

UNIVERSITAT POLITÈCNICA DE VALÈNCIA

DEPARTAMENTO DE INGENIERÍA ELÉCTRICA



**DIAGNÓSTICO DE FALLOS ELECTROMECAÑICOS
EN MOTORES ELÉCTRICOS MEDIANTE EL
ANÁLISIS AVANZADO DEL FLUJO MAGNÉTICO Y
SU IMPLEMENTACIÓN EN HARDWARE**

TESIS DOCTORAL

PRESENTADA POR:

D. ISRAEL ZAMUDIO RAMÍREZ

DIRIGIDA POR:

DR. D. JOSÉ ALFONSO ANTONINO DAVIU

DR. D. ROQUE ALFREDO OSORNIO RÍOS

Valencia, Julio de 2023



TESIS DOCTORAL

DIAGNÓSTICO DE FALLOS ELECTROMECAÑICOS EN MOTORES ELÉCTRICOS MEDIANTE EL ANÁLISIS AVANZADO DEL FLUJO MAGNÉTICO Y SU IMPLEMENTACIÓN EN HARDWARE

REALIZADA POR: D. ISRAEL ZAMUDIO RAMÍREZ

DIRIGIDA POR:

Dr. D. José Alfonso Antonino Daviu

Dr. D. Roque Alfredo Osornio Ríos

TRIBUNAL CALIFICADOR:

Presidente:

Secretario:

Vocal:

Valencia, Julio de 2023



Agradecimientos

A mi asesor, Dr. José Alfonso Antonino Daviu, por brindarme la oportunidad de participar en este proyecto, por sus acertados comentarios, por todo el apoyo y confianza que siempre me ha brindado, y por su invaluable tiempo y dedicación brindado para el asesoramiento y orientación de la presente tesis.

Al Dr. Roque Alfredo Osornio Ríos, 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.

A mi familia por brindarme siempre su apoyo y cariño impulsándome a seguir adelante en cada reto que se me presenta. A mi padre, 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.

Resumen

Los motores eléctricos de inducción son máquinas eléctricas rotativas que permiten realizar la conversión de energía eléctrica en energía mecánica, la cual resulta de gran utilidad en diversos procesos industriales, principalmente para accionar mecanismos y cadenas cinemáticas complejas involucradas en aplicaciones diversas como: sistemas de inyección de plástico, prensas, bandas transportadoras, plantas de tratamiento de aguas residuales, accionamiento de compresores, bombas, entre muchas otras. La amplia utilización de las máquinas de inducción en una gran variedad de procesos industriales se debe principalmente a sus excelentes características y prestaciones, tales como: robustez, fácil control, simplicidad, fiabilidad, y fácil mantenimiento. Sin embargo, a pesar de su elevada robustez, este tipo de máquinas se encuentran sujetas a diversos esfuerzos mecánicos, térmicos, eléctricos y ambientales, los cuales actúan conjuntamente bajo diversas condiciones de operación durante su vida útil, lo que de forma inevitable conduce a la aparición de diversos fallos o averías. Los principales fallos que suelen presentarse en los motores eléctricos de inducción son aquellos relacionados a sus componentes internos como defectos en el rotor, problemas en los rodamientos o fallos en el aislamiento del estator. Adicionalmente, también se pueden presentar problemas relacionados a la carga, así como en los componentes que permiten el acoplamiento entre el motor y la ésta (engranajes, sistemas de poleas y correas, etc...). En la literatura se han reportado diversas investigaciones en las que se concluye que cuando un motor eléctrico se encuentra operando bajo alguna condición de fallo, su rendimiento puede verse afectado, lo que se traduce en consumos de energía más elevados, causando a su vez altos costes en la factura eléctrica. Por otra parte, si el motor continúa operando bajo alguna avería, ésta se puede convertir en un fallo irreversible, lo que puede causar el paro repentino del proceso en el cual esté operando el motor, además de costes elevados de reparación. Adicionalmente, debido en gran parte a los actuales requerimientos en los procesos industriales, es una prioridad mantener en funcionamiento óptimo el ciclo de producción, sin interrupciones. A su vez es un aspecto de gran relevancia poder contar con sistemas capaces de monitorear de forma constante el estado de los motores impulsores involucrados en dichos procesos ya que, de esta manera, es posible asumir acciones de mantenimiento adecuadas, lo que evita tiempos de inactividad no programados y reduce los costes de mantenimiento. Por tanto, resulta de gran relevancia estudiar los principales fallos en estos motores, y más aún, es de suma importancia generar metodologías adecuadas para el diagnóstico oportuno de los mismos, a través de la monitorización continua y correspondiente análisis de ciertas magnitudes de máquina, antes de que estos fallos devengan en una avería catastrófica de la máquina.

En la presente tesis se presentan diversas contribuciones enmarcadas en una metodología innovadora, capaz de generar un diagnóstico adecuado y de forma automática de la ocurrencia de los fallos más comunes que pueden aparecer en motores eléctricos de inducción que trabajan bajo diversas condiciones de operación. La metodología se basa en el análisis avanzado del flujo magnético de dispersión (el cual puede ser capturado en la carcasa del propio motor utilizando sensores simples y económicos) a través de la aplicación de herramientas de descomposición tiempo-frecuencia, técnicas 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.

En este contexto, en primer lugar, se proponen tecnologías innovadoras para la medida del flujo, basadas en la utilización de sensores triaxiales que permiten la captura de las diferentes componentes del flujo de dispersión (radial, axial y combinado) en unas condiciones muy ventajosas en cuanto a coste y requerimientos de volumen. Por otro lado, se aplican diversas técnicas de análisis tiempo frecuencia a un amplio espectro de averías (algunas de ellas apenas abordadas en la literatura del área mediante esta técnica), como son rotura de barras rotóricas, desalineamientos, desgaste gradual de pista exterior en rodamientos metálicos de bolas, desgaste uniforme gradual en engranajes, entre otras. La aplicación de la técnica se efectúa bajo una diversidad de condiciones de trabajo y de suministro, incluyendo motores arrancados tanto con variador de frecuencia, como mediante arranque directo. Además, se valida la técnica en motores con diferentes características constructivas. Asimismo, se abordan casos especialmente complejos, como el análisis de arranques con duración inferior a 1s, caso particular con cierto grado de dificultad debido a la superposición de componentes de fallo y la componente fundamental (de gran amplitud) en su evolución durante el transitorio de arranque. La metodología desarrollada incluye no solamente la aplicación de técnicas tiempo-frecuencia sobre señales de flujo sino también, como se ha apuntado, una etapa ulterior de clasificación y determinación de severidad del fallo, la cual se basa en la detección automática de los patrones de fallo y en la evaluación de los mismos, para lo cual se han empleado técnicas adecuadas de inteligencia artificial. Los resultados obtenidos de las pruebas efectuadas han sido excelentes y muestran el gran potencial de la metodología para el diagnóstico de fallos en motores de inducción.

Visto el éxito conseguido con las pruebas previas, se ha abordado también en la tesis la extrapolación de la aplicación de la técnica basada en el análisis del flujo de dispersión a otras aplicaciones y tipologías de máquinas. De esta forma, se ha hecho uso de la misma para el diagnóstico de desgaste gradual de herramientas de corte en máquinas CNC, con la ventaja e innovación de generar un diagnóstico automático y no invasivo (una restricción de las técnicas convencionales reportadas

en la literatura, sobre todo bajo términos prácticos, al emplear sensores invasivos al proceso de mecanizado). Además, se ha aplicado la técnica a máquinas de inducción de rotor bobinado en las que los fallos en el devanado rotórico son mucho más frecuentes y para cuya detección, la metodología propuesta ha dado excelentes prestaciones.

A modo de resumen, pues, se pueden sintetizar las aportaciones de la tesis en los siguientes puntos:

- Utilización y optimización de nuevas tipologías de sensores (sensor triaxial) para la medida simultánea de las diferentes componentes del flujo de dispersión (radial, axial y combinado), bajo premisas de simplicidad, bajo coste y volumen reducido.
- Aplicación y optimización de diversas herramientas de análisis tiempo-frecuencia (MUSIC, STFT, DWT...) a señales de flujo capturadas en régimen transitorio de operación de la máquina, bajo diversas condiciones de fallo.
- Desarrollo de nuevos indicadores de severidad de fallo basados en los resultados de aplicación de las herramientas tiempo-frecuencia aplicadas.
- Presentación de metodologías de diagnóstico complementarias, basadas en la computación de parámetros estadísticos calculados sobre las señales de flujo.
- Desarrollo y aplicación de técnicas para la automatización del proceso de diagnóstico basadas en herramientas de reducción de la dimensionalidad y técnicas de clasificación basadas en herramientas de inteligencia artificial.
- Aplicación de la metodología de diagnóstico basada en análisis de flujo en motores operando en nuevas aplicaciones: máquinas CNC.
- Aplicación de la metodología de diagnóstico a otras tipologías de máquinas: motores de inducción de rotor bobinado.
- Comparación entre la técnica de análisis del flujo en régimen transitorio y otras técnicas de diagnóstico (como análisis de corrientes o termografía infrarroja) y evaluación de la complementariedad entre las mismas.
- Desarrollo de prototipos preliminares de sensores inteligentes que combinan la aplicación de la técnica de análisis del flujo de dispersión y otras técnicas.

La relevancia de la investigación desarrollada en esta tesis queda corroborada por el ingente número de publicaciones que derivan directa o indirectamente de la misma, muchas de las cuales se han publicado en revistas de prestigio, siendo el autor de esta tesis el primer o segundo firmante de muchos de esos trabajos. En concreto, se han publicado 18 artículos en revista y 13 publicaciones a congreso, además de participar en proyectos de envergadura relacionados con el trabajo desarrollado.



Palabras clave: Fallos electromecánicos, flujo magnético de dispersión, procesamiento de señales, motores de inducción, mantenimiento predictivo, Short Time Fourier Transform, análisis transitorio, diagnóstico automático.

Abstract

Induction 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 involved in various applications such as fuel plastic injection systems, presses, conveyor belts, wastewater treatment plants, compressor drive, pumps, among many others. The wide use of induction machines in various industrial processes is mainly due to their 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 various mechanical, thermal, electrical, and environmental stresses, which act together under various operating conditions during its useful life, inevitably leading to failure. The main failures that usually occur in electric induction motors are those related to their internal components, such as rotor defects, bearing problems, or stator insulation failures. Additionally, problems related to the load may also arise in the components that allow the coupling between the motor and the latter (gears, pulleys, belt systems, among others). Various investigations have been reported in the literature. It is concluded that when an electric motor operates under some fault condition, its performance may be affected, which translates into higher energy consumption, causing high costs on the electric bill.

On the other hand, if the motor continues to operate under some fault, this can become an irreversible failure, which can cause the sudden stoppage of the process in which the motor is operating and high repair costs. Additionally, due in large part to the current requirements in industrial processes, it is a priority to keep the production cycle running optimally, without interruptions, for which, in turn, it is a highly relevant aspect to be able to count on systems capable of monitoring the status of the drive motors involved in these processes is constantly monitored, since, in this way, it is possible to take appropriate maintenance actions, which avoids unscheduled downtime and reduces maintenance costs. Therefore, it is highly relevant to study the main failures in these motors. Even more so, it is crucial to generate adequate methodologies for their timely diagnosis through continuous monitoring and the corresponding analysis of certain machine magnitudes before these failures result in a catastrophic breakdown of the machine.

This thesis presents various contributions framed in an innovative methodology capable of generating an adequate and automatic diagnosis of the most common failures that can appear in electric induction motors that work under various operating conditions. The methodology is based on the advanced analysis of the stray magnetic flux (which can be captured in the motor's casing using simple and inexpensive sensors) through the application of time-frequency decomposition tools,

data classification techniques, and signal characterization parameters. In addition, an optimization of the parameters of these tools is carried out to provide generality and flexibility to the methodology addressed in this thesis.

In this context, first of all, innovative technologies for magnetic flux measurement are proposed, based on the use of triaxial sensors that allow the capture of the different components of the stray magnetic flux (radial, axial, and combined) in very advantageous conditions in regarding cost and volume requirements. On the other hand, various time-frequency analysis techniques are applied to a broad spectrum of failures (some of them barely addressed in the literature of the area using this technique), such as broken rotor bars, misalignment, gradual wear of the outer race in metallic bearings, gradual uniform wear in gears, among others. The application of the technique is carried out under various working and supply conditions, including motors started with a variable frequency drive and by direct online start. In addition, the technique is validated in motors with different construction characteristics. Likewise, complex cases are addressed, such as the analysis of starts with a duration of less than 1s, a particular case with a certain degree of difficulty due to the overlapping of fault components, and the fundamental component (of great amplitude) in its evolution during the startup transient. The developed methodology includes not only the application of time-frequency techniques on magnetic stray flux signals but also, as has been pointed out, a subsequent stage of classification and determination of failure severity based on the automatic detection of failure patterns and their evaluation, for which appropriate artificial intelligence techniques have been used. The results obtained from the tests have been excellent and show the methodology's great potential for diagnosing different failures in induction motors.

Given the success achieved with the previous tests, the thesis has also addressed the extrapolation of applying the technique based on the magnetic stray flux analysis to other applications and types of machines. In this way, it has been used for the diagnosis of gradual wear of cutting tools in CNC machines, with the advantage and innovation of generating an automatic and non-invasive diagnosis (a restriction of the conventional techniques reported in the literature, especially in practical terms, when using invasive sensors to the machining process). In addition, the technique has been applied to wound-rotor induction machines in which failures in the rotor winding are much more frequent and for whose detection the proposed methodology has provided excellent performance.

As a summary, then, the contributions of the thesis can be synthesized in the following points:

- Use and optimization of new types of sensors (triaxial sensor) for the simultaneous measurement of the different components of the stray magnetic flux (radial, axial, and combined) under premises of simplicity, low cost, and reduced volume.

- Application and optimization of various time-frequency analysis tools (MUSIC, STFT, DWT...) to magnetic stray flux signals captured in the transitory regime of machine operation under various fault conditions.
- Development of new failure severity indicators based on the application results of the applied time-frequency tools.
 - Presentation of complementary diagnostic methodologies based on the computation of statistical parameters calculated on the magnetic stray flux signals.
 - Development and application of techniques for automating the diagnostic process established on dimensionality reduction tools and classification techniques based on artificial intelligence tools.
- Application of the diagnostic methodology based on magnetic stray flux analysis in motors operating in new applications: CNC machines.
 - Application of the diagnostic methodology to other types of machines: wound rotor induction motors.
 - Comparison between the transient magnetic stray flux analysis technique and other diagnostic techniques (such as current analysis or infrared thermography) and evaluation of the complementarity between them.
 - Development of preliminary prototypes of smart sensors that combine the application of the magnetic stray flux analysis technique and other techniques.

The relevance of the research developed in this thesis is corroborated by the vast number of publications that derive directly or indirectly from it, many of which have been published in prestigious journals, the author of this thesis being the first or second author of many of those papers. Specifically, 18 journal articles and 13 congress publications have been published, in addition to participating in major projects related to the work.

Keywords: Asynchronous machines, induction motors, predictive maintenance, broken bar, stray flux analysis, Short Time Fourier Transform, Fourier Transform, soft starter.

Resum

Els motors elèctrics d'inducció són màquines elèctriques rotatives que permeten realitzar la conversió d'energia elèctrica en energia mecànica, la qual resulta de gran utilitat en diversos processos industrials, principalment per accionar mecanismes i cadenes cinemàtiques complexes involucrades en aplicacions diverses com: sistemes d'injecció de plàstic, premses, bandes transportadores, plantes de tractament d'aigües residuals, accionament de compressors, bombes, entre moltes altres. L'ampli ús de les màquines d'inducció en una gran varietat de processos industrials es deu principalment a les seves excel·lents característiques i prestacions, tals com: robustesa, fàcil control, simplicitat, fiabilitat i fàcil manteniment. No obstant això, malgrat la seva elevada robustesa, aquest tipus de màquines estan sotmeses a diversos esforços mecànics, tèrmics, elèctrics i ambientals, els quals actuen conjuntament en diverses condicions de funcionament durant la seva vida útil, la qual cosa inevitablement condueix a l'aparició de diverses fallades o avaries. Les principals fallades que solen presentar-se en els motors elèctrics d'inducció estan relacionades amb els seus components interns, com ara defectes en el rotor, problemes en els coixinets o fallades en l'aïllament de l'estator. A més, també es poden presentar problemes relacionats amb la càrrega, així com en els components que permeten el coplement entre el motor i aquesta (engranatges, sistemes de pols i corretges, etc.). A la literatura s'han reportat diverses investigacions en les quals es conclou que quan un motor elèctric es troba en funcionament sota alguna condició de fallada, el seu rendiment pot veure's afectat, la qual cosa es tradueix en consums d'energia més elevats, provocant al seu torn alts costos a la factura elèctrica. D'altra banda, si el motor continua funcionant amb alguna avaria, aquesta es pot convertir en una fallada irreversible, la qual cosa pot provocar la parada sobtada del procés en el qual estigui operant el motor, a més de costos elevats de reparació. A més, degut en gran part als actuals requeriments en els processos industrials, és una prioritat mantenir en funcionament òptim el cicle de producció, sense interrupcions. Al seu torn, és un aspecte de gran rellevància poder comptar amb sistemes capaços de monitorar de forma constant l'estat dels motors impulsors involucrats en aquests processos, ja que d'aquesta manera és possible assumir accions de manteniment adequades, la qual cosa evita temps d'inactivitat no programats i redueix els costos de manteniment. Per tant, resulta de gran rellevància estudiar les principals fallades en aquests motors i, més encara, és de suma importància generar metodologies adequades per al diagnòstic oportú dels mateixos, mitjançant la monitorització contínua i l'anàlisi corresponent de certes magnituds de màquina, abans que aquestes fallades esdevinguin en una avaria catastròfica de la màquina. En la present tesi es presenten diverses contribucions emmarcades en una metodologia

innovadora, capaç de generar un diagnòstic adequat i de forma automàtica de la presència de les fallades més comunes que poden aparèixer en motors elèctrics d'inducció que treballen en diverses condicions de funcionament. La metodologia es basa en l'anàlisi avançat del flux magnètic de dispersió (el qual pot ser capturat en la carcassa del mateix motor utilitzant sensors simples i econòmics) mitjançant l'aplicació d'eines de descomposició temps-freqüència, tècniques de classificació de dades i paràmetres de caracterització de senyals. A més, es realitza una optimització dels paràmetres d'aquestes eines per tal de proporcionar generalitat i flexibilitat a la metodologia que s'aborda en la present tesi. En aquest context, en primer lloc, es proposen tecnologies innovadores per a la mesura del flux, basades en la utilització de sensors triaxials que permeten la captura de les diferents components del flux de dispersió (radial, axial i combinat) en unes condicions molt avantatjoses en quant a cost i requeriments de volum. Per altra banda, s'apliquen diverses tècniques d'anàlisi temps-freqüència a un ampli espectre de fallades (algunes d'elles a penes abordades en la literatura de l'àrea mitjançant aquesta tècnica), com ara ruptura de barres rotòriques, desalineaments, desgast gradual de pista exterior en coixinets metàl·lics de boles, desgast uniforme gradual en engranatges, entre d'altres. L'aplicació de la tècnica es fa en diversitat de condicions de treball i subministrament, incloent motors engegats tant amb variador de freqüència com mitjançant engegada directa. A més, es valida la tècnica en motors amb diferents característiques constructives. A més, s'aborden casos especialment complexos, com ara l'anàlisi d'engegades amb durada inferior a 1s, cas particular amb cert grau de dificultat a causa de la superposició de components de falla i el component fonamental (de gran amplitud) en la seva evolució durant el transitori d'engegada. La metodologia desenvolupada inclou no solament l'aplicació de tècniques temps-freqüència sobre senyals de flux sinó també, com s'ha apuntat, una etapa posterior de classificació i determinació de severitat de la fallada, la qual es basa en la detecció automàtica dels patrons de fallada i en l'avaluació dels mateixos, per al qual s'han emprat tècniques adequades d'intel·ligència artificial. Els resultats obtinguts de les proves efectuades han sigut excel·lents i mostren el gran potencial de la metodologia per al diagnòstic de fallades en motors d'inducció. Vist l'èxit aconseguit amb les proves prèvies, s'ha abordat també en la tesi l'extrapolació de l'aplicació de la tècnica basada en l'anàlisi del flux de dispersió a altres aplicacions i tipologies de màquines. D'aquesta manera, s'ha fet ús de la mateixa per al diagnòstic de desgast gradual d'eines de tall en màquines CNC, amb l'avantatge i la innovació de generar un diagnòstic automàtic i no invasiu (una restricció de les tècniques convencionals reportades en la literatura, sobretot en termes pràctics, en emprar sensors invasius al procés d'abricat). A més, s'ha aplicat la tècnica a màquines d'inducció de rotor bobinat en les quals les fallades en el devanat rotòric són molt més freqüents i per a la seua detecció, la metodologia proposada ha donat excel·lents prestacions. A manera de resum, doncs, es poden sintetitzar les aportacions de la tesi en els següents punts:



- Utilització i optimització de noves tipologies de sensors (sensor triaxial) per a la mesura simultània de les diferents components del flux de dispersió (radial, axial i combinat), sota premisses de simplicitat, baix cost i volum reduït.
- Aplicació i optimització de diverses eines d'anàlisi temps-freqüència (MUSIC, STFT, DWT...) a senyals de flux capturades en règim transitori de funcionament de la màquina, sota diverses condicions de fallada.
- Desenvolupament de nous indicadors de severitat de fallada basats en els resultats de l'aplicació de les eines temps-freqüència aplicades.
- Presentació de metodologies de diagnòstic complementàries, basades en el còmput de paràmetres estadístics calculats sobre les senyals de flux.
- Desenvolupament i aplicació de tècniques per a l'automatització del procés de diagnòstic basades en eines de reducció de la dimensionalitat i tècniques de classificació basades en eines d'intel·ligència artificial.
- Aplicació de la metodologia de diagnòstic basada en anàlisi de flux en motors que operen en noves aplicacions: màquines CNC.
- Aplicació de la metodologia de diagnòstic a altres tipologies de màquines: motors d'inducció de rotor bobinat.
- Comparació entre la tècnica d'anàlisi del flux en règim transitori i altres tècniques de diagnòstic (com ara anàlisi de corrents o termografia infraroja) i avaluació de la complementarietat entre elles.
- Desenvolupament de prototips preliminars de sensors intel·ligents que combinen l'aplicació de la tècnica d'anàlisi del flux de dispersió i altres tècniques.

La rellevància de la investigació desenvolupada en aquesta tesi queda corroborada per l'ingent nombre de publicacions que deriven directa o indirectament de la mateixa, moltes de les quals s'han publicat en revistes de prestigi, sent l'autor d'aquesta tesi el primer o segon signant de molts d'aquests treballs. Concretament, s'han publicat 18 articles en revista i 13 publicacions en congressos, a més de participar en projectes d'envergadura relacionats amb el treball desenvolupat.

Paraules clau: Fallades electromecàniques, flux magnètic de dispersió, processament de senyals, motors d'inducció, manteniment predictiu, Short Time Fourier Transform, anàlisi transitori, diagnòstic automàtic.



Tabla de Contenidos

TESIS DOCTORAL.....	0
REALIZADA POR: D. ISRAEL ZAMUDIO RAMÍREZ.....	1
1. INTRODUCCIÓN.....	31
1.1 Antecedentes.....	32
1.2 Objetivos de la tesis.....	40
1.2.1 Objetivo general.....	40
1.2.2 Objetivos particulares:.....	40
2. FUNDAMENTACIÓN TEÓRICA.....	42
2.1 Introducción.....	42
2.2 Clasificación de averías en motores eléctricos de inducción.....	44
2.2.1 Fallos en rodamientos.....	44
2.2.2 Barras de rotor rotas.....	48
2.2.3 Desalineamientos.....	53
2.2.4 Fallos en engranajes.....	55
2.2.5 Fallos en el aislamiento.....	57
2.2.6 Resumen de componentes frecuenciales amplificadas debido a fallos en señales de corriente.....	60
3. TÉCNICAS DE PROCESAMIENTO Y CLASIFICACIÓN DE SEÑALES PARA EL DIAGNÓSTICO DE FALLAS EN MÁQUINAS ELÉCTRICAS.....	62
3.1 Análisis en régimen permanente.....	63
3.1.1 Transformada de Fourier y algoritmo transformada rápida de Fourier (FFT).....	63
3.1.2 Indicadores estadísticos y no estadísticos.....	65
3.1.3 Indicador de fallo basado en la energía DWT (.....)	69
3.1.4 Fractales.....	72
3.1.5 Entropía wavelet.....	74
3.2 Análisis en estado transitorio.....	76
3.2.1 Short Time Fourier Transform (STFT).....	77
3.2.2 Algoritmo de clasificación de señales para la estimación del contenido frecuencial de una señal en el tiempo (algoritmo MUSIC).....	79



3.2.3 Transformada wavelet.....	82
3.2.4 Transformada wavelet discreta (DWT).....	83
3.2.5 Principio de incertidumbre en la transformada wavelet.....	85
3.2.6 Familias wavelet madre.....	86
3.2.7 Transformada wavelet discreta inversa (IDWT).....	88
3.3 Análisis discriminante lineal.....	89
3.4 Clasificación de datos mediante redes neuronales artificiales (RNA).....	90
3.5 Detección automática del arranque del motor y del régimen permanente.....	92
4. ANÁLISIS DEL FLUJO MAGNÉTICO DE DISPERSIÓN PARA LA MONITORIZACIÓN DE LA CONDICIÓN DE MOTORES ELÉCTRICOS.....	94
4.1 Componentes frecuenciales amplificadas en señales de flujo magnético de dispersión debido a fallos en motores de inducción.....	96
4.1.1 Componentes frecuenciales relacionadas a barras de rotor rotas.....	96
4.1.2 Componentes frecuenciales relacionadas a cortocircuitos entre espiras... ..	98
4.1.3 Componentes frecuenciales relacionadas a fallas mecánicas.....	98
4.1.4 . Resumen de componentes frecuenciales amplificadas debido a fallos en señales de flujo magnético.....	101
4.1.5 Evolución de componentes de falla durante el transitorio de arranque....	103
4.2 Sensores típicos empleados para la adquisición de señales de flujo magnético.	106
4.2.1 Sensores de bobina para capturar flujo magnético.....	106
4.2.2 Sensor fluxgate.....	108
4.2.3 Sensores de efecto Hall.....	109
4.3 Sensor triaxial propuesto.....	110
4.4 Diseño digital de sistemas de procesado y adquisición.....	112
4.4.1 Tarjeta de adquisición.....	113
4.4.2 Tarjeta de procesado.....	115
5. METODOLOGÍA.....	118
6. RESULTADOS Y DISCUSIÓN.....	126
6.1 Aplicación de la metodología propuesta para el diagnóstico automático de asimetrías rotóricas en motores de inducción de rotor bobinado.....	127
6.1.1 Motivación del caso de estudio.....	127



6.1.2 Desarrollo de los ensayos.....	128
6.1.3 Resultados y discusión del caso de estudio.....	129
6.1.4 Conclusiones caso de estudio.....	137
6.2 Aplicación de la metodología propuesta para el diagnóstico automático de fallo de barras rotas y desalineamiento durante el arranque del motor.....	139
6.2.1 Motivación del caso de estudio.....	139
6.2.2 Desarrollo de los experimentos.....	140
6.2.3 Resultados y discusión del caso de estudio.....	143
6.2.4 Conclusiones caso de estudio.....	152
6.3 Aplicación de la metodología propuesta al diagnóstico automático de fallo gradual en la pista exterior de rodamientos.....	154
6.3.1 Motivación del caso de estudio.....	154
6.3.2 Desarrollo de los experimentos.....	155
6.3.3 Resultados y discusión del caso de estudio.....	158
6.3.4 Conclusiones caso de estudio.....	170
6.4 Aplicación de la metodología propuesta para el diagnóstico de fallo de barras rotas en motores de arranque de corta duración.....	172
6.4.1 Motivación del caso de estudio.....	172
6.4.2 Puesta en marcha de experimentos.....	173
6.4.3 Resultados y discusión del caso de estudio.....	175
6.4.4 Conclusiones caso de estudio.....	181
6.5 Aplicación de la metodología propuesta para el diagnóstico de desgaste gradual en cajas de engranes.....	182
6.5.1 Motivación del caso de estudio.....	182
6.5.2 Puesta en marcha de experimentos.....	183
6.5.3 Resultados y discusión del caso de estudio.....	185
6.5.4 Conclusiones caso de estudio.....	192
6.6 Aplicación de la metodología propuesta para el diagnóstico de desgaste de herramientas de corte en máquinas CNC.....	194
6.6.1 Motivación del caso de estudio.....	194
6.6.2 Puesta en marcha de experimentos.....	195
6.6.3 Resultados y discusión del caso de estudio.....	198



