de tiempo que tiene 4096 muestras, que se obtienen bajo los mismos parámetros de corte para los tres diferentes niveles de desgaste de la herramienta de corte aquí estudiados. Nótese la variación de amplitud del componente de frecuencia fundamental (f). Así, para una herramienta de corte en óptimas condiciones, se observa un valor cercano a 0.0125 mT de amplitud en f , mientras que para una herramienta de corte rota, la amplitud de f es casi el doble con respecto a una herramienta de corte nueva. Evidentemente, existe una gradualidad en la amplitud de la componente fundamental en las señales de flujo de dispersión axial +radial, siendo mayor cuanto mayor es el desgaste de la herramienta de corte.

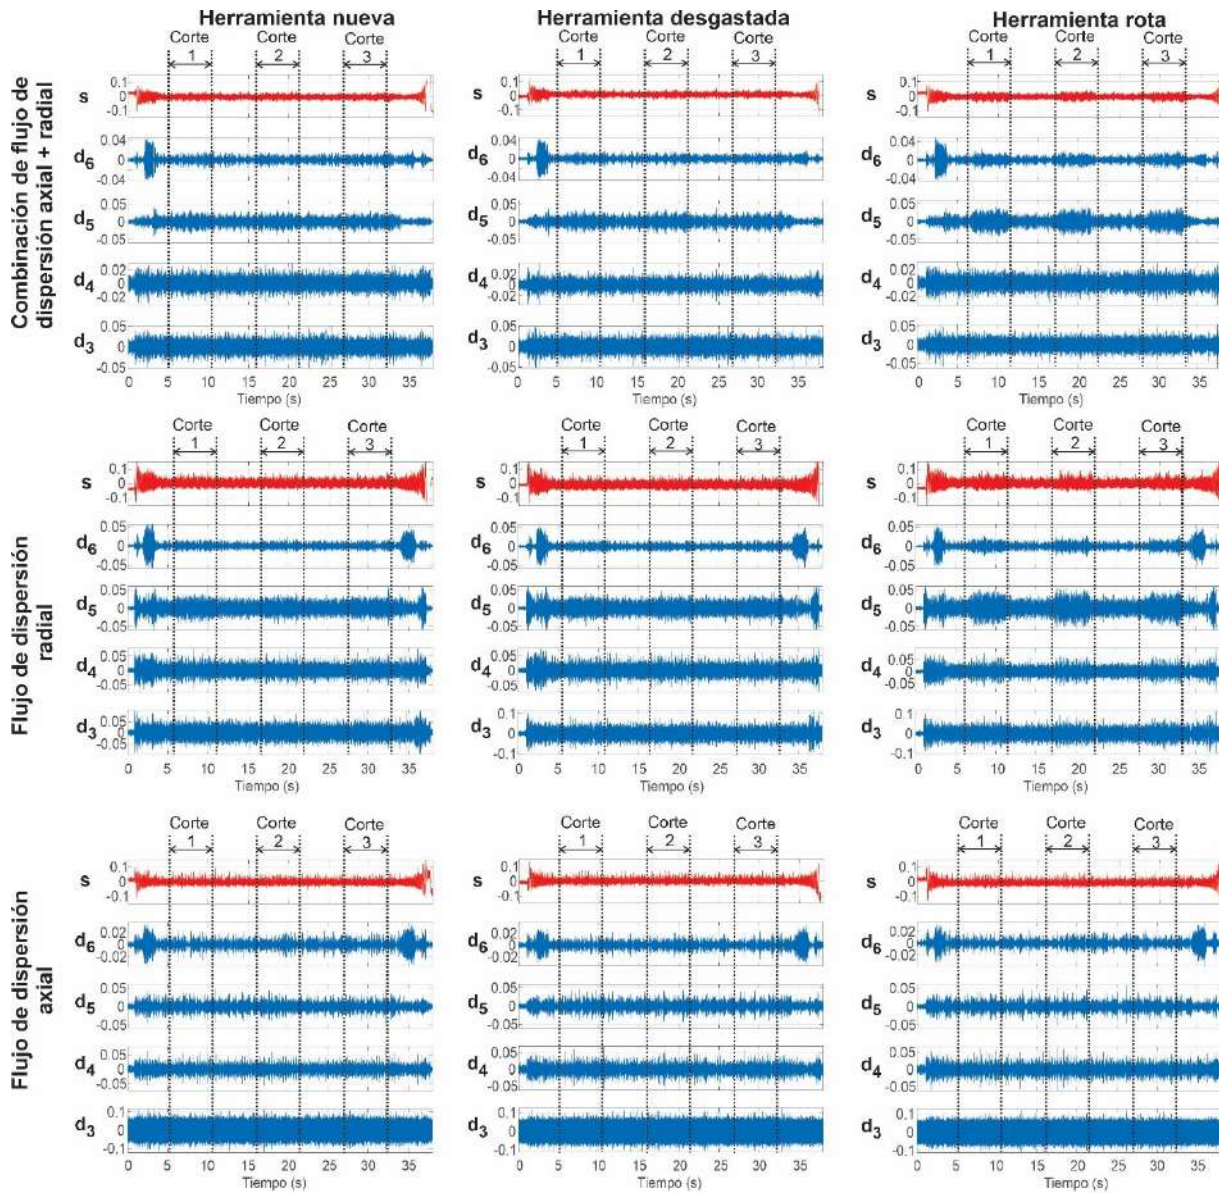


Figura 77. Análisis DWT de las diferentes señales de flujo magnético de dispersión para una profundidad de corte de 1,25 mm y para los tres niveles de desgaste de la herramienta de corte analizados en este trabajo (Zamudio-Ramirez, et al., 2022).




Figura 78. Análisis FFT para la combinación de flujo de dispersión axial y radial con una profundidad de corte de 1,25 mm para: (a) herramienta nueva, (b) herramienta desgastada y (c) herramienta rota (Zamudio-Ramirez, et al., 2022).

La Figura 79 muestra las amplitudes calculadas del parámetro γ_{DWT} obtenidas para las diferentes profundidades de corte analizadas en este trabajo, los tres niveles de desgaste y los tres diferentes componentes del flujo magnético de dispersión examinados para la señal wavelet d_5 . Se debe tener en cuenta que el parámetro γ_{DWT} proporciona un índice normalizado, que brinda información relevante relacionada con las amplitudes observadas en la señal de wavelet bajo análisis. Los resultados obtenidos indican una fuerte relación del desgaste de la herramienta de corte con las amplitudes de la señal wavelet que cubre la frecuencia fundamental de la fuente de alimentación, de tal manera que una herramienta rota proporciona índices de amplitud más bajos en comparación con una herramienta de corte sana y desgastada. Además, el flujo de dispersión axial parece tener menor relación con la falla estudiada, este hecho se puede verificar comparando las amplitudes para los diferentes niveles de desgaste para este caso específico, ya que los índices obtenidos son muy similares. Claramente, a través de este parámetro es posible discriminar entre los diferentes niveles de desgaste de la herramienta de corte estudiados en este trabajo independientemente de la profundidad de corte, especialmente cuando se analiza la señal del flujo magnético de dispersión axial + radial.

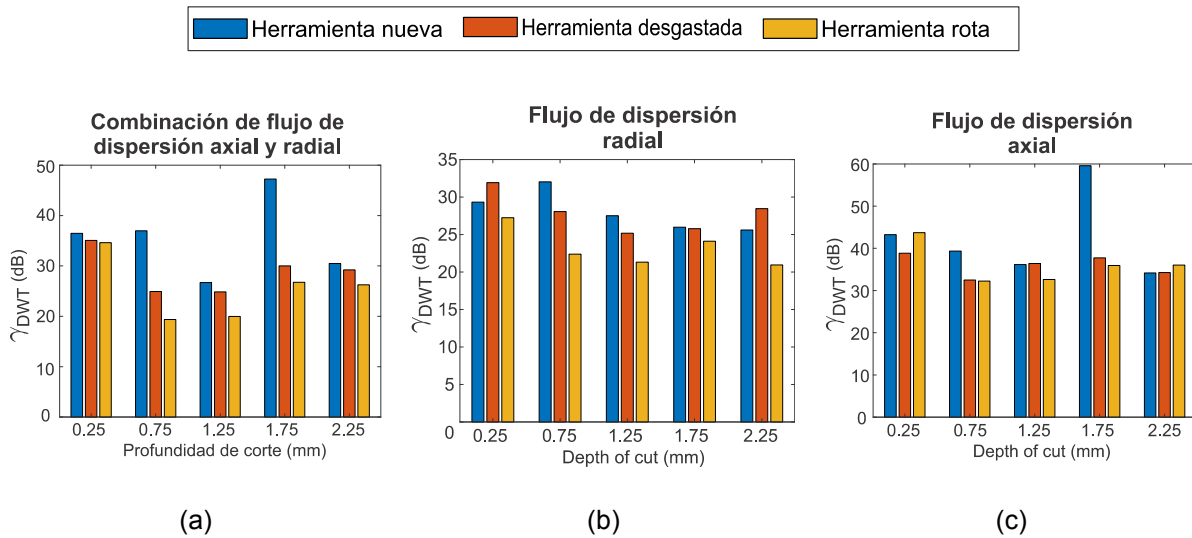


Figura 79. Valores del indicador γ_{DWT} para cada condición de desgaste de la herramienta de corte, diversas profundidades de corte, y para cada señal de las diferentes componentes del flujo de dispersión cuando se basa en la energía de la señal wavelet d_5 . (a) Flujo de dispersión axial + radial. (b) Flujo de dispersión radial. (c) Flujo de dispersión axial (Zamudio-Ramirez, et al., 2022).

Debido a la relevancia de realizar un diagnóstico oportuno en el proceso de mecanizado, en esta propuesta se utiliza una red neuronal artificial con el fin de generar un diagnóstico final automático del desgaste de la herramienta de corte. La Tabla 13 muestra los resultados de la clasificación, así como el porcentaje de efectividad de la metodología propuesta. Las clasificaciones correctas se encuentran en la diagonal de la Tabla 13 (resaltadas en negrita). A través de la metodología propuesta es posible clasificar correctamente los diferentes niveles de desgaste aquí estudiados con una efectividad superior al 88,9% (cuando la herramienta tiene desgaste leve), teniendo una efectividad del 100% para las condiciones extremas de herramienta de corte (herramienta de corte nueva y rota). La efectividad, por estado de condición de la herramienta, se obtiene a través del cálculo del índice de tasa de detección de fallas (FDR) al dividir el número de clasificaciones correctas entre el número total de muestras (45 muestras totales por estado de condición como se describe en la sección 6.6.2).



Tabla 13. Porcentaje de efectividad de la metodología propuesta al analizar el flujo de dispersión axial + radial (matriz de confusión).

Clase asignada	Clase verdadera			Efectividad (%)
	Herramienta nueva	Herramienta desgastada	Herramienta rota	
Herramienta nueva	45	0	0	100
Herramienta desgastada	5	45	0	88,9
Herramienta rota	0	0	45	100



7. CONCLUSIONES Y PROSPECTIVAS

En la presente tesis se ha desarrollado una metodología novedosa capaz de diagnosticar diversas fallas electromecánicas que suelen ocurrir en motores eléctricos, especialmente en motores de inducción, a saber: fallas de barras rotas en motores de inducción tipo jaula de ardilla, fallas de asimetrías en el rotor en motores de inducción de rotor bobinado, fallas de excentricidades, desalineamientos entre el motor y la carga, desgaste gradual en la pista exterior de rodamientos metálicos de bolas, desgaste gradual de engranes en cajas de engranes. Una de las grandes ventajas que presenta la metodología aquí propuesta es la automatización del proceso de diagnóstico final, de tal manera que no se requiere de la intervención de un experto en el tema para discernir si existe algún fallo o la gravedad del mismo, además que mediante metodologías de diagnóstico automático es posible generar análisis oportunos y en línea, antes que una falla se convierta en un daño irreversible. En el presente trabajo de tesis, este diagnóstico final se encuentra basado en el análisis y caracterización de trayectorias y patrones producidos por la amplificación de frecuencias específicas en caso de presencia de alguna avería en el motor bajo análisis. Debido a que dichas frecuencias se encuentran estrechamente relacionadas con el deslizamiento en motores eléctricos de inducción, se espera que un cambio producido en la velocidad de operación del motor se vea reflejado directamente en la frecuencia de falla. Por lo anterior, se espera que, durante estados transitorios se observe una trayectoria bien definida de la evolución de la frecuencia de fallo. Así entonces, durante el transitorio de arranque se observará un patrón claro en caso de presencia de alguna falla, ya que durante este transitorio el deslizamiento cambia de un valor 1, a un valor próximo a 0 cuando el motor alcanza el estado estable. Respecto a esto, se ha demostrado que mediante los mapas tiempo-frecuencia obtenidos a partir de señales de flujo magnético de dispersión (capturado en la periferia del motor mediante un sensor adecuado) es posible generar un diagnóstico oportuno y confiable, ya que fenómenos ajenos a la falla tienen una baja o nula repercusión en dichos patrones. Esta metodología puede encontrar muchos campos de aplicación, ya que es capaz de diagnosticar diversas fallas electromecánicas de forma automática, en línea, no invasiva, y bajo diversas condiciones de operación, inclusive en motores cuyo transitorio de arranque es de muy corta duración, como se demostró en los resultados y casos de estudio presentados en secciones anteriores. Así entonces, de acuerdo al mejor conocimiento del autor, en el momento de proponer y llevar a cabo dicha propuesta de tesis, es la primera vez en la literatura que se propone un método automático basado en el análisis de señales de flujo magnético de dispersión durante el transitorio de arranque para el monitoreo de la condición del motor de inducción, y su implementación en un dispositivo de procesamiento digital mediante lenguaje C. A diferencia de otros trabajos, el método presentado no requiere la intervención de un usuario experto para identificar los patrones de falla en las señales de flujo magnético de dispersión y llegar a



una conclusión de diagnóstico. El método inteligente desarrollado en el trabajo es capaz de identificar por sí mismo la evolución de múltiples componentes relacionados con fallas y llegar a una conclusión directa sobre la salud de la máquina.