6.6.4 Conclusiones caso de estudio.....	203
7. CONCLUSIONES Y PROSPECTIVAS.....	205

Índice de figuras

Figura 1. Distribución de fallos en motores eléctricos con capacidad mayor a 200 hp (Thomson & Fenger, 2001).....	32
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).....	45
Figura 3. Parámetros de rodamientos de bolas (autoría propia).....	47
Figura 4. Tipos de desalineamiento de eje. (a) Desalineamiento angular. (b) Desalineamiento paralelo. (c) Desalineamiento combinado.....	53
Figura 5. Ejemplo de uso de transformada de Fourier: (a) señal en el tiempo, (b) espectro de Fourier.....	64
Figura 6. Cálculo de los indicadores propuestos a partir de una señal capturada en el dominio del tiempo.....	68
Figura 7. Ventana rectangular considerada para calcular el valor del indicador analizando la señal wavelet	71
Figura 8. Short Time Fourier Transform con superposición de ventanas sucesivas de una señal en el dominio del tiempo.....	78
Figura 9. Transformada MUSIC de tiempo corto con superposición de ventanas sucesivas de una señal en el dominio del tiempo.....	81
Figura 10. Diagrama a bloques del análisis de filtros desarrollado en la DWT.....	84
Figura 11. Diagrama a bloques de banco de filtros de 3 niveles.....	84
Figura 12. Resolución en tiempo y frecuencia para diferentes zonas del mapa tiempo-frecuencia.....	85
Figura 13. Coeficientes de filtro para distintas familias wavelet.....	87
Figura 14. Diagrama de bloques transformada wavelet discreta inversa.....	88
Figura 15. Red neuronal artificial: (a) arquitectura de red neuronal feed-forward (FFNN); (b) estructura funcional de una neurona.....	91
Figura 16. Obtención de envolvente superior de señal en el dominio del tiempo.....	92
Figura 17. Obtención de transitorio de arranque a partir de la envolvente de la señal en el tiempo.....	93
Figura 18. Componentes del flujo magnético de dispersión: (a) flujo de dispersión radial; (b) flujo de dispersión axial.....	94

Figura 19. Evoluciones teóricas de los componentes amplificadas por las asimetrías del rotor durante un transitorio de arranque simulado en un motor de inducción....	105
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).....	107
Figura 21. Configuración básica de un sensor tipo fluxgate.....	108
Figura 22. Foto de sensor fluxgate comercial modelo DRV425 de Texas Instrument.	109
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.....	111
Figura 24. Etapas de un sistema básico de un procesamiento digital de señales...	112
Figura 25. Configuración de amplificador operacional no inversor restador.....	114
Figura 26. Esquema 3D de la tarjeta desarrollada para el acondicionamiento y adquisición de señales del sensor de flujo de dispersión triaxial desarrollado.....	114
Figura 27. Principales componentes de procesador empleado para la implementación de la metodología propuesta.....	115
Figura 28. Tareas principales llevadas a cabo e implementadas a través del procesador principal basado en la plataforma Raspberry Pi 4.....	117
Figura 29. Diagrama de flujo de la metodología propuesta.....	120
Figura 30. División del mapa tiempo-frecuencia STFT en regiones de interés	122
Figura 31. Banco de pruebas de laboratorio: (a) osciloscopio registrador de forma de onda y motor de inducción de rotor bobinado ensayado; (b) reóstato de arranque y resistencia externa para forzar las asimetrías; y (c) sensor de flujo magnético tipo bobina instalado en la posición B.....	129
Figura 32. Análisis DWT de la señal durante el arranque del motor (señal roja) con el sensor en las tres posiciones diferentes consideradas para un motor sano (lado izquierdo) y para un motor con asimetría de rotor nivel cuatro con una resistencia adicional de 1,9 veces la resistencia de fase del rotor (lado derecho).....	131
Figura 33. Análisis DWT de la señal inducida en el sensor de bobina cuando éste se coloca en la posición B: (a) señal total capturada durante el arranque; (b) señal para un motor sano; (c) señal para un motor con asimetría de rotor nivel dos (resistencia adicional de 1,6 veces la resistencia de fase del rotor); y (d) señal para un motor con asimetría de rotor nivel cuatro (resistencia adicional de 1,9 veces la resistencia de fase del rotor) (Zamudio-Ramirez et al., 2020).....	132

Figura 34. Análisis STFT de las señales del sensor de flujo capturadas durante el arranque del motor para la máquina con asimetría en el devanado del 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 et al., 2020).....	133
Figura 35. Análisis STFT de las señales del sensor de flujo capturadas durante el arranque del motor para la máquina con asimetría de rotor nivel dos y motor con asimetría de rotor nivel cuatro, para las tres posiciones consideradas del sensor. El motor funciona en condición sin carga (Zamudio-Ramirez et al., 2020).....	134
Figura 36. Análisis STFT de las señales del sensor de flujo capturadas durante el arranque del motor para la máquina con asimetría de rotor nivel dos y motor con asimetría de rotor nivel cuatro, para las tres posiciones consideradas del sensor. El motor funciona en condición con carga parcial (Zamudio-Ramirez et al., 2020).....	135
Figura 37. Valores del indicador basados en la energía de la señal wavelet d8, para un motor WRIM sano y para el motor con distintos niveles de asimetría en el devanado del rotor (Zamudio-Ramirez et al., 2020).....	137
Figura 38. Configuración experimental: (a) banco de pruebas de motor de inducción, (b) vista lateral del banco de pruebas, (c) vista frontal del banco de pruebas.....	141
Figura 39. Banco de pruebas de motores: (a) Motor alineado. (b) motor desalineado.	142
Figura 40. Banco de pruebas de motores: (a) Rotor con dos barras rotas; (b) Rotor con una barra rota.....	143
Figura 41. Bandas de frecuencia consideradas para los análisis y caracterización de los mapas STFT.....	144
Figura 42. 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 combinado (axial +radial).....	146
Figura 43. 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 combinado (axial +radial).....	146
Figura 44. 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 combinado (axial +radial).....	147
Figura 45. 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 combinado (axial +radial).....	148

Figura 46. 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 combinado (axial + radial); (c) flujo de dispersión radial.....	148
Figura 47. Análisis STFT obtenidos para cada una de las condiciones de fallo consideradas 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.....	150
Figura 48. 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.....	152
Figura 49. Configuración experimental: (a) Banco de pruebas de cadena cinemática. (b) Vista lateral del banco de pruebas. (c) Vista frontal del banco de pruebas.....	156
Figura 50. Rodamiento metálico modelo 6203 2RS, utilizado durante la experimentación.....	158
Figura 51. Rodamientos utilizados durante los experimentos. (a) Rodamiento sano. (b) Rodamiento con un daño de 1 mm en la pista exterior. (c) Rodamiento con un daño de 2 mm en la pista exterior. (d) Rodamiento con un daño de 3 mm en la pista exterior. (e) Rodamiento con un daño de 4 mm en la pista exterior. (f) Rodamiento con un daño de 5 mm en la pista exterior.....	158
Figura 52. Funciones de densidad normalizadas que definen las zonas de detectabilidad obtenidas por los diferentes indicadores estadísticos y no estadísticos aquí propuestos para las diferentes componentes del flujo de dispersión utilizando: (a) Valor medio. (b) valor RMS. (c) valor SMR. (d) valor de	161
Figura 53. Funciones de densidad normalizadas que definen las zonas de detectabilidad obtenidas por los diferentes indicadores estadísticos y no estadísticos aquí propuestos para las diferentes componentes del flujo de dispersión utilizando: (a) valor . (b) Valor . (c) Valor CF. (d) Valor LF.....	163
Figura 54. Funciones de densidad normalizadas que definen las zonas de detectabilidad obtenidas por los diferentes indicadores estadísticos y no estadísticos aquí propuestos para las diferentes componentes del flujo de dispersión utilizando: (a) valor . (b) Valor . (c) Valor . (d) Valor KFD.....	164
Figura 55. Proyección de las regiones de decisión para la clasificación de fallos múltiples calculada mediante el clasificador basado en la red neuronal artificial propuesto 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.....	166

Figura 56. Proyección de las regiones de decisión para la clasificación de fallos múltiples calculada mediante 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.....	167
Figura 57. Proyección de las regiones de decisión para la clasificación de fallos múltiples calculada mediante 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.....	167
Figura 58. Proyección de las regiones de decisión para la clasificación de fallos múltiples calculada mediante 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.....	168
Figura 59. Proyección de las regiones de decisión para la clasificación de fallos múltiples calculada mediante 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.....	168
Figura 60. Banco de pruebas de laboratorio (motor 1).....	174
Figura 61. Dimensiones del sensor de bobina empleado durante los experimentos del presente caso de estudio.....	174
Figura 62. Segundo motor probado durante los experimentos (motor 2): 7,5 kW, 2 pares de polos.....	175
Figura 63. 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.....	177
Figura 64. 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.....	178
Figura 65. Regiones consideradas en los mapas tiempo-frecuencia MUSIC para la automatización de la técnica.....	179
Figura 66. 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).....	180

Figura 67. 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.....	184
Figura 68. Engranajes utilizados durante la experimentación: (a) engrane sano, (b) 25 % y (c) 75 % de desgaste uniforme de los dientes.....	185
Figura 69. Representación bidimensional resultante obtenida aplicando la técnica de análisis discriminante lineal a las matrices de indicadores estadísticos para todas las condiciones consideradas.....	187
Figura 70. 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.....	189
Figura 71. 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%.....	191
Figura 72. Configuración experimental: (a) banco de pruebas de máquinas CNC, (b) vista lateral del banco de pruebas de máquinas CNC y (c) área de trabajo.....	196
Figura 73. Estados de desgaste de la herramienta: (a) herramienta nueva, (b) herramienta desgastada y (c) herramienta rota.....	197
Figura 74. Ciclo de torneado ejecutado durante en los ensayos experimentales....	197
Figura 75. 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.....	200
Figura 76. 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.....	201
Figura 77. 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.....	202

Índice de tablas

Tabla 1: Efectos en la vida útil del aislamiento al operar bajo temperaturas elevadas (Bonnett & Soukup, 1992).....	58
Tabla 2. Principales componentes de frecuencia amplificados por distintas fallas en las señales de corriente.....	61
Tabla 3. Indicadores estadísticos considerados para la caracterización del comportamiento dinámico de una señal capturada en el tiempo.....	66
Tabla 4. Bandas de frecuencia asociadas con las señales ondoleta para y.....	69
Tabla 5. Funciones de activación comúnmente empleadas en una red neuronal artificial.....	91
Tabla 6. Principales componentes de frecuencia amplificados por distintas fallas en las señales de corriente.....	101
Tabla 7. Bandas de frecuencia asociadas con las señales ondoleta para y.....	130
Tabla 8. Efectividad de la metodología propuesta en la identificación de las condiciones de falla del motor de inducción estudiadas aquí. HLT, motor saludable; MAL, desalineación; 1 BRB + MAL, 1 barra de rotor rota y desalineación; 2 BRB + MAL, 2 barras de rotor rotas y desalineación.....	151
Tabla 9. Matriz de prueba para los diferentes niveles de desgaste del rodamiento.	156
Tabla 10. 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 60 Hz y 50 Hz.	164
Tabla 11. 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 15 Hz y 5 Hz..	165
Tabla 12. Porcentaje de efectividad de la metodología propuesta (matriz de confusión) al analizar todas las condiciones de rodamiento consideradas para una alimentación directa desde la red a 60 Hz, y para una alimentación mediante VFD a 60 Hz, 50 Hz y 15 Hz.....	169
Tabla 13. Porcentaje de efectividad de la metodología propuesta (matriz de confusión) al analizar todas las condiciones de rodamiento consideradas para una alimentación mediante VFD a 5 Hz.....	170
Tabla 14. Valores propios resultantes, varianza individual y acumulativa para los componentes principales.....	186



Tabla 15. Matriz de confusión conseguida por la clasificación individual resultante mediante el clasificador basado en redes neuronales artificiales aquí propuesto...	188
Tabla 16. Amplitud máxima rastreada para el armónico relacionado con la falla....	191
Tabla 17. Bandas de frecuencia cubiertas por las señales wavelet más representativas, de acuerdo a la frecuencia de muestreo empleada de 5 kHz.....	199
Tabla 18. Porcentaje de efectividad de la metodología propuesta al analizar el flujo de dispersión axial + radial (matriz de confusión).....	203

Relación de artículos publicados

Publicaciones en Revista

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: 8.162

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: 3.252

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: 3.847

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: 4.079

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: 11.648

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: 2.690



Artículo 7.

Saucedo-Dorantes, J. J., Zamudio-Ramirez, I., Cureno-Osornio, J., Osornio-Rios, R. A., & Antonino-Daviu, J. A. (2021). Condition monitoring method for the detection of fault graduality in outer race bearing based on vibration-current fusion, statistical features and neural network. *Applied Sciences*, 11(17), 8033.

Factor de impacto de revista: 11.648

Artículo 8.

Jaen-Cuellar, A. Y., Osornio-Ríos, R. A., Trejo-Hernández, M., Zamudio-Ramírez, I., Díaz-Saldaña, G., Pacheco-Guerrero, J. P., & Antonino-Daviu, J. A. (2021). System for Tool-Wear Condition Monitoring in CNC Machines under Variations of Cutting Parameter Based on Fusion Stray Flux-Current Processing. *Sensors*, 21(24), 8431.

Factor de impacto de revista: 2.838

Artículo 9.

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: 11.648

Artículo 10.

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: 8.162

Artículo 11.

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: 0.756

Artículo 12.

Navarro-Navarro, A., Zamudio-Ramirez, I., Biot-Monterde, V., Osornio-Rios, R. A., & Antonino-Daviu, J. A. (2022). Current and Stray Flux Combined Analysis for the Automatic Detection of Rotor Faults in Soft-Started Induction Motors. *Energies*, 15(7), 2511.

Factor de impacto de revista: 3.252

Artículo 13.

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: 4.079

Artículo 14.

Osornio-Rios, R. A., Jaen-Cuellar, A. Y., Alvarado-Hernandez, A. I., Zamudio-Ramirez, I., Cruz-Albarran, I. A., & Antonino-Daviu, J. A. (2022). Fault detection and classification in kinematic chains by means of PCA extraction-reduction of features from thermographic images. *Measurement*, 111340.

Factor de impacto de revista: 5.131

Artículo 15.

Alvarado-Hernandez, A. I., Zamudio-Ramirez, I., Jaen-Cuellar, A. Y., Osornio-Rios, R. A., Donderis-Quiles, V., & Antonino-Daviu, J. A. (2022). Infrared Thermography Smart Sensor for the Condition Monitoring of Gearbox and Bearings Faults in Induction Motors. *Sensors*, 22(16), 6075.

Factor de impacto de revista: 3.847

Artículo 16.

Díaz-Saldaña, G., Osornio-Ríos, R. A., Zamudio-Ramírez, I., Cruz-Albarrán, I. A., Trejo-Hernández, M., & Antonino-Daviu, J. A. (2023). Methodology for Tool Wear Detection in CNC Machines Based on Fusion Flux Current of Motor and Image Workpieces. *Machines*, 11(4), 480.

Factor de impacto de revista: 2.899

Artículo 17.

Cureño-Osornio, J., Zamudio-Ramirez, I., Morales-Velazquez, L., Jaen-Cuellar, A. Y., Osornio-Rios, R. A., & Antonino-Daviu, J. A. (2023). FPGA-Flux Proprietary System for Online Detection of Outer Race Faults in Bearings. *Electronics*, 12(8), 1924.

Factor de impacto de revista: 2.690

Artículo 18.

Osornio-Rios, R. A., Zamudio-Ramírez, I., Jaen-Cuellar, A. Y., Antonino-Daviu, J., & Dunai, L. (2023). Data Fusion System for Electric Motors Condition Monitoring: An Innovative Solution. *IEEE Industrial Electronics Magazine*.

Factor de impacto de revista: 8.36

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.

Artículo 12.

Zamudio-Ramirez, I., Antonino-Daviu, J., Osornio-Rios, R. A., Dunai, L., Quijano-Lopez, A., & Fuster-Roig, V. (2022, October). Detection of Stator



Asymmetries in Wound Rotor Induction Motors through the Advanced Analysis of Rotor Currents. In 2022 IEEE Energy Conversion Congress and Exposition (ECCE) (pp. 1-5). IEEE.

Artículo 13.

Zamudio-Ramirez, I., Biot-Monterde, V., Navarro-Navarro, A., Antonino-Daviu, J., Osornio-Rios, R. A., Mäki-Ontto, P., ... & Fajt, T. (2022, October). Detection of corrosion in ball bearings through the computation of statistical indicators of stray-flux signals. In IECON 2022–48th Annual Conference of the IEEE Industrial Electronics Society (pp. 1-6). IEEE.

1. INTRODUCCIÓN

Los motores eléctricos son dispositivos de importancia capital en muchos procesos industriales, siendo 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% de la energía total demandada en una planta industrial ([Abd-el-Malek et al., 2017](#); [Al Badawi et al., 2015](#)). Los motores de inducción están especialmente extendidos por su robustez, fácil mantenimiento, bajo coste y versatilidad ([Amezquita-Sanchez et al., 2017](#)). Así, este tipo de motores suele tener un amplio campo de aplicación en sistemas mecatrónicos, al utilizarse en la mayoría de las tareas dentro del área de producción, por ejemplo: sistemas de inyección de plástico, prensas, bandas transportadoras, plantas de tratamiento de aguas residuales, accionamiento de compresores, bombas, entre muchas otras.

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 poder contar con sistemas capaces de monitorizar de forma constante el estado de los motores impulsores involucrados en dichos procesos ya que, de esta manera, es posible adoptar acciones de mantenimiento adecuadas, lo que evita tiempos de inactividad no programados y reduce los costes de mantenimiento. Adicionalmente, se sabe que los motores en los que existen averías consumen más energía y tienen menores rendimientos, provocando facturas eléctricas más altas que las que podrían tener si operaran en condiciones de salud óptima ([Garcia et al., 2019](#)). Debido a esto, resulta de gran relevancia estudiar los principales fallos en estos tipos de motores y generar metodologías adecuadas para el diagnóstico oportuno de los mismos, antes que estos devengan en averías irreversibles.

En lo que respecta a los motores de inducción, hay que mencionar que se trata de máquinas que, por lo general, presentan una elevada fiabilidad. Sin embargo, ello no implica que no puedan aparecer ciertos fallos en estas máquinas, los cuales, por otro lado, pueden ser relativamente frecuentes. Estos fallos son más comunes en aplicaciones en las que las condiciones de operación de la máquina son exigentes (arranques pesados, niveles de carga elevado...) o en las que los factores ambientales (temperatura, suciedad, humedad...) son desfavorables, entre otras razones. Durante las últimas décadas se han desarrollado diversos estudios para determinar la ocurrencia de los diferentes fallos 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. A modo de ejemplo, cabe destacar las conclusiones obtenidas de una investigación referida a motores eléctricos industriales con potencias mayores a 200 hp, las cuales se ilustran en la Fig. 1.

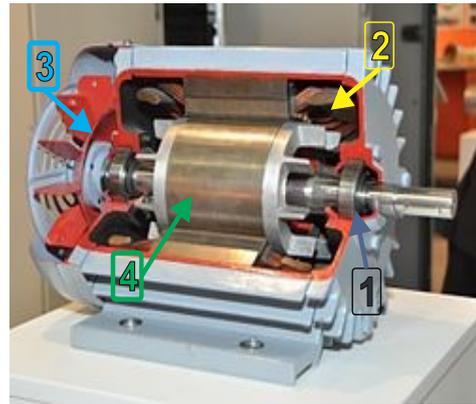
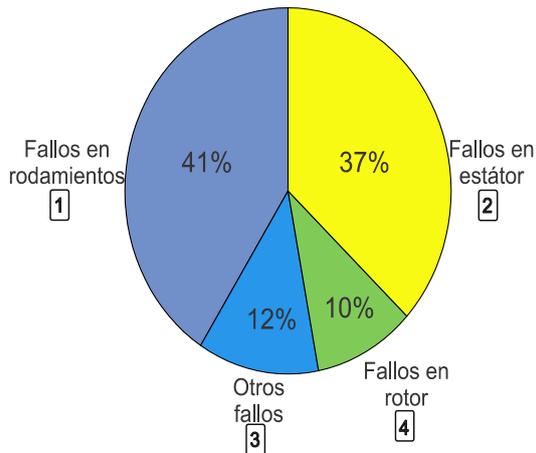


Figura 1. Distribución de fallos en motores eléctricos con capacidad mayor a 200 hp (Thomson & Fenger, 2001).

1.1 Antecedentes

Fallos inesperados en motores eléctricos pueden causar interrupciones repentinas del proceso de producción en el cual participan, pudiendo acarrear elevados costes económicos (costes de reparación o sustitución, costes por interrupción de la producción...), así como posibles problemas de seguridad de los usuarios (por malfuncionamiento del sistema). Debido a esto, es deseable el desarrollo de sistemas que permitan la detección rápida de las diferentes anomalías o fallos que pueden estar presentes en motores eléctricos, incluso cuando se encuentran en estado todavía incipiente, de cara a poder adoptar acciones de mantenimiento oportunas con suficiente antelación que eviten que las citadas anomalías deriven en fallos más graves. El desarrollo de este tipo de sistemas ha cobrado gran relevancia en el ámbito industrial, en el que existen muchos procesos que no se pueden permitir una parada intempestiva, al deber operar de forma continuada, esto es, sin interrupción, durante largos periodos de tiempo.

La detección de algunas averías en motores eléctricos se ha basado principalmente en metodologías que realizan el análisis de diversas magnitudes físicas, especialmente de señales eléctricas (tensiones y corrientes, principalmente) y mecánicas (vibraciones). En lo que respecta al análisis de señales de vibración, se conocen ciertos inconvenientes inherentes; uno de ellos radica en la imposibilidad de discriminar, en ocasiones, entre diferentes tipos de fallo e incluso entre ciertos fallos y determinadas condiciones de operación no relacionadas con un fallo. Además, la técnica implica la instalación de sensores de medida específicos (acelerómetros, etc.), que no son siempre factibles de instalar en ciertas aplicaciones. Además, en

ciertas aplicaciones (tracción eléctrica) la señal de vibración suele aparecer tan contaminada por el ruido que resulta complicado utilizarla como base para diagnosticar un posible fallo. Debido a estos inconvenientes, se ha venido explorando durante las últimas décadas en técnicas que permitan un diagnóstico no invasivo del fallo, evitando ciertas desventajas del análisis vibracional.

En este contexto, una de las técnicas más recurrentes es el conocido análisis espectral de la corriente en régimen permanente (MCSA, por su abreviatura en inglés Motor Current Signature Analysis), la cual se basa en la aplicación de la transformada rápida de Fourier (FFT, por su abreviatura en inglés Fast Fourier Transform) a la citada señal de corriente. Este método ha sido ampliamente utilizado a nivel industrial ya que ha permitido el diagnóstico de una gran variedad de averías, tales como roturas de barras rotóricas, excentricidades o cortocircuitos en el estator, entre otras. Esta técnica basa su principio de funcionamiento en evaluar las amplitudes de las componentes frecuenciales amplificadas en el espectro FFT debido a las distintas averías; se ha demostrado que cada tipo de fallo amplifica unas componentes frecuenciales muy concretas que pueden utilizarse para evaluar la severidad del citado fallo ([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, las amplitudes de sus componentes frecuenciales asociadas se amplifican en el espectro de Fourier, lo cual permite diagnosticar la presencia del fallo en la máquina, e incluso determinar la severidad del mismo mediante la comparación con niveles umbrales previamente establecidos.

A título de ejemplo, se sabe que la presencia de barras rotas provoca una distorsión en el campo magnético del entrehierro, la 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 son los armónicos laterales y sus frecuencias (f_{SH} vienen dadas por la expresión (1), donde f = frecuencia de alimentación de la máquina y s = deslizamiento ([Gyftakis et al., 2016](#)). Al armónico con signo (-) se le denomina lateral inferior o lateral izquierdo y al armónico con signo (+) se le denomina lateral superior o derecho.

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

De este modo, si existe este fallo en el rotor, los armónicos laterales serán claramente visibles en el espectro de Fourier al aplicar la FFT a las señales de la corriente estática en régimen permanente ([Fernandez Cabanas et al. 1998](#)), incrementando su amplitud a medida que aumenta la severidad del fallo. A este respecto, se han establecido indicadores que permiten determinar la severidad de a

avería en el rotor en base a la amplitud del armónico lateral inferior ([Fernandez Cabanas et al. 1998](#))

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 = frecuencia de rotación del rotor, $k=1,2,3,\dots$. De estas componentes asociadas con la excentricidad, las más relevantes son las que se obtienen para $k=1$.

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

A pesar de que este método MCSA, que constituye el método tradicional de análisis de corrientes, ha sido utilizado ampliamente en la industria, se pueden apuntar diversos inconvenientes del mismo, los cuales pueden resultar problemáticos en ciertas aplicaciones. Así, se ha demostrado que la aplicación de esta técnica puede no resultar efectiva si la máquina diagnosticada se encuentra operando con un bajo nivel de carga ($s \approx 0$) ya que, en estas condiciones, los armónicos laterales pueden superponerse con la componente fundamental (debido al reducido valor de s), siendo muy complicado identificar dichas componentes y determinar si existe o no fallo ([Antonino-daviu et al., 2014](#)). Además, otro inconveniente de este método se debe al hecho de que fenómenos ajenos a la avería, tales como cargas pulsantes, tensiones de suministro oscilantes, conductos axiales de refrigeración, anisotropía magnética del rotor, 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 cual puede conducir a falsos diagnósticos ([Lee, Stone et al., 2020](#)). También se han reportado otros casos en los que la aplicación de MCSA puede no llevar a diagnósticos fiables del fallo, como es el caso de roturas de barra en la jaula externa de rotores de doble jaula o en caso de roturas de barra no consecutivas.

Debido a los problemas e inconvenientes que presenta el método MCSA, durante la última década ha ido consolidándose un nuevo enfoque que propone el análisis de algunas magnitudes de la máquina capturadas durante los procesos transitorios a través de los que ésta puede operar. Dentro de este enfoque, basado en el análisis transitorio, se ha considerado especialmente la corriente como magnitud de referencia y, en concreto, se ha hecho especial énfasis en el análisis de la corriente durante el transitorio de arranque. En este contexto, 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 mencionada corriente de arranque. Estas herramientas permiten identificar los patrones o huellas específicas causados por las componentes de fallo durante el arranque. En efecto, a medida que el deslizamiento

s varía durante el citado transitorio, las frecuencias de las componentes de fallo (que dependen del deslizamiento, como muestra, por ejemplo, la expresión (1)) también variarán, dando lugar a evoluciones características de las mismas en el tiempo que pueden ser detectadas con las mencionadas herramientas TFD. La identificación y evaluación de la energía de dichos patrones asociados a los distintos fallos se ha mostrado altamente fiable para la detección de un múltiple rango de fallos y constituye la base de la metodología de análisis transitorio, que se ha venido a denominar ATCSA, por su abreviatura en inglés Advanced Transient Current Signature Analysis ([Lee, Stone et al., 2020](#)).