Derivado de aplicar y analizar los resultados obtenidos de la metodología propuesta bajo una gran diversidad de casos de estudio, se han obtenido las siguientes conclusiones:

- Se propuso y desarrolló un sensor triaxial capaz de capturar el flujo magnético de dispersión localizado en la periferia de la carcasa del motor. Dicho sensor utiliza como sensor primario una matriz de tres sensores de efecto Hall ubicados en ejes perpendiculares entre sí, de modo que es posible adquirir simultáneamente, en una sola posición, los diferentes componentes de flujo disperso que contienen información de gran relevancia para el diagnóstico de fallas en motores eléctricos. Una de las principales ventajas de este sensor es que se puede ubicar prácticamente en cualquier parte del marco de la máquina, de tal manera que aún podrá capturar los diferentes componentes del flujo magnético de dispersión. Esto resulta ser de gran relevancia en términos prácticos, ya que no siempre se tiene el espacio suficiente, ni el acceso a las tres posiciones que demanda la utilización de sensores del tipo bobina.
- Se demostró que a través del sensor triaxial propuesto es posible visualizar claramente, por medio de mapas de tiempo-frecuencia, la aparición y evolución de patrones característicos que se presentan en condiciones de falla durante el transitorio de arranque y que han sido reportados y justificados en otros trabajos. Además, los resultados son totalmente consistentes con la teoría, ya que muestran que el armónico $f \cdot (1 - 2 \cdot s)$, que se amplifica por la presencia de barras de rotor rotas, se observa de forma clara y concisa al estudiar el flujo de dispersión radial, mientras que el armónico $s \cdot f$ (amplificado por la presencia de desalineaciones mecánicas entre la carga y el motor y por la presencia de barras rotativas rotas) hace su aparición con mayor intensidad en los mapas tiempo-frecuencia obtenidos mediante el análisis axial y la combinación del flujo de dispersión axial y radial.
- El enfoque propuesto se basa en la detección de patrones que aparecen en los mapas de tiempo-frecuencia bajo el arranque del motor cuando la falla está presente. Estos patrones se detectaron de manera eficiente utilizando diferentes técnicas de procesamiento de señales aplicadas a las señales de flujo de dispersión magnético capturado durante el transitorio de arranque.
- Para el caso de diagnóstico de fallas de asimetría en motores de inducción de rotor bobinado, es posible observar la evolución de la componente de falla $f \cdot (1 - 2 \cdot s)$ durante el transitorio de arranque en todos los componentes del flujo magnético de



dispersión (flujo magnético de dispersión axial, radial y axial + radial), dejando un patrón característico en forma de V en el caso de una falla de asimetría del rotor.

- Para el caso de diagnóstico de fallas de asimetría en motores de inducción de rotor bobinado, fue posible cuantificar el nivel de asimetría por medio del indicador de severidad de falla propuesto γ_{DWT} basándose en el DWT de las señales de flujo magnético de dispersión capturado en la periferia del motor. Se estableció un valor de umbral de 35 dB para discriminar entre condiciones saludables y defectuosas.
- La metodología propuesta ha demostrado ser capaz de diagnosticar el desgaste gradual de fallas en la pista exterior en rodamientos metálicos de bolas mediante el análisis y caracterización de las señales del flujo magnético de dispersión (capturadas mediante el sensor triaxial propuesto) a través de indicadores estadístico y no estadístico en el dominio del tiempo y métodos de aprendizaje automático. Se ha demostrado la viabilidad de analizar diferentes indicadores y la dimensión fractal de Katz para vincular información relevante relacionada con las fallas de los rodamientos. De acuerdo con los resultados obtenidos, no existe un indicador estadístico y/o no estadístico (de los empleados en este trabajo de tesis) individual capaz de discriminar entre los diferentes desgastes graduales aquí estudiados; sin embargo, con la combinación de la información proporcionada por distintos indicadores y el KFD por medio de un análisis discriminante lineal (LDA) es posible clasificar y diagnosticar de manera confiable diferentes grados de desgaste. La metodología propuesta supera un principal inconveniente que se encuentra en los métodos convencionales, ya que no requiere un conocimiento previo relacionado con el rodamiento instalado o la información de la velocidad de rotación del rotor. Como se muestra en los resultados obtenidos, la propuesta es capaz de diagnosticar automáticamente las diferentes severidades de falla de los rodamientos aquí estudiadas con una efectividad del 100% para los casos en que el motor impulsor se alimenta a 60 Hz, 50 Hz y 15 Hz, y un 97.5% la clasificación correcta se obtiene cuando el motor de accionamiento se alimenta a 5 Hz. A partir de estos resultados, se evidencia que la propuesta es una metodología adecuada y confiable para la detección automática de daños en rodamientos por desgaste gradual. Además, el diagnóstico final no se ve afectado por señales de baja amplitud, una de las principales limitaciones que se encuentran en algunos métodos. La propuesta puede encontrar una amplia aplicabilidad en esquemas en línea con la capacidad de detectar fallas incipientes.
- El método presentado se ha aplicado para detectar diferentes niveles de falla del rotor, pero también ha mostrado potencial para detectar la presencia de



desalineaciones entre el motor y la carga accionada (a través de la amplificación del componente en $f - fr$).

- El método propuesto basa la detección de patrones mediante mapas tiempo-frecuencia, a través de un análisis MUSIC, STFT, o DWT de señales transitorias de flujo magnético de dispersión. La detección de dichos patrones, o firmas, seguidas por los componentes de falla durante la operación transitoria demuestra ser una forma confiable de detectar muchas fallas, brindando importantes ventajas frente a los métodos clásicos basados en la evaluación de frecuencias relacionadas con fallas en los análisis FFT de estacionarios. señales Esto se debe al hecho de que es muy poco probable que estos patrones característicos sean causados por otros fenómenos que no sean una falla, mientras que un componente de frecuencia en el espectro FFT puede verse amplificado por la falla, pero también por otros efectos relacionados con la operación de la máquina (fluctuaciones de carga). ...) o características constructivas (conductos de refrigeración del rotor). Debido a estos hechos, los métodos convencionales basados en el análisis estacionario pueden conducir fácilmente a indicaciones falsas (positivas o negativas) al diagnosticar el estado de la máquina.
- El análisis MUSIC de tiempo corto utilizado en este trabajo de tesis permite conservar las características sobresalientes del pseudo-espectro MUSIC que mitiga los efectos del ruido y evidencia solo componentes de frecuencia más grandes con la ventaja de recuperar también información en el dominio del tiempo.
- La propuesta de evaluación de la condición que conduce a la identificación de fallas incipientes, como el desgaste uniforme en los dientes del engranaje muestra superioridad en comparación con trabajos similares relacionados donde se han analizado fallas discretas, es decir, dientes astillados o completamente rotos en un engranaje, ya que se lleva a cabo un análisis y diagnóstico automático de desgaste gradual.
- La reducción de características a través del LDA facilita la tarea de clasificación para la estructura clásica propuesta del clasificador basado en redes neuronales artificiales, de hecho, la relación de clasificación global lograda por el clasificador basado en redes neuronales artificiales es superior al 99,8% para el diagnóstico de desgaste gradual de dientes de engranes en cajas de cambios. Por lo tanto, los resultados de alto rendimiento demuestran la efectividad del método propuesto y hacen que el método propuesto sea adecuado para ser implementado como una herramienta de diagnóstico no invasiva que puede incorporarse en los programas de Mantenimiento Basado en la Condición para aplicaciones industriales.



- Debido al excelente desempeño mostrado por la metodología propuesta para identificar y caracterizar patrones de falla en mapas tiempo-frecuencia, fue posible aplicar y trasladar los conocimientos de la metodología propuesta para el diagnóstico de desgaste gradual de herramientas de corte en máquinas CNC. Esta posibilidad fue detectada debido a la revisión de literatura llevada a cabo, en la que se llegó a la conclusión que era indispensable contar con metodologías no invasivas para el diagnóstico de desgaste de herramientas en máquinas CNC, ya que métodos convencionales suelen ser invasivos al área de trabajo y maquinado, lo que en términos prácticos no es lo más óptimo. Por lo expuesto en renglones anteriores, en este trabajo de tesis se propone, por primera vez, una novedosa metodología no invasiva para la detección y diagnóstico del nivel de desgaste en herramientas de corte utilizadas en máquinas CNC mediante el análisis de las señales de flujo magnético de dispersión capturadas alrededor del motor del husillo de la máquina. Dado que los procesos de las máquinas CNC normalmente funcionan en condiciones de carga variable, se utiliza el DWT para el análisis, ya que esta herramienta matemática de descomposición tiempo-frecuencia tiene una respuesta adecuada a las señales variables en el tiempo. Al evaluar las amplitudes de Y_{DWT} obtenidas para los casos de estudio de este trabajo, se puede observar que este índice presenta una clara tendencia a tomar valores más altos para herramientas de corte en mejores condiciones de salud según la profundidad de corte. Evidentemente, este hecho se atribuye a la naturaleza del indicador introducido ya que, a mayores magnitudes en la banda de frecuencias analizada (que abarca el armónico de alimentación), menor es el índice obtenido. Esta circunstancia está muy relacionada con el desgaste de la herramienta de corte ya que, como se ha observado en los resultados, la amplitud del armónico fundamental es mayor cuanto mayor es el desgaste de la herramienta de corte.

Debido a los excelentes resultados obtenidos al aplicar la metodología propuesta para la caracterización del comportamiento dinámico de señales, especialmente para la caracterización de fallas en motores eléctricos de inducción, el presente trabajo abre la posibilidad a diversas áreas e investigación, como se enumera a continuación:

- Empleo de la metodología propuesta para el diagnóstico automático de fallas en motores eléctricos con distintas características constructivas a las ya estudiadas aquí, como lo son motores eléctricos de imanes permanentes, motores eléctricos de reluctancia variable, motores eléctricos alimentados por corriente directa, máquinas eléctricas empleadas para la generación de energía eléctrica, entre otros tipos de máquinas.



- Adaptación de la metodología para otro tipo de fallas, como lo son fallas en la jaula de rodamientos de bolas.
- Adaptación de la metodología propuesta para combinar indicadores provenientes de diferentes magnitudes físicas relacionadas al motor bajo análisis, como lo son corrientes estatóricas de alimentación, termogramas, vibración, etc. Esto con el objetivo de distinguir el origen del fallo, como por ejemplo distinción entre problemas debidos a excentricidades, y problemas debidos a desalineamientos.



Apéndice A. Relación de artículos publicados en revista JCR

A.1. Artículo 1.

Zamudio-Ramirez, I., Antonino-Daviu, J. A., Osornio-Rios, R. A., de Jesus Romero-Troncoso, R., & Razik, H. (2019). Detection of winding asymmetries in wound-rotor induction motors via transient analysis of the external magnetic field. *IEEE Transactions on Industrial Electronics*.



Factor de impacto de revista (2022): 8.162

5050

IEEE TRANSACTIONS ON INDUSTRIAL ELECTRONICS, VOL. 67, NO. 6, JUNE 2020



Detection of Winding Asymmetries in Wound-Rotor Induction Motors via Transient Analysis of the External Magnetic Field

Israel Zamudio-Ramirez , Jose Alfonso Antonino-Daviu , Senior Member, IEEE, Roque A. Osornio-Rios , Member, IEEE, Rene de Jesus Romero-Troncoso , Senior Member, IEEE, and Hubert Razik , Senior Member, IEEE

Abstract—Over recent decades, the detection of faults in induction motors (IMs) has been mainly focused in cage motors due to their extensive use. However, in recent years, wound-rotor motors have received special attention because of their broad use as generators in wind turbine units, as well as in some large power applications in industrial plants. Some classical approaches perform the detection of certain faults based on the fast Fourier transform analysis of the steady state current (motor current signature analysis); they have been lately complemented with new transient time–frequency-based techniques to avoid false alarms. Nonetheless, there is still a need to improve the already existing methods to overcome some of their remaining drawbacks and increase the reliability of the diagnostic. In this regard, emergent technologies are being explored, such as the analysis of stray flux at the vicinity of the motor, which has been proven to be a promising option to diagnose the motor condition. Recently, this technique has been applied to detect broken rotor bar failures and misalignments in cage motors, offering the advantage of being a noninvasive tool with simple implementation and even avoiding some drawbacks of well-established tools. However, the application of these techniques to wound rotor IMs (WRIMs) has not been studied. This article explores the analysis of

the external magnetic field under the starting to detect rotor winding asymmetry defects in WRIMs by using advanced signal processing techniques. Moreover, a new fault indicator based on this quantity is introduced, comparing different levels of fault and demonstrating the potential of this technique to quantify and monitor rotor winding asymmetries in WRIMs.

Index Terms—Stray flux, time–frequency transforms, transient analysis, wound rotor induction motor (WRIM).

I. INTRODUCTION

DU E to their robustness, simplicity, and reliability, induction motors (IMs) have been widely used as electromechanical devices for energy conversion [1]. Among the IM types, squirrel-cage and wound-rotor are the most common, the latter being less employed, but with some advantageous characteristics over other types of motors. In this regard, they are able to develop high start torques at lower start-up currents, making them adequate for industrial applications such as ball and sag mills, cranes, pumps, fans and blowers, conveyors, chippers, or hoists [2], [3]. Recently, they have been massively used as generators in wind turbine units. One of the drawbacks of the wound rotor IMs (WRIMs) in comparison with their cage rotor counterparts is their more delicate maintenance due to the more complex configuration of the rotor circuit, which implies the use of slip-ring/brushes systems to access the rotor winding. These systems are prone to suffering different types of failures due to defective contacts between slip-ring and brushes, uneven wear of the brushes in the three phases, high-resistive joints, and inadequate or uneven tightening of the springs. Indeed, some studies have shown that most failures of electric motors can be attributed to the bearings and windings [4]. Rotor winding asymmetries can lead to very negative consequences, causing unbalanced systems of rotor currents with subsequent parasitic torques and can also cause excessive vibrations and high energy dissipations [5]. These can lead to abnormal motor operation and even to irreparable insulation damages, causing notable losses for the involved companies [6]. Hence, an early detection of rotor asymmetries is of paramount importance for

Manuscript received September 26, 2018; revised March 6, 2019 and June 4, 2019; accepted July 14, 2019. Date of publication July 31, 2019; date of current version February 10, 2020. This work was supported by the Spanish “Ministerio de Ciencia Innovación y Universidades” and Fondo Europeo de Desarrollo Regional 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” under Grant PGC2018-095747-B-I00. (Corresponding author: Jose Alfonso Antonino-Daviu.)

I. Zamudio-Ramirez, R. A. Osornio-Rios, and R. de J. Romero-Troncoso are with the CA Mecatronica, Facultad de Ingenieria, Campus San Juan del Rio, Universidad Autonoma de Queretaro, 76807 San Juan del Rio, Mexico (e-mail: isra.zam.ram@hotmail.com; raosornio@hspdigital.org; troncoso@hspdigital.org).

J. Antonino-Daviu is with the Instituto Tecnológico de la Energía, Universitat Politècnica de València, 46022 Valencia, Spain (e-mail: joanda@die.upv.es).

H. Razik is with Laboratoire Ampère, Univ Claude Bernard, CNRS, University of Lyon, Villeurbanne, F-69621, France (e-mail: hubert.razik@univ-lyon1.fr).

Color versions of one or more of the figures in this article are available online at <http://ieeexplore.ieee.org>.

Digital Object Identifier 10.1109/TIE.2019.2931274

0278-0046 © 2019 IEEE. Personal use is permitted, but republication/redistribution requires IEEE permission. See <https://www.ieee.org/publications/rights/index.html> for more information.



A.2. Artículo 2.

Zamudio-Ramirez, I., Osornio-Rios, R. A., Trejo-Hernandez, M., Romero-Troncoso, R. D. J., & Antonino-Daviu, J. A. (2019). Smart-Sensors to Estimate Insulation Health in Induction Motors via Analysis of Stray Flux. *Energies*, 12(9), 1658.

Factor de impacto de revista (2022): 3.252



Article

Smart-Sensors to Estimate Insulation Health in Induction Motors via Analysis of Stray Flux

Israel Zamudio-Ramirez ¹, Roque Alfredo Osornio-Rios ¹ , Miguel Trejo-Hernandez ¹, Rene de Jesus Romero-Troncoso ¹ and Jose Alfonso Antonino-Daviu ^{2,*}

¹ Engineering Faculty, San Juan del Río Campus, Universidad Autónoma de Querétaro, Av. Río Moctezuma 249, C.P. 76808 San Juan del Río, Querétaro, México; isra.zam.ram@hotmail.com (I.Z.-R.); raosornio@hspdigital.org (R.A.O.-R.); miguel8010@yahoo.com.mx (M.T.-H.); troncoso@hspdigital.org (R.d.J.R.-T.)

² Instituto Tecnológico de la Energía, Universitat Politècnica de València (UPV), Camino de Vera s/n, 46022 Valencia, Spain

* Correspondence: joanda@die.upv.es; Tel.: +34-963-877-592

Received: 6 April 2019; Accepted: 25 April 2019; Published: 1 May 2019



Abstract: Induction motors (IMs) are essential components in industrial applications. These motors have to perform numerous tasks under a wide variety of conditions, which affects performance and reliability and gradually brings faults and efficiency losses over time. Nowadays, the industrial sector demands the necessary integration of smart-sensors to effectively diagnose faults in these kinds of motors before faults can occur. One of the most frequent causes of failure in IMs is the degradation of turn insulation in windings. If this anomaly is present, an electric motor can keep working with apparent normality, but factors such as the efficiency of energy consumption and mechanical reliability may be reduced considerably. Furthermore, if not detected at an early stage, this degradation could lead to the breakdown of the insulation system, which could in turn cause catastrophic and irreversible failure to the electrical machine. This paper proposes a novel methodology and its application in a smart-sensor to detect and estimate the healthiness of the winding insulation in IMs. This methodology relies on the analysis of the external magnetic field captured by a coil sensor by applying suitable time-frequency decomposition (TFD) tools. The discrete wavelet transform (DWT) is used to decompose the signal into different approximation and detail coefficients as a pre-processing stage to isolate the studied fault. Then, due to the importance of diagnosing stator winding insulation faults during motor operation at an early stage, this proposal introduces an indicator based on wavelet entropy (WE), a single parameter capable of performing an efficient diagnosis. A smart-sensor is able to estimate winding insulation degradation in IMs using two inexpensive, reliable, and noninvasive primary sensors: a coil sensor and an E-type thermocouple sensor. The utility of these sensors is demonstrated through the results obtained from analyzing six similar IMs with differently induced severity faults.

Keywords: induction motor; smart-sensor; stray flux; time-frequency transforms; wavelet entropy

1. Introduction

In the companies, electric motors have gained great importance, and have been widely used as electromechanical devices for the conversion of energy, consuming more than 60% of all the energy of any industrial nation [1]. Current quality requirements consider the use of monitoring systems and the development of incipient failure detection techniques increasingly necessary in order to enhance the reliability of these industrial systems so that production is not interrupted. Machines operating under faulty conditions consume and spend more energy, causing additional economical losses. Furthermore,



A.3. Artículo 3.

Zamudio-Ramírez I, Osornio-Ríos RA, Antonino-Daviu JA, Quijano-Lopez A. Smart-Sensor for the Automatic Detection of Electromechanical Faults in Induction Motors Based on the Transient Stray Flux Analysis. *Sensors*. 2020 Jan;20(5):1477.

Factor de impacto de revista (2022): 3.847



sensors



Article

Smart-Sensor for the Automatic Detection of Electromechanical Faults in Induction Motors Based on the Transient Stray Flux Analysis

Israel Zamudio-Ramírez ¹, Roque Alfredo Osornio-Ríos ¹ , Jose Alfonso Antonino-Daviu ^{2,*} 
and Alfredo Quijano-Lopez ²

¹ Engineering Faculty, San Juan del Río Campus, Universidad Autónoma de Querétaro, Av. Río Moctezuma 249, San Juan del Río, Querétaro 76807, Mexico; isra.zam.ram@hotmail.com (I.Z.-R.); raosornio@hspdigital.org (R.A.O.-R.)

² Instituto Tecnológico de la Energía, Universitat Politècnica de València (UPV), Camino de Vera s/n, 46022 Valencia, Spain; aquiqano@ite.upv.es

* Correspondence: joanda@die.upv.es; Tel.: +34-96387-7592

Received: 9 February 2020; Accepted: 5 March 2020; Published: 8 March 2020



Abstract: Induction motors are essential and widely used components in many industrial processes. Although these machines are very robust, they are prone to fail. Nowadays, it is a paramount task to obtain a reliable and accurate diagnosis of the electric motor health, so that a subsequent reduction of the required time and repairing costs can be achieved. The most common approaches to accomplish this task are based on the analysis of currents, which has some well-known drawbacks that may lead to false diagnosis. With the new developments in the technology of the sensors and signal processing field, the possibility of combining the information obtained from the analysis of different magnitudes should be explored, in order to achieve more reliable diagnostic conclusions, before the fault can develop into an irreversible damage. This paper proposes a smart-sensor that explores the weighted analysis of the axial, radial, and combination of both stray fluxes captured by a low-cost, easy setup, non-invasive, and compact triaxial stray flux sensor during the start-up transient through the short time Fourier transform (STFT) and characterizes specific patterns appearing on them using statistical parameters that feed a feature reduction linear discriminant analysis (LDA) and then a feed-forward neural network (FFNN) for classification purposes, opening the possibility of offering an on-site automatic fault diagnosis scheme. The obtained results show that the proposed smart-sensor is efficient for monitoring and diagnosing early induction motor electromechanical faults. This is validated with a laboratory induction motor test bench for individual and combined broken rotor bars and misalignment faults.

Keywords: induction motor; smart-sensor; triaxial stray flux sensor; time–frequency transforms

1. Introduction

Electric motors are very important devices for many industrial processes, as they are widely used as primary movers of most of the loads involved in those applications. Their vast usage can represent, in terms of electrical consumption, between 40% and 60% of the total in any industrial site [1]. Induction motors are especially widespread owing to their robustness, easy maintenance, low cost, and versatility [2]. However, regardless of their great advantages and exceptional features, these machines are susceptible to failure during their service life situations that compromise their performance and reliability, bringing time-gradually faults, and efficiency losses, which in turn, if not attended at incipient stages, can lead to the shutdown of processes, causing huge time and economical losses. In this regard, new techniques and methodologies to detect failures in electric motors have



A.4. Artículo 4.

Zamudio-Ramirez I, Ramirez-Núñez JA, Antonino-Daviu J, Osornio-Rios RA, Quijano-Lopez A, Razik H, Romero-Troncoso RJ. Automatic diagnosis of electromechanical faults in induction motors based on the transient analysis of the stray flux via MUSIC methods. *IEEE Transactions on Industry Applications*. 2020 Apr 16.

Factor de impacto de revista (2022): 4.079

Automatic Diagnosis of Electromechanical Faults in Induction Motors Based on the Transient Analysis of the Stray Flux via MUSIC Methods

Israel Zamudio-Ramírez[✉], Juan Angel Ramirez-Núñez, Jose Antonino-Daviu[✉], *Senior Member, IEEE*, Roque A. Osornio-Rios[✉], *Member, IEEE*, Alfredo Quijano-Lopez[✉], Hubert Razik[✉], *Senior Member, IEEE*, and Rene de Jesus Romero-Troncoso[✉], *Senior Member, IEEE*

Abstract—In the induction motor predictive maintenance area, there is a continuous search for new techniques and methods that can provide additional information for a more reliable determination of the motor condition. In this context, the analysis of the stray flux has drawn the interest of many researchers. The simplicity, low cost and potential of this technique makes it attractive for complementing the diagnosis provided by other well-established methods. More specifically, the study of this quantity under the starting has been recently proposed as a valuable tool for the diagnosis of certain electromechanical faults. Despite this fact, the research in this approach is still incipient and the employed signal processing tools must be still optimized for a better visualization of the fault components. Moreover, the development of advanced algorithms that enable the automatic identification of the resulting transient patterns is another crucial target within this area. This article presents an advanced algorithm based on the combined application of MUSIC and neural networks that enables the automatic identification of the time-frequency patterns created by the stray flux fault components under starting as well as the subsequent determination of the fault severity level. Two faults are considered in the work: rotor problems and misalignments. Also, different positions of the external coil sensor are studied. The results prove the potential of the intelligent algorithm for the reliable diagnosis of electromechanical faults.

Index Terms—Fault diagnosis, induction motors, MUSIC, neural networks, predictive maintenance, reliability, rotor, stray flux, transient analysis.

I. INTRODUCTION

THE ultimate trend in the induction motors condition monitoring area relies on combining the information coming from the analysis of different quantities in order to reach a more accurate and reliable conclusion of the motor condition. It has been concluded that no technique based on the analysis of a single quantity is able to provide a complete knowledge of the motor health, since each particular quantity is valid for the diagnosis of specific failures. In this regard, *analysis of vibrational data* is the most widespread technique in industry and has provided good results for diagnosing faults with mechanical origin, such as misalignments, bearing faults or gear failures, among others [1], [2]. On the other hand, the *analysis of motor currents* has been also proven to be effective for the detection of certain faults, such as rotor damages or eccentricities, becoming an interesting complementary option for the diagnosis of bearing damages, coupling system problems or even load anomalies [3], [4]. Analysis of motor currents includes both classical methods relying on the analysis of steady-state currents [5], as well as modern techniques based on the analysis of transient current signals; these latter have proven to provide some advantages versus the classical steady-state methods under several situations [6], [7]. *Infrared (IR) data analysis* is suitable to detect faults such as cooling system problems, deficient bearing lubrication or transmission system issues [8]–[10]. However, none of the aforementioned techniques has proven to be effective to detect other types of faults such as insulation damages. For this specific fault, *analysis of partial discharge (PD) data* has given satisfactory results [11]. In addition to these facts, each particular technique has its own constraints that may make its application difficult in specific cases. For instance, installation of vibration, PD or even current sensors is not feasible in some specific applications. In other situations, one technique can provide false indications when diagnosing the faults for which it is theoretically more appropriate.

The insufficiency of a single technique to determine the health condition of the whole motor has led to the emergence of

Manuscript received January 25, 2020; revised March 11, 2020; accepted April 10, 2020. Date of publication April 15, 2020; date of current version July 1, 2020. Paper 2019-EMC-1619.R1, presented at the 2019 IEEE 12th International Symposium on Diagnostics for Electrical Machines, Power Electronics and Drives, Toulouse, France, Aug. 27–30, and approved for publication in the IEEE TRANSACTIONS ON INDUSTRY APPLICATIONS by the Electric Machines Committee of the IEEE Industry Applications Society. This work was supported in part by the Spanish “Ministerio de Ciencia Innovación y Universidades” and in part by FEDER program in 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” (PGC2018-095747-B-I00). (Corresponding author: Jose Antonino-Daviu)

Israel Zamudio-Ramírez, Juan Angel Ramirez-Núñez, Roque A. Osornio-Rios, and Rene de Jesus Romero-Troncoso are with the CA Mecatronica, Facultad de Ingenieria, Campus San Juan del Rio, Universidad Autonoma de Queretaro, Queretaro 76807, Mexico (e-mail: isra.zam.ram@hotmail.com; joroama@hotmail.com; raosornio@hspdigital.org; troncoso@hspdigital.org).