Los resultados obtenidos al aplicar la metodología ATCSA 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 los casos en los que el método MCSA, basado en la FFT, no resulta adecuado, como 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, conductos axiales de refrigeración). Adicionalmente, la técnica ATCSA se ha aplicado con éxito al diagnóstico de casos en los que las averías estaban simultáneamente presentes en la máquina o combinadas con otros fenómenos que dificultaban el diagnóstico ([Antonino-Daviu et al., 2018](#)).

A pesar de las buenas prestaciones que proporciona el análisis transitorio de la corriente y, más concretamente, el análisis de la corriente de arranque, existen situaciones en las que el análisis de la corriente no resulta concluyente para determinar el origen del fallo. Esto es debido, por un lado, a que la corriente, siendo una magnitud de gran potencial para detectar ciertos tipos de fallo, no resulta útil para detectar todos los fallos posibles en un motor eléctrico. En otras palabras, el análisis de la corriente se muestra útil para la detección de ciertos fallos (rotor, excentricidades, etc...) pero no para otros fallos (aislamiento). Por otro lado, el análisis de la corriente no es inmune a la posible aparición de falsos diagnósticos ([Nemec et al., 2019](#)); en este sentido, si bien el análisis transitorio viene a paliar algunos problemas ([Lee, Stone et al., 2020](#)), siempre resulta bienvenido el uso de otras magnitudes que ayuden a complementar el diagnóstico proporcionado por la misma. Finalmente, el análisis de corrientes no permite discriminar, por sí mismo, entre ciertos tipos de fallo (por ejemplo, excentricidades y desalineamientos) ([Shin et al., 2021](#)), dado que éstos inducen idénticas componentes de fallo en el espectro de corrientes; esta distinción es de gran importancia, ya que cada fallo implica sus propias acciones de mantenimiento a adoptar.

Debido a estos problemas, muchos autores han ahondado en la investigación en nuevas técnicas que pudieran complementar el diagnóstico proporcionado por el

análisis de corrientes, paliando las posibles deficiencias de éste. En este contexto, en años recientes, ha concitado gran atención el análisis del flujo magnético de dispersión, como medio para el diagnóstico de ciertos fallos. Esta renovada atención se ha debido, por un lado, a los avances en el desarrollo de nuevas tipologías de sensores de flujo, las cuales han mostrado prestaciones crecientemente favorables en términos de coste, volumen, portabilidad y características de registro. Por otro lado, se ha avanzado enormemente en el desarrollo y optimización de las herramientas de procesamiento de señal empleadas para el análisis de las señales capturadas y para la extracción de la información relevante para el diagnóstico. Por si ello fuera poco, se ha probado que el contenido armónico de las señales de flujo magnético es más abundante que el de la señal de corrientes, lo cual resulta útil para obtener mayor información para el diagnóstico (Tian et al., 2020). Asimismo, el análisis de las señales de flujo magnético puede aportar información de gran valor para la discriminación entre ciertos tipos de fallos (Shin et al., 2021).

La idea principal que subyace a la aplicación de la técnica se basa en el hecho que la máquina eléctrica produce un flujo magnético de dispersión, provocado por las corrientes circulantes por los devanados del rotor (jaula) y estator. Cuando la máquina está en estado sano, aparecen ciertas componentes en el citado flujo magnético de dispersión asociadas a las características de la tensión de suministro y a las propias características constructivas de la máquina. Cuando algún fallo está presente en la máquina, aparecen, además de las componentes anteriores (ya presentes en estado sano), ciertas componentes asociadas al fallo que ven amplificada su amplitud. Esto es debido a que el fallo produce distorsiones en el campo magnético externo que repercuten en las componentes que aparecen en el flujo de dispersión (Romary et al., 2013). La identificación de las citadas componentes y la evaluación de sus amplitudes permite el diagnóstico del fallo, así como la determinación de su severidad. Usualmente, el flujo de dispersión se captura de forma indirecta, a través de la medida de la fuerza electromotriz que el citado flujo induce en bobinas externas (sensores) que se ubican en la carcasa del motor.

Diversas investigaciones han demostrado la efectividad del análisis del flujo magnético, medido mediante sensores adecuados, para la detección de diversas averías en motores eléctricos y, especialmente, en motores de inducción. Con respecto a las fallas del rotor, Romary et al., (2013) demostraron que las componentes que aparecen a $s \cdot f$ y $3 \cdot s \cdot f$ (donde f = frecuencia de alimentación y s = deslizamiento), correspondientes al campo axial, son particularmente sensibles a la presencia de daños en el rotor. Estas componentes se deben a la variación de la velocidad angular a $2 \cdot s \cdot f$ causada por la presencia de barras rotas (Ceban et al., 2012; Romary et al., 2013). El monitoreo de las amplitudes de estas 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 estas componentes hacen necesario disponer de tiempos de adquisición largos, de modo que el análisis FFT pueda distinguirlos correctamente (Ceban et al., 2012; Romary et al., 2013). Además de las citadas componentes de origen axial, se ha constatado que el fallo en el rotor también provoca incrementos en las amplitudes de las componentes dadas por (1), de origen radial, de modo que éstas también se pueden emplear para un diagnóstico efectivo del fallo, complementando el diagnóstico obtenido con las componentes axiales. Por otro lado, diversos autores como Verucchi et al. (2016) han constatado que la presencia de excentricidades aumenta las amplitudes de las componentes ubicadas a $f \pm f_r$, (donde f_r = 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 régimen permanente. Esas frecuencias (f_{ecc}) vienen dadas por la expresión (3) (p = número de par de polos de la máquina, $m=1,2,3,\dots$) Otras expresiones han sido también propuestas para la detección de otros tipos de fallo (por ejemplo, fallos en rodamientos o en engranajes) en base a la detección de componentes frecuenciales en las señales de flujo.

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

Considerando el éxito que ha tenido en tiempos recientes el análisis transitorio de corrientes para aumentar la fiabilidad del diagnóstico de ciertos fallos, algunas investigaciones han decidido evaluar la viabilidad de aplicar esta metodología de análisis transitorio a las señales de flujo de dispersión. A este respecto, diversos trabajos han probado el potencial de la técnica para detectar fallos como barras rotas, espiras en cortocircuito en el devanado del estator, excentricidad estática y dinámica del rotor e incluso fallos en rodamientos (Frosini et al., 2015, 2017; Panagiotou et al., 2018, 2019; Ramirez-Nunez et al., 2018; Romary et al., 2013). En todos estos trabajos resulta primordial la tarea de procesamiento de señal mediante la aplicación de 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 monitorizada presenta características no estacionarias, lo cual provoca algunas distorsiones en los resultados al analizarla con estas herramientas (Rivera-Guillen et al., 2018). A este respecto, 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), en el que se emplea el método de

descomposició de modo empíric (EMD, por su abreviatura en inglés Empirical Mode Decomposition) el cual es intuitivo, no supervisado y autoadaptivo y que puede descomponer una señal no estacionaria y no lineal en componentes oscilatorias de banda estrecha llamadas 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 diversos fallos 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 la aplicación offline de las técnicas propuestas, y esto se debe a la complejidad de las citadas técnicas, así como a su alta carga computacional. En este contexto, algunos autores como [Camarena-Martinez et al., \(2014a\)](#) proponen el empleo de un dispositivo de lógica programable basado en FPGA, por su abreviatura en inglés Field Programmable Gate Array, para llevar a cabo el procesamiento de la señal; estos permiten implementar algoritmos de análisis de señales no estacionarias mediante hardware y, de esta manera, diagnosticar fallos como roturas de barra en motores de inducción empleando, en el caso del citado trabajo, un acelerómetro, y demostrando así el potencial que el empleo de estos dispositivos tiene en la tarea de diagnóstico de fallos en máquinas eléctricas.

A tenor de todo lo apuntado, se concluye pues que existe un gran dinamismo investigador en el área de la monitorización de la condición de motores eléctricos que está orientado hacia el desarrollo de nuevas metodologías de diagnóstico de fallos que se muestren plenamente fiables y que puedan ser extrapoladas para su uso masivo a nivel industrial. A pesar de las excelentes prestaciones que han venido ofreciendo técnicas como el análisis vibracional o el análisis de corrientes, éstas presentan inconvenientes que resultan muy relevantes en muchas aplicaciones industriales; estos inconvenientes, ya apuntados en este epígrafe, se basan principalmente en la imposibilidad de discriminar entre ciertos tipos de fallos, en la posibilidad de falsos diagnósticos que pueden conllevar consecuencias nefastas o en la imposibilidad de detección de ciertos fallos. Aunque, como se ha apuntado, variantes más modernas de estas técnicas, como el análisis transitorio ATCSA, pueden ayudar a evitar algunos de estos inconvenientes, todavía subsisten notables carencias que vienen asociadas al hecho de aplicar una única técnica, ya que se ha probado que ninguna técnica es, por sí sola, suficiente para diagnosticar el estado completo de la máquina. Es por ello que el estudio de nuevas técnicas, como el análisis del flujo de dispersión, propuesto en esta tesis, resulta plenamente procedente, ya que puede ayudar a evitar inconvenientes de las técnicas clásicas, complementando el diagnóstico proporcionado por las mismas. Resulta también de gran interés otro reto abordado en esta tesis, como es la aplicación de metodologías

más modernas basadas en análisis transitorio al análisis de señales de flujo, para estudiar su viabilidad para la detección de ciertos fallos y desarrollar indicadores de severidad de fallo oportunos. En este sentido, se plantea también el reto de la automatización del proceso del diagnóstico, esto es, que se evite la necesidad de intervención de un usuario experto para decidir si hay fallo o no, en base a los resultados de aplicación de las técnicas de análisis transitorio. A tal fin, la utilización de herramientas de reducción de dimensionalidad y de técnicas de inteligencia artificial resulta de gran interés y también se aborda en la presente tesis. Como culminación de lo anterior, resulta relevante abordar la implementación de las técnicas y algoritmos desarrollados en un prototipo de sistema inteligente que permita corroborar que las soluciones planteadas son implementables en dispositivos reales que permitan un diagnóstico automático de la condición de cualquier motor, independientemente de sus condiciones de trabajo. Este aspecto también se aborda en la presente tesis. Finalmente, resulta de gran interés probar la validez de la metodología de diagnóstico en base al análisis de señales de flujo de dispersión en una variedad de aplicaciones, que vayan más allá de las aplicaciones al uso a nivel industrial. En este contexto, se aborda la aplicación de la metodología para el diagnóstico de diversos fallos en máquinas CNC, constatándose la validez y utilidad de la metodología. En línea con este reto, se aborda también la aplicabilidad de la metodología en otras tipologías de máquinas, como motores de inducción de rotor bobinado, constatando el enorme potencial de la metodología en este ámbito, que es probado con casos de éxito en industria.



1.2 Objetivos de la tesis

1.2.1 Objetivo general

El objetivo general que se plantea en la presente tesis queda sintetizado en el siguiente párrafo:

Desarrollar e implementar una metodología para el diagnóstico de los fallos electromecánicos más comunes en motores eléctricos de inducción (fallos en el rotor, averías en rodamientos, fallos en el estator). Basada en el análisis del flujo de dispersión, tanto durante el transitorio de arranque como en régimen permanente, empleando herramientas matemáticas de descomposición tiempo-frecuencia, y técnicas de clasificación de datos y abordando también la implementación en hardware de esta metodología.

1.2.2 Objetivos particulares:

El anterior objetivo general se puede desglosar en una serie de objetivos e hitos más específicos que se han acometido durante el presente trabajo:

- Documentar las técnicas propuestas en la literatura basadas en el análisis del flujo magnético de dispersión, haciendo especial énfasis en aquellas posibles técnicas que se centran en el análisis transitorio.
- Realizar ensayos experimentales para la obtención de datos sobre los cuales aplicar y validar la metodología a desarrollar:
 - Ensayo de motores con diferentes características constructivas y condiciones de operación.
 - Ensayo bajo diferentes condiciones de fallo
- Generar una base de datos con las señales experimentales obtenidas.
- Determinar la técnica de procesamiento de señal más idónea que sirva como base para la aplicación óptima de la metodología propuesta.
- Analizar las señales obtenidas mediante la técnica de procesamiento de señal seleccionada.
- Idear indicadores de severidad del fallo en base a los resultados de la aplicación de las herramientas tiempo-frecuencia.
- Desarrollar nuevos indicadores basados en parámetros estadísticos computados en base a las señales de flujo.



- Desarrollar herramientas de diagnóstico automático basadas en técnicas de inteligencia artificial, que utilicen como base los indicadores propuestos.
- Validar las técnicas desarrolladas en motores de laboratorio y de campo.
- Estudiar la viabilidad de la técnica para su extensión a otras averías, máquinas, o condiciones.
- Implementar los algoritmos de la metodología propuesta mediante un lenguaje de programación en C para su utilización en un procesador de tarjeta única.
- Validar el sistema desarrollado en diferentes bancos de ensayo.

2. FUNDAMENTACIÓN TEÓRICA.

2.1 Introducción

Los motores eléctricos son dispositivos que tienen gran relevancia en la operación de 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, 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 en los que operan, así como la seguridad de máquinas y usuarios. Los motores eléctricos también resultan imprescindibles en otras aplicaciones, más allá de la industria, como las centrales de generación o en aplicaciones del sector terciario. Por si esto no fuera poco, 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 se puede aseverar que más del 90% de motores eléctricos industriales son máquinas pertenecientes a esta tipología.

Además de los motores de jaula de ardilla, dentro de los motores asíncronos existe otra tipología relevante: los motores de inducción de rotor bobinado. En estos motores el devanado rotórico está constituido por bobinas, en lugar de por barras. Se trata de máquinas que presentan algunas ventajas interesantes, como la posibilidad de acceso al devanado del rotor para la medida de corrientes (lo cual resulta útil cuando se realiza el diagnóstico de la condición del rotor) o para insertar resistencias externas durante el proceso de arranque, hecho que 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 coste y complejidad

constructiva que presentan en comparación con las máquinas de rotor de jaula. No obstante, podemos encontrar estas máquinas en aplicaciones de elevada potencia (del orden de MW), con lo que resulta muy relevante idear técnicas predictivas que permitan el diagnóstico efectivo de los posibles fallos que pueden aparecer en ellas. En la presente tesis, se incluyen sendos casos de la aplicación de las técnicas consideradas a máquinas de rotor bobinado, algunas de ellas operando en instalaciones industriales.

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 coste 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 a aplicaciones de potencias más reducidas, debido fundamentalmente a los mayores rendimientos que presentan, factor éste 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 de inducción, 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, costes 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 debido a averías intempestivas en algunas de estas máquinas.

2.2 Clasificación de averías en motores eléctricos de inducción

Los motores eléctricos son uno de los componentes más importantes en una amplia variedad de aplicaciones industriales y comerciales al servir como impulsores primarios de las diversas cadenas cinemáticas involucradas. Estos motores están en constante uso y, por lo tanto, pueden estar sujetos a una variedad de fallos y problemas. En esta sección, se describirán los fallos más comunes que se presentan en los motores eléctricos, con un enfoque especial en los motores de inducción. Se dará detalle sobre las causas más comunes de estos fallos y se explicarán las posibles repercusiones que pueden tener en el funcionamiento del motor.

2.2.1 Fallos en rodamientos.

Los fallos en los rodamientos constituyen una de las averías que suelen ocurrir de manera más frecuente en los motores de inducción. De acuerdo con lo reportado en la literatura, se ha demostrado que la mayoría de los fallos de los motores eléctricos se pueden atribuir a los rodamientos y al aislamiento del estator. Algunos estudios apuntan que los fallos en rodamientos pueden suponer hasta casi el 70% del total de fallos que acontecen en motores eléctricos (Bonnett et al., 2008). Algunas de las principales causas que pueden provocar fallos en los rodamientos son: cargas excesivas, lubricación insuficiente o excesiva, contaminación externa, montaje incorrecto, y circulación de corrientes a través de los rodamientos entre otras (SKF, 2017). Estas situaciones pueden conducir a la aparición de defectos en las diferentes partes del rodamiento (pista interna o externa, elemento rodante, jaula) y a vibraciones indeseables, con la consiguiente posibilidad de que el rodamiento colapse en cierto tiempo. La presencia de estos fallos puede provocar interrupciones inesperadas y pérdidas de producción (Frosini, 2020). Una causa común de fallos en rodamientos es la presencia de excentricidades excesivas. Estas excentricidades pueden ser debidas, entre otras causas, a montajes deficientes, rotor o estator deformados, y fuerzas debidas a empuje magnético desequilibrado (UMP, por sus siglas en inglés) (D. Guo et al., 2003; Salah et al., 2019). La aparición de corrientes de descarga a través de los rodamientos es otra causa común de fallo reportada recientemente (Oliver et al. 2015). Este fallo es causado por el accionamiento del motor mediante variador de frecuencia (VFD por sus siglas en ingles). Como se ha explicado en varias investigaciones (Plazenet et al., 2018), el variador de frecuencia induce una tensión de modo común en el eje, la cual provoca la circulación de corrientes a tierra. Estas corrientes pueden cerrarse a través del propio rodamiento, a través de la película de lubricante del mismo, y provocar así daños en las pistas del rodamiento (el fallo da lugar a una firma característica en la pista externa,

además de un color mate característico en los elementos rodantes). En efecto, la aparición del arco eléctrico entre elementos rodantes y las pistas provoca un micro desgaste de las superficies rodantes (Oliver et al., 2015). La corriente circulante puede generar pequeños cráteres en las superficies de apoyo (pistas de rodadura exteriores y/o interiores), como se muestra en la Figura 2a. Esta corriente puede producir un proceso de soldadura por arco, al producirse 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 se sobrecalienta, 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.

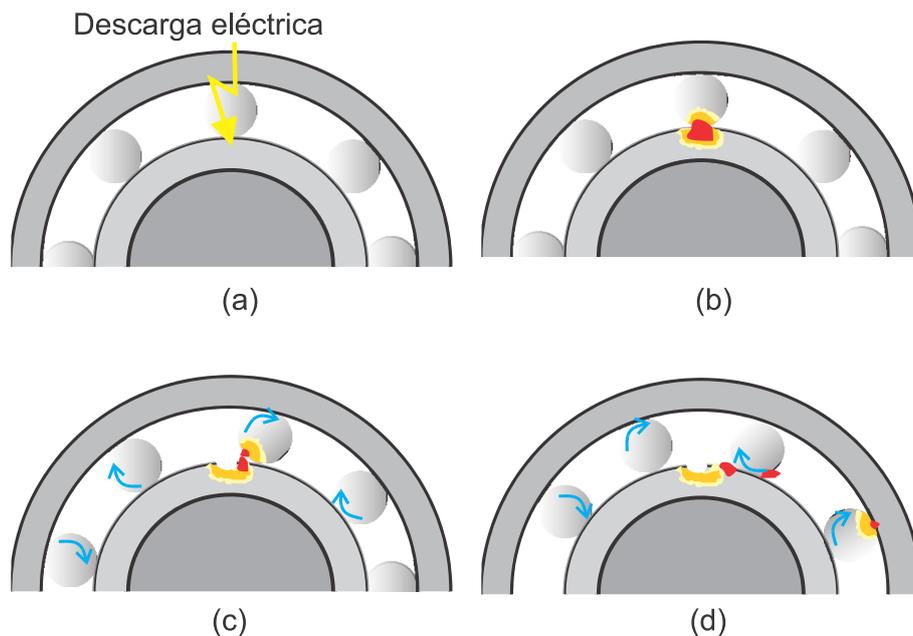


Figura 2. Arco eléctrico en un rodamiento metálico: (a) La corriente eléctrica pasa a través de los elementos rodantes. (b) La soldadura por arco se produce entre los elementos rodantes y la pista del rodamiento. (c) El material fundido se solidifica y se separa. (d) El exceso de material se elimina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

Los defectos en rodamientos se detectan usualmente mediante el análisis de las señales de vibración. Cada tipo de defecto concreto (fallo en la pista externa, fallo en la pista interna, fallo en el elemento rodante, fallo en la jaula) da lugar a la amplificación de distintos componentes de frecuencia en el espectro vibracional de la máquina, y que se pueden atribuir a defectos de un solo punto, específicamente, el impacto de la parte móvil del rodamiento en el defecto local. Un estudio (Trajin et al.,



2010), ha identificado las siguientes frecuencias asociadas con diferentes tipos de fallas en los rodamientos:

La frecuencia de paso de bola de la pista exterior es indicativa de una falla en la pista exterior, y que amplifica las componentes frecuenciales dadas por (4).

$$f_o = f_r \frac{N_b}{2} \left(1 - \frac{D_b \cdot \cos(\phi)}{D_p} \right) \quad (4)$$

La ocurrencia de una falla en la pista interna de un rodamiento se puede determinar analizando la frecuencia de paso de bola de la pista interna, de acuerdo con las frecuencias identificadas para varios tipos de fallas en los rodamientos (Trajin et al., 2010) (5).

$$f_i = f_r \frac{N_b}{2} \left(1 + \frac{D_b \cdot \cos(\phi)}{D_p} \right) \quad (5)$$

Una falla de bola en un rodamiento se puede identificar por la ocurrencia la frecuencia de giro de la bola, según las frecuencias identificadas para diferentes tipos de fallas de rodamiento (6).

$$f_B = f_r \frac{D_p}{D_b} \left(1 + \frac{D_b^2 \cdot \cos^2(\phi)}{D_p^2} \right) \quad (6)$$

La presencia de una falla en la jaula de un rodamiento puede ser indicada por la frecuencia fundamental del tren, según las frecuencias identificadas para varios tipos de fallas en los rodamientos (7).

$$f_c = f_r \frac{D_b}{2} \left(1 \pm \frac{D_b \cdot \cos(\phi)}{D_p} \right) \quad (7)$$

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.

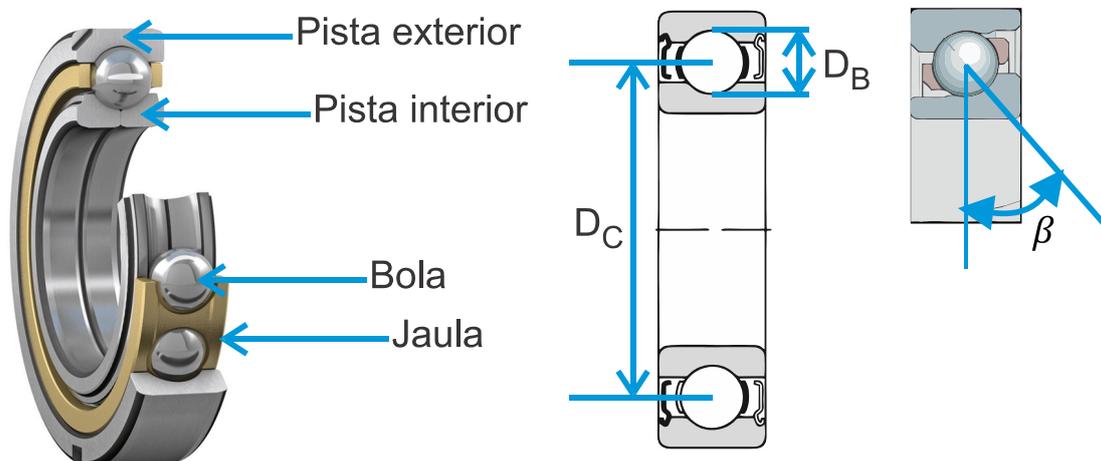


Figura 3. Parámetros de rodamientos de bolas (autoría propia).

Por otro lado, 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 fallo 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 (8) (Bellini, et al., 2008):

$$f_{BE} = f_s \pm k \cdot f_{BPOF} \quad (8)$$

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 también como una excentricidad estática, que provoca la amplificación de las frecuencias f_{BE} antes comentadas.



2.2.2 Barras de rotor rotas

La rotura de barras de rotor es uno de los fallos que puede acontecer en los motores de inducción tipo jaula de ardilla, siendo más frecuente en motores de elevada potencia. Se sabe que las barras del rotor de este tipo de motores eléctricos están sometidas a importantes esfuerzos electromagnéticos y térmicos durante su operación; éstos son principalmente debidos a diversas causas, como arranques pesados o fluctuaciones bruscas de carga. Estos esfuerzos propician usualmente la aparición de microgrietas en las barras; en los rotores de barras de cobre, estas microgrietas surgen normalmente en el punto de unión entre la barra y el anillo de cortocircuito, que suele ser un punto especialmente crítico en el que la citada unión se produce por soldadura. Una vez surge la microgrieta, ésta se va agrandando debido a los efectos térmicos y electrodinámicos a los que se ve sometida la barra, conduciendo finalmente a una rotura completa de barra ([Fernandez Cabanas et al. 1998](#)). Una vez tiene lugar la rotura completa de barra, la corriente que circulaba por ésta se redistribuye entre las barras adyacentes, con lo que éstas se sobrecargan siendo, por tanto, las más propensas a fallar a continuación, debido a los mayores esfuerzos electrodinámicos y térmicos a las que están sometidas.

Thomson agrupa los esfuerzos que provocan la aparición de barras rotas en las siguientes tipologías ([Thomson et al., 2016](#)):

- 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. 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 de los anillos de cortocircuito 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 barras del rotor. Estos esfuerzos se acentúan durante el arranque, especialmente cuando el motor es alimentado directamente desde la red. La cantidad de calor máximo generada dependerá, entre otras cuestiones, de la diferencia entre las curvas de par del motor y de la carga accionada y de la inercia del conjunto motor-carga. Así, cuanto mayor sea el tiempo de arranque (tiempo en alcanzar el régimen permanente), mayor será la temperatura alcanzada durante este transitorio ([Thomson et al., 2016](#)). La distribución no uniforme de la disipación de calor en la barra del rotor da como resultado una distribución desigual de temperaturas, siendo el aumento de temperatura en la parte superior de la barra mayor que en la parte inferior de la misma. Por lo tanto, durante la aceleración, esta distribución no uniforme



de temperatura 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 disminuye 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 las barras 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 de las barras puede seguir siendo alta desde el primer arranque, provocando el segundo arranque aumentos adicionales de la temperatura. De esta forma, si se realizan arranques repetidos, el calentamiento acumulativo del rotor puede conducir a temperaturas en las barras indeseablemente altas. Tales problemas de sobrecalentamiento de las barras del rotor son mucho más probables en motores que arrancan directamente equipos de elevada 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 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 de cortocircuito se agrieten y, finalmente, fallen (Thomson et al., 2016).

A pesar de que la rotura de barras o de anillos de cortocircuito se da con menos frecuencia que otros tipos de fallo (como fallos en rodamientos o en el aislamiento), se trata de una avería bastante peligrosa y con relevancia industrial por diversas razones:

- En primer lugar, es bastante más frecuente en motores de elevada potencia que en motores de bajas potencias. Esto es debido a la diferente construcción del rotor dependiendo del tipo de motor: en motores grandes, el rotor suele estar constituido por barras de cobre unidas a los anillos de cortocircuito por soldadura, siendo este punto de unión especialmente propenso al fallo (Fernandez Cabanas et al. 1998). En motores de potencia menor, las jaulas se suelen fabricar a base de aluminio inyectado. En este tipo de rotores, el fallo suele producirse por porosidad de las barras o por elevadas sobrecorrientes debidas a condiciones de funcionamiento anómalas, si bien



estos tipos de fallo son mucho menos frecuentes. El problema es que los motores de elevada potencia, en los que el fallo se da con más asiduidad, son los más costosos y complejos de reparar.