Jose Antonino-Daviu and Alfredo Quijano-Lopez are with the Instituto Tecnológico de la Energía, Universitat Politècnica de València, 46022 Valencia, Spain (e-mail: joanda@die.upv.es; aquijsano@ite.upv.es).

Hubert Razik is with the Univ Lyon, CNRS, Ampère, UMR5005, F-69622 Villeurbanne, France (e-mail: Hubert.razik@univ-lyon1.fr).

Color versions of one or more of the figures in this article are available online at <https://ieeexplore.ieee.org>.

Digital Object Identifier 10.1109/TIA.2020.2988002

0093-9994 © 2020 IEEE. Personal use is permitted, but republication/redistribution requires IEEE permission. See <https://www.ieee.org/publications/rights/index.html> for more information.



A.5. Artículo 5.

Zamudio-Ramirez, I., Antonino-Daviu, J. A., Trejo-Hernandez, M., & Osornio-Rios, R. A. A. (2020). Cutting Tool Wear Monitoring in CNC Machines Based in Spindle-Motor Stray Flux Signals. *IEEE Transactions on Industrial Informatics*.





Factor de impacto de revista (2022): 11.648



IEEE TRANSACTIONS ON INDUSTRIAL INFORMATICS, VOL. 18, NO. 5, MAY 2022

3267

Cutting Tool Wear Monitoring in CNC Machines Based in Spindle-Motor Stray Flux Signals

Israel Zamudio-Ramírez , Jose Alfonso Antonino-Daviu , Senior Member, IEEE, Miguel Trejo-Hernandez , and Roque Alfredo Osornio-Rios , Member, IEEE

Abstract—Tool condition monitoring (TCM) is one of the most relevant tasks during a machining process. The latest high-quality productivity standards make it essential to monitor the cutting tool wearing. Current TCM methodologies demand the installation of sensors near the working area, which in practical terms, it is not the most optimal solution since the final diagnosis can be disturbed by noisy signals and direct interferences with the machining process. This article proposes a novel noninvasive methodology based on the time–frequency analysis of the stray flux captured around the spindle-motor to detect and estimate the wearing level in cutting tools. Moreover, a new fault indicator based on this quantity is introduced through the application of the discrete wavelet transform. The results obtained are promising and demonstrates the effectiveness of the proposal to become a complementary source of information to classical approaches. This is validated with a Fanuc Oi mate computer numeric control turning machine for three different cutting tool wearing levels and different cutting depths.

Index Terms—Cutting tools, induction motors, noninvasive, stray flux, tool wear monitoring.

I. INTRODUCTION

THE MANUFACTURING industry represents a highly relevant sector in the economic development of many countries [1]. The optimization of manufacturing processes is an

important aspect to be taken into consideration for the companies involved since it can represent great economic benefits, this being one of the main objectives pursued along with the increasing quality of the manufactured product. Cutting tool costs, electricity costs, machining efficiency, and machined surface quality are among the main factors that can strongly influence the manufacturing expenses [2]. During a machining process in a computer numeric control (CNC) machine, the cutting tool is subjected to constant stresses, which leads to an imminent and gradually wear. According to [3], the costs of machining and replacing the cutting tool can represent up to 12% of the total production costs, and even, the reduction of machine cutting tool downtime improves the production rate significantly [4]. In this context, it is evident the indispensable use of cutting tools in excellent conditions without replacing them unnecessarily. For these purposes, it is essential to develop tool condition monitoring (TCM) systems able to effectively diagnose the healthiness state of cutting tools by means of the information obtained from the machining process and its different elements. Essentially, a CNC machine can be equipped with two types of electric motors for its proper operation: a servo motor per moving axis, and an induction motor to provide torque to the spindle. Currently, most of the TCM methodologies have extracted information of different physical magnitudes, among others: servomotor feed current, cutting forces, acoustic emissions, infrared images, and vibrations of the mechanical structure. Nevertheless, very few works have been focused on the spindle-motor, despite the fact that this is an element in direct connection with the cutting tool and, consequently relevant information may be extracted [5]. To this point, although TCM is not a new topic, it is still the focus of diverse research studies due to its great relevance since some limitations and challenges are still uncovered by current methodologies, which inherently limit their viability on real industrial applications [6].

The diagnosis and monitoring of cutting tool wear in CNC machines has been the focus of several research works over recent years, in such a way that the use of various physical quantities has been proposed for this task. According to [7], there are essentially two groups of TCM methods: (a) direct techniques and (b) indirect techniques. Direct techniques require the removal of the cutting tool from service and analyzing it in isolation, which turns out to be not the most optimal solution since an unwanted downtime is required and, in some cases, the cutting tool is still in optimal conditions. Direct measurement of the flank wear width, crater depth and crater area with tool

Manuscript received June 21, 2020; revised August 14, 2020; accepted September 1, 2020. Date of publication September 8, 2020; date of current version February 2, 2022. This work was supported by the Spanish “Ministerio de Ciencia Innovación y Universidades” and FEDER program in 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” under Grant PGC2018-095747-B-I00. Paper TII-20-3034. (Corresponding author: Roque Alfredo Osornio-Rios.)

Israel Zamudio-Ramírez is with the CA Mecatronica, Facultad de Ingeniería, Campus San Juan del Río, Universidad Autónoma de Querétaro, San Juan del Río 76807, Mexico, and also with the Department of Electrical Engineering, Universitat Politècnica de Valencia, 46022 Valencia, Spain (e-mail: isra.zam.ram@hotmail.com).

Jose Alfonso Antonino-Daviu is with the Instituto Tecnológico de la Energía, Universitat Politècnica de Valencia, 46022 Valencia, Spain (e-mail: joanda@die.upv.es).

Miguel Trejo-Hernandez and Roque Alfredo Osornio-Rios are with the CA Mecatronica, Facultad de Ingeniería, Campus San Juan del Río, Universidad Autónoma de Querétaro, San Juan del Río 76807, Mexico (e-mail: mtrejo@hspdigital.org; raosornio@hspdigital.org).

Color versions of one or more figures in this article are available at <https://doi.org/10.1109/TII.2020.3022677>.

Digital Object Identifier 10.1109/TII.2020.3022677



A.6. Artículo 6.

Zamudio-Ramirez, I., Osornio-Rios, R. A., Antonino-Daviu, J. A., Cureño-Osornio, J., & Saucedo-Dorantes, J. J. (2021). Gradual Wear Diagnosis of Outer-Race Rolling Bearing Faults through Artificial Intelligence Methods and Stray Flux Signals. *Electronics*,10(12), 1486.

Factor de impacto de revista (2022): 2.690



electronics



Article

Gradual Wear Diagnosis of Outer-Race Rolling Bearing Faults through Artificial Intelligence Methods and Stray Flux Signals

Israel Zamudio-Ramirez ^{1,2}, Roque A. Osornio-Rios ¹, Jose A. Antonino-Daviu ^{2,*}, Jonathan Cureño-Osornio ¹ and Juan-Jose Saucedo-Dorantes ¹

- ¹ Engineering Faculty, San Juan del Río Campus, Universidad Autónoma de Querétaro, Av. Río Moctezuma 249, San Juan del Río, Querétaro 76807, Mexico; iszara@doctor.upv.es (I.Z.-R.); raosornio@hspdigital.org (R.A.O.-R.); jcureno08@alumnos.uaq.mx (J.C.-O.); jsaucedo@hspdigital.org (J.-J.S.-D.)
- ² Instituto Tecnológico de la Energía, Universitat Politècnica de València (UPV), Camino de Vera s/n, 46022 Valencia, Spain
- * Correspondence: joanda@die.upv.es; Tel.: +34-96387-7592

Abstract: Electric motors have been widely used as fundamental elements for driving kinematic chains on mechatronic systems, which are very important components for the proper operation of several industrial applications. Although electric motors are very robust and efficient machines, they are prone to suffer from different faults. One of the most frequent causes of failure is due to a degradation on the bearings. This fault has commonly been diagnosed at advanced stages by means of vibration and current signals. Since low-amplitude fault-related signals are typically obtained, the diagnosis of faults at incipient stages turns out to be a challenging task. In this context, it is desired to develop non-invasive techniques able to diagnose bearing faults at early stages, enabling to achieve adequate maintenance actions. This paper presents a non-invasive gradual wear diagnosis method for bearing outer-race faults. The proposal relies on the application of a linear discriminant analysis (LDA) to statistical and Katz’s fractal dimension features obtained from stray flux signals, and then an automatic classification is performed by means of a feed-forward neural network (FFNN). The results obtained demonstrate the effectiveness of the proposed method, which is validated on a kinematic chain (composed by a 0.746 KW induction motor, a belt and pulleys transmission system and an alternator as a load) under several operation conditions: healthy condition, 1 mm, 2 mm, 3 mm, 4 mm, and 5 mm hole diameter on the bearing outer race, and 60 Hz, 50 Hz, 15 Hz and 5 Hz power supply frequencies

Keywords: bearing fault; induction motor; Katz’s fractal dimension; linear discriminant analysis; machine learning; stray flux



Citation: Zamudio-Ramirez, I.; Osornio-Rios, R.A.; Antonino-Daviu, J.A.; Cureño-Osornio, J.; Saucedo-Dorantes, J.-J. Gradual Wear Diagnosis of Outer-Race Rolling Bearing Faults through Artificial Intelligence Methods and Stray Flux Signals. *Electronics* **2021**, *10*, 1486. <https://doi.org/10.3390/electronics10121486>

Academic Editor: Marcin Witzczak

Received: 28 May 2021

Accepted: 16 June 2021

Published: 20 June 2021

Publisher’s Note: MDPI stays neutral with regard to jurisdictional claims in published maps and institutional affiliations.



Copyright: © 2021 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

1. Introduction

Induction motors (IM) are relevant devices that have been extensively used for driving kinematic chains on a diverse number of mechatronic systems. This situation makes them essential machines for several industrial applications, which are primordial for the economy of many developed countries [1]. Its low cost, easy maintenance, robustness, and easy control explains their wide utilization. Nevertheless, despite their advantages and high robustness, IM are prone to suffer from early-stage faults (i.e., when the fault is starting to develop) mainly due to inherent operating circumstances such as thermal, electrical, mechanical or environmental stresses. Some studies have shown that most failures of electric motors can be attributed to the bearings and windings, being approximately 69% of total fault rate related to bearings [2]. The most common reported failures linked to bearings are generally due to excessive loads, insufficient lubrication, external contamination, improper








A.7. Artículo 7.

Zamudio-Ramirez, I., Osornio-Rios, R. A. A., Antonino-Daviu, J. A., Razik, H., & de Jesus Romero-Troncoso, R. (2021). Magnetic flux analysis for the condition monitoring of electric machines: a review. *IEEE Transactions on Industrial Informatics*. Factor de impacto de revista (2022): 11.648



Magnetic Flux Analysis for the Condition Monitoring of Electric Machines: A Review

Israel Zamudio-Ramirez , Roque Alfredo Osornio-Rios , Member, IEEE, Jose A. Antonino-Daviu , Senior Member, IEEE, Hubert Razik , Senior Member, IEEE, and Rene de Jesus Romero-Troncoso , Senior Member, IEEE

Abstract—Magnetic flux analysis is a condition monitoring technique that is drawing the interest of many researchers and motor manufacturers. The great enhancements and reduction in the costs and dimensions of the required sensors, the development of advanced signal processing techniques that are suitable for flux data analysis, along with other inherent advantages provided by this technology, are relevant aspects that have allowed the proliferation of flux-based techniques. This article reviews the most recent scientific contributions related to the development and application of flux-based methods for the monitoring of rotating electric machines. Particularly, aspects related to the main sensors used to acquire magnetic flux signals as well as the leading signal processing and classification techniques are commented on. The discussion is focused on the diagnosis of different types of faults in the most common rotating electric machines used in industry, namely: squirrel cage induction machines, wound rotor induction machines, permanent magnet machines, and wound field synchronous machines. A critical insight of the techniques developed in the area is provided and several open challenges are also discussed.

Index Terms—Condition monitoring, electric machines, fault diagnosis, industry, magnetic flux analysis.

I. INTRODUCTION

IN RECENT years, the rotating electric machines condition monitoring area has received great interest from both academia and industry. This is partly due to the relevance of these machines in the industrial sector, which is primordial for the economy of many developed countries [1]. In order to ensure the high efficiency, safety, and performance of the different electric machines involved in a wide variety of industrial processes, it is essential to have schemes, methodologies, and monitoring systems capable of diagnosing and detecting anomalies or defects on them. Additionally, these instruments enable us to achieve adequate maintenance actions, which prevent unscheduled downtimes and reduce maintenance costs [2]. To this end, a large percentage of methodologies, which are based on the analysis of different physical magnitudes, have been proposed, namely: stator/rotor currents, mechanical vibrations, partial discharges, temperature, among others [2], [3]. Despite the relevant advances obtained with the vast diversity of proposed approaches, each specific technique is subjected to its own constraints. As a result, it has been concluded that there is no single technique capable of diagnosing all the failures that usually occur in a rotating electric machine. Moreover, even for the faults for which the techniques have shown good results, there are still some problems that need to be addressed. This situation has triggered a number of research studies focused on the analysis of diverse signals from rotating electric machines and the application of signal processing techniques to find an optimal solution to the main drawbacks of conventional methodologies.

In order to find complementary and/or alternative options to well-established condition monitoring techniques, the investigation of other physical magnitudes has turned out to be a solution. In this context, the analysis of the magnetic flux has drawn the attention of many researchers in this area as well as some motor manufacturers who have decided to install magnetic sensors embedded in their machines with the aim of providing integrated self-diagnostic capabilities [4], [5]. This clear trend is partially due to the diverse advantages and benefits offered by the flux data analysis over other conventional techniques. In order to explain these advantages, it should be noticed that magnetic flux-based methodologies can be split into two main groups: 1) those based

Manuscript received November 23, 2020; revised March 2, 2021 and March 21, 2021; accepted March 28, 2021. Date of publication April 2, 2021; date of current version February 2, 2022. 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' reference PGC2018-095747-B-I00 and by the Consejo Nacional de Ciencia y Tecnología under CONACyT Scholarship with key code 2019-000037-02NACF. Paper no. TII-20-5308. (Corresponding author: Jose A. Antonino-Daviu.)

Israel Zamudio-Ramirez is with CA Mecatronica, Facultad de Ingeniería, Universidad Autónoma de Querétaro, San Juan del Río 76807, Mexico, and also with the Department of Electrical Engineering, Universitat Politècnica de València, 46022 Valencia, Spain (e-mail: isra.zam.ram@hotmail.com).

Roque Alfredo Osornio-Rios and Rene de Jesus Romero-Troncoso are with CA Mecatronica, Facultad de Ingeniería, Universidad Autónoma de Querétaro, San Juan del Río Querétaro 76807, Mexico (e-mail: raosornio@hspdigital.org; troncoso@hspdigital.org).

Jose A. Antonino-Daviu is with the Instituto Tecnológico de la Energía, Universitat Politècnica de València, 46022 Valencia, Spain (e-mail: joanda@die.upv.es).

Hubert Razik is with the Laboratoire Ampere, Claude Bernard University, CNRS, F-69622 Villeurbanne, France, and also with the Logistics Engineering College, Shanghai Maritime University, Shanghai 201306, China (e-mail: hubert.razik@univ-lyon1.fr).

Color versions of one or more figures in this article are available at <https://doi.org/10.1109/TII.2021.3070581>.

Digital Object Identifier 10.1109/TII.2021.3070581



A.8. Artículo 8.

Zamudio-Ramirez, I., Antonino-DAVIU, J. A., Osornio, R. A., & Dunai, L. (2021). Tracking of high-order stray-flux harmonics under starting for the detection of winding asymmetries in wound-rotor induction motors. *IEEE Transactions on Industrial Electronics*.





Factor de impacto de revista (2022): 8.162



IEEE TRANSACTIONS ON INDUSTRIAL ELECTRONICS, VOL. 69, NO. 8, AUGUST 2022

8463

Tracking of High-Order Stray-Flux Harmonics Under Starting for the Detection of Winding Asymmetries in Wound-Rotor Induction Motors

Israel Zamudio-Ramirez , Jose A. Antonino-Daviu , Senior Member, IEEE, Roque A. Osornio-Rios , Senior Member, IEEE, and Larisa Dunai , Member, IEEE

Abstract—Wound rotor induction motors (WRIM) are widely used in a vast number of high output power industrial applications due to their capability of reaching high start torques while maintaining low inrush currents. Nonetheless, these machines are very prone to require early maintenance, and the possibility of presenting rotor winding asymmetry failures is high due to their more complex rotor circuit. Although some recent works have proposed techniques that overcome the drawbacks of conventional methods, an additional research effort for the development of alternative approaches able to enhance their performance and reliability is desirable. In this work, a new method for the diagnosis of rotor asymmetries in WRIM is presented. The proposed methodology is based on a feed-forward neural network fed by suitable fault severity indicators, which rely on the maximum energy density of higher order harmonics (amplified by the failure) at strategic regions of the time-frequency maps obtained from stray flux signals under startup transient. Experimental results for three different levels of rotor asymmetries in a 11-KW WRIM prove the reliability of the enhanced proposed system in comparison to conventional approaches that only rely on the main sideband fault-harmonic amplitudes.

Index Terms—Currents, fault diagnosis, rotor asymmetries, stray flux, transient analysis, wound rotor induction motors (WRIM).

I. INTRODUCTION

WOUND rotor induction motors (WRIM) are much less used in industry than their cage counterparts. Their greater constructive complexity together with their frequent maintenance problems make the use of cage induction motors preferable, compared with the use of WRIM [1], [2]. Nonetheless, these motors also have important advantages that make them a very interesting option in many applications of diverse industries (cement, paper, steel, water distribution, etc.). One of these advantages is the possibility of accessing the rotor winding, which enables the insertion of external rheostats during motor starting; this modifies the torque-speed characteristic of these machines, yielding higher starting torques, while maintaining low starting currents [3]. This advantage is crucial when starting loads that present high resistive torques. It is frequent to find this type of motors in the medium-high power range (usually, above 1000 hp), driving loads such as pumps, cranes, fans, ball and sag mills, lowers, or conveyors [2]. In the past, these machines were also a preferred alternative for variable speed applications, taking part in configurations as the subsynchronous cascade drive, which is also widely known as slip energy recovery drive [4].

Despite their wide use in specific industrial applications, WRIM are very prone to require early maintenance and different faults may take place in a WRIM. Among them, rotor winding asymmetries are rather frequent. This is mainly due to their more complex rotor circuit, which is not only based on the winding itself, but also on additional elements such as slip rings/brushes system, external rheostat, as well as the different switchgear and connections between all these elements. The conclusion is that an asymmetry in the rotor circuit may be created by problems in any of these components, a fact that yields a high number of potential sources for this failure: uneven wear of brushes, defective contacts between slip and brushes, high resistance connections between coils of the rotor winding, unbalances in the external rheostat, and among others. In this context, some predictive maintenance techniques such as current analysis or even infrared thermography have been developed for detecting

Manuscript received March 13, 2021; revised July 13, 2021; accepted August 16, 2021. Date of publication September 3, 2021; date of current version March 1, 2022. This work was supported in part by the Spanish "Ministerio de Ciencia Innovación y Universidades" and in part by 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: Jose A. Antonino-Daviu.)

Israel Zamudio-Ramirez is with the CA Mecatronica, Facultad de Ingeniería, Campus San Juan del Río, Universidad Autónoma de Querétaro, 76807 Querétaro, Mexico, and also with the Department Electrical Engineering, Universitat Politècnica de València, 46022 Valencia, Spain (e-mail: iszara@doctor.upv.es).

Jose A. Antonino-Daviu is with the Instituto Tecnológico de la Energía, Universitat Politècnica de València, 46022 Valencia, Spain (e-mail: joanda@die.upv.es).

Roque A. Osornio-Rios is with the CA Mecatronica, Facultad de Ingeniería, Campus San Juan del Río, Universidad Autónoma de Querétaro, 76807 Querétaro, Mexico (e-mail: raor@uaq.mx).

Larisa Dunai is with the Centro de Investigación en Tecnologías Gráficas, Universitat Politècnica de València, 46022 Valencia, Spain (e-mail: ladu@upv.es).

Color versions of one or more figures in this article are available at <https://doi.org/10.1109/TIE.2021.3108716>.

Digital Object Identifier 10.1109/TIE.2021.3108716

0278-0046 © 2021 IEEE. Personal use is permitted, but republication/redistribution requires IEEE permission. See <https://www.ieee.org/publications/rights/index.html> for more information.

A.9. Artículo 9.

Zamudio-Ramirez, I., Osornio-Rios, R. A., & Antonino-Daviu, J. (2021). Smart Sensor for Fault Detection in Induction Motors Based on the Combined Analysis of Stray-Flux and Current Signals: A Flexible, Robust Approach. *IEEE Industry Applications Magazine*.

Factor de impacto de revista (2022): 0.756

Smart Sensor for Fault Detection in Induction Motors Based on the Combined Analysis of Stray-Flux and Current Signals

A FLEXIBLE, ROBUST APPROACH

By Israel Zamudio-Ramírez,
Roque Alfredo Osornio-Rios, and
Jose Alfonso Antonino-Daviu

THE MOST RECENT TREND IN THE ELECTRIC MOTOR condition monitoring area relies on combining the information obtained from different machine quantities to reach a more reliable conclusion about the motor's health. This knowledge is of critical importance today, especially in industrial applications, in which unexpected outages can lead to severe repercussions. This article presents a new intelligent sensor that combines, in a single unit, the information obtained from the analysis of stray fluxes (both axial and radial) and currents by means of a feedforward neural network (FFNN) for classification purposes. Unlike other solutions, the sensor is based on the application of advanced signal processing tools that are adapted to the online analysis of these quantities under transient conditions from a single processing unit (a smart sensor). The combination



Digital Object Identifier 10.1109/IAS.2021.3114647
Date of current version: 20 November 2021

©IEEE/ASME/IEEE/ASME








A.10. Artículo 10.

Zamudio-Ramirez, I., Saucedo-Dorantes, J. J., Antonino-Daviu, J., Osornio-Rios, R. A., & Dunai, L. (2022). Detection of Uniform Gearbox Wear in Induction Motors based on the Analysis of Stray Flux Signals through Statistical Time-Domain Features and Dimensionality Reduction Techniques. *IEEE Transactions on Industry Applications*. Factor de impacto de revista (2022): 4.079

4648

IEEE TRANSACTIONS ON INDUSTRY APPLICATIONS, VOL. 58, NO. 4, JULY/AUGUST 2022

Detection of Uniform Gearbox Wear in Induction Motors Based on the Analysis of Stray Flux Signals Through Statistical Time-Domain Features and Dimensionality Reduction Techniques

Israel Zamudio-Ramirez , Juan Jose Saucedo-Dorantes , *Member, IEEE*, Jose Antonino-Daviu , *Senior Member, IEEE*, Roque Alfredo Osornio-Rios , *Senior Member, IEEE*, and Larisa Dunai , *Member, IEEE*

Abstract—Gearboxes are core elements in power transmission systems. Although gearboxes are reliable and high-efficiency components, the occurrence of different faults is frequent since they are often subjected to adverse operating conditions. Classical gearbox condition monitoring approaches are based on the analysis of vibration and current motor signals and rely on the identification of specific fault-related frequency patterns. In this regard, this article proposes a novel diagnosis methodology based on the analysis of stray flux signals for detecting uniform wear in the gear teeth. The proposed methodology is based on the processing of the stray flux signals through feature calculation and extraction stages that lead to a high-performance signal characterization by estimating a set of statistical time domain-based features and then reducing the dimensionality by means of the principal component analysis and linear discriminant analysis techniques. Additionally, an automatic fault diagnosis is achieved through a neural network-based classifier for the detection and identification of uniform wear in a gearbox. The obtained results prove the potential of the proposal for its incorporation in condition maintenance programs in the industry, becoming an excellent alternative to classical approaches.

Index Terms—Fault diagnosis, feature extraction, gearbox wear, induction motor, linear discriminant analysis, stray flux.

Manuscript received November 13, 2021; revised February 19, 2022; accepted May 3, 2022. Date of publication May 10, 2022; date of current version July 19, 2022. This work was supported in part by Spanish “Ministerio de Ciencia Innovación y Universidades” and FEDER Program in “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” under Grant PGC2018-095747-B-I00 and in part by Consejo Nacional de Ciencia y Tecnología under Grant 652815. Paper 2021-EMC-1436.R1, presented at the IEEE Energy Conversion Congress and Exposition, Vancouver, BC, Canada, Oct. 10–14, 2021, and approved for publication in the IEEE TRANSACTIONS ON

I. INTRODUCTION

THE implementation of condition-based maintenance programs has played a key role in industrial sites to ensure the proper working condition and availability of industrial machinery [1]. Indeed, most of the industrial applications are based on electromechanical systems or kinematic chains where multiple electromechanical configurations can be made by involving the use of induction motors (IM), couplings, shafts, belts, pulleys, and gearboxes. Generally, most of these elements are mechanically coupled to be part of power transmission systems (PTS) that may be found in many industrial applications in aerospace, heavy-duty industry, wind turbines, and machining tools [2], [3]. Certainly, although gearboxes are the key element of PTS due to their high efficiency and robustness [3], adverse operating conditions produce constant stresses causing gradual wear on the gear teeth that can lead to an unacceptable reduction of their performance [4]. In this sense, the development of effective and reliable condition monitoring strategies for the assessment and detection of incipient faults such as the uniform wear in gearboxes is necessary.

A great deal of condition monitoring strategies based on the analysis of vibration, stator currents, torque, and sound have been proposed to diagnose discrete faults in gearboxes like broken or chipped teeth [1], [2], [4]. In this regard, it has been proved that the fault identification in gearboxes can be associated to the amplitude increase of the characteristic fault-related frequency components and sidebands in a vibration spectrum [1], [5]; whereas, the fault detection may be also performed by analyzing the modulation effects on stator current spectrum [6], by using



Apéndice B. Relación de comunicaciones a congresos.

Artículo 1.

Zamudio-Ramirez, I., Osornio-Rios, R. A., Romero-Troncoso, R. D. J., & Antonino-Daviu, J. A. (2019, October). Wavelet entropy to estimate the winding insulation healthiness in induction motors. In *IECON 2019-45th Annual Conference of the IEEE Industrial Electronics Society* (Vol. 1, pp. 3716-3722). IEEE.

Artículo 2.

Antonino-Daviu, J., Zamudio-Ramírez, I., Osornio-Ríos, R. A., Fuster-Roig, V., de Jesús Romero-Troncoso, R., & Dunai, L. D. (2019, October). Stray flux analysis for the detection of rotor failures in wound rotor induction motors. In *IECON 2019-45th Annual Conference of the IEEE Industrial Electronics Society* (Vol. 1, pp. 3704-3709). IEEE.

Artículo 3.

Zamudio-Ramirez, I., Osornio-Rios, R. A., & Antonino-Daviu, J. (2020, October). Triaxial Smart Sensor Based on the Advanced Analysis of Stray Flux and Currents for the Reliable Fault Detection in Induction Motors. In *2020 IEEE Energy Conversion Congress and Exposition (ECCE)* (pp. 4480-4484). IEEE.

Artículo 4.