- Otra característica del fallo en las barras es que puede pasar inadvertido, a no ser que se empleen técnicas predictivas adecuadas para su detección. En efecto, la aparición de una rotura de barra, usualmente, no da lugar a síntomas externos apreciables. Esto es, el motor continúa operando en condiciones aparentemente normales si se observan sus magnitudes básicas (par, velocidad, corriente). Solamente al alcanzar el fallo un nivel de severidad importante es cuando se empiezan a detectar evidencias externas de la presencia del mismo (por ejemplo, una oscilación en la corriente demandada). Sin embargo, cuando se alcanza tal punto de severidad, el colapso del motor puede ser inminente y el tiempo de reacción para adoptar acciones de mantenimiento oportunas, limitado. Es por ello por lo que resulta de gran interés tener vigilada la salud del rotor, aplicando técnicas adecuadas, para poder detectar el fallo cuando éste todavía se encuentra en un estadio incipiente.
- Otro problema asociado al fallo es que, si bien su progresión suele ser lenta en muchos casos (el fallo se va propagando de una barra a otra, tal y como se ha comentado), no siempre es así. En ocasiones, puede ocurrir una protrusión de barra o un desprendimiento de un fragmento de una barra rota que impacte con el aislamiento del estator, dañándolo y produciendo un fallo catastrófico en el motor (Lee et al., 2013). Debido a ello, conviene tener vigilada la salud del rotor en todo momento, dado que el fallo puede dar lugar a consecuencias catastróficas de forma inmediata.
- Finalmente, en el ámbito industrial, a veces se adopta la falsa creencia de que el rotor nunca falla y que no precisa de mantenimiento. Esta creencia, como se puede concluir de lo dicho, es totalmente errónea, como muestra el hecho de que se hayan reportado en la literatura numerosos casos reales de fallo en el rotor (Lee et al., 2013), muchos de ellos correspondientes a motores críticos y de elevada potencia.

Cuando se produce una rotura de barra, debido a cualquiera de las causas anteriormente descritas, se produce una distorsión en el campo del entrehierro (Fernandez Cabanas et al. 1998). Como resultado, se pierde la simetría de la máquina. 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

lateral inferior (LSH por su abreviatura en inglés, Lower Side-band Harmonic), dando lugar a la componente frecuencial (f_{LSH}) de fallo dada por (9):

$$f_{LSH} = (1 - 2 \cdot s) \cdot f \quad (9)$$

Esta variación de corriente cíclica implica una oscilación de velocidad y una pulsación de par al doble de la frecuencia de deslizamiento ($2 \cdot s \cdot f_s$) (Fernandez Cabanas et al. 1998). Esta oscilación de velocidad induce, en el devanado del estator, una componente superior a $f_{USH} = (1 + 2 \cdot s) \cdot f_s$. (Filippetti et al. 1998) demuestra que la aparición del armónico lateral superior provoca la aparición de un campo magnético giratorio a la frecuencia $3 \cdot s \cdot f$ respecto del rotor. Esta asimetría provoca que las corrientes rotóricas generadas por las correspondientes fem produzcan dos campos giratorios a las frecuencias $\pm 3 \cdot s \cdot f$. La secuencia del fenómeno continua pues; aparece otro armónico lateral inducido por el campo directo a la frecuencia $f \cdot (1 - 4 \cdot s)$, el cual, a su vez, provoca una oscilación de velocidad que dar lugar a un armónico a $f \cdot (1 + 4 \cdot s)$ y así sucesivamente (Antonino-Daviu, 2006). Este proceso se produce de forma recurrente, dando lugar a una familia de componentes ubicadas a las frecuencias f_{BB1} dadas por la expresión (10) que están asociadas a la rotura de barras:

$$f_{BB1} = (1 \pm 2 \cdot k \cdot s) \cdot f \quad (10)$$

$$k = 0, 1, 2, \dots$$

Por otro lado, tal y como se demuestra en (Fernandez Cabanas et al. 1998), la rotura de barras da lugar a una segunda familia de componentes, muchas de ellas ubicadas a mayores frecuencias. La expresión de esta segunda familia viene dada por (11):

$$f_{bb2} = \left[\frac{k}{p} (1 - s) \pm s \right] f, \frac{k}{p} = 1, 3, 5 \dots \quad (11)$$

Asignando valores al parámetro k/p en la expresión (11), se obtienen los armónicos de fallo dados por esta expresión.

Cabe apuntar que, aunque en la literatura se ha justificado el uso de las anteriores expresiones para detectar asimetrías rotóricas (roturas de barra) en

motores de jaula de ardilla, estas mismas expresiones pueden emplearse para la detección de asimetrías en el devanado del rotor de máquinas de rotor bobinado, como así se ha probado en varios trabajos ([Antonino-Daviu et al., 2017](#)). La aparición de asimetrías en el rotor de máquinas de rotor bobinado es mucho más usual que en máquinas de rotor de jaula; esto es principalmente debido a la construcción más compleja del circuito del rotor y a los múltiples elementos que en él intervienen, a saber: bobinas del devanado rotórico (puede haber varias bobinas conectadas en serie por fase), sistema de anillos rozantes-escobillas, reóstato de arranque, etc...). Precisamente, debido a esta mayor complejidad del devanado del circuito del rotor y a los múltiples elementos que en él intervienen, resulta mucho más probable que aparezca una asimetría, la cual puede ser originada por múltiples causas asociadas a estos elementos: problemas de conexionado entre bobinas del cada fase del rotor, conexiones defectuosas entre las bobinas y la caja de bornas, problemas en el reóstato de arranque (desequilibrio entre fases), problemas en el sistema de anillos rozantes escobillas (contactos deficientes entre escobillas y anillos rozantes, desgaste no uniforme de las escobillas,...), etc...Debido a ello, es de especial interés aplicar técnicas que permitan diagnosticar el estado del rotor en este tipo de máquinas, ya que el fallo es todavía más frecuente que en máquinas de jaula de ardilla. En concreto, la técnica de análisis de corriente ha mostrado un potencial especialmente interesante, como se ha probado en varios trabajos que incluso han abordado la aplicación de la misma en régimen transitorio de funcionamiento ([Antonino-Daviu et al., 2017](#)). Resulta de gran interés validar el potencial de la técnica de análisis del flujo, ya que muchas de las técnicas aplicadas a señales de corriente, son directamente extrapolables al análisis de las señales de flujo. Este constituye uno de los objetivos de la presente tesis.

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. Este fenómeno se produce cuando el eje del motor no queda alineado con el de la carga impulsada. Se pueden distinguir dos tipos principales de desalineamiento: desalineamiento angular, y desalineamiento paralelo, este último también conocido como desalineamiento radial; adicionalmente, se puede dar el caso en que ambos desalineamientos se encuentren presentes de forma simultánea. El desalineamiento 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 desalineamiento está dado por el ángulo α entre los dos ejes. Cuando los ejes están perfectamente paralelos entre sí, pero no en la misma recta, 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 especifica como d en la Figura 4b.

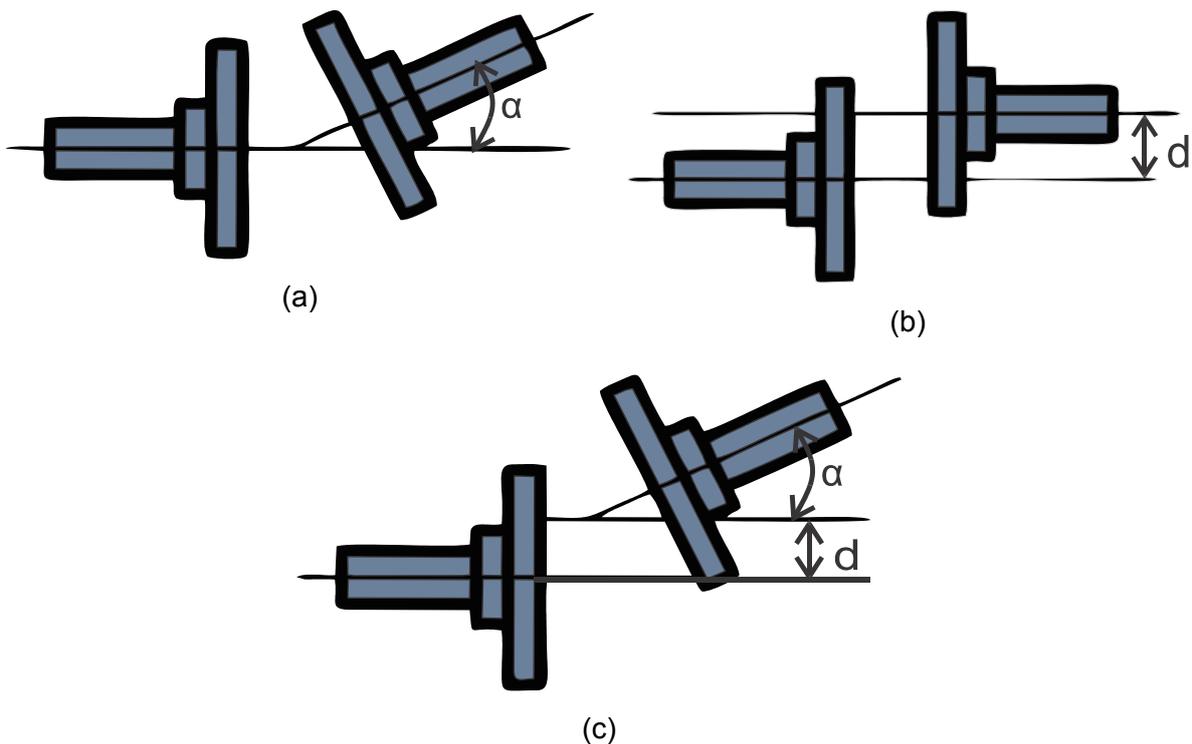


Figura 4. Tipos de desalineamiento de eje. (a) Desalineamiento angular. (b) Desalineamiento paralelo. (c) Desalineamiento combinado.



Dependiendo de su tipo, el desalineamiento puede producir y/o aumentar vibraciones a diferentes frecuencias. En particular, el desalineamiento 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, el desalineamiento muestra tener influencia en el espectro de corriente del estator, ya que afecta al 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 (12), lo que permite detectar estos fenómenos. Sin embargo, dado que todos ellos producen componentes similares, su diagnóstico sigue siendo difícil. Uno de los retos que se presentan es extraer indicadores a partir de la aplicación de las diferentes técnicas que sean capaces de discriminar la presencia de un desalineamiento de la presencia de otros tipos de fallos mecánicos (excentricidades, desequilibrios...) que amplifican las mismas componentes en el espectro de corrientes. La aplicación de la técnica de análisis de flujo, en combinación con otras técnicas, como análisis de corrientes, se ha mostrado efectiva para este propósito, como prueban ciertos trabajos ([Park, Choi, Lee, et al., 2020](#)).

$$f_{DES} = f \pm n \cdot f_r \quad (12)$$

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

2.2.4 Fallos en engranajes

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 sistemas de acoplamiento ofrecen: industria aeroespacial, de trabajo pesado, turbinas eólicas, máquinas herramienta en industrias manufactureras, entre otras (Praveenkumar et al., 2017; Salameh et al., 2018). Recientemente, se han utilizado masivamente como sistemas de transmisión en vehículos eléctricos, los cuales vienen cobrando un protagonismo espectacular en los últimos años (Praveenkumar et al., 2017). Su alta eficiencia de transmisión y su elevada capacidad de carga explican su uso generalizado. Durante su vida útil, los reductores basados en cajas de engranajes están sometidos a esfuerzos constantes que provocan un desgaste significativo y gradual del engranaje dentado. Esta situación puede conducir a un rendimiento inaceptable, vibraciones indeseables y elevado ruido. Además, el fallo de estos sistemas puede provocar interrupciones inesperadas y paradas 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 que aparecen 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 par. Estas frecuencias pueden ser calculadas de acuerdo a la ecuación (13) (Kuang et al., 2003).

$$\begin{aligned} f_{malla} &= N_{r1} \cdot f_{r1} = N_{r2} \cdot f_{r2} \\ f_{Gr1malla} &= N_{r1} \cdot f_{r1} \pm f_{r1} \end{aligned} \quad (13)$$

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 engranajes, 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, Kia et al., (2007) muestra que, en presencia de fallos 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 las componentes asociadas a los engranajes de entrada y salida, f_{Gr1} y f_{Gr2} , también puede aparecer, produciendo la amplificación de sus armónicos relacionados ($f_{Gr1-Gr2}$). De forma similar, pueden ser amplificadas las componentes de frecuencias características asociadas al engranaje de entrada y la frecuencia de malla ($f_{Gr1-malla}$), y las relacionadas con el engranaje de salida y la frecuencia de malla ($f_{Gr1-Gr2-malla}$). 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 (14) a (20):

$$f_{Gr1} = f_s \pm m \cdot f_{r1} \quad (14)$$

$$f_{Gr2} = f_s \pm n \cdot f_{r2} \quad (15)$$

$$f_{Gmalla} = f_s \pm p \cdot f_{mesh} \quad (16)$$

$$f_{Gr1-r2} = f_s \pm m \cdot f_{r1} \pm n \cdot f_{r2} \quad (17)$$

$$f_{Gr1-malla} = f_s \pm m \cdot f_{r1} \pm p \cdot f_{malla} \quad (18)$$

$$f_{Gr2-malla} = f_s \pm n \cdot f_{r2} \pm p \cdot f_{malla} \quad (19)$$

$$f_{Gr1-r2-malla} = f_s \pm m \cdot f_{r1} \pm n \cdot f_{r2} \pm p \cdot f_{malla} \quad (20)$$

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.

Algunos autores apuntan la dificultad de detectar algunas de estas componentes en el espectro de corrientes dado que sus amplitudes, a veces, no resultan muy elevadas. No obstante, el análisis de corrientes es una fuente de información de gran interés para determinar la condición de este tipo de sistemas de acoplamiento, especialmente cuando no es posible aplicar otras técnicas (vibraciones). La aplicación de técnicas de análisis de flujo, especialmente en régimen transitorio, constituye un reto latente, de cara a determinar si esta técnica pudiera aportar información valiosa para el diagnóstico de los sistemas de engranajes.

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 con el aislamiento ([Donnell et al., 1987](#)). Aunque el modo de fallo final suele ser la ruptura del dieléctrico, el mecanismo subyacente que provoca esta ruptura suele ser debido esencialmente a 4 tipos de esfuerzos: térmicos, eléctricos, mecánicos, y esfuerzos ambientales ([Bonnett et al., 1992](#); [Siddique et al., 2005](#)). Eventualmente, dichos esfuerzos debilitarán tanto el aislamiento que éste se perforará, pudiendo devenir una derivación a tierra.

1. Esfuerzos térmicos:

Una de las principales causas conocidas que originan una aceleración en el deterioro de los aislamientos es provocada por aumentos en la temperatura de operación del motor. Estos aumentos provocan 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 en un 50 %. En condiciones normales de funcionamiento, el proceso de envejecimiento en sí mismo no causa un fallo, 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 tensión, tensiones de alimentación desequilibradas, sobrecarga, ventilación obstruida o excesiva temperatura ambiente. A modo de regla práctica, un desequilibrio de tensiones del 3.5% puede ocasionar incrementos de temperatura de hasta un 25% en la fase con corriente más elevada. La Tabla 1 muestra los efectos aproximados sobre la vida útil del aislamiento cuando éste opera bajo temperaturas ambientes 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 los esfuerzos eléctricos conducen al fallo del aislamiento del estátor. Estos generalmente pueden deberse a la aparición de descargas parciales, efecto corona o tensiones transitorias 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 el asociado a transitorios en la tensión de suministro. Estos transitorios pueden causar fallos a tierra. Las principales causas que originan estos transitorios se deben a problemas en el suministro de energía asociados a 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 fallos de aislamiento producidos por los transitorios de conmutación que estos generan. Esta situación que se ve causada 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 las causadas por vibraciones y movimientos de las bobinas y por impactos del propio rotor (debido a protrusión de barras, impacto de fragmentos de barras rotas, excentricidades excesivas etc..). Los esfuerzos dinámicos entre bobinas con proporcionales al producto de sus respectivas corrientes y alcanzan su valor máximo durante el arranque del motor. Estas fuerzas hacen que las bobinas se muevan y vibren. El movimiento de las bobinas puede causar daños severos al aislamiento de la bobina o al conductor. Por otro lado, existen diferentes motivos que pueden provocar impactos con el aislamiento del estator e incluso que el rotor roce con el estator. Esto último puede ser causado por fallos en los cojinetes, deflexión del eje, desalineación del rotor, etc... ([Bonnett et al., 1992](#)).

4. Esfuerzos ambientales:

Los esfuerzos ambientales son ocasionados principalmente por la presencia de materiales contaminantes externos que reducen la capacidad de disipación de calor, producen fallos prematuros en los rodamientos e incluso daños en el aislamiento. Es por esta razón que este tipo de máquinas se deben de mantener en condiciones limpias y permanecer secas, 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 Resumen de componentes frecuenciales amplificadas debido a fallos en señales de corriente.

Cuando una máquina eléctrica experimenta una falla, como un cortocircuito, barras de rotor rotas, excetricidades, etc., se produce una asimetría en el campo magnético giratorio. Esta asimetría causa una variación en el flujo magnético a través de los devanados del estator de la máquina, lo que a su vez induce una tensión y una corriente en los devanados. Esta corriente de fallo tiene una frecuencia característica que depende del tipo de falla que se está produciendo, lo que hace que la falla sea detectable en el dominio del tiempo y/o de la frecuencia. En otras palabras, las fallas en los motores eléctricos pueden ser detectadas por la medición de la corriente eléctrica en el motor. El método más común utilizado para detectar y diagnosticar fallas en motores eléctricos es el análisis de firma de corriente del motor (MCSA). En este método, se utiliza la transformada de Fourier para analizar la corriente eléctrica en el motor y observar los componentes de frecuencia producidos por las fallas en el estator. Estas frecuencias amplificadas pueden ser útiles para identificar la causa de la falla y tomar medidas correctivas antes de que se produzca un fallo catastrófico del motor.

Debido a que los motores eléctricos pueden fallar de diversas partes constructivas del mismo, se han identificado diversas componentes frecuenciales que se encuentran asociadas a fallas específicas. Estas componentes se han determinado mediante el análisis de las frecuencias amplificadas en caso de fallas en los motores eléctricos. Para resumir la estimación de estas componentes y sus causas, la Tabla 2 presenta algunas de las expresiones matemáticas más comunes que proporcionan una estimación de las frecuencias amplificadas en caso de fallas en motores eléctricos. Esta tabla proporciona una guía general para la interpretación de estas frecuencias

Tabla 2. Principales componentes de frecuencia amplificados por distintas fallas en las señales de corriente.

Origen	Componentes frecuenciales amplificadas
Fallas en el rotor	$f_{BRB} = \left[\frac{k}{p} (1-s) \pm s \right] \cdot f_s$
Excentricidades/desalineaciones	$f_{ecc} = f_s \pm f_r$ $f_{ecc} = f_s \left[\frac{R}{p} (1-s) \pm n_{\omega s} \right] \pm f_r$
Pista exterior del rodamiento	$f_o = f_s \pm k \frac{N}{2} \cdot f_r \left(1 - \frac{D_b}{D_c} \cos(\beta) \right)$
Pista interior del rodamiento	$f_i = f_s \pm k \frac{N}{2} \cdot f_r \left(1 + \frac{D_b}{D_c} \cos(\beta) \right)$
Falla de bola de rodamiento	$f_B = f_s \pm \frac{D_p}{D_b} \cdot f_r \left(1 - \frac{D_b^2}{D_c^2} \cos(\beta)^2 \right)$
Falla de la jaula en rodamiento	$f_C = f_s \pm \frac{f_r}{2} \left(1 \pm \frac{D_b}{D_c} \cos(\beta) \right)$
Averías relacionadas con la caja de cambios	$f_{gear} = \left f_s \pm (N_d \pm k_{gear}) \cdot f_r \right $
<p>Donde f_s = la frecuencia de la fuente de alimentación, f_r = la velocidad de rotación del rotor, k = número entero (= 1, 2, 3, ...), N = número de rodamientos, k_{odd} es un número entero impar, n es un número entero diferente de $6 \cdot j \pm 1$ (j es un número entero), N_r es el número de ranuras del rotor, $n_d = 0$ para la excentricidad estática y $n_d = 1, 2, 3$ para la excentricidad dinámica.</p>	



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

Como se comentó en secciones previas, cuando un motor de inducción se encuentra operando bajo un fallo específico, diversas magnitudes electromecánicas relacionadas a sus condiciones naturales de operación pueden verse alteradas, tales como corrientes, vibraciones, ruido o par, entre otras. Consecuentemente, un adecuado análisis de estas magnitudes físicas puede ayudar a diagnosticar la presencia del correspondiente fallo. 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 magnitudes específicas de la máquina. El empleo de técnicas de procesamiento de señal 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 fallos en máquinas eléctricas: 1) análisis en régimen permanente mediante el uso convencional de la transformada rápida de Fourier (FFT), así como de indicadores estadísticos y no estadísticos, y 2) diagnóstico basado en análisis transitorio, mediante la aplicación de herramientas matemáticas de descomposición tiempo-frecuencia (TFD, por su abreviatura en inglés Time-Frequency Decomposition).

3.1 Análisis en régimen permanente

Se detalla en esta sección, en primer lugar, la transformada básica empleada para el análisis en régimen permanente (transformada de Fourier). A continuación, se detallan varios indicadores y herramientas que se aplican en esta tesis sobre señales capturadas en régimen permanente. Estos indicadores son útiles para la identificación de distintos modos de fallo y para la evaluación de su severidad.

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

La transformada de Fourier (FT) es una herramienta matemática que descompone una función (señal) en el dominio del tiempo en las componentes frecuenciales que la integran. La transformada de Fourier de una función en el dominio tiempo se expresa matemáticamente mediante la ecuación (21) y constituye una representación en el dominio de frecuencia de la señal original. En términos prácticos, 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 = tiempo, f = frecuencia, x = Señal en función del tiempo, j = 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).

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

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 3b), 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 solamente aparecen las componentes esperadas. Sin embargo, la transformada de Fourier aplicada a señales no estacionarias permite extraer las componentes frecuenciales presentes en la señal, pero no indica el tiempo de aparición de cada una de ellas, es decir, se pierde la información temporal.

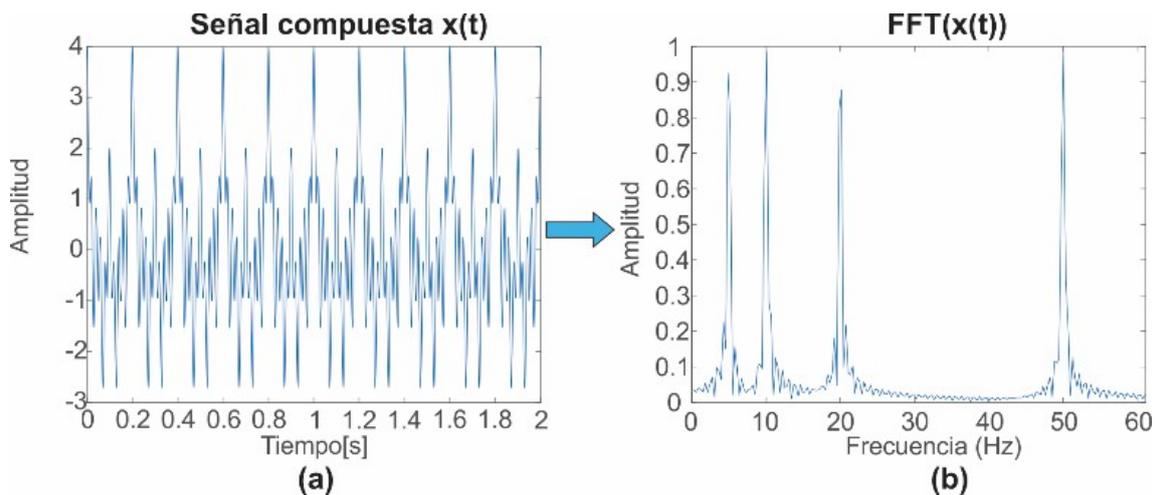


Figura 5. Ejemplo de uso de transformada de Fourier: (a) señal en el tiempo, (b) espectro de Fourier.

3.1.2 Indicadores estadísticos y no estadísticos.

Dado un sistema caracterizado mediante una señal capturada en el dominio del tiempo, el objetivo principal de los indicadores estadísticos es obtener información relevante sobre su comportamiento. Debido a que un sistema bajo diferentes condiciones de operación se puede caracterizar por señales con parámetros estadísticos variados, se espera que un estado de fallo 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 sobre el sistema bajo estudio) para la detección de fallas se basa en obtener parámetros que puedan reflejar correctamente la condición de trabajo del sistema y, en consecuencia, identificar sus patrones de fallo (Huerta-Rosales et al., 2021). En este contexto, indicadores 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 diversos fallos 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 3. Estos indicadores son elegidos debido a las diversas ventajas que presentan, las cuales han hecho posible su proliferación para esquemas de diagnóstico destinados al diagnóstico en línea y su implementación en hardware (Huerta-Rosales et al., 2021), a saber: reducida carga computacional y la consiguiente necesidad de una mínima cantidad de recursos de memoria para calcularlos, capacidad de proporcionar información sobre tendencias generales y simplicidad.

A fin de mantener únicamente los indicadores estadísticos más representativos, es decir, aquellos que presentan más importancia a efectos de clasificación entre estados de fallo, y minimizar los problemas de redundancia, se realiza una etapa de preprocesamiento posterior aplicando la técnica de puntuación de Fisher. Este método puede interpretarse como una medida relativa que representa la distancia entre diferentes clases y la dispersión entre muestras pertenecientes a cada clase. De esta manera, un valor de Fisher (FS) pequeño implica una capacidad discriminatoria deficiente, mientras que un valor de Fisher elevado conlleva una mejor característica discriminatoria. Considerando esto, la selección de características se realiza bajo un enfoque combinatorio en el que los valores de Fisher se obtienen realizando combinaciones entre todas las características estadísticas disponibles. Por lo tanto, la capacidad de discriminación se evalúa 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 $F S^j$ 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 3. Indicadores estadísticos considerados 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 (SRM)	$T_3 = \sqrt{\frac{1}{N} \cdot \sum_{i=1}^N (x_i)^2}$	(26)
Raíz cuadrada media (RMS)	$T_4 = \left(\frac{1}{N} \cdot \sum_{i=1}^N \sqrt{ x_i } \right)^2$	(27)
Desviación estándar (σ)	$T_5 = \sqrt{\frac{1}{N} \cdot \sum_{i=1}^N (x_i - T_1)^2}$	(28)
Varianza (σ^2)	$T_6 = \frac{1}{N} \cdot \sum_{i=1}^n (x_i - T_1)^2$	(29)
Factor de forma RMS (SF_{RMS})	$T_7 = \frac{T_3}{\frac{1}{N} \cdot \sum_{i=1}^N x_i }$	(30)
Factor de forma SRM (SF_{SRM})	$T_8 = \frac{T_4}{\frac{1}{N} \cdot \sum_{i=1}^N x_i }$	(31)

Factor cresta (CF)	$T_9 = \frac{T_2}{T_3}$	(32)
Factor de latitud (LF)	$T_{10} = \frac{T_2}{T_4}$	(33)
Factor de impulso (IF)	$T_{11} = \frac{T_2}{\frac{1}{N} \cdot \sum_{i=1}^N x_i }$	(34)
Oblicuidad (S_k)	$T_{12} = \frac{\sum [(x_i - T_1)^3]}{T_5^3}$	(35)
Curtosis (k)	$T_{13} = \frac{\sum [(x_i - T_1)^4]}{T_5^4}$	(36)
Quinto momento ($5_{th} M$)	$T_{14} = \frac{\sum [(x_i - T_1)^5]}{T_5^5}$	(37)
Sexto momento ($6_{th} M$)	$T_{15} = \frac{\sum [(x_i - T_1)^6]}{T_5^6}$	(38)

La Figura 6 muestra un ejemplo del proceso de obtención de los indicadores aquí propuestos. Como se puede observar, se considera una señal capturada en el dominio del tiempo, en la que es necesario generar ventanas rectangulares deslizantes con o sin superposición entre ventanas. El tamaño de la ventana es previamente seleccionado; para los fines considerados en esta tesis, se emplea un tamaño de ventana de 1s, con el fin de evitar procesar perturbaciones puntuales en la señal capturada. Finalmente, para cada ventana de datos, se calcula cada uno de los indicadores aquí propuestos aplicando las expresiones (24) a (38).