Zamudio-Ramirez, I., Osornio-Ríos, R. A., Diaz-Saldaña, G., Trejo-Hernández, M., & Antonino-Daviu, J. A. (2020, October). STFT-based induction motor stray flux analysis for the monitoring of cutting tool wearing in CNC machines. In *IECON 2020 The 46th Annual Conference of the IEEE Industrial Electronics Society* (pp. 2511-2516). IEEE.

Artículo 5.

Antonino-Daviu, J. A., Zamudio-Ramirez, I., Osornio-Rios, R. A., Dunai, L., & Quijano-Lopez, A. (2021, April). Application of Transient Analysis to Detect Rotor and Stator Asymmetries in Wound Rotor Induction Motors: A Field Case. In *2021 IEEE Workshop on Electrical Machines Design, Control and Diagnosis (WEMDCD)* (pp. 237-242). IEEE.

Artículo 6.

Zamudio-Ramirez, I., Osornio-Rios, R. A., Cureño-Osornio, J., Saucedo-Dorantes, J. J., & Antonino-Daviu, J. A. (2021, August). Three-States Fault Detection in Rolling Bearings of Induction Motors through the analysis of Stray Flux signals using the



DWT. In *2021 IEEE 13th International Symposium on Diagnostics for Electrical Machines, Power Electronics and Drives (SDEMPED)* (Vol. 1, pp. 525-531). IEEE.

Artículo 7.

Zamudio-Ramirez, I., Osornio-Rios, R. A., & Antonino-Daviu, J. (2021, October). Transient Stray Flux Analysis Via MUSIC Methods for the Detection of Uniform Gearbox Teeth Wear Faults. In *2021 IEEE Energy Conversion Congress and Exposition (ECCE)* (pp. 4431-4435). IEEE.

Artículo 8.

Alvarado-Hernandez, A. I., Zamudio-Ramirez, I., Antonino-Daviu, J. A., & Osornio-Rios, R. A. (2021, October). Infrared thermography image processing for the electromechanical fault detection on the kinematic chain. In *IECON 2021–47th Annual Conference of the IEEE Industrial Electronics Society* (pp. 1-6). IEEE.

Artículo 9.

Biot-Monterde, V., Navarro-Navarro, A., Zamudio-Ramirez, I., Osornio-Rios, R. A., Antonino-Daviu, J., Mäki-Ontto, P., ... & Fajt, T. (2022, September). Effect of the Misalignment Level on the Analyses of Current and Stray Flux Signals in Induction Motors. In *2022 International Conference on Electrical Machines (ICEM)* (pp. 1530-1536). IEEE.

Artículo 10.

Navarro-Navarro, A., Biot-Monterde, V., Zamudio-Ramirez, I., Antonino-Daviu, J., Osornio-Rios, R. A., Mäki-Ontto, P. & Fajt, T. (2022, September). Detection of Induction Motor Coupling Unbalance through the Analysis of Electrical Quantities under Starting and at Steady-state. In *2022 International Conference on Electrical Machines (ICEM)* (pp. 663-669). IEEE.

Artículo 11.

Cureño-Osornio, J., Saucedo-Dorantes, J. J., Elvira-Ortiz, D. A., Jaen-Cuellar, A. Y., Zamudio-Ramirez, I., Antonino-Daviu, J. A., & Osornio-Rios, R. A. (2022, September). Gradual Fault Condition Detection in the Outer Race of Induction Motor Hybrid Bearings Based on Stray Flux and LDA-FFNN Approaches. In *2022 International Conference on Electrical Machines (ICEM)* (pp. 1809-1815). IEEE.



BIBLIOGRAFÍA

- Abd-el-Malek, M., Abdelsalam, A. K., & Hassan, O. E. (2017). Induction motor broken rotor bar fault location detection through envelope analysis of start-up current using Hilbert transform. *Mechanical Systems and Signal Processing*, 93, 332–350. <https://doi.org/10.1016/j.ymssp.2017.02.014>
- Al Badawi, F. S., & Al Muhaini, M. (2015). Reliability modelling and assessment of electric motor driven systems in hydrocarbon industries. *IET Electric Power Applications*, 9(9), 605–611. <https://doi.org/10.1049/iet-epa.2015.0089>
- Alberto, B., Filippetti, F., Franceschini, G., Tassoni, C., & Kliman, G. B. (2000). Quantitative Evaluation of Induction Motor Broken Bars by Means of Electrical Signature Analysis. *IEEE Transactions on Industry Applications*, 00(C), 1248–1255.
- Amezquita-Sanchez, J. P., Valtierra-Rodriguez, M., Perez-Ramirez, C. A., Camarena-Martinez, D., Garcia-Perez, A., & Romero-Troncoso, R. J. (2017). Fractal dimension and fuzzy logic systems for broken rotor bar detection in induction motors at start-up and steady-state regimes. *Measurement Science and Technology*, 28(7), 75001. <https://doi.org/10.1088/1361-6501/aa6adf>
- Antonino-daviu, J. A., Lee, S.-B., & Wiedenbrug, E. (2014). Reliable Detection of Rotor Bar Failures in Induction. *Petroleum and Chemical Industry Conference Europe*, 1–9.
- Antonino-Daviu, J., & Popaleny, P. (2018). Detection of induction motor coupling unbalanced and misalignment via advanced transient current signature analysis. *Proceedings - 2018 23rd International Conference on Electrical Machines, IECM 2018*, 2359–2364. <https://doi.org/10.1109/ICELMACH.2018.8506949>
- Antonino-Daviu, J., Riera-Guasp, M., Roger-Folch, J., Martínez-Giménez, F., & Peris, A. (2006). Application and optimization of the discrete wavelet transform for the detection of broken rotor bars in induction machines. *Applied and Computational Harmonic Analysis*, 21(2), 268–279. <https://doi.org/10.1016/j.acha.2005.12.003>
- Azamfar, M., Singh, J., Bravo-Imaz, I., & Lee, J. (2020). Multisensor data fusion for gearbox fault diagnosis using 2-D convolutional neural network and motor current signature analysis. *Mechanical Systems and Signal Processing*, 144, 106861. <https://doi.org/10.1016/j.ymssp.2020.106861>
- Bacha, K., Henao, H., Gossa, M., & Capolino, G. A. (2008). Induction machine fault detection using stray flux EMF measurement and neural network-based decision. *Electric Power Systems Research*, 78(7), 1247–1255. <https://doi.org/10.1016/j.epsr.2007.10.006>
- Bediaga, I., Mendizabal, X., Arnaiz, A., & Munoa, J. (2013). Ball bearing damage detection using traditional signal processing algorithms. *IEEE Instrumentation and Measurement Magazine*, 16(2), 20–25. <https://doi.org/10.1109/MIM.2013.6495676>
- Bellini, A., Concari, C., Franceschini, G., Tassoni, C., & Toscani, A. (2006). Vibrations, currents and stray flux signals to asses induction motors rotor conditions. *IECON*



- Proceedings (Industrial Electronics Conference)*, 2(3), 4963–4968. <https://doi.org/10.1109/IECON.2006.347365>
- Bellini, A., Filippetti, F., Tassoni, C., & Capolino, G. (2008). Advances in Diagnostic Techniques for Induction Machines. *IEEE Transactions on Industrial Electronics*, 55(12), 228–293. <https://doi.org/10.1201/b11685-11>
- Bellini, A., Immovilli, F., Rubini, R., & Tassoni, C. (2008). Diagnosis of bearing faults in induction machines by vibration or current signals: A critical comparison. *Conference Record - IAS Annual Meeting (IEEE Industry Applications Society)*, 46(4), 1350–1359. <https://doi.org/10.1109/08IAS.2008.26>
- Bessous, N., Zouzou, S. E., Sbaa, S., Bentrach, W., Becer, Z., & Ajgou, R. (2017). Static eccentricity fault detection of induction motors using MVSA, MCSA and discrete wavelet transform (DWT). *2017 5th International Conference on Electrical Engineering - Boumerdes, ICEE-B 2017, 2017-Janua*, 1–10. <https://doi.org/10.1109/ICEE-B.2017.8192035>
- Blanco, S., Figliola, A., Quiroga, R. Q., Rosso, O. A., & Serrano, E. (1998). Time-frequency analysis of electroencephalogram series. III. Wavelet packets and information cost function. *Physical Review E - Statistical Physics, Plasmas, Fluids, and Related Interdisciplinary Topics*, 57(1), 932–940. <https://doi.org/10.1103/PhysRevE.57.932>
- Bonnett, A. H., & Soukup, G. C. (1992). Cause and Analysis of Stator and Rotor Induction Motors. *IEEE Transactions on Industry Applications*, 28(4), 921–937.
- Bonnett, A. H., & Yung, C. (2008). Increased efficiency versus increased reliability. *IEEE Industry Applications Magazine*, 14(1), 29–36. <https://doi.org/10.1109/MIA.2007.909802>
- Bossio, J. M., Bossio, G. R., & De Angelo, C. H. (2009). Angular misalignment in induction motors with flexible coupling. *IECON Proceedings (Industrial Electronics Conference)*, 1033–1038. <https://doi.org/10.1109/IECON.2009.5414696>
- Caesarendra, W., & Tjahjowidodo, T. (2017). A review of feature extraction methods in vibration-based condition monitoring and its application for degradation trend estimation of low-speed slew bearing. *Machines*, 5(4). <https://doi.org/10.3390/machines5040021>
- Camarena-Martinez, D., Valtierra-Rodriguez, M., Garcia-Perez, A., Osornio-Rios, R. A., & Romero-Troncoso, R. D. J. (2014a). Empirical mode decomposition and neural networks on FPGA for fault diagnosis in induction motors. *The Scientific World Journal*, 2014. <https://doi.org/10.1155/2014/908140>
- Camarena-Martinez, D., Valtierra-Rodriguez, M., Garcia-Perez, A., Osornio-Rios, R. A., & Romero-Troncoso, R. D. J. (2014b). Empirical mode decomposition and neural networks on FPGA for fault diagnosis in induction motors. *The Scientific World Journal*, 2014, 908140. <https://doi.org/10.1155/2014/908140>
- Ceban, A., Pusca, R., & Romary, R. (2012). Study of rotor faults in induction motors using external magnetic field analysis. *IEEE Transactions on Industrial Electronics*, 59(5), 2082–2093. <https://doi.org/10.1109/TIE.2011.2163285>



- Chavez, O., Amezquita-Sanchez, J. P., Valtierra-Rodriguez, M., Cruz-Abeyro, J. A., Kotsarenko, A., Millan-Almaraz, J. R., Dominguez-Gonzalez, A., & Rojas, E. (2016). Novel ST-MUSIC-based spectral analysis for detection of ULF geomagnetic signals anomalies associated with seismic events in Mexico. *Geomatics, Natural Hazards and Risk*, 7(3), 1162–1174. <https://doi.org/10.1080/19475705.2015.1016554>
- 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>
- Daubechies, I. (1990). The Wavelet Transform, Time-Frequency Localization and Signal Analysis. *IEEE Transactions on Information Theory*, 36(5), 961–1005. <https://doi.org/10.1109/18.57199>
- Delgado-Arredondo, P. A., Garcia-Perez, A., Morinigo-Sotelo, D., Osornio-Rios, R. A., Avina-Cervantes, J. G., Rostro-Gonzalez, H., & Romero-Troncoso, R. D. J. (2015). Comparative Study of Time-Frequency Decomposition Techniques for Fault Detection in Induction Motors Using Vibration Analysis during Startup Transient. *Shock and Vibration*, 2015. <https://doi.org/10.1155/2015/708034>
- Donnell, P. O., Heising, C., Singh, C., & Wells, S. J. (1987). Report of Large Motor Reliability Survey of Industrial and Commercial Installations: Part 3. *IEEE Transactions on Industry Applications*, IA-23(1), 153–158. <https://doi.org/10.1109/TIA.1987.4504880>
- Dutta, S., Pal, S. K., Mukhopadhyay, S., & Sen, R. (2013). Application of digital image processing in tool condition monitoring: A review. *CIRP Journal of Manufacturing Science and Technology*, 6(3), 212–232. <https://doi.org/https://doi.org/10.1016/j.cirpj.2013.02.005>
- Feng, J., & Lu, S. (2019). Performance analysis of various activation functions in artificial neural networks. *Journal of Physics: Conference Series*, 1237(2), 22030.
- Fernandez-Cavero, V., Morinigo-Sotelo, D., Duque-Perez, O., & Pons-Llinares, J. (2017). A Comparison of Techniques for Fault Detection in Inverter-Fed Induction Motors in Transient Regime. *IEEE Access*, 5, 8048–8063. <https://doi.org/10.1109/ACCESS.2017.2702643>
- Filippetti, F., Franceschini, G., Tassoni, C., & Vas, P. (1998). AI techniques in induction machines diagnosis including the speed ripple effect. *IEEE Transactions on Industry Applications*, 34(1), 98–108. <https://doi.org/10.1109/28.658729>
- Fortescue, C. L. (1918). Method of symmetrical co-ordinates applied to the solution of polyphase networks. *Transactions of the American Institute of Electrical Engineers*, 37, 1027–1140. <https://doi.org/10.1109/T-AIEE.1918.4765570>
- Frosini, L. (2020). Novel diagnostic techniques for rotating electrical machines—A review. *Energies*, 13(19), 5066. <https://doi.org/10.3390/en13195066>
- Frosini, L., Albin, A., & Beccarisi, F. (2017). Detection of torque oscillations in induction motor drives by linear discriminant analysis. *Proceedings of the 2017 IEEE 11th International Symposium on Diagnostics for Electrical Machines, Power Electronics and Drives, SDEMPED 2017, 2017-Janua(1)*, 510–516.