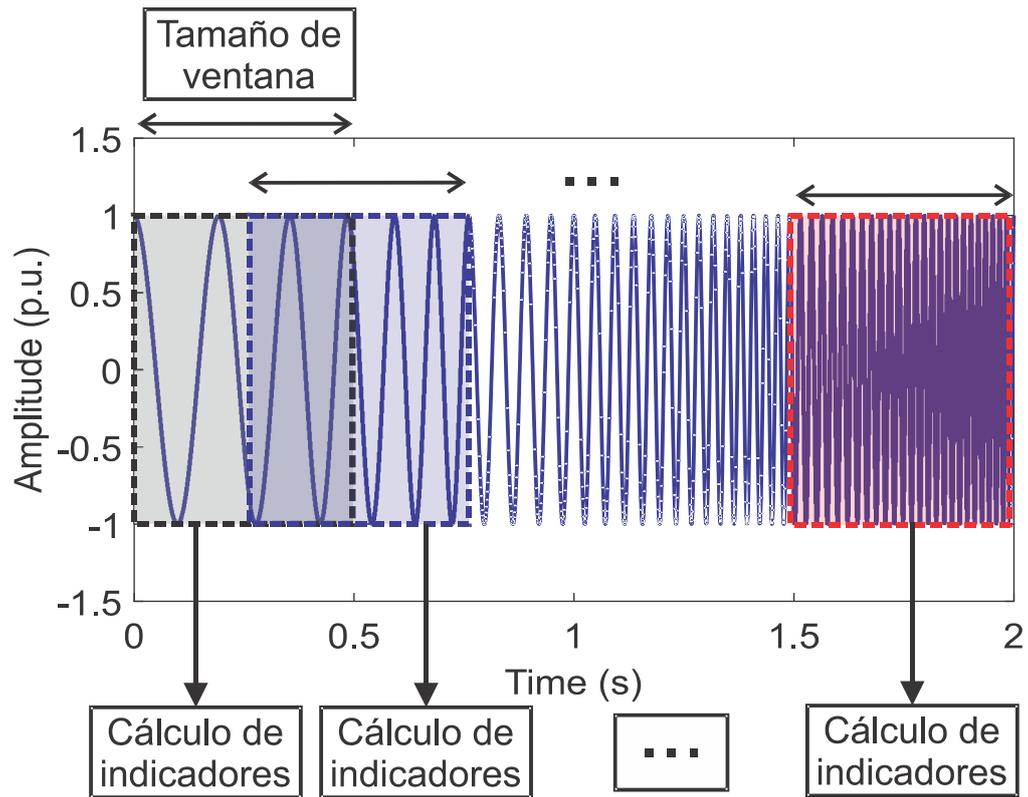


Figura 6. Cálculo de los indicadores propuestos a partir de una señal capturada en el dominio del tiempo.

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

La transformada wavelet discreta (DWT) es una transformación que convierte una señal en el dominio del tiempo a un dominio tiempo-frecuencia utilizando técnicas de filtrado digital. Esta transformada captura tanto la información sobre el contenido en frecuencias como la ubicación temporal de las componentes frecuenciales, lo que la hace superior a las transformadas de Fourier en términos de resolución temporal. El algoritmo de Mallat, [Mallat \(1989\)](#), es utilizado para calcular la DWT, que consiste en aplicar una serie de filtros paso alto y paso bajo a la señal de entrada para extraer las componentes de alta y baja frecuencia, señales de detalle y señales de aproximación, respectivamente. Los coeficientes de los filtros son determinados por una ondoleta madre, seleccionada según las características de la señal. El proceso se repite para aumentar la resolución en frecuencia y los coeficientes son submuestreados. Este proceso se puede representar mediante un árbol binario con nodos que representan diferentes localizaciones de tiempo-frecuencia. Así entonces, cada señal ondoleta, incluidas las señales de aproximación (a_j) y detalle (d_j), corresponde a una banda de frecuencia particular con límites establecidos. Los límites de la banda de frecuencia para cada señal ondoleta dependen de la tasa de muestreo (f_m) y el nivel de la señal ondoleta correspondiente (j). Por ejemplo, si la frecuencia de muestreo de la señal original es $f_m=5000$ muestras/segundo y la descomposición DWT se realiza en $n=8$ niveles, las bandas de frecuencia asociadas con cada señal ondoleta se pueden encontrar en la Tabla 4.

Tabla 4. Bandas de frecuencia asociadas con las señales ondoleta para $f_m=5$ kHz y $n=8$.

Señal ondoleta	Banda de frecuencia
a8	0–9.78
d8	9.78–19.5
d7	19.5–39.06
d6	39.06–78.12
d5	78.12–156.25

d4	156.25–312.5
d3	312.5–625
d2	625–1250
d1	1250–2500

Así entonces, la transformada wavelet discreta (γ_{DWT}) puede ser utilizada como un indicador normalizado para proporcionar una idea general de los cambios de energía en una señal dada. Esta técnica ha sido ampliamente aplicada con éxito en el diagnóstico de fallos en motores eléctricos debido a su capacidad para evaluar la energía en una banda de frecuencia específica. Es adecuado para medir las amplitudes en una banda de frecuencias limitada donde se encuentra presente una componente de fallo. El indicador basado en la DWT utiliza la señal analizada y la compara con la señal ondleta que contiene la mayor parte de la componente de fallo (señal d_n). Este parámetro se ha sugerido previamente para la detección de fallos en motores eléctricos, como problemas en el rotor (Riera-Guasp et al., 2008), y se adapta aquí para los propósitos de esta tesis. Su expresión normalizada se encuentra en la ecuación (39), donde N_b representa la posición de la primera muestra considerada y N_s es la última muestra que abarca el intervalo de tiempo analizado.

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 ondoleta d_5 para calcular el índice γ_{DWT} .

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

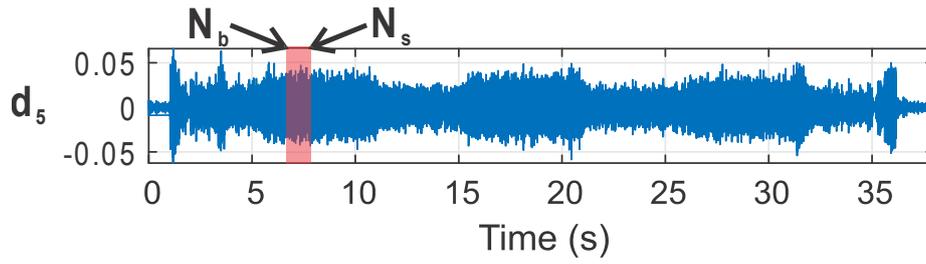


Figura 7. Ventana rectangular considerada para calcular el valor del indicador γ_{DWT} analizando la señal wavelet d_5 .

3.1.4 Fractales.

El análisis de dimensión fractal (FD por sus siglas en inglés) es un concepto de la teoría del caos, que intenta medir la cantidad de autosimilitud o patrones repetidos que están presentes en una señal en el dominio del tiempo (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 estos conceptos al caso de diagnóstico de fallos en motores eléctricos, la idea es que si hay una alteración en la señal medida debida a la presencia del fallo (aumento de amplitud de las frecuencias relacionadas con el fallo o características transitorias en la señal medida), la cual puede variar según la gravedad del daño, esta alteración puede caracterizarse mediante un índice fractal. Las dimensiones fractales de una señal en el dominio del tiempo pueden oscilar entre 1,0 para señales de DC (constantes) y 2,0 según la complejidad y la autosimilitud (Katz, 1988) de la señal. Según la literatura existente, 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 reducidos requisitos computacionales, la dimensión fractal de Katz resulta ser óptima para la implementación en procesadores para esquemas de cálculo en línea. La dimensión fractal de Katz mide la fractalidad de una señal de serie temporal x (con N número de muestras) 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 $k=1, \dots, N$).
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).

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



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 de algunas transformadas 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 frecuencia será pobre. Por otro lado, si la ventana es demasiado ancha, la localización en el tiempo será menos precisa. Esta limitación se convierte en un punto crítico y de gran relevancia cuando la señal bajo análisis tiene componentes transitorias localizadas en el tiempo, las cuales resultan frecuentes 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, la cual es calculado 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 tempo-frecuencial óptima. Por lo tanto, dado que la entropía basada en la transformada wavelet refleja el grado de orden / desorden de la señal, ésta puede proporcionar información adicional sobre el proceso dinámico subyacente asociado a 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). La idea se basa en combinar la información de todas las bandas cubiertas por las señales wavelet; los datos de señales wavelet adyacentes se toman y combinan en un índice para evitar enfocarse en una sola banda wavelet que tiene su propia resolución tiempo-frecuencia. La entropía wavelet total (S_{WT}) se define mediante 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 representan 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 de a partir del cómputo de la transformada wavelet discreta.

3.2 Análisis en estado transitorio.

Como se comentó en secciones anteriores, cuando un motor de inducción se encuentra operando bajo condiciones de avería (barras rotas, excentricidades, desalineamientos, fallos en los rodamientos, etc.), diversas magnitudes físicas del propio motor (corrientes de alimentación estatórica, vibraciones, temperaturas, flujo magnético del entrehierro, flujo magnético de dispersión, etc.) se ven afectadas, modificando así su comportamiento dinámico. En ciertas magnitudes (corrientes, flujos...), las variaciones en las mismas suelen verse reflejadas a través de la amplificación de determinadas frecuencias, las cuales suelen ser distintas dependiendo del fallo que esté presente (tal y como se vio en la Sección 2.2). Como se ha reportado en la literatura técnica, estas frecuencias están bien identificadas y fundamentadas, estando la mayoría de ellas ligadas al deslizamiento bajo el que opera el motor, en el caso de motores de inducción. Debido a esta relación entre las frecuencias amplificadas por un fallo y el deslizamiento en un motor de inducción, se espera que, cualquier operación transitoria del motor que haga variar el deslizamiento (arranque, variación de carga, transitorio de frenado, desconexión...), acabe afectando a las frecuencias de las componentes de fallo. De hecho, si la variación del deslizamiento durante el transitorio en cuestión es conocida, se podrá prever la evolución que seguirán las frecuencias de fallo durante el citado transitorio, ya que deslizamiento y frecuencia vienen relacionados por las expresiones mencionadas.

Tomando como base estas consideraciones, se han desarrollado durante los últimos años diversas metodologías de diagnóstico basadas en la aplicación de herramientas que son capaces de rastrear las evoluciones de las componentes de fallo en régimen transitorio. Es decir, estas herramientas permiten saber cómo varían estas frecuencias de fallo con el tiempo mientras se produce el transitorio en la máquina. Estas herramientas se denominan transformadas tiempo-frecuencia y permiten analizar una señal obteniendo como resultado una representación tiempo-frecuencial de la misma, lo cual permite no solamente identificar las componentes frecuenciales presentes en la señal, sino también cómo varían éstas con el tiempo.

A modo de ejemplo, si se considera un arranque directo de un motor de inducción (probablemente, el transitorio más conocido), es sabido que el deslizamiento (s) experimenta una variación muy característica durante el mismo; en efecto, s varía entre 1 (cuando se conecta la alimentación) hasta un valor cercano a 0 (una vez se alcanza el régimen permanente). Esta evolución tan característica del deslizamiento da lugar, a su vez, a evoluciones muy específicas de las componentes frecuenciales asociadas a cada fallo ya que, como se ha comentado, ambas (frecuencias de fallo y deslizamiento) vienen ligadas por las expresiones comentadas en la Sección 2.2. Una evolución muy conocida es la del armónico lateral inferior asociado al fallo en el

rotor, cuya frecuencia (en valor absoluto), dada por $f_{LSH} = |f \cdot (1 - 2 \cdot s)|$, desciende primero entre un valor de f (frecuencia de suministro) hasta cero (cuando $s=0.5$), ascendiendo posteriormente hasta alcanzar un valor cercano a f (cuando se alcanza el régimen permanente). Ello da lugar a un patrón característico en forma de V en el mapa tiempo frecuencia, que se ha mostrado muy fiable para la identificación de este armónico durante el transitorio y, por tanto, para el diagnóstico de este tipo de fallo (Antonino-Daviu et al., 2006).

En las siguientes secciones se revisan las herramientas tiempo-frecuencia que han sido principalmente empleadas en la literatura técnica del área para el análisis de magnitudes (especialmente de corrientes y flujo) en régimen transitorio.

3.2.1 Short Time Fourier Transform (STFT)

La Short Time Fourier Transform (STFT) 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). De este modo, 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. Una de las desventajas de la STFT es que la resolución de frecuencia es constante en todas las ventanas de tiempo, lo que limita su capacidad para analizar señales con componentes de frecuencia de alta y baja frecuencia simultáneamente.

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 (la cual puede ser del tipo ventana cuadrada, ventana Hamming, ventana Hanning, entre otras). L determina la separación de tiempo entre ventanas sucesivas.

La Figura 8 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 para cada de 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.

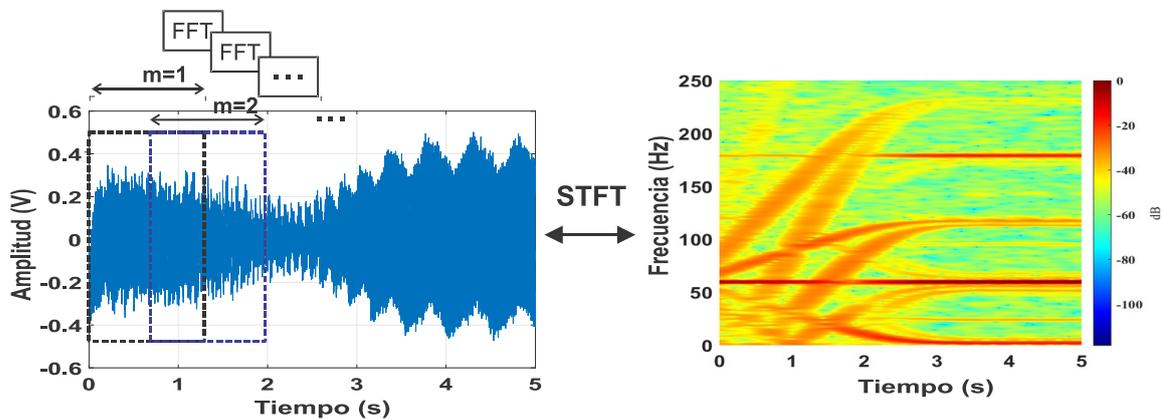


Figura 8. Short Time Fourier Transform con superposición de ventanas sucesivas de una señal en el dominio del tiempo.

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 introducida 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 sólo 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 en las que se tienen componentes frecuenciales adyacentes de gran amplitud, las cuales pueden encontrarse solapadas en caso de que no se tenga una buena resolución en frecuencia de la técnica empleada. De este modo, el uso de técnicas de alta resolución como MUSIC proporciona superficies más regulares, mitiga los efectos del ruido y evidencia sólo componentes de frecuencia más significativas, lo que la convierte en una herramienta útil para el análisis de señales con elevado nivel de ruido con frecuencias cambiantes en el tiempo ([Chavez et al., 2016](#)). Además, uno de los principales beneficios del algoritmo MUSIC es su capacidad para detectar componentes de baja amplitud en señales con alta relación señal/ruido, lo que lo hace especialmente adecuado para aplicaciones en las que la señal bajo análisis está sujeta a un alto nivel de ruido. Además, el algoritmo es capaz de proporcionar una alta resolución en frecuencia, lo que lo hace útil para analizar señales con componentes frecuenciales adyacentes de gran amplitud que pueden solaparse si no se dispone de una buena resolución en frecuencia. Por lo tanto, MUSIC es una herramienta útil para el análisis de señales con elevado nivel de ruido y frecuencias cambiantes en el tiempo.

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 \(1986\)](#):

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

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 senoide no son aleatorias ni desconocidas. Las fases de las senoideas 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 para 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 9.

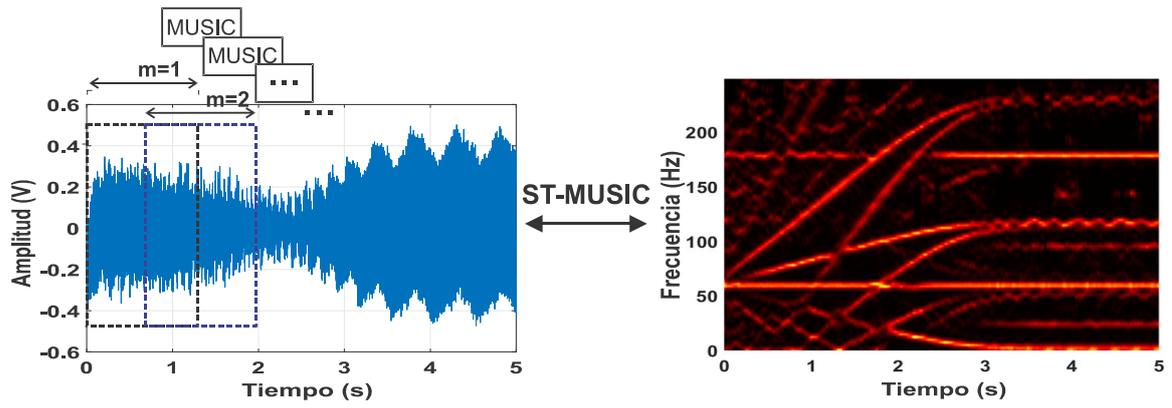


Figura 9. Transformada MUSIC de tiempo corto con superposición de ventanas sucesivas de una señal en el dominio del tiempo.

3.2.3 Transformada wavelet

Las wavelets (*ondículas*) 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 $\psi(x)$, denominada “wavelet madre”, que está confinada en un intervalo finito. Las “wavelets hija”, expresadas matemáticamente mediante la ecuación (2), se forman por la traslación (b) y la contracción (a) de ésta. De esta manera, la transformada wavelet, definida mediante la ecuación (3), 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 sólo 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 = Contracción, b = Traslación.

3.2.4 Transformada wavelet discreta (DWT).

La 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 *wavelets* se muestrean discretamente. Al igual que ocurre con otras transformadas wavelets, una ventaja clave que tiene sobre las transformadas de Fourier es la resolución temporal: la DWT captura tanto la información sobre el contenido en frecuencias como la ubicación (información temporal) de estas componentes frecuenciales utilizando, en este caso, técnicas de filtrado digital. Esto es, filtros de diferentes frecuencias de corte se utilizan para analizar la señal a diferentes escalas. Más específicamente, 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 paso alto a la señal de entrada x para extraer las componentes de alta frecuencia, y de manera simultánea, una serie de filtros paso bajo para extraer las componentes de baja frecuencia. Los coeficientes de dichos filtros son determinados mediante la selección de una wavelet madre, que se elige según las características de la señal a analizar, las cuales están frecuentemente ligadas a la aplicación en cuestión. En primer lugar, la señal muestreada x se pasa a través de un filtro paso alto con respuesta de impulso $h[n]$ y que tiene 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 paso bajo $g[n]$ 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 dan como resultado los coeficientes de detalle ($D[n]$, filtro paso alto) y los coeficientes de aproximación ($A[n]$, filtro paso bajo), respectivamente. Se debe tener en cuenta que dichos filtros deben estar relacionados, y deben 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 el criterio de Nyquist. La salida del filtro paso bajo $A[n]$ se submuestra por 2 y se procesa nuevamente aplicando el filtro paso bajo $g[n]$ y un filtro paso alto $h[n]$ con la mitad de la frecuencia de corte de la anterior como se

muestra en la Figura 10. Esta descomposición reduce a la mitad la resolución temporal, ya que sólo la mitad de cada salida de filtro caracteriza la señal. Sin embargo, cada salida tiene la mitad de la banda de frecuencia de la señal de entrada, por lo que la resolución en frecuencia se duplica.

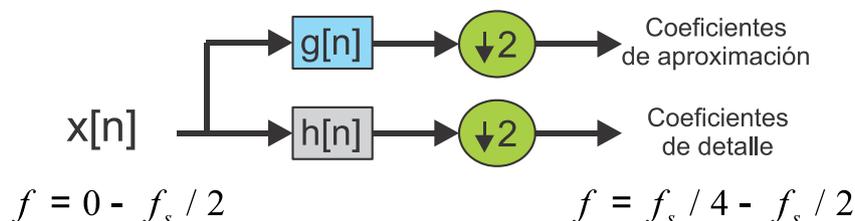


Figura 10. Diagrama a bloques del análisis de filtros desarrollado en la DWT.

Dicha descomposición se repite para aumentar aún más la resolución en frecuencia, y los coeficientes de aproximación anteriormente descompuestos con filtros paso alto y paso bajo son diezmados (submuestreados). Este proceso se puede representar mediante un árbol binario con nodos que representan un subespacio con una localización de tiempo-frecuencia diferente tal y como se observa en la Figura 11, 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. Al filtrado representado en la Figura 11 se le suele denominar diádico, ya que las bandas frecuenciales asociadas a las señales de detalle siempre se van dividiendo por 2 en cada etapa.

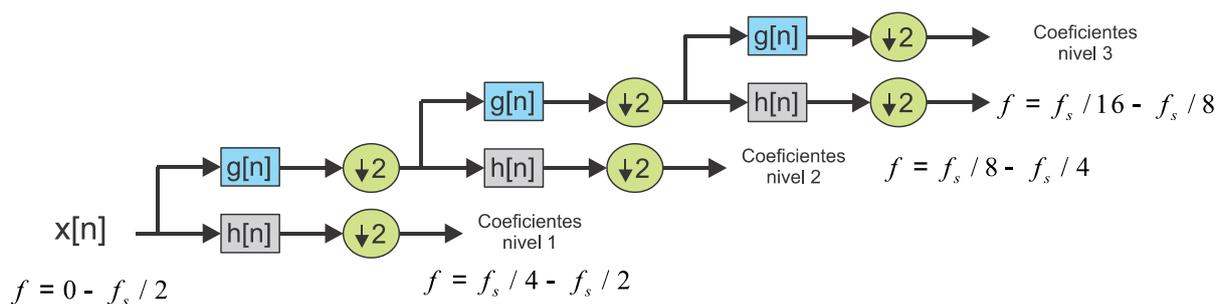


Figura 11. Diagrama a bloques de banco de filtros de 3 niveles.

3.2.5 Principio de incertidumbre en la transformada wavelet.

Conviene destacar que la resolución en tiempo y en frecuencia es diferente en el plano tiempo-frecuencia en una transformada wavelet, o lo que es lo mismo, 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 (inversamente, la resolución en frecuencias es baja a altas frecuencias). 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 12 muestra esta idea. En esta figura, se puede observar con claridad la distribución de la resolución obtenida mediante la transformada wavelet, tanto en dimensión temporal como frecuencial. De este modo, para bajas frecuencias, la resolución frecuencial es buena, pero ocurre lo contrario con la temporal. Por el contrario, a mayor frecuencia de análisis, la localización en el tiempo de ese contenido frecuencial es más precisa mayor (peor resolución temporal), sin embargo, el ancho de banda es mayor (peor resolución frecuencial).

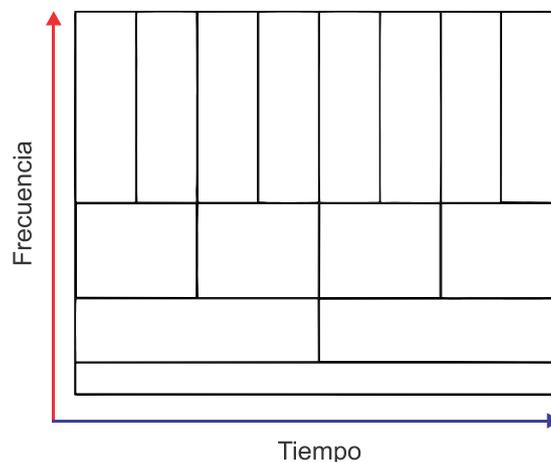


Figura 12. Resolución en tiempo y frecuencia para diferentes zonas del mapa tiempo-frecuencia.

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 paso bajo $g[n]$ y los coeficientes de filtro paso alto $h[n]$ para poder aplicar la operación de convolución a la señal bajo análisis x . Se debe de tener en cuenta que dichos filtros debee estar relacionados, y deben de cumplir con las características de un filtro de espejo en cuadratura. De este modo, existen diversas familias de filtros que cumplen con estas características, pero cada uno de ellos tiene una respuesta distinta, por lo que es de suma importancia elegir la familia wavelet más adecuada dependiendo la aplicación, para poder así obtener resultados significativos. Algunos de los criterios que se deben de tomar en 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 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 dada 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 o Coiflet. La Figura 13 muestra los filtros de paso bajo y de paso alto para las familias de wavelet madre anteriormente mencionadas.

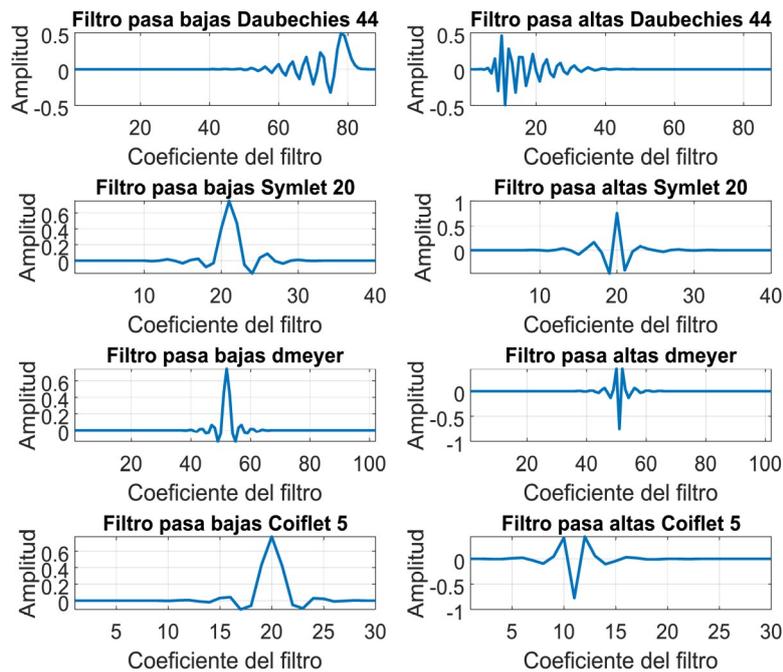


Figura 13. Coeficientes de filtro para distintas familias wavelet.

Es común aplicar la familia Daubechies en el análisis de tendencias. Por otro lado, es recomendable realizar el cómputo de la transformada wavelet discreta empleando una wavelet madre de orden superior, es decir, en la que el filtro asociado tenga un elevado número de coeficientes, puesto que el filtrado suele ser menos ideal si el número de coeficientes es bajo. Esto se traduce en que existe la posibilidad de un solape entre bandas adyacentes (Antonino-Daviu et al., 2006) empeorando la respuesta en frecuencia, 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 paso bajo (Lo_R) y paso alto (Hi_R) como se muestra en la Figura 14.

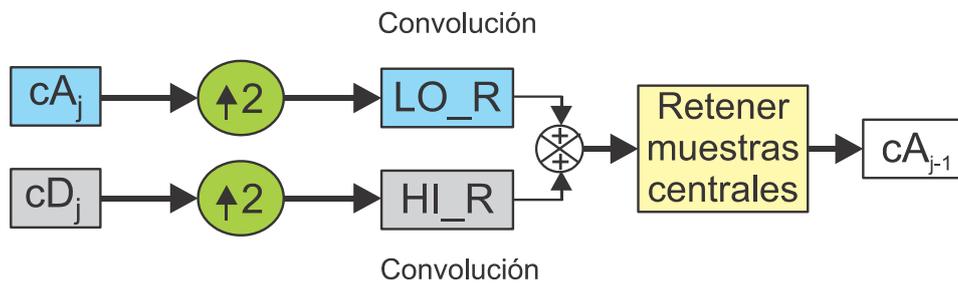


Figura 14. Diagrama de bloques transformada wavelet discreta inversa.

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 paso de preprocesamiento para aplicaciones de aprendizaje automático y clasificación de patrones. El objetivo principal de esta técnica 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 permite 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 otras (Saucedo-Dorantes et al., 2016). El procedimiento para desarrollar el 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 forme 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 minimice 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. De esta forma, 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 fallos complejos sin la necesidad de tener un gran conocimiento del proceso, las señales usadas o los propios patrones de los fallos. En este sentido, 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. Se requiere poco o ningún conocimiento del proceso para el uso de redes neuronales. Una ventaja especial es que no se requiere conocimiento sobre patrones de fallos.
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 supone una carga muy reducida. 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 15a, 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 15b. 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.

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

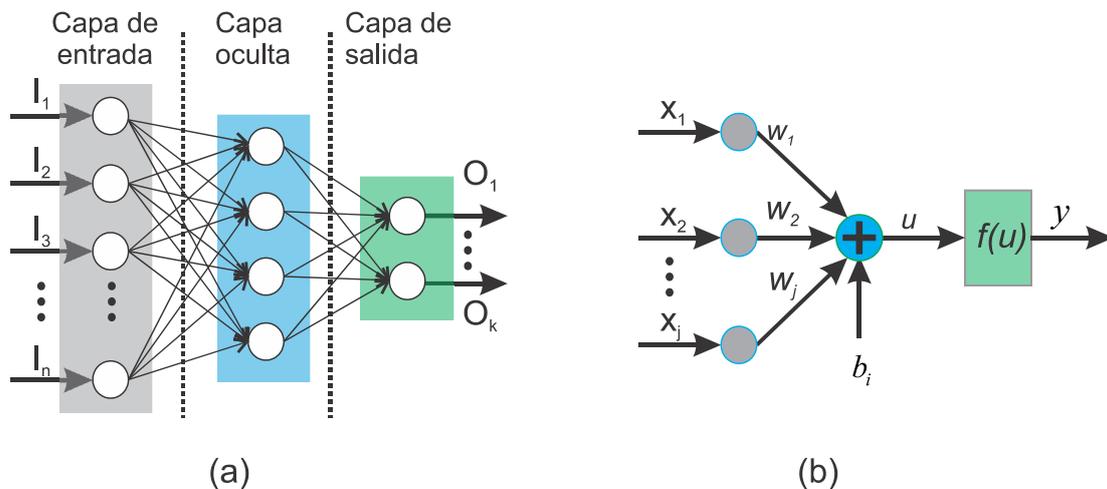


Figura 15. Red neuronal artificial: (a) arquitectura de red neuronal feed-forward (FFNN); (b) estructura funcional de una neurona.

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 recogen en la Tabla 5.

Tabla 5. 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 del régimen permanente.

Como se ha reportado en la literatura, algunos de los fallos más comunes en los motores eléctricos de inducción se ven reflejados en diferentes señales de la propia máquina (vibración, corriente estática, flujo, 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 causado por la evolución de la componente frecuencial amplificada debido a algún fallo específico durante el citado transitorio (a medida que el deslizamiento s varía durante el arranque). La identificación de estos patrones permite determinar, con cierto grado de certidumbre, el estado del motor bajo análisis, permitiendo así distinguir cuando el motor se encuentra operando bajo una avería. En este contexto, para metodologías en las que se requiere realizar un diagnóstico automático, resulta imprescindible identificar y, en su caso, aislar de forma automática la parte de la señal correspondiente al transitorio de arranque, separándola de aquella correspondiente al régimen permanente. Para estos fines, en la presente tesis se propone un método simple para aislar el transitorio de arranque mediante un algoritmo sencillo, que no demanda mucha carga computacional. Este algoritmo se basa en los siguientes pasos:

1. Obtener la envolvente superior de la señal en el dominio del tiempo, como se muestra en la Figura 16. Para ello se puede seguir el procedimiento propuesto por Jarne (2018).

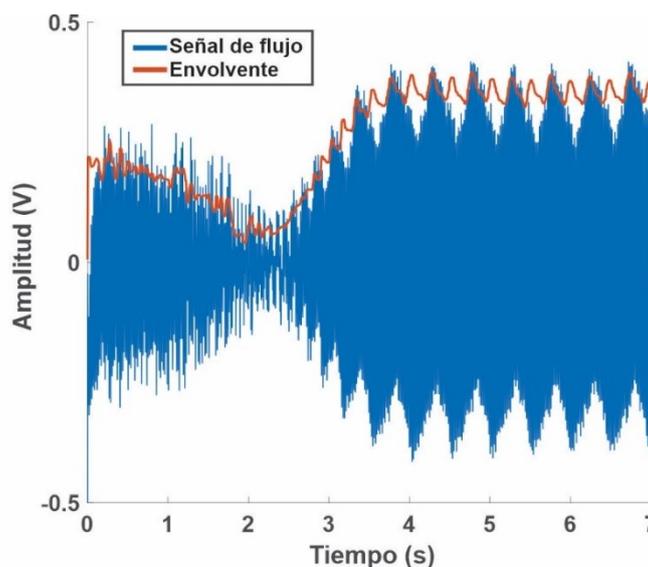


Figura 16. Obtención de envolvente superior de señal en el dominio del tiempo.

2. Establecer un valor límite (obtenido a través de las últimas muestras) igual al promedio de la amplitud de la envolvente en régimen permanente. La proyección de la intersección de este valor límite con la envolvente sobre el eje del tiempo será prácticamente el final del transitorio de arranque. Este hecho se puede observar en la Figura 17.

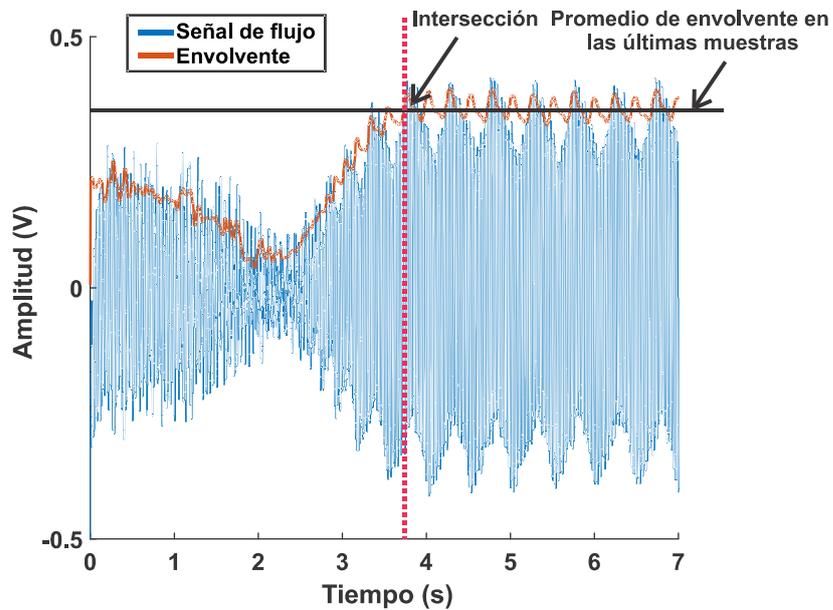


Figura 17. Obtención de transitorio de arranque a partir de la envolvente de la señal en el tiempo.

4. ANÁLISIS DEL FLUJO MAGNÉTICO DE DISPERSIÓN PARA LA MONITORIZACIÓN DE LA CONDICIÓN DE MOTORES ELÉCTRICOS

El flujo magnético de dispersión que está presente alrededor de un motor de inducción durante la operación del mismo es un efecto residual e indeseable, debido a que este flujo no contribuye al proceso de generación de par útil. Este flujo de dispersión es producido por las corrientes circulantes por los devanados del estator y de rotor (Bellini et al., 2006). Estas corrientes (y, por lo tanto, el flujo de dispersión) se ven afectadas cuando el motor eléctrico funciona bajo ciertas anomalías o averías. Según lo reportado por Romary et al. (2009), el flujo de dispersión se puede analizar a través de sus dos componentes principales: flujo de dispersión axial y flujo de dispersión radial. De acuerdo a lo reportado en la literatura, es posible capturar por separado las componentes de flujo de dispersión axial y radial e incluso la combinación de ambas (flujo combinado) instalando sensores adecuados en posiciones específicas sobre la carcasa del motor. La Figura 18 muestra la distribución de las líneas de campo para el flujo radial y para el flujo axial (Romary et al., 2009), así como las posibles posiciones en las que se pueden instalar sensores basados en bobinas para capturar cada porción de flujo. El flujo de dispersión axial se puede adquirir instalando un sensor ubicado en la posición A de la Figura 18. Por su parte, es posible adquirir la porción de flujo radial mediante la instalación de un sensor adecuado ubicado en la posición C mostrada en la Figura 18. Finalmente, si se instala un sensor como en la posición B mostrada en la Figura 18 se captura la combinación del flujo de dispersión axial y radial.

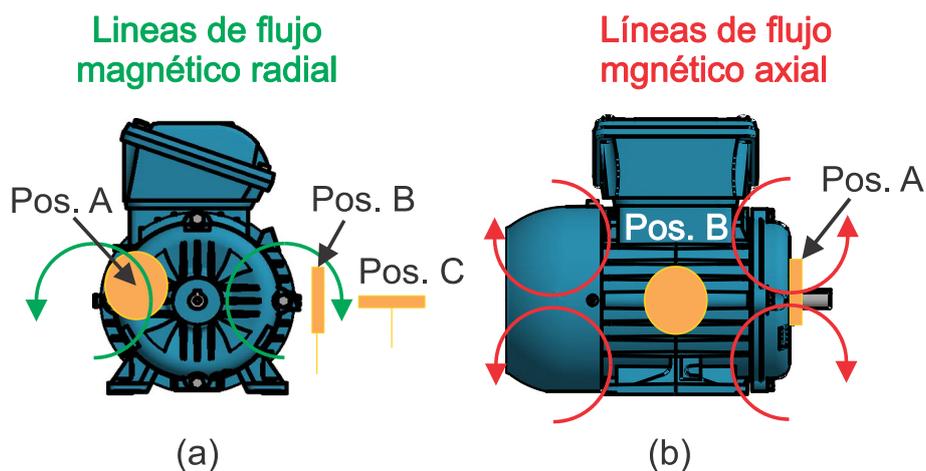


Figura 18. Componentes del flujo magnético de dispersión: (a) flujo de dispersión radial; (b) flujo de dispersión axial.



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). De este modo, en una máquina simétrica sana, las corrientes del estator y del rotor están equilibradas y no se produciría distorsión alguna en el flujo de dispersión circundante. Por el contrario, cuando existe algún fallo o daño en algún componente del motor eléctrico bajo análisis (como por ejemplo una avería en el rotor), éste puede conllevar una asimetría, la cual provoca una distorsión en dicho flujo, que se traduce en la amplificación de componentes frecuenciales específicas y que se encuentran asociadas a la avería. La detección de estas componentes y su evaluación es la base de las técnicas de diagnóstico basadas en el análisis del flujo magnético de dispersión.

4.1 Componentes frecuenciales amplificadas en señales de flujo magnético de dispersión debido a fallos en motores de inducción.

El análisis del flujo magnético ha demostrado ser una técnica valiosa y efectiva para la detección de fallas en máquinas eléctricas, y se ha comparado favorablemente con otros métodos establecidos. Al enfocarse en la detección y monitoreo de las amplitudes de componentes frecuenciales específicos que se ven afectados por una falla en particular, se pueden identificar y diagnosticar las averías en las máquinas eléctricas. Es fundamental conocer y estimar las frecuencias específicas de falla para una detección efectiva. En consecuencia, la identificación y comprensión de las diferentes averías que pueden surgir en los motores eléctricos de inducción, junto con las correspondientes componentes frecuenciales, son cruciales para la aplicación y entendimiento del análisis del flujo magnético.

En la siguiente sección, se proporcionará un resumen de las diversas averías comunes que pueden surgir en los motores eléctricos de inducción, así como las expresiones matemáticas que permiten estimar el valor de la frecuencia asociada con cada avería en señales de flujo magnético de dispersión. Este conocimiento es esencial para la aplicación exitosa del análisis del flujo magnético para la detección de fallas en máquinas eléctricas y proporciona un marco de referencia indicativo de variaciones en las señales del flujo magnético de dispersión en caso de alguna avería en específico.

4.1.1 Componentes frecuenciales relacionadas a barras de rotor rotas.

Varios estudios han destacado el potencial del análisis de flujo magnético para detectar fallas de rotor en motores de inducción de jaula de ardilla. Estas investigaciones, incluyendo (Capolino et al., 2013; Antonino-Daviu et al., 2017; Soleimani et al., 2018), han demostrado que una falla en el rotor puede causar una asimetría en la distribución del campo magnético giratorio. Se sabe que las barras de rotor rotas generan bandas laterales de la frecuencia de la fuente de alimentación (f_s) en el flujo de entrehierro radial, como se demuestra en (Lee et al., 2020). La ecuación (55) expresa las componentes frecuenciales amplificadas en las señales de flujo magnético de dispersión radial debido a barras de rotor rotas en motores de inducción.

$$f_{flux} = f_s \pm k \cdot f_r = f_s \cdot \left(1 + k \cdot \frac{(1-s)}{p} \right) \quad (55)$$

Además de generar bandas laterales de la frecuencia de la fuente de alimentación en el flujo de entrehierro radial, también se ha encontrado que las fallas de barras de rotor rotas producen bandas laterales del doble de la frecuencia de deslizamiento en el flujo de dispersión radial. Esta observación se ha realizado en varios estudios, incluidos (Romary et al., 2013; Goktas et al., 2017). Los componentes de frecuencia generados en el flujo de dispersión radial debido a fallas de barras de rotor rotas están dados por la ecuación (56). Específicamente, las frecuencias de la banda lateral son el doble de la frecuencia de deslizamiento ($s \cdot f_s$) sumadas y restadas de la frecuencia de la fuente de alimentación. Por lo tanto, las componentes de frecuencia de flujo magnético radial debidas a barras rotas se pueden expresar de la siguiente manera:

$$f_{BRB(radial)} = \begin{cases} f_s \cdot (1 \pm 2 \cdot k \cdot s) \\ f_s \pm f_r \pm 2 \cdot k \cdot s \cdot f_s \end{cases} \quad (56)$$

En general, la detección de estos componentes de frecuencia adicionales ha mejorado la precisión y la confiabilidad del diagnóstico de fallas mediante el análisis de flujo magnético.

Además de la generación de bandas laterales de la frecuencia de la fuente de alimentación y el doble de la frecuencia de deslizamiento en el flujo radial, se ha encontrado que las fallas del rotor en motores de inducción amplifican los componentes de la frecuencia de deslizamiento en el flujo axial, como se informó en (Ceban et al., 2012; Ramirez-Nunez et al., 2018). Las componentes de la frecuencia de deslizamiento en el flujo axial vienen dadas por la ecuación (57), que se expresa de la siguiente manera:

$$f_{BRB(axial)} = \begin{cases} s \cdot f_s \\ 3 \cdot s \cdot f_s \end{cases} \quad (57)$$

En general, la combinación de análisis de flujo radial y axial puede mejorar significativamente la precisión y la eficacia de la detección de fallas del rotor en motores de inducción. Estas técnicas se han adoptado ampliamente en aplicaciones

industriales, lo que permite la detección y el diagnóstico tempranos de fallas en el rotor.

4.1.2 Componentes frecuenciales relacionadas a cortocircuitos entre espiras.

Los cortocircuitos entre espiras del estator son un tipo frecuente de falla en los motores eléctricos que pueden provocar el apagado repentino de la máquina y se consideran particularmente peligrosos. La degradación del sistema de aislamiento, debido a causas como el sobrecalentamiento, la vibración y las duras condiciones ambientales, puede provocar la aparición de cortocircuitos entre espiras.

El estudio realizado por [Henao et al. \(2003\)](#) investigó el impacto de las fallas del estator en la generación de armónicos espaciales de fuerza magnetomotriz. La fórmula para calcular las componentes frecuenciales amplificadas por estos armónicos viene dada por (58).

$$f_{\text{cortocircuito}} = k_{\text{impar}} \cdot f_s \pm n \cdot f_r \quad (58)$$

Donde k_{impar} es un entero impar y n es un entero diferente de $6 \cdot j \pm 1$ (j es un número entero).

4.1.3 Componentes frecuenciales relacionadas a fallas mecánicas.

El análisis del flujo magnético de dispersión ha mostrado potencial para identificar fallas mecánicas en varias máquinas eléctricas, incluidas fallas de excentricidad. [Vitek et al. \(2011\)](#) han demostrado que la excentricidad dinámica produce bandas laterales f_r de f_s en el espectro de Fourier de señales de flujo magnético de dispersión dadas por la ecuación (55).

$$f_{\text{ecc}(\text{flux})} = f_s \pm k \cdot f_r = f_s \cdot \left(1 + k \cdot \frac{(1-s)}{p} \right) \quad (55)$$

Otros estudios, como los presentados en ([Chernyavskaen et al., 2017](#)), han investigado frecuencias relacionadas con el efecto de ranurado para diagnosticar

fallas de excentricidad dinámicas y estáticas a través de señales de flujo magnético, obteniendo la expresión (59) que permite estimar dichas frecuencias de fallo.

$$f_{ecc2(flux)} = f_s \pm (k \cdot N_r \cdot \pm n_d) \cdot f_r \quad (59)$$

donde N_r es el número de ranuras del rotor, $n_d=0$ para la excentricidad estática y $n_d=1,2,3$ para la excentricidad dinámica. En algunos casos, la frecuencia $s \cdot f_s$ con valores bajos de amplitud puede estar presente en máquinas consideradas perfectas debido a los procesos de fabricación, como se señala en (Ceban et al., 2008).

Con respecto a las fallas por desalineación, entre otros estudios (Ramirez-Nunez et al., 2008; Park et al., 2020; Pastor-Osorio et al., 2020), han demostrado que las bandas laterales f_r de f_s en las señales de flujo magnético de dispersión radial, dadas por la ecuación (60) son sensibles a las desalineaciones.

$$f_{desb} = f_s \pm k \cdot f_r \quad (60)$$

Con respecto a la detección de fallas en rodamientos, diversas investigaciones han demostrado la presencia y amplificación de componentes frecuenciales específicas en señales de flujo magnético de dispersión (Vitek et al., 2011). Así entonces, mediante el análisis de los componentes armónicos, es posible identificar el tipo de falla, como un defecto en la pista exterior, la pista interior, la bola o la jaula. Un parámetro crucial para identificar el tipo de falla del rodamiento es la frecuencia de la vibración asociada con la falla, que se denota como f_v , y que depende de la localización del defecto: pista exterior, pista interior, bola o jaula, de acuerdo a las ecuaciones (62) a (65), respectivamente. La expresión matemática para estimar las frecuencias de las componentes amplificadas por estos armónicos viene dada por (61).

$$f_{bng} = |f_s \pm k \cdot f_v| \quad (61)$$

$$f_o = f_r \frac{N_b}{2} \left(1 - \frac{D_b \cdot \cos(\phi)}{D_p} \right) \quad (62)$$

$$f_i = f_r \frac{N_b}{2} \left(1 + \frac{D_b \cdot \cos(\phi)}{D_p} \right) \quad (63)$$

$$f_B = f_r \frac{D_p}{D_b} \left(1 + \frac{D_b^2 \cdot \cos^2(\phi)}{D_p^2} \right) \quad (64)$$

$$f_C = f_r \frac{D_b}{2} \left(1 \pm \frac{D_b \cdot \cos(\phi)}{D_p} \right) \quad (65)$$

donde f_r es la velocidad del rotor, N_b el número de bolas, D_b es el diámetro de la bola, D_p es el diámetro de paso de la bola, y ϕ el ángulo de contacto.

La fórmula (61) indica que los componentes de frecuencia de las señales de flujo magnético de dispersión son similares a los que se encuentran en las señales de corriente, que se pueden utilizar para detectar fallas en los rodamientos. A pesar de la baja amplitud de estos componentes armónicos en las señales de flujo magnético de dispersión, su existencia es evidencia, que fallas en los rodamientos generan un cambio en el comportamiento dinámico en estas señales. En consecuencia, es vital examinar las señales de flujo magnético de dispersión con diligencia para detectar cualquier componente armónico que pueda sugerir la presencia de fallas en los rodamientos.

Por otra parte, en otros trabajos de investigación como ([Rastegar et al., 2008](#); [Fatemi et al., 2008](#)), los investigadores han examinado las frecuencias que se amplifican por fallas relacionadas con las cajas de engranajes. En estos trabajos se ha demostrado que las frecuencias asociadas con fallas en los engranajes dependen de la cantidad de dientes en la caja de engranajes y pueden identificarse en el espectro del flujo magnético de dispersión. Estas frecuencias vienen dadas por la siguiente ecuación (66):

$$f_{gear} = \left| f_s \pm (N_d \pm k_{gear}) \cdot f_r \right| \quad (66)$$

donde, N_d es el número de dientes en la caja de engranajes y k_{gear} puede tomar valores de 0, 1, 2, etc.

4.1.4 Resumen de componentes frecuenciales amplificadas debido a fallos en señales de flujo magnético.

Debido a que las fallas en los motores eléctricos pueden ocurrir en diferentes partes del mismo, se han identificado varias componentes de frecuencia que están asociadas con fallas específicas. Estas componentes se han determinado a través del análisis de las frecuencias amplificadas en caso de fallas en los motores eléctricos, específicamente en el flujo magnético de dispersión. En resumen, la Tabla 6 presenta algunas de las expresiones matemáticas más comunes que se utilizan para estimar las frecuencias amplificadas en caso de fallas en motores eléctricos y proporciona una guía general para interpretar estas frecuencias y sus causas.

Tabla 6. Principales componentes de frecuencia amplificados por distintas fallas en las señales de corriente.

Origen	Componentes frecuenciales amplificadas
Fallas en el rotor	$f_{flux} = f_s \pm k \cdot f_r = f_s \cdot \left(1 + k \cdot \frac{(1-s)}{p} \right)$ $f_{BRB(radial)} = \begin{cases} f_s \cdot (1 \pm 2 \cdot k \cdot s) \\ f_s + f_r \pm 2 \cdot k \cdot s \cdot f_s \end{cases}$ $f_{BRB(axial)} = \begin{cases} s \cdot f_s \\ 3 \cdot s \cdot f_s \end{cases}$
Cortocircuitos entre espiras	$f_{cortocircuito} = k_{impar} \cdot f_s \pm n \cdot f_r$
Excentricidades/desalineaciones	$f_{ecc(flux)} = f_s \pm k \cdot f_r = f_s \cdot \left(1 + k \cdot \frac{(1-s)}{p} \right)$ $f_{ecc2(flux)} = f_s \pm (k \cdot N_r \pm n_d) \cdot f_r$
Pista exterior del rodamiento	$f_o = f_s \pm k \frac{N}{2} \cdot f_r \left(1 - \frac{D_b}{D_c} \cos(\beta) \right)$
Pista interior del rodamiento	$f_i = f_s \pm k \frac{N}{2} \cdot f_r \left(1 + \frac{D_b}{D_c} \cos(\beta) \right)$



Falla de bola de rodamiento	$f_B = f_s \pm \frac{D_p}{D_b} \cdot f_r \left(1 - \frac{D_b^2}{D_c^2} \cos(\beta)^2 \right)$
Falla de la jaula en rodamiento	$f_C = f_s \pm \frac{f_r}{2} \left(1 \pm \frac{D_b}{D_c} \cos(\beta) \right)$
Averías relacionadas con la caja de cambios	$f_{gear} = \left f_s \pm (N_d \pm k_{gear}) \cdot f_r \right $
<p>Donde f_s = la frecuencia de la fuente de alimentación, f_r = la velocidad de rotación del rotor, k: número entero (= 1, 2, 3, ...), N: número de rodamientos, k_{odd} es un número entero impar, n es un número entero diferente de $6 \cdot j \pm 1$ (j es un número entero), N_r es el número de ranuras del rotor, $n_d = 0$ para la excentricidad estática y $n_d = 1, 2, 3$ para la excentricidad dinámica.</p>	



4.1.5 Evolución de componentes de falla durante el transitorio de arranque.

Como se revisó en secciones anteriores, los métodos que se basan en el análisis del flujo magnético de dispersión se apoyan en la idea de que la presencia de ciertos fallos en diversas máquinas eléctricas puede modificar el flujo magnético alrededor de ellas (según [Ceban Ceban et al., 2012](#); [Henaó et al., 2003](#); [Penman et al., 1994](#)). Si la máquina eléctrica es simétrica y está en buen estado, las corrientes del estator y del rotor están equilibradas, lo que significa que no habría ninguna distorsión en el flujo de dispersión cercano. Sin embargo, si hay algún fallo o daño en algún componente del motor eléctrico que se está analizando, como una avería en el rotor, esto puede causar una asimetría y, por lo tanto, una distorsión en el flujo. Esta distorsión se traduce en la amplificación de componentes de frecuencia específicas que están asociadas con la avería, mismas que guardan una relación estrecha con el nivel de deslizamiento del motor. Lo anterior sugiere que, estados transitorios del motor darán lugar a la modificación de las frecuencias de falla. En este sentido, es de particular interés el transitorio de arranque, ya que durante este transitorio el deslizamiento (s) experimenta una variación muy característica durante el mismo; s varía entre 1 (cuando se conecta la alimentación) hasta un valor cercano a 0 (una vez se alcanza el régimen permanente) siguiendo una trayectoria particular. Por ejemplo, si hay una barra de rotor rota, el componente de falla aparecerá como una frecuencia distinta en el mapa de tiempo-frecuencia que evoluciona en un patrón específico, típicamente con bandas laterales que aparecen en la frecuencia de rotación y sus armónicos. De manera similar, si existe una excentricidad del entrehierro, la componente de falla aparecerá como una modulación de la frecuencia fundamental, con bandas laterales en múltiplos de la frecuencia rotacional. Al analizar la evolución del patrón de las frecuencias relacionadas con fallas en el mapa de tiempo-frecuencia, es posible identificar el tipo de falla. Por lo tanto, el análisis transitorio es una herramienta poderosa para detectar fallas en motores de inducción, ya que puede proporcionar información valiosa sobre la condición del motor.

Con el fin de explicar con mayor claridad la idea central de las metodologías basadas en el análisis tiempo-frecuencia de los armónicos amplificados debido a fallas en motores eléctricos de inducción en señales de flujo magnético de dispersión, se presenta un ejemplo teórico que ilustra los patrones producidos por fallas de asimetría en motores de inducción de rotor bobinado. En este caso, se debe tener en cuenta que la asimetría del rotor en los motores de inducción de rotor bobinado produce la amplificación de frecuencias específicas relacionadas con el deslizamiento del motor, como se muestra en la sección 4.1.1 del presente trabajo

de tesis. Por lo tanto, mediante la ecuación (55) dada (que se muestra a continuación con fines prácticos), es posible estimar estas frecuencias.

$$f_{flux} = f_s \pm k \cdot f_r = f_s \cdot \left(1 + k \cdot \frac{(1-s)}{p} \right) \quad (55)$$

Como puede apreciarse a partir de dicha ecuación, en el caso 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 19 muestra la trayectoria teórica seguida por dichas familias de armónicos de fallo, y que se describen a continuación:

- Componentes radiales: dados por la expresión (55). Estos corresponden a una familia de armónicos amplificados por la asimetría del devanado del rotor en motores de inducción de rotor bobinado. Para cada valor de k/p , la expresión (55) 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., $f(3-4 \cdot s)$, $f(5-6 \cdot s)$, $f(7-8 \cdot s)$, 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., $f(3-2 \cdot s)$, $f(5-4 \cdot s)$, $f(7-6 \cdot s)$, 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 19.
- Componentes de frecuencia de rotación: componentes en $f \pm fr$, que se ven amplificados 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 ($f + f_r$ o $f - f_r$, respectivamente), como se muestra en la Figura 19.