<https://doi.org/10.1109/DEMPED.2017.8062403>

- Frosini, L., Harlisca, C., & Szabo, L. (2015). Induction machine bearing fault detection by means of statistical processing of the stray flux measurement. *IEEE Transactions on Industrial Electronics*, 62(3), 1846–1854. <https://doi.org/10.1109/TIE.2014.2361115>
- Garcia, M., Panagiotou, P. A., Antonino-Daviu, J. A., & Gyftakis, K. N. (2019). Efficiency assessment of induction motors operating under different faulty conditions. *IEEE Transactions on Industrial Electronics*, 66(10), 8072–8081. <https://doi.org/10.1109/TIE.2018.2885719>
- Goktas, T., Zafarani, M., Lee, K. W., Akin, B., & Sculley, T. (2017). Comprehensive Analysis of Magnet Defect Fault Monitoring Through Leakage Flux. *IEEE Transactions on Magnetics*, 53(4).
- Grande-Barreto, J., Morales-Perez, C., Rangel-Magdaleno, J., & Peregrina-Barreto, H. (2017). Half-broken bar detection using MCSA and statistical analysis. *2017 IEEE International Autumn Meeting on Power, Electronics and Computing, ROPEC 2017, 2018-Janua(ROPEC)*, 1–5. <https://doi.org/10.1109/ROPEC.2017.8261598>
- Gritli, Y., Zarri, L., Rossi, C., Filippetti, F., Capolino, G. A., & Casadei, D. (2013). Advanced diagnosis of electrical faults in wound-rotor induction machines. *IEEE Transactions on Industrial Electronics*, 60(9), 4012–4024. <https://doi.org/10.1109/TIE.2012.2236992>
- Guo, D., Chu, F., & Chen, D. (2003). The unbalanced magnetic pull and its effects on vibration in a three-phase generator with eccentric rotor. *Journal of Sound and Vibration*, 254(2), 297–312. <https://doi.org/10.1006/jsvi.2001.4088>
- Guo, H., & Liu, M. K. (2018). Induction motor faults diagnosis using support vector machine to the motor current signature. *Proceedings - 2018 IEEE Industrial Cyber-Physical Systems, ICPS 2018*, 417–421. <https://doi.org/10.1109/ICPHYS.2018.8390701>
- Gyftakis, K. N., Antonino-Daviu, J. A., Garcia-Hernandez, R., McCulloch, M. D., Howey, D. A., & Cardoso, A. J. M. (2016). Comparative Experimental Investigation of Broken Bar Fault Detectability in Induction Motors. *IEEE Transactions on Industry Applications*, 52(2), 1452–1459. <https://doi.org/10.1109/TIA.2015.2505663>
- Gyftakis, K. N., Panagiotou, P. A., & Lee, S. Bin. (2019). The Role of the Mechanical Speed Frequency on the Induction Motor Fault Detection via the Stray Flux. *Proceedings of the 2019 IEEE 12th International Symposium on Diagnostics for Electrical Machines, Power Electronics and Drives, SDEMPED 2019*, 201–207. <https://doi.org/10.1109/DEMPED.2019.8864863>
- Gyftakis, K. N., Panagiotou, P. A., & Lee, S. Bin. (2020). Generation of Mechanical Frequency Related Harmonics in the Stray Flux Spectra of Induction Motors Suffering from Rotor Electrical Faults. *IEEE Transactions on Industry Applications*, 56(5), 4796–4803. <https://doi.org/10.1109/TIA.2020.3002975>
- Haraguchi, N., Cheng, C. F. C., & Smeets, E. (2017). The Importance of Manufacturing in Economic Development: Has This Changed? *World Development*, 93, 293–315. <https://doi.org/10.1016/j.worlddev.2016.12.013>
- 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>
- Henao, H., Demian, C., & Capolino, G. A. (2003). A frequency-domain detection of stator winding faults in induction machines using an external flux sensor. *IEEE Transactions on Industry Applications*, 39(5), 1272–1279. <https://doi.org/10.1109/TIA.2003.816531>
- Heo, S., & Lee, J. H. (2018). Fault detection and classification using artificial neural networks. *IFAC-PapersOnLine*, 51(18), 470–475. <https://doi.org/10.1016/j.ifacol.2018.09.380>
- Higuchi, T. (1988). Approach to an irregular time series on the basis of the fractal theory. *Physica D: Nonlinear Phenomena*, 31(2), 277–283. [https://doi.org/10.1016/0167-2789\(88\)90081-4](https://doi.org/10.1016/0167-2789(88)90081-4)
- Huerta-Rosales, J. R., Granados-Lieberman, D., Garcia-Perez, A., Camarena-Martinez, D., Amezcua-Sanchez, J. P., & Valtierra-Rodriguez, M. (2021). Short-circuited turn fault diagnosis in transformers by using vibration signals, statistical time features, and support vector machines on fpga. *Sensors*, 21(11). <https://doi.org/10.3390/s21113598>
- Irhoumah, M., Pusca, R., Lefevre, E., Mercier, D., & Romary, R. (2020). Adapted coil sensors for measuring the external magnetic field of electrical machines. *ACM International Conference Proceeding Series*. <https://doi.org/10.1145/3410352.3410824>
- Ishkova, I., & Vítek, O. (2016). Detection and classification of faults in induction motor by means of motor current signature analysis and stray flux monitoring. *Przeglad Elektrotechniczny*, 92(4), 166–170. <https://doi.org/10.15199/48.2016.04.36>
- Jarne, C. G. (2018). A heuristic approach to obtain signal envelope with a simple software implementation. *Asociación Física Argentina*.
- Kalpakjian, S., & Schmid, S. R. (2014). *Manufacturing engineering and technology*. Pearson Prentice Hall.
- Kar, C., & Mohanty, A. R. (2006). Monitoring gear vibrations through motor current signature analysis and wavelet transform. *Mechanical Systems and Signal Processing*, 20(1), 158–187. <https://doi.org/10.1016/j.ymssp.2004.07.006>
- Katz, M. J. (1988). Fractals and the analysis of waveforms. *Computers in Biology and Medicine*, 18(3), 145–156. [https://doi.org/10.1016/0010-4825\(88\)90041-8](https://doi.org/10.1016/0010-4825(88)90041-8)
- Kia, S. H. (2018). Monitoring of Wound Rotor Induction Machines by Means of Discrete Wavelet Transform. *Electric Power Components and Systems*, 46(19–20), 2021–2035. <https://doi.org/10.1080/15325008.2018.1562647>
- Kia, S. H., Hénao, H., & Capolino, G. A. (2007). Gearbox monitoring using induction machine stator current analysis. *2007 IEEE International Symposium on Diagnostics for Electric Machines, Power Electronics and Drives, SDEMPED*, 149–154. <https://doi.org/10.1109/DEMPED.2007.4393086>
- Kuang, J. H., & Lin, A. D. (2003). Theoretical aspects of torque responses in spur gearing due to mesh stiffness variation. *Mechanical Systems and Signal Processing*, 17(2), 255–271. <https://doi.org/10.1006/mssp.2002.1516>



- Lee, S. Bin, Shin, J., Park, Y., Kim, H., & Kim, J. (2021). Reliable Flux-Based Detection of Induction Motor Rotor Faults from the Fifth Rotor Rotational Frequency Sideband. *IEEE Transactions on Industrial Electronics*, 68(9), 7874–7883. <https://doi.org/10.1109/TIE.2020.3016241>
- Lee, S.-B., Shin, J., Park, Y., Kim, H., & Kim, J. (2020). Reliable Flux based Detection of Induction Motor Rotor Faults from the 5th Rotor Rotational Frequency Sideband. *IEEE Transactions on Industrial Electronics*, 0046(c), 1–1. <https://doi.org/10.1109/tie.2020.3016241>
- Lin, X., Zhou, B., & Zhu, L. (2017). Sequential spindle current-based tool condition monitoring with support vector classifier for milling process. *International Journal of Advanced Manufacturing Technology*, 92(9–12), 3319–3328. <https://doi.org/10.1007/s00170-017-0396-9>
- Lo, N. G., Soualhi, A., Frini, M., & Razik, H. (2018). Gear and bearings fault detection using motor current signature analysis. *Proceedings of the 13th IEEE Conference on Industrial Electronics and Applications, ICIEA 2018*, 900–905. <https://doi.org/10.1109/ICIEA.2018.8397840>
- Lu, J., Wang, P., Duan, S., Shi, L., & Han, L. (2018). Detection of Broken Rotor Bars Fault in Induction Motors by Using an Improved MUSIC and Least-Squares Amplitude Estimation. *Mathematical Problems in Engineering*, 2018. <https://doi.org/10.1155/2018/5942890>
- Luan, X., Zhang, S., Li, J., Mendis, G., Zhao, F., & Sutherland, J. W. (2018). Trade-off analysis of tool wear, machining quality and energy efficiency of alloy cast iron milling process. *Procedia Manufacturing*, 26, 383–393. <https://doi.org/https://doi.org/10.1016/j.promfg.2018.07.046>
- Mallat, G. S. (1989). A Theory for Multiresolution Signal Decomposition: The Wavelet Representation. *IEEE Transactions On Pattern Analysis And Machine Intelligence*, 28(11), 79–85.
- Mao, W., Wang, L., & Feng, N. (2019). A new fault diagnosis method of bearings based on structural feature selection. *Electronics (Switzerland)*, 8(12), 1–26. <https://doi.org/10.3390/electronics8121406>
- Morales-Perez, C., Grande-Barreto, J., Rangel-Magdaleno, J., & Peregrina-Barreto, H. (2018). Bearing fault detection in induction motors using MCSA and statistical analysis. *I2MTC 2018 - 2018 IEEE International Instrumentation and Measurement Technology Conference: Discovering New Horizons in Instrumentation and Measurement, Proceedings*, 1–5. <https://doi.org/10.1109/I2MTC.2018.8409780>
- Nemec, M., Ambrožič, V., Fišer, R., Nedeljković, D., & Drobnič, K. (2019). Induction motor broken rotor bar detection based on rotor flux angle monitoring. *Energies*, 12(5). <https://doi.org/10.3390/en12050794>
- Obaid, R. R., Habetler, T. G., & Tallam, R. M. (2003). Detecting load unbalance and shaft misalignment using stator current in inverter-driven induction motors. *IEMDC 2003 - IEEE International Electric Machines and Drives Conference*, 3, 1454–1458. <https://doi.org/10.1109/IEMDC.2003.1210643>



- Oliver, J. A., Guerrero, G., & Goldman, J. (2017). Ceramic bearings for electric motors: eliminating damage with new materials. *IEEE Industry Applications Magazine*, 23(6), 14–20.
- Oliver, J., Guerrero, G., & Goldman, J. (2015). Ceramic bearings for electric motors. *IEEE Cement Industry Technical Conference (Paper)*, 2015-June(december), 14–20. <https://doi.org/10.1109/CITCON.2015.7122604>
- Panagiotou, P. A., Arvanitakis, I., Lophitis, N., Antonino-Daviu, J. A., & Gyftakis, K. N. (2019). FEM approach for diagnosis of induction machines' non-adjacent broken rotor bars by short-time Fourier transform spectrogram. *The Journal of Engineering*, 2019(17), 4566–4570. <https://doi.org/10.1049/joe.2018.8240>
- Panagiotou, P. A., Arvanitakis, I., Lophitis, N., & Gyftakis, K. N. (2018). FEM Study of Induction Machines Suffering from Rotor Electrical Faults Using Stray Flux Signature Analysis. *Proceedings - 2018 23rd International Conference on Electrical Machines, ICM 2018*, 1861–1867. <https://doi.org/10.1109/ICELMACH.2018.8506707>
- Park, Y., Choi, H., Lee, S. Bin, & Gyftakis, K. N. (2020). Search Coil-Based Detection of Nonadjacent Rotor Bar Damage in Squirrel Cage Induction Motors. *IEEE Transactions on Industry Applications*, 56(5), 4748–4757. <https://doi.org/10.1109/TIA.2020.3000461>
- Park, Y., Choi, H., Shin, J., Park, J., Lee, S. Bin, & Jo, H. (2020). Airgap flux based detection and classification of induction motor rotor and load defects during the starting transient. *IEEE Transactions on Industrial Electronics*, 67(12), 10075–10084. <https://doi.org/10.1109/TIE.2019.2962470>
- Park, Y., Yang, C., Kim, J., Kim, H., Lee, S. Bin, Gyftakis, K. N., Panagiotou, P. A., Kia, S. H., & Capolino, G. A. (2019). Stray flux monitoring for reliable detection of rotor faults under the influence of rotor axial air ducts. *IEEE Transactions on Industrial Electronics*, 66(10), 7561–7570. <https://doi.org/10.1109/TIE.2018.2880670>
- Penman, J., Sedding, H. ., & . (1994). Detection and Location of Interturn Short Circuits. *IEEE Transactions on Energy Conversion*, 9(4), 652–658.
- Petrov, A., Plokhov, I., Rassolkin, A., Vaimann, T., Kallaste, A., & Belahcen, A. (2017). Adjusted electrical equivalent circuit model of induction motor with broken rotor bars and eccentricity faults. *Proceedings of the 2017 IEEE 11th International Symposium on Diagnostics for Electrical Machines, Power Electronics and Drives, SDEMPED 2017, 2017-Janua*, 58–64. <https://doi.org/10.1109/DEMPED.2017.8062334>
- Piotrowski, J., & Saunders, H. (1989). Shaft Alignment Handbook. *Journal of Vibration and Acoustics*, 111(1), 118–119. <https://doi.org/10.1115/1.3269808>
- Plazenet, T., Boileau, T., Caironi, C., & Nahid-Mobarakeh, B. (2018). A Comprehensive Study on Shaft Voltages and Bearing Currents in Rotating Machines. *IEEE Transactions on Industry Applications*, 54(4), 3749–3759. <https://doi.org/10.1109/TIA.2018.2818663>
- Pons, J., Antonino-daviu, J. A., Member, S., & Riera-, M. (2014). Diagnosis Via Continuous and Discrete Time- Frequency Tools. *IEEE Transactions on Industrial Electronics*, 0046(c), 1791–1802.