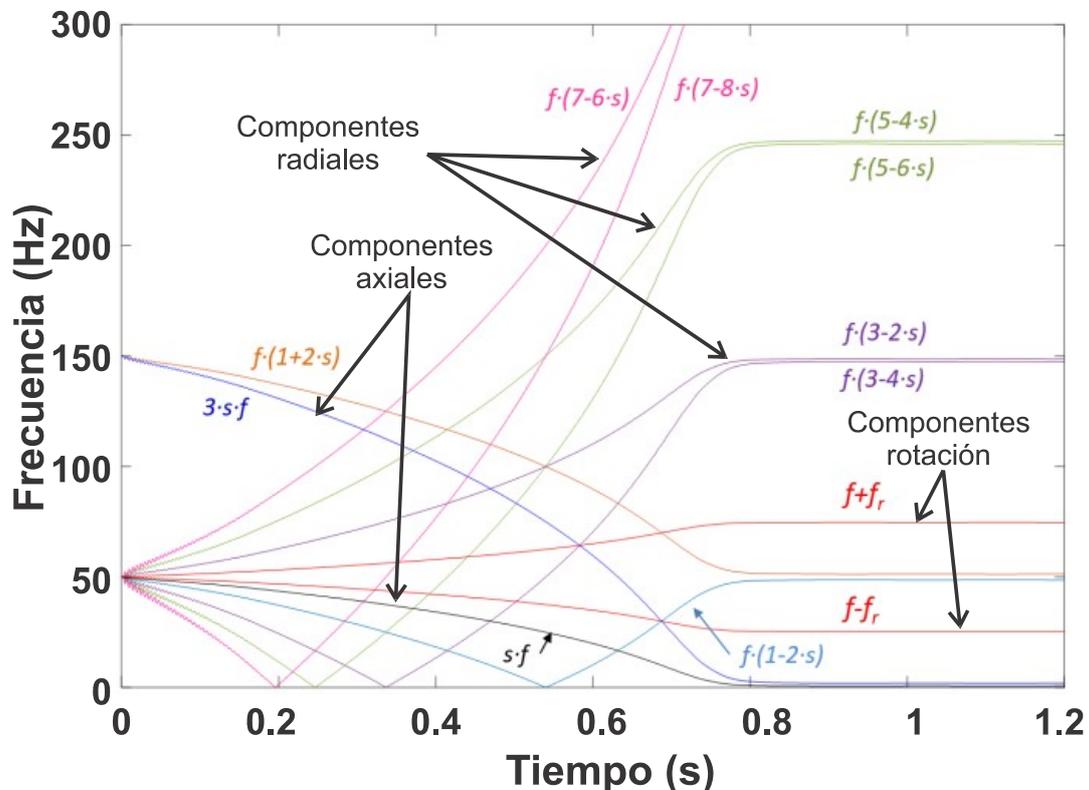


Figura 19. Evoluciones teóricas de los componentes amplificados por las asimetrías del rotor durante un transitorio de arranque simulado en un motor de inducción.

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.

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

4.2.1 Sensores de bobina para capturar flujo magnético.

Los sensores basados en bobinas son comúnmente empleados en el área del diagnóstico basado en análisis de flujo. Por lo general, tienen formas circulares y están formados por hilos de cobre (con o sin núcleo ferromagnético), teniendo un bajo número de vueltas (comúnmente, entre 10 y 3000 dependiendo de la aplicación - medición de flujo magnético de dispersión o entrehierro) y dimensiones variables (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, del diámetro del sensor, así como del tipo de núcleo sobre la señal de flujo magnético capturada. En estos trabajos se demuestra 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 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 fallos, mientras que se obtiene una tensión inducida de amplitud significativamente mayor para la misma cantidad de flujo magnético de dispersión (una característica importante en aplicaciones con elevado ruido). Esta situación revela que los sensores de flujo con núcleo de hierro parecen ofrecer ventajas respecto a los sensores con núcleo de aire cuando se adquieren señales de flujo de dispersión.

Las principales limitaciones de los sensores basados en bobinas cuando se emplean con fines de diagnóstico de fallos en motores de inducción son los 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 del flujo

magnético de dispersión en un motor de inducción. Como se puede observar en dicha figura, se requieren tres sensores distintos instalados en diferentes posiciones del motor para poder capturar de forma simultánea las diferentes componentes de flujo magnético (axial, radial y combinado). 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 de que puede resultar complejo tener acceso a todas las posiciones del motor.

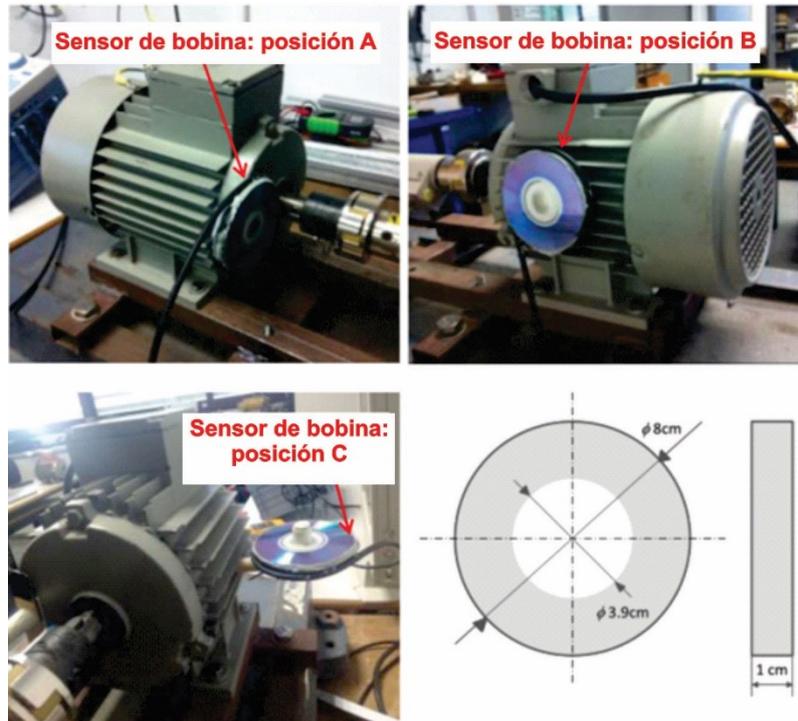


Figura 20. Posiciones alternativas de instalación de sensores tipo bobina para capturar las diferentes componentes del flujo magnético de dispersión en un motor de inducción (Ramirez-Nunez et al., 2018).

4.2.2 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, se induce una tensión 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 fallos 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 coste en tiendas de electrónica, siendo el modelo DRV425 de la marca Texas Instrument uno de los comúnmente empleados. Sus características principales, como 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, combinadas 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 coste a nivel del sistema. La Figura 22 muestra una imagen de dicho dispositivo.

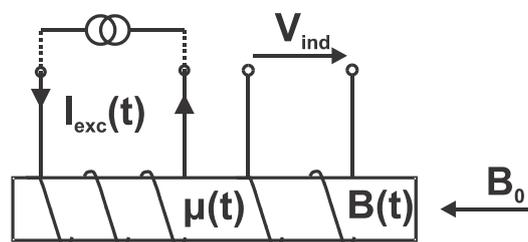


Figura 21. Configuración básica de un sensor tipo fluxgate.

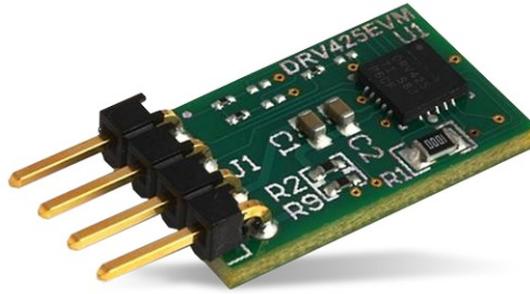


Figura 22. Foto de sensor fluxgate comercial modelo DRV425 de Texas Instrument.

4.2.3 Sensores de efecto Hall

Los sensores de efecto Hall se han utilizado e instalado ampliamente en numerosas máquinas eléctricas para el control de movimiento, estimación de la posición inicial del rotor y detección y diagnóstico de averías. Los sensores de efecto Hall son dispositivos de bajo coste y reducido tamaño (lo que permite instalarlos en lugares con espacio limitado). Tienen la capacidad de adquirir flujos magnéticos constantes y variables con medidas absolutas y lineales en un rango 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 del entorno puede perturbar fácilmente las mediciones, aunque estos efectos pueden disminuirse o anularse mediante el uso de circuitos electrónicos adecuados.

4.3 Sensor triaxial propuesto

Debido a las limitaciones encontradas en los sensores convencionales (que son los normalmente 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 en un solo punto en la carcasa del motor bajo análisis. En este sentido, el sensor triaxial propuesto se basa esencialmente en 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, y que tienen una sensibilidad de 5 mV/G. Este sensor mide 3,02 mm de ancho y 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 la respectiva ficha técnica. Los sensores primarios están ubicados en ejes perpendiculares entre sí, con el fin de capturar las componentes del flujo de dispersión axial, radial y la combinación de axial y radial, independientemente de su ubicación respecto a la estructura del motor. La Figura 23b muestra una vista esquemática del sensor de flujo de dispersión triaxial propuesto. 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. Equivalentemente, 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 de la carcasa de la máquina, de forma que se pueden siempre capturar las diferentes componentes del flujo magnético de dispersión.

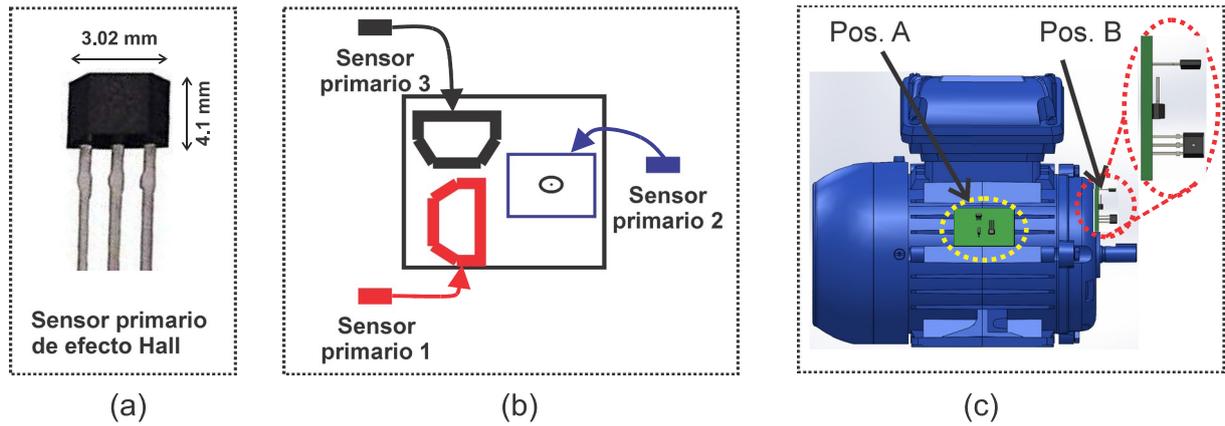


Figura 23. Sensor de flujo magnético de dispersión triaxial propuesto: (a) sensor primario de efecto Hall; (b) composición del sensor de flujo magnético de dispersión triaxial; (c) instalación del sensor de flujo magnético de dispersión triaxial.

4.4 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.

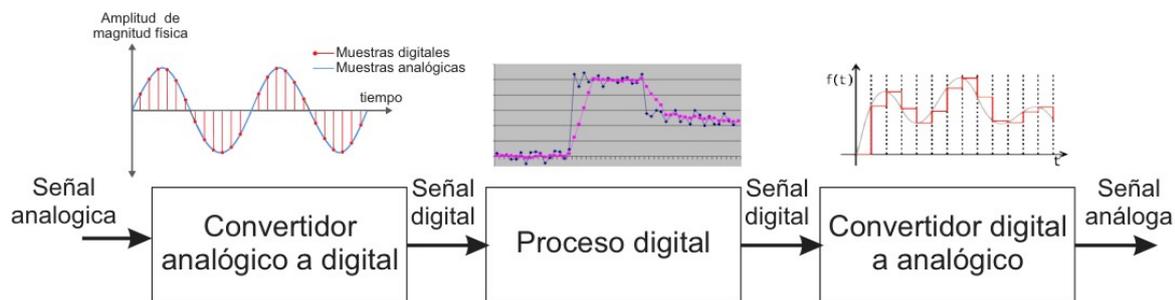


Figura 24. Etapas de un sistema básico de un procesamiento digital de señales.

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 limitado al verse afectados por cambios de temperatura, cambios de voltaje y vibraciones mecánicas, entre otros. Por su parte el procesamiento digital de señales conlleva 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 costes o 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 hardware, 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. Debido a lo anterior se propone el uso de un procesador basado en computadora de placa única (SBC, por su abreviatura en inglés Single Board Computer), el cual 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.

4.4.1 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). A este respecto, 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 de dispersión consta de una etapa de acondicionamiento de la señal en la que se realiza un filtro anti-aliasing por medio de amplificadores operacionales, seguida 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 esquema 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 con el objetivo de 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 empleando amplificadores

operacionales típicos. Por su parte, la expresión (67) 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.

$$V_{out} = (V_2 - V_1) \cdot \frac{R_3}{R_1} \quad (67)$$

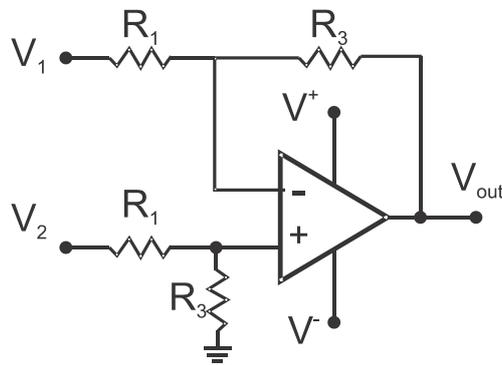


Figura 25. Configuración de amplificador operacional no inversor restador.

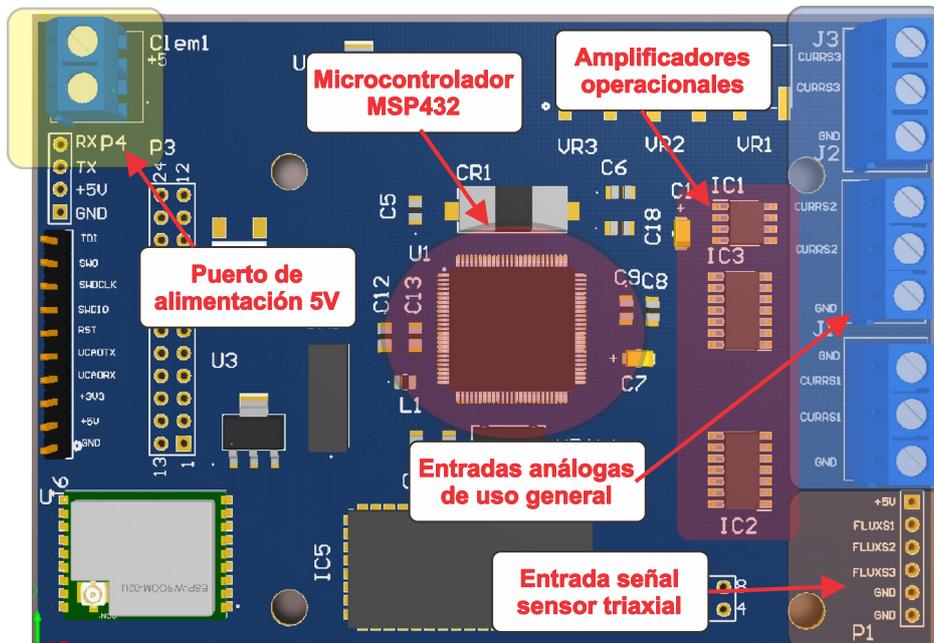


Figura 26. Esquema 3D de la tarjeta desarrollada para el acondicionamiento y adquisición de señales del sensor de flujo de dispersión triaxial desarrollado.

4.4.2 Tarjeta de procesado

La tarjeta de procesado es la encargada de almacenar y procesar las seales digitales provenientes de la etapa de acondicionamiento descrita en la secci3n 4.4.1. Esta tarjeta es del tipo procesador basado en computadora de placa nica, el cual puede realizar el clculo de la STFT, DWT, ST-MUSIC, extracci3n de caractersticas de parmetros estadsticos, reducci3n de dimensionalidad de anlisis discriminante lineal y clasificaci3n mediante una red neuronal artificial, tal y como se describe en la secci3n 3 de este trabajo de tesis. Como se ha comentado, el procesador SBC utilizado est basado en una Raspberry Pi Modelo 4 que cuenta con un procesador 4x 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 tctil Raspberry. Adicionalmente, esta tarjeta cuenta con 2 GB de memoria RAM, ms que suficiente para almacenar de forma dinmica la informaci3n intermedia para llevar a cabo las tareas de adquisici3n, almacenamiento y procesamiento de seales. La Figura 27 muestra la tarjeta modelo Raspberry Pi 4 y sus principales componentes. Como principales caractersticas de conectividad de dicho procesador se tiene un puerto de expansi3n de entradas y salidas de prop3sito general, en las que se implementan distintos protocolos de comunicaci3n industriales y estandarizados, como son protocolos de comunicaci3n I2C, SPI, UART, entre otros. Adicionalmente, esta tarjeta cuenta con conectividad inalbrica LAN 2.4 GHz and 5.0 GHz IEEE 802.11b/g/n/ac, Bluetooth 5.0, BLE Gigabit Ethernet 2 x puertos USB 3.0, 2 x puertos USB 2.0.

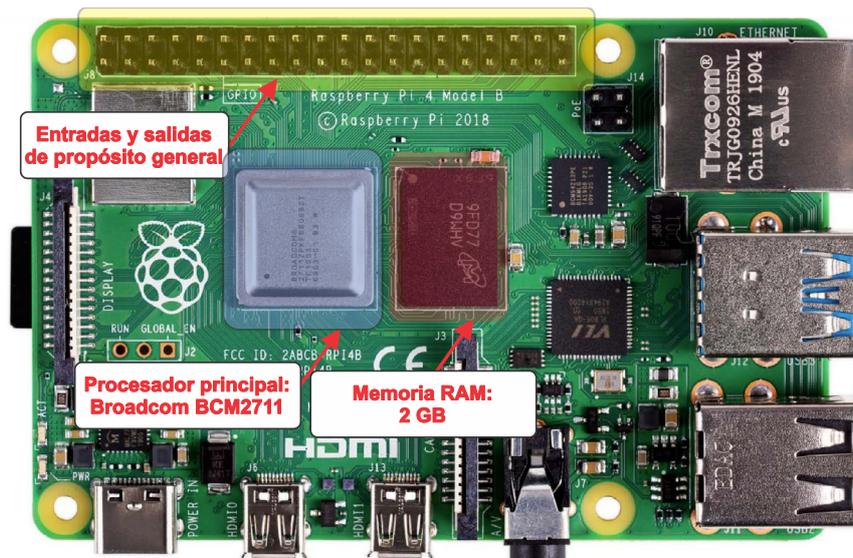


Figura 27. Principales componentes de procesador empleado para la implementaci3n de la metodologa propuesta.

Por otra parte, la Figura 28 muestra las principales técnicas implementadas en la tarjeta Raspberry Pi, las cuales permiten realizar los cálculos necesarios para un diagnóstico continuo de la máquina bajo análisis empleando la metodología propuesta. Así, se pueden distinguir cuatro tareas esenciales, que se describen 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. Para implementar dicha comunicación e intercambio de información se hace uso del protocolo de comunicación estandarizado UART, que contienen ambos procesadores mencionados anteriormente.
2. Herramientas de procesamiento de señales. Aquí es donde se implementan los cálculos matemáticos básicos que se requieren para llevar a cabo tareas de procesamiento más complejas, como el cálculo de la DWT, STFT, MUSIC. Estos cálculos corresponden con los descritos en la Sección 3 de este trabajo de tesis, y que se enumeran a continuación:
 - Implementación de filtro digital paso bajo, 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. En esta tarea se lleva a cabo la etapa de automatización del proceso de clasificación del fallo mediante la implementación de las herramientas de inteligencia artificial como lo son redes neuronales artificiales (RNA), análisis discriminante lineal (LDA), análisis de componente principal (PCA). Esta tarea se lleva a cabo mediante la implementación de las expresiones matemáticas descritas en la Sección 3.4.

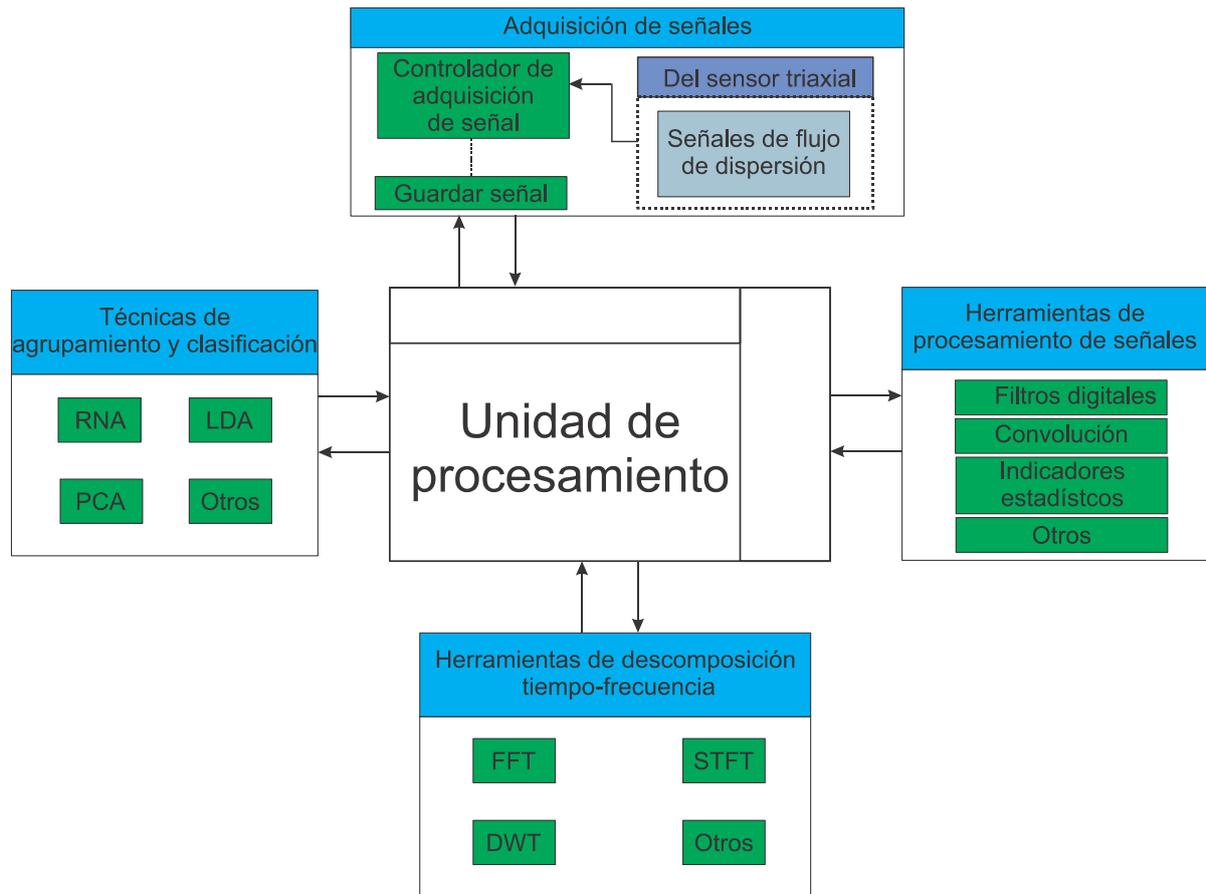


Figura 28. Tareas principales llevadas a cabo e implementadas a través del procesador principal basado en la plataforma Raspberry Pi 4.

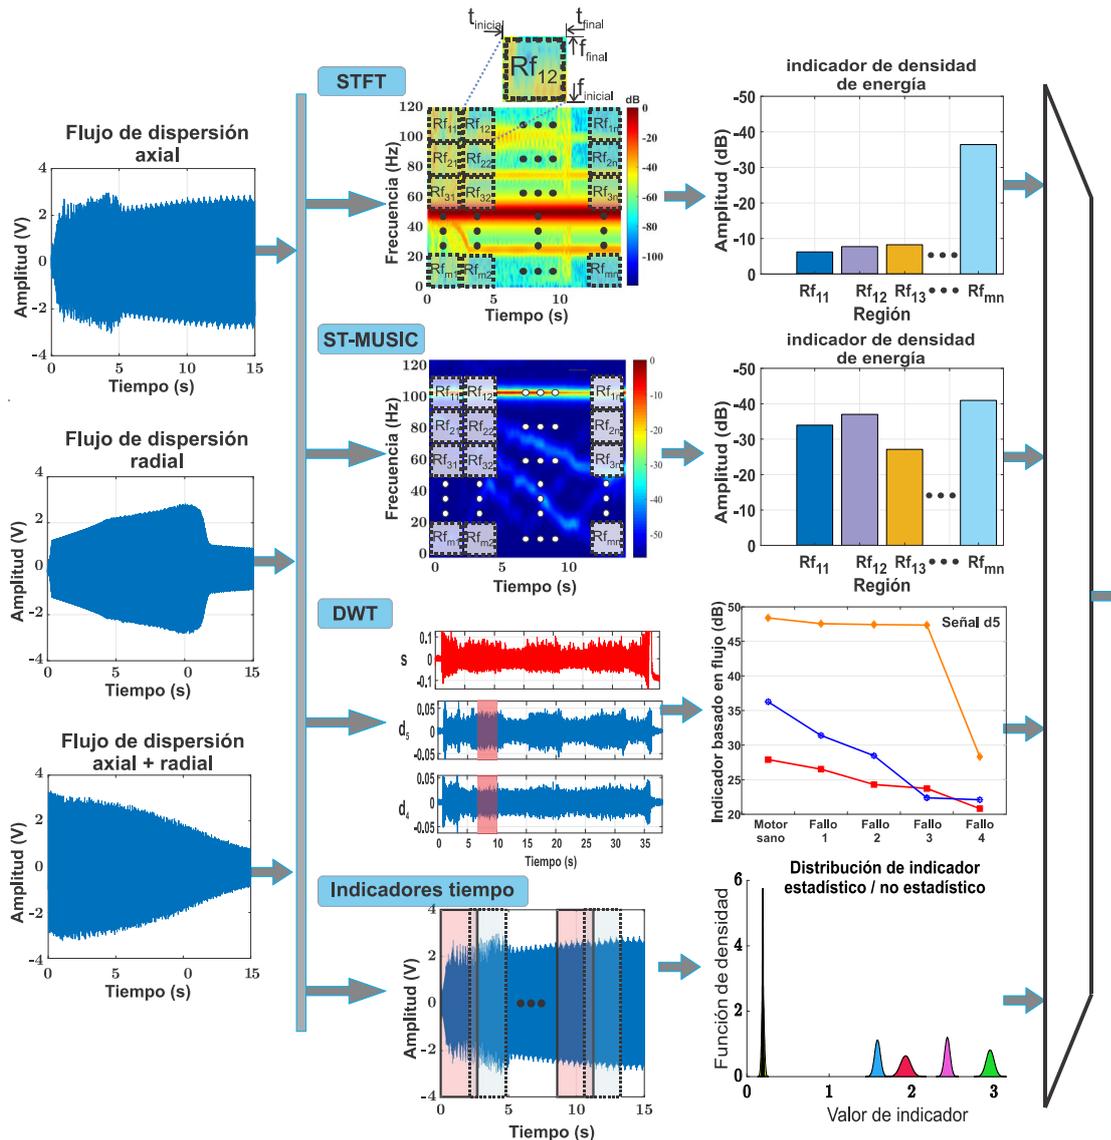
5. METODOLOGÍA

En el siguiente apartado se describe a detalle la metodología propuesta en este trabajo de tesis. Primeramente se describen las bases de la metodología. Posteriormente, se introduce el esquema de la metodología propuesta, en el que se muestra el flujo de señales y las etapas de procesamiento que se siguen para lograr un diagnóstico oportuno y automático de los diversos fallos electromecánicos considerados en motores eléctricos de inducción, a saber: barras de rotor rotas, excentricidades, desalineamientos, desgaste de engranajes, asimetrías de rotor en motores de inducción de rotor bobinado, fallos de pista externa en rodamientos de bolas, entre otros. 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 averías que suelen ocurrir en los motores eléctricos generarán un cambio en el comportamiento dinámico de las magnitudes físicas asociadas al propio motor (como corrientes de alimentación, señales de vibración, señales acústicas, temperaturas, 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 asociadas al fallo, cambios en el gradiente de temperatura, cambios en la amplitud las señales de vibración, de emisión sonora, entre otros, que son debidos a la aparición del fallo. Pues bien, la idea principal de la metodología propuesta es caracterizar los cambios y comportamientos dinámicos de las señales de flujo de dispersión (capturado en la carcasa del motor) cuando ocurre una avería específica, respecto al estado base, esto es, cuando el motor se encuentra en estado saludable. Para este fin, 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 un mapa tiempo-frecuencia (obtenido mediante la aplicación de herramientas de descomposición tiempo-frecuencia como lo son STFT, y ST-MUSIC), y a partir de indicadores normalizados (Y_{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 averías específicas. Finalmente, sabiendo la importancia que tiene el hecho de poder generar un diagnóstico automático, se propone el empleo de técnicas de inteligencia artificial, tales como 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



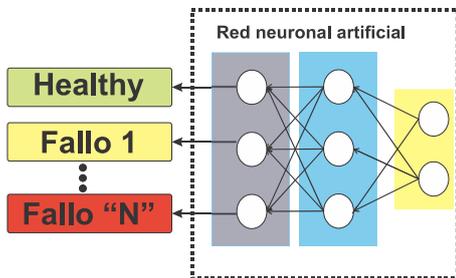
diferentes fallos que suelen ocurrir en los motores eléctricos de inducción, éstos son identificados de forma automática por la red neuronal artificial. La Figura 29 muestra el diagrama de flujo de la metodología propuesta. Como se puede observar, ésta se compone esencialmente de 5 etapas de procesamiento que se detallan a continuación:



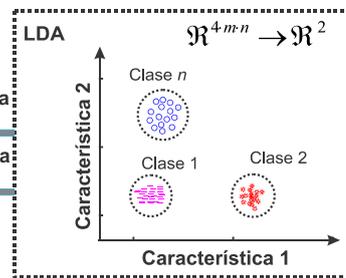
Obtención de señales en el tiempo (paso 1)

Detección automática de arranque de motor (paso 2)

Obtención de indicadores (paso 3)



Clasificación automática de estado de motor (paso 5)



Reducción de características y fusión de información (paso 4)

Figura 29. Diagrama de flujo de la metodología propuesta.