- Praveenkumar, T., Saimurugan, M., & Ramachandran, K. I. (2017). Comparison of vibration, sound and motor current signature analysis for detection of gear box faults. *International Journal of Prognostics and Health Management*, 8(2), 1–10. <https://doi.org/10.36001/ijphm.2017.v8i2.2642>
- Pusca, R., Romary, R., Ceban, A., & Brudny, J.-F. (2010). An online universal diagnosis procedure using two external flux sensors applied to the ac electrical rotating machines. *Sensors*, 10(11), 10448–10466.
- Quian Quiroga, R., Rosso, O. A., Başar, E., & Schürmann, M. (2001). Wavelet entropy in event-related potentials: A new method shows ordering of EEG oscillations. *Biological Cybernetics*, 84(4), 291–299. <https://doi.org/10.1007/s004220000212>
- Rafiee, J., Rafiee, M. A., Prause, N., & Tse, P. W. (2009). Application of Daubechies 44 in machine fault diagnostics. *2009 2nd International Conference on Computer, Control and Communication, IC4 2009*. <https://doi.org/10.1109/IC4.2009.4909247>
- Rairán Antolines, D. (2014). Reconstruction of periodic signals using neural networks. *Revista Tecnura*, 18(39), 34–46. <https://doi.org/10.14483/udistrital.jour.tecnura.2014.1.a03>
- Ramirez-Nunez, J. A., Antonino-Daviu, J. A., Climente-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>
- Ramirez-Nunez, 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>
- Rastegar Fatemi, S. M. J., Henao, H., & Capolino, G. A. (2008). Gearbox monitoring by using the stray flux in an induction machine based electromechanical system. *Proceedings of the Mediterranean Electrotechnical Conference - MELECON*, 484–489. <https://doi.org/10.1109/MELCON.2008.4618482>
- Riera-Guasp, M., Antonino-Daviu, J. A., Pineda-Sanchez, M., Puche-Panadero, R., & Perez-Cruz, J. (2008). A general approach for the transient detection of slip-dependent fault components based on the discrete wavelet transform. *IEEE Transactions on Industrial Electronics*, 55(12), 4167–4180. <https://doi.org/10.1109/TIE.2008.2004378>
- Riera-Guasp, M., Cabanas, M. F., Antonino-Daviu, J. A., Pineda-Sánchez, M., & Rojas García, C. H. (2010). Influence of nonconsecutive bar breakages in motor current signature analysis for the diagnosis of rotor faults in induction motors. *IEEE Transactions on Energy Conversion*, 25(1), 80–89. <https://doi.org/10.1109/TEC.2009.2032622>
- Ripka, P. (2003). Advances in fluxgate sensors. *Sensors and Actuators*, 106(1–3), 8–14. [https://doi.org/10.1016/S0924-4247\(03\)00094-3](https://doi.org/10.1016/S0924-4247(03)00094-3)



- Rivera-Guillen, J. R., De Santiago-Perez, J. J., Amezquita-Sanchez, J. P., Valtierra-Rodriguez, M., & Romero-Troncoso, R. J. (2018). Enhanced FFT-based method for incipient broken rotor bar detection in induction motors during the startup transient. *Measurement*, 124, 277–285. <https://doi.org/https://doi.org/10.1016/j.measurement.2018.04.039>
- Romary, R., Pusca, R., Lecointe, J. P., & Brudny, J. F. (2013). Electrical machines fault diagnosis by stray flux analysis. *Proceedings - 2013 IEEE Workshop on Electrical Machines Design, Control and Diagnosis, WEMDCD 2013*, 247–256. <https://doi.org/10.1109/WEMDCD.2013.6525184>
- Romary, R., Roger, D., & -F. Brudny, J. (2009). Analytical computation of an AC machine external magnetic field. *EPJ Applied Physics*, 47(3). <https://doi.org/10.1051/epjap/2009102>
- Rosso, O. A., Blanco, S., Yordanova, J., Kolev, V., Figliola, A., Schürmann, M., & Ba ar, E. (2001). Wavelet entropy: A new tool for analysis of short duration brain electrical signals. *Journal of Neuroscience Methods*, 105(1), 65–75. [https://doi.org/10.1016/S0165-0270\(00\)00356-3](https://doi.org/10.1016/S0165-0270(00)00356-3)
- Salah, A. A., Dorrell, D. G., & Guo, Y. (2019). A review of the monitoring and damping unbalanced magnetic pull in induction machines due to rotor eccentricity. *IEEE Transactions on Industry Applications*, 55(3), 2569–2580. <https://doi.org/10.1109/TIA.2019.2892359>
- Salameh, J. P., Cauet, S., Etien, E., Sakout, A., & Rambault, L. (2018). Gearbox condition monitoring in wind turbines: A review. *Mechanical Systems and Signal Processing*, 111, 251–264. <https://doi.org/10.1016/j.ymssp.2018.03.052>
- Saucedo-Dorantes, J. J., Delgado-Prieto, M., Ortega-Redondo, J. A., Osornio-Rios, R. A., & Romero-Troncoso, R. D. J. (2016). Multiple-Fault Detection Methodology Based on Vibration and Current Analysis Applied to Bearings in Induction Motors and Gearboxes on the Kinematic Chain. *Shock and Vibration*, 2016. <https://doi.org/10.1155/2016/5467643>
- Saucedo-Dorantes, J. J., Delgado-Prieto, M., Osornio-Rios, R. A., & Romero-Troncoso, R. de J. (2018). Diagnosis methodology for identifying gearbox wear based on statistical time feature reduction. *Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science*, 232(15), 2711–2722. <https://doi.org/10.1177/0954406217721727>
- Schmidt, R. O. (1986). Multiple emitter location and signal parameter estimation. *IEEE TRANSACTIONS ON ANTENNAS AND PROPAGATION*, 3, 95–145. <https://doi.org/10.1109/9780470544075.ch2>
- Shaikh, M. F., Park, J., & Lee, S. Bin. (2021). A Non-Intrusive Leakage Flux Based Method for Detecting Rotor Faults in the Starting Transient of Salient Pole Synchronous Motors. *IEEE Transactions on Energy Conversion*, 36(2), 1262–1270. <https://doi.org/10.1109/TEC.2020.3021207>
- Shin, J., Park, Y., & Lee, S. Bin. (2021). Flux-Based Detection and Classification of Induction Motor Eccentricity, Rotor Cage, and Load Defects. *IEEE Transactions on*



- Industry Applications*, 57(3), 2471–2480. <https://doi.org/10.1109/TIA.2021.3066960>
- Siddique, A., Yadava, G. S., & Singh, B. (2005). A review of stator fault monitoring techniques of induction motors. *IEEE Transactions on Energy Conversion*, 20(1), 106–114. <https://doi.org/10.1109/TEC.2004.837304>
- Singru, P., Krishnakumar, V., Natarajan, D., & Raizada, A. (2018). Bearing failure prediction using wigner-ville distribution, modified poincare mapping and fast fourier transform. *Journal of Vibroengineering*, 20(1), 127–137. <https://doi.org/10.21595/jve.2017.17768>
- SKF, the knowledge engineering. (2017). Bearing damage and failure analysis Contents. *Bearing Damage and Failure Analysis*, 106. https://www.skf.com/binaries/pub12/Images/0901d1968064c148-Bearing-failures---14219_2-EN_tcm_12-297619.pdf
- Song, X., Liu, Z., Yang, X., Yang, J., & Qi, Y. (2015). Extended semi-supervised fuzzy learning method for nonlinear outliers via pattern discovery. *Applied Soft Computing Journal*, 29, 245–255. <https://doi.org/10.1016/j.asoc.2014.12.034>
- Technology, M. (1997). *Wound Rotor*. http://www.ewh.ieee.org/soc/es/Nov1997/09/B_WOU1.JPG
- Thomson, W. T., & Culbert, I. (2016). Current Signature Analysis for Condition Monitoring of Cage Induction Motors: Industrial Application and Case Histories. In *Current Signature Analysis for Condition Monitoring of Cage Induction Motors: Industrial Application and Case Histories*. <https://doi.org/10.1002/9781119175476>
- Tian, P., Platero, C. A., Gyftakis, K. N., & Guerrero, J. M. (2020). Stray flux sensor core impact on the condition monitoring of electrical machines. *Sensors (Switzerland)*, 20(3), 1–15. <https://doi.org/10.3390/s20030749>
- Toliyat, H. A., & Kliman, G. B. (2018). Handbook of Electric Motors. In *Handbook of Electric Motors* (Vol. 120). CRC press. <https://doi.org/10.1201/9781420030389>
- Trajin, B., Regnier, J., & Faucher, J. (2010). Comparison between vibration and stator current analysis for the detection of bearing faults in asynchronous drives. *IET Electric Power Applications*, 4(2), 90–100. <https://doi.org/10.1049/iet-epa.2009.0040>
- Vedreño Santos, F. J. (2013). *Diagnosis of electric induction machines in non-stationary regimes working in randomly changing conditions*. Thesis Report, Universitat Politècnica de València.
- Verucchi, C., Bossio, J., Bossio, G., & Acosta, G. (2016). Misalignment detection in induction motors with flexible coupling by means of estimated torque analysis and MCSA. *Mechanical Systems and Signal Processing*, 80, 570–581. <https://doi.org/10.1016/j.ymssp.2016.04.035>
- Vitek, O., Janda, M., Hajek, V., & Bauer, P. (2011). Detection of eccentricity and bearings fault using stray flux monitoring. *8th IEEE Symposium on Diagnostics for Electrical Machines, Power Electronics & Drives*, 456–461.
- Wang, B. (2005). Detection of structural damage using fractal dimension technique. *Zhendong Yu Chongji(J. Vibr. Shock)*, 24(2), 87–88.



- Weckenmann, A., & Nalbantic, K. (2003). Precision Measurement of Cutting Tools with two Matched Optical 3D-Sensors. *CIRP Annals*, 52(1), 443–446. [https://doi.org/10.1016/S0007-8506\(07\)60621-0](https://doi.org/10.1016/S0007-8506(07)60621-0)
- Wen, J., Fang, X., Cui, J., Fei, L., Yan, K., Chen, Y., & Xu, Y. (2019). Robust Sparse Linear Discriminant Analysis. *IEEE Transactions on Circuits and Systems for Video Technology*, 29(2), 390–403. <https://doi.org/10.1109/TCSVT.2018.2799214>
- Wong, S. Y., Chuah, J. H., & Yap, H. J. (2020). Technical data-driven tool condition monitoring challenges for CNC milling: a review. *International Journal of Advanced Manufacturing Technology*, 4837–4857. <https://doi.org/10.1007/s00170-020-05303-z>
- Wu, Z., Zhang, Q., Wang, L., Cheng, L., & Zhou, J. (2018). Early fault detection method for rotating machinery based on harmonic-assisted multivariate empirical mode decomposition and transfer entropy. *Entropy*, 20(11). <https://doi.org/10.3390/e20110873>
- Zamudio-Ramirez, I., Antonino-Daviu, J. A., Osornio-Rios, R. A., De Jesus Romero-Troncoso, R., & Razik, H. (2020). Detection of Winding Asymmetries in Wound-Rotor Induction Motors via Transient Analysis of the External Magnetic Field. *IEEE Transactions on Industrial Electronics*, 67(6), 5050–5059. <https://doi.org/10.1109/TIE.2019.2931274>
- Zamudio-Ramirez, I., Antonino-Daviu, J. A., Trejo-Hernandez, M., & Osornio-Rios, R. A. (2022). Cutting Tool Wear Monitoring in CNC Machines Based in Spindle-Motor Stray Flux Signals. *IEEE Transactions on Industrial Informatics*, 18(5), 3267–3275. <https://doi.org/10.1109/TII.2020.3022677>
- Zamudio-Ramirez, I., Osornio-Rios, R. A., Antonino-Daviu, J. A., Cureño-Osornio, J., & Saucedo-Dorantes, J. J. (2021). Gradual wear diagnosis of outer-race rolling bearing faults through artificial intelligence methods and stray flux signals. *Electronics (Switzerland)*, 10(12). <https://doi.org/10.3390/electronics10121486>
- Zamudio-Ramírez, 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>
- Zamudio-Ramirez, I., Osornio-Rios, R. A., Antonino-Daviu, J. A., Razik, H., & Romero-Troncoso, R. (2022). Magnetic Flux Analysis for the Condition Monitoring of Electric Machines: A Review. In *IEEE Transactions on Industrial Informatics* (Vol. 18, Issue 5, pp. 2895–2908). <https://doi.org/10.1109/TII.2021.3070581>
- Zamudio-Ramirez, I., Ramirez-Nunez, J. A., Antonino-Daviu, J., Osornio-Rios, R. A., Quijano-Lopez, A., Razik, H., & De Jesus Romero-Troncoso, R. (2020). Automatic Diagnosis of Electromechanical Faults in Induction Motors Based on the Transient Analysis of the Stray Flux via MUSIC Methods. *IEEE Transactions on Industry Applications*, 56(4), 3604–3613. <https://doi.org/10.1109/TIA.2020.2988002>
- Zamudio-Ramirez, I., Saucedo-Dorantes, J. J., Antonino-Daviu, J., Osornio-Rios, R. A., & Dunai, L. (2022). Detection of Uniform Gearbox Wear in Induction Motors Based on the Analysis of Stray Flux Signals Through Statistical Time-Domain Features and



Dimensionality Reduction Techniques. *IEEE Transactions on Industry Applications*, 58(4), 4648–4656. <https://doi.org/10.1109/TIA.2022.3174049>

Zhang, S., Zhang, S., Wang, B., & Habetler, T. G. (2020). Deep Learning Algorithms for Bearing Fault Diagnostics - A Comprehensive Review. *IEEE Access*, 8, 29857–29881. <https://doi.org/10.1109/ACCESS.2020.2972859>