- 1. Adquisición de señales del flujo magnético de dispersión** (flujo de dispersión axial, radial y combinado). 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 4.3. Este sensor puede ser instalado en la parte externa de la carcasa, como se muestra en la Figura 23. Se propone el empleo de este sensor debido a las ventajas que este representa sobre algunas otras alternativas, ya que permite capturar las diferentes componentes magnéticas del flujo de dispersión en un único punto en de la carcasa del motor, permite capturar inclusive flujos magnéticos constantes, es de reducido tamaño (lo que posibilita su instalación incluso en emplazamientos de difícil acceso), y tiene muy bajo coste. Por otro lado, también es posible emplear sensores tipo bobina, como el que se describe en la sección 4.2.1; sin embargo, para capturar 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 dichas señales es necesario contar con un equipo registrador de señales, como 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 en este trabajo se basan en la densidad de energía de diferentes zonas de interés del mapa tiempo-frecuencia (obtenido a partir del análisis de las señales capturadas durante el arranque del motor), resulta indispensable contar con una metodología capaz de garantizar de forma automática que la señal capturada corresponde exclusivamente al citado transitorio de arranque del motor. Para ello, en este trabajo de tesis se plantea un método simple para aislar el transitorio de arranque mediante un algoritmo simple, el cual no demanda mucha carga computacional, tal como se describe en la sección 3.5
- 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. Este caso en particular se trata de 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 varía de forma siempre igual durante un arranque directo (entre un valor de $s=1$ y un valor cercano a cero en régimen permanente). Estas evoluciones se identifican mediante el uso de algunos indicadores, que corresponden a la media aritmética y al valor máximo de la densidad de energía en regiones específicas del mapa tiempo-frecuencia (representadas como áreas sombreadas en la Figura 29), y que se muestra de forma ampliada en la Figura 30 para mayor claridad. Dichos indicadores se pueden calcular mediante (68) y (69) para obtener el valor medio y máximo, respectivamente.

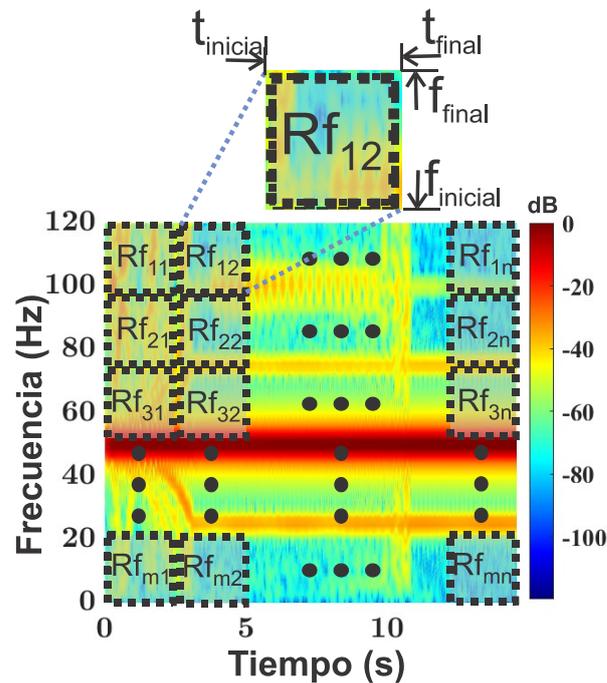


Figura 30. División del mapa tiempo-frecuencia STFT en regiones de interés $Rf_{11}, Rf_{12} \dots Rf_{mn}$.

$$\text{mean}(RF_{ij}) = \frac{1}{N_{dp}} \left(\sum_{k=t_{inicial}}^{t_{final}} \sum_{l=f_{inicial}}^{f_{final}} (E_{k,l})_{RF_{ij}} \right) \quad (68)$$

$$\text{max}(RF_{ij}) = \text{max} \left(\sum_{k=t_{inicial}}^{t_{final}} \sum_{l=f_{inicial}}^{f_{final}} (E_{k,l})_{RF_{ij}} \right) \quad (69)$$

donde $E_{k,l}$ es la densidad de energía normalizada (en relación a la 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, el cual se describe con mayor detalle en la sección 3.2.2 de este trabajo. Se propone el empleo de esta técnica para los casos en el que 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 evolucionan muy cercanos entre sí, como 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 incluso imposibilitan la distinción de los armónicos amplificados por un fallo. Cabe recalcar que, debido a sus características, la aplicación de la técnica ST-MUSIC es especialmente adecuada para detectar componentes de baja amplitud en señales con una baja relación señal/ruido (alto nivel de ruido en la señal).
- i. 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} , del cual 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 determinada dentro de la cual evoluciona una componente de fallo. Su uso está basado en el hecho de que la energía de la señal wavelet asociada a la banda de frecuencia en la que evoluciona la componente de fallo aumenta a medida que aumenta la severidad del fallo estudiado. El indicador se basa en dividir esta energía de la señal wavelet entre la energía de la señal total considerada (por ejemplo, la señal de flujo), computadas ambas en el intervalo temporal durante el que evoluciona la componente de fallo.

- ii. 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 fallo 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 fallos en el mismo es obtener parámetros que puedan reflejar correctamente la condición de trabajo de un sistema y, en consecuencia, identificar sus patrones de fallo (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). A continuación, se obtiene una proyección bidimensional, en la que se maximiza la distancia euclidiana entre diferentes severidades de falla. Esta proyección permite observar la agrupación de datos entre diferentes severidades de fallos, 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 los diferentes fallos estudiados.

6. RESULTADOS Y DISCUSIÓN.

En esta sección se presentan los resultados obtenidos al aplicar la metodología propuesta a diversos casos de estudio, sobre numerosos bancos de motores con diferentes características constructivas. En cada caso, se pone en contexto la relevancia de su estudio mediante una subsección denominada “Motivación del caso de estudio”. En 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. En esta sección se estudian diferentes fallos electromecánicos que suelen ser frecuentes en motores eléctricos de inducción, a saber: barras de rotor rotas, excentricidades, desalineamientos, desgaste de engranajes, asimetrías rotóricas en motores de inducción de rotor bobinado, daños en la pista exterior en rodamientos de bolas, entre otras. A tal fin, se utilizan una variedad de bancos de ensayo de motores, así como motores de diferentes potencias. Debido a ello, se ha habilitado, para cada caso, una subsección exclusiva para dar detalle del banco de motores empleado, las señales capturadas, la forma de instalación del sensor de flujo de dispersión, el proceso de registro de señales, el proceso de desarrollo del fallo, además de otra información de relevancia, a fin de que el lector disponga de los elementos necesarios para poder analizar y replicar los resultados aquí expuestos. Adicionalmente, se da también información sobre los parámetros específicos y de la técnica empleada en cada caso de estudio. Finalmente, se examinan con detalle los resultados obtenidos mediante la discusión de los análisis llevados a cabo.

Finalmente, como prueba del hecho de que la técnica expuesta es extrapolable a un amplio rango de diferentes aplicaciones en las que intervengan motores eléctricos, se incluye también el caso de la aplicación de la técnica al diagnóstico del desgaste de herramientas de corte en máquinas de control numérico computarizado (máquinas CNC).

En síntesis, en esta sección se abordan, primeramente, los casos de estudio relacionados con el diagnóstico de diversos fallos electromecánicos en motores eléctricos de inducción de diferente tipología (sección 6.1 a sección 6.5), concluyendo la misma con 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 rotóricas en motores de inducción de rotor bobinado.

6.1.1 Motivación del caso de estudio

Los motores de inducción de rotor bobinado permiten la inserción de resistencias externas en serie con los devanados del rotor, lo que permite modificar su curva par-velocidad, consiguiendo pares de arranque elevados, al mismo tiempo que mantienen la corriente de arranque en un valor reducido. Ello 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). En su modalidad de operación como generador, este tipo de máquinas se han utilizado masivamente en aplicaciones como generación eólica. Uno de los inconvenientes de los motores de rotor bobinado (WRIM por su abreviatura en inglés, Wound Rotor Induction Motor), en comparación con los motores de jaula de ardilla, es su mantenimiento más delicado, debido a la complejidad constructiva del circuito del rotor, el cual implica la participación de diferentes elementos: las propias bobinas del rotor (varias conectadas en serie en grandes motores), sistemas de anillos rozantes-escobillas (que permiten acceder al circuito del rotor), reóstato de arranque o la aparamenta necesaria para puentear el citado reóstato, una vez finaliza el proceso de arranque. Este circuito es especialmente propenso a la aparición de asimetrías entre fases del rotor, las cuales pueden ocurrir por múltiples causas: contactos defectuosos entre los anillos rozantes y las escobillas, desgaste desigual de las escobillas en las tres fases, contactos de alta resistencia entre bobinas, apriete inadecuado o desigual de los muelles de las escobillas, etc... Las asimetrías en el devanado del rotor pueden tener consecuencias muy negativas, provocando sistemas desequilibrados de corrientes de rotor que dan lugar a pares parásitos y que también pueden causar vibraciones excesivas y disipaciones térmicas elevadas (Bellini, et al., 2008). Todo ello puede acarrear un funcionamiento anormal del motor e incluso daños irreparables en el aislamiento, causando pérdidas notables para las empresas involucradas (Grande-Barreto et al., 2017). En esta sección se muestran los resultados obtenidos al aplicar la metodología propuesta para la detección de asimetrías rotóricas en motores de inducción de rotor bobinado. El procedimiento de diagnóstico propuesto fue validado en el laboratorio en un motor de inducción de rotor bobinado de 4 polos, 400 V y 11 kW. Los devanados del rotor se ubicaron en 24 ranuras y la resistencia por fase fue de 0.335Ω (Zamudio-Ramirez 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.

6.1.2 Desarrollo de los ensayos

La bancada experimental básicamente consistía en el WRIM antes mencionado, que arrastraba en el mismo eje a otra máquina que actuaba como carga (ver Figura 33). El motor WRIM era arrancado con un reóstato de arranque (elemento azul en Figura 33 (b)) que se conectaba al rotor mediante un sistema de anillos rozantes-escobillas. El procedimiento de ensayo para forzar la avería consistió en insertar una resistencia externa variable (elemento amarillo en Figura 31(b)) en serie con una de las fases del devanado del rotor. Variando el valor de esta resistencia se podían conseguir diferentes niveles de asimetría en el devanado del rotor (la resistencia variable podía fijarse hasta en 10 niveles, lográndose diferentes niveles de asimetría rotórica). El nivel máximo de resistencia de fase a fase de la resistencia externa era de $11,6 \Omega$ (paso 10) y el mínimo de $0,14 \Omega$ (paso 1). Así entonces, mediante este caso de estudio se logró investigar tres niveles diferentes de gravedad de la falla, a saber, un motor en buen estado (con asimetría de rotor inherente), asimetría moderada nivel 2 (con una resistencia adicional de 1,6 veces la resistencia de fase del rotor) y asimetría alta nivel 4 (con una resistencia adicional de 1,9 veces la resistencia de fase del rotor).

Por otro lado, para obtener las 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 (mostradas anteriormente en la Figura 18). El sensor de flujo magnético fue elaborado a partir de una bobina circular construida a partir de hilo 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 (f_{em}) inducidas se capturaron tanto durante el arranque del motor como en régimen permanente, conectando el sensor tipo bobina a un osciloscopio capaz de registrar la forma de onda digitalmente, así como almacenar las señales registradas. Se fijó una frecuencia de muestreo $f_s = 5 \text{ kHz}$ y un tiempo de adquisición de 60 s , suficiente para capturar el transitorio de arranque y una porción del régimen permanente del motor.

La Figura 31 muestra el motor de inducción de rotor bobinado ensayado, 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 las componentes asociadas a averías 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 estas 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.

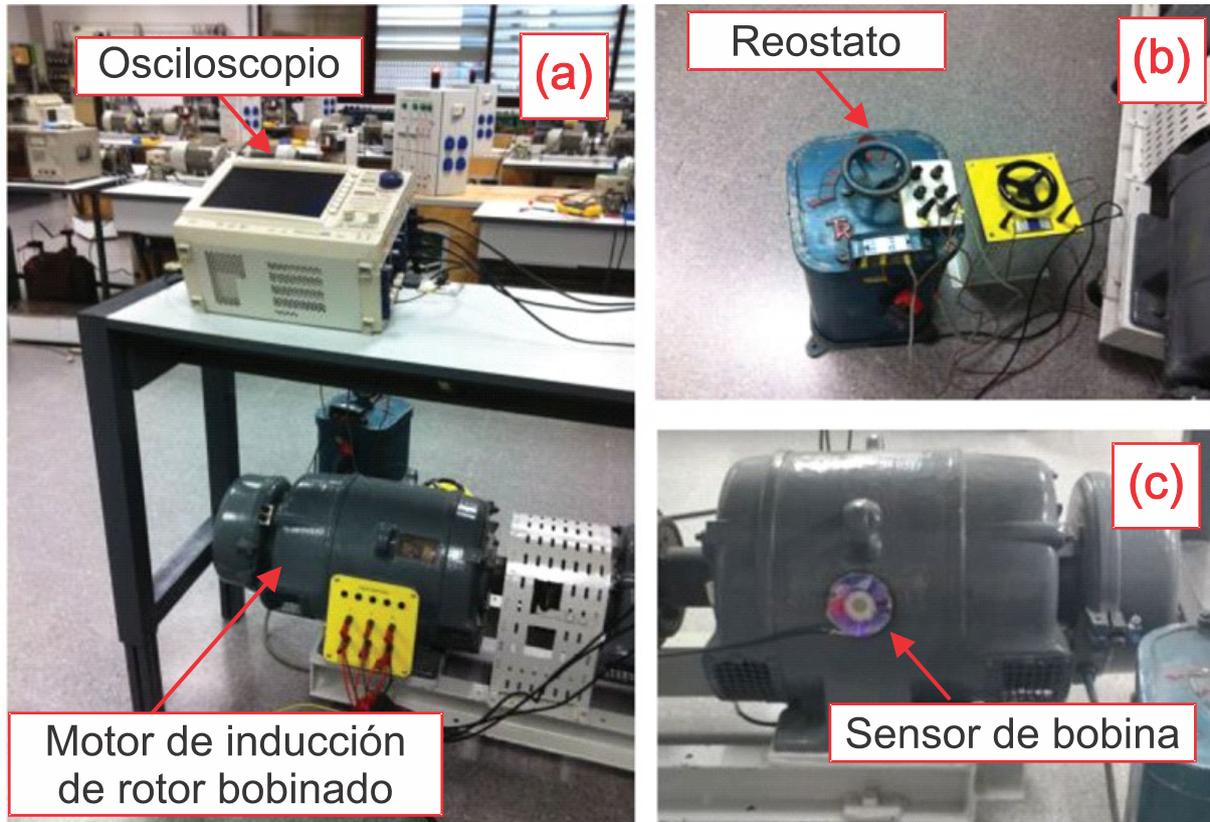


Figura 31. Banco de pruebas de laboratorio: (a) osciloscopio registrador de forma de onda y motor de inducción de rotor bobinado ensayado; (b) reóstato de arranque y resistencia externa para forzar las asimetrías; y (c) sensor de flujo magnético tipo bobina instalado en la posición B.

6.1.3 Resultados y discusión del caso de estudio.

Para realizar los análisis de las señales, los datos registrados se transfirieron a una computadora en la cual se aplicaron las técnicas de procesamiento de señal correspondientes. Dado que el análisis presentado en la presente sección se centra en el rango de frecuencias por debajo de 150 Hz , ya que la frecuencia de suministro es igual a 50 Hz (para este caso) y a que el valor máximo de frecuencia alcanzado por las componentes de interés es de 3 veces la frecuencia de suministro (alcanzado 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 .

Para los análisis tiempo-frecuencia de los datos de flujo capturados mediante el sensor tipo bobina durante el arranque, se aplicaron dos herramientas diferentes. Por un lado, la STFT se utilizó para rastrear la evolución de las componentes de

avería consideradas durante el transitorio de arranque del motor. En estado sano, en el mapa tiempo-frecuencia solamente debe estar presente la componente fundamental; ésta debe aparecer como una línea horizontal en la frecuencia de suministro (50 Hz para este caso de estudio). Además de ésta, puede haber múltiplos de esta frecuencia asociados a armónicos de la tensión de alimentación (armónicos de devanado) y otras evoluciones asociadas a los armónicos principales de ranura (Corral., 2018). Bajo la presencia de asimetría del devanado del rotor, se espera que las anteriores componentes estén acompañadas por los patrones característicos tiempo-frecuencia causados por la evolución de las componentes amplificadas debidas a la avería estudiada.

La segunda técnica de procesamiento de señales utilizada es la DWT. En esta transformada, una buena selección de la(-s) señal(-es) wavelet a considerar resulta fundamental para que el diagnóstico sea fiable; estas señales wavelet deben cubrir parte de la banda de frecuencias a través de la cual evoluciona la componente de fallo considerada que, por lo general, suele ser el armónico lateral inferior ($f \cdot (1 - 2 \cdot s)$) que es el que se suele emplear principalmente para diagnosticar este fallo. Como se vio en secciones previas, este armónico evoluciona entre 0 y casi la frecuencia fundamental durante el arranque, con lo que hay que considerar señales wavelet que cubran, al menos parcialmente, esta banda. La Figura 32 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, ya que esta proporciona un buen filtrado de las señales wavelet, tal y como se justificó anteriormente). En esta figura se pueden observar los diferentes niveles de descomposición wavelet para los casos de motor sano (ver parte izquierda de la Figura 32) y de motor con presencia de asimetría en el rotor (ver parte derecha de la Figura 32). La forma de onda superior (en color rojo) es la señal f_{em} analizada. Las formas de onda que se muestran en color azul corresponden a las señales ondoleta que son más relevantes para los propósitos descritos en este caso de estudio, a saber, $d6$, $d7$, $d8$ y $a8$, las cuales cubren una banda de frecuencias desde los 0 Hz hasta los 78.12 Hz (correspondiente precisamente a una banda de frecuencia por la que la falla evoluciona durante el transitorio de arranque), como se describe en la Tabla 7.

Tabla 7. Bandas de frecuencia asociadas con las señales ondoleta para $f_s = 5\text{kHz}$ y $n = 8$.

Señal ondoleta	a8	d8	d7	d6	d5
Banda de frecuencia	0–9.78	9.78–19.5	19.5–39.06	39.06–78.12	78.12–156.25

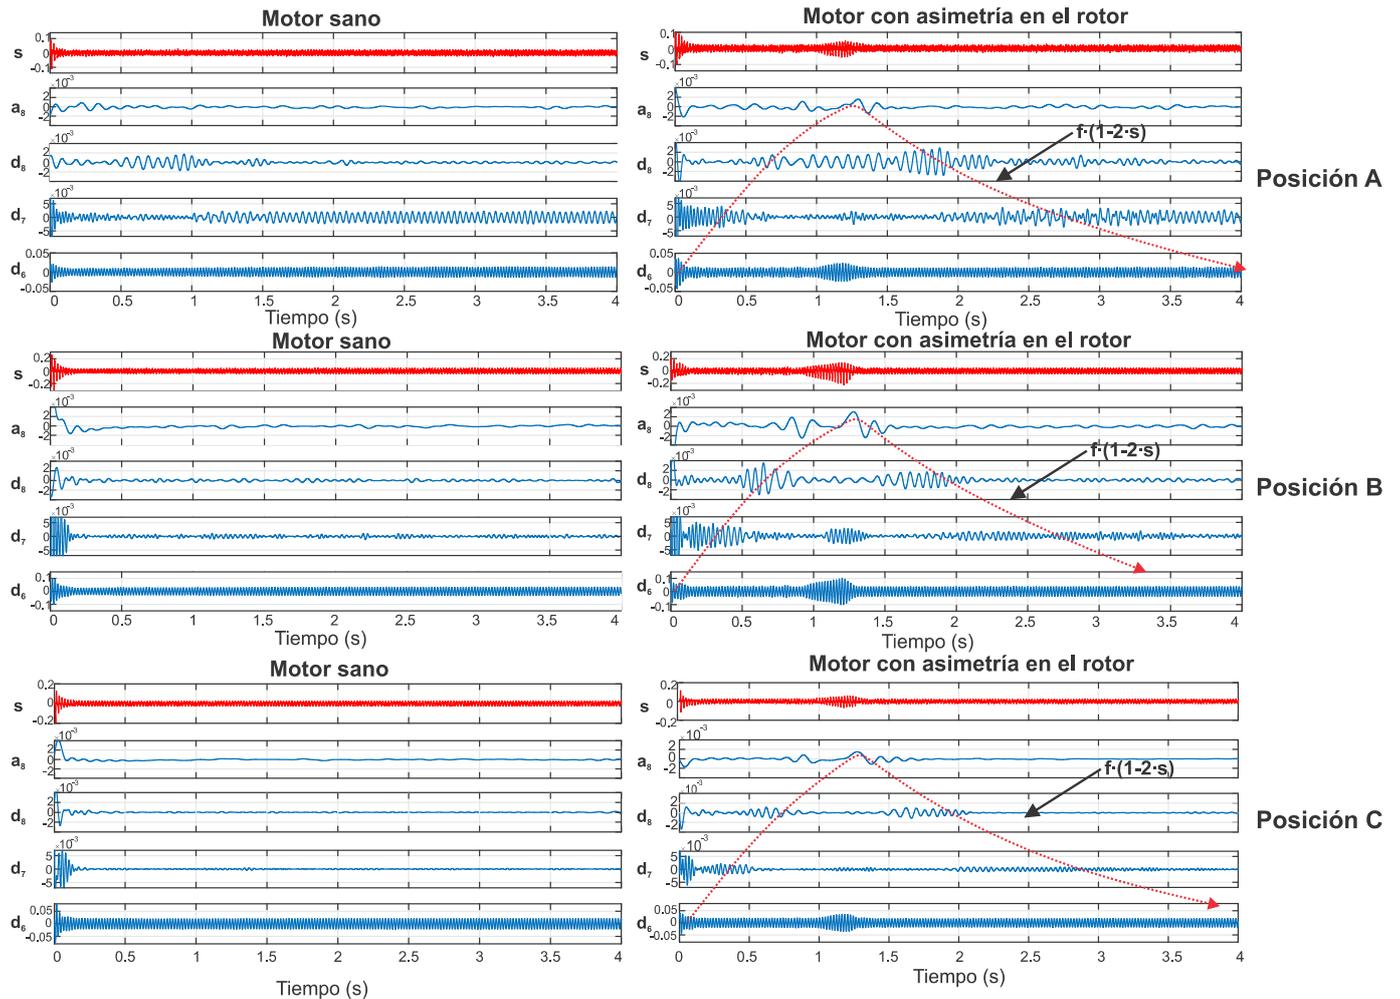


Figura 32. Análisis DWT de la señal fem durante el arranque del motor (señal roja) con el sensor en las tres posiciones diferentes consideradas para un motor sano (lado izquierdo) y para un motor con asimetría de rotor nivel cuatro con una resistencia adicional de 1,9 veces la resistencia de fase del rotor (lado derecho).

Como se observa en la Figura 34, las señales $d7$, $d8$ y $a8$ tienen amplitudes reducidas cuando el motor está sano. Por contra, cuando existe asimetría en el devanado del rotor, aparecen oscilaciones muy claras, con amplitudes mayores en las señales $d7$, $d8$ y $a8$ (ver parte derecha de la Figura 32). 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 asimetría rotórica. En efecto, cuando el motor se conecta y comienza su aceleración, la componente de fallo comienza evolucionando en la señal $d6$, ya que su frecuencia inicialmente es igual a la fundamental; posteriormente, evoluciona sucesivamente a través de las señales $d7$, $d8$ y $a8$, a medida que su frecuencia disminuye durante el arranque, traspasando las bandas de frecuencia cubiertas por dichas señales. Posteriormente, a medida que la frecuencia de la componente de fallo crece de nuevo hacia la fundamental, vuelve a traspasar las bandas asociadas a las señales $d8$ y $d7$

creando las correspondientes oscilaciones en dichas señales. En conclusión, la evolución del armónico lateral durante el arranque da lugar a un patrón específico en las señales wavelet resultantes de la DWT (marcado como unas líneas discontinuas de color rojo en la Figura 34). Obsérvese que, además de las oscilaciones mencionadas, también existen otras oscilaciones menores en estas señales causadas por la evolución durante el arranque de otras componentes relacionadas con la avería (por ejemplo, $s \cdot f$).

Considerando todo lo anterior, se propone emplear la información proporcionada por la señal wavelet d_8 , que cubre aproximadamente el rango de frecuencias [10-20 Hz], a través del cual evoluciona parcialmente el armónico lateral durante el arranque. La Figura 33 ilustra las diferencias de amplitud de la señal d_8 , para distintos niveles de severidad de fallo considerados, para el sensor colocado en la Posición B. Obsérvese que, cuanto mayor es la severidad de la avería, mayor es la amplitud de las oscilaciones, lo que demuestra que la energía de esta señal wavelet se ve significativamente afectada por la presencia de la asimetría. En la misma figura, las áreas resaltadas en rojo son las áreas utilizadas para el cálculo del indicador de severidad de fallo basado en flujo γ_{DWT} , el cual se describe en la sección 3.1.3; dichas áreas corresponden precisamente al intervalo de tiempo en el que la componente de fallo penetra la señal d_8 .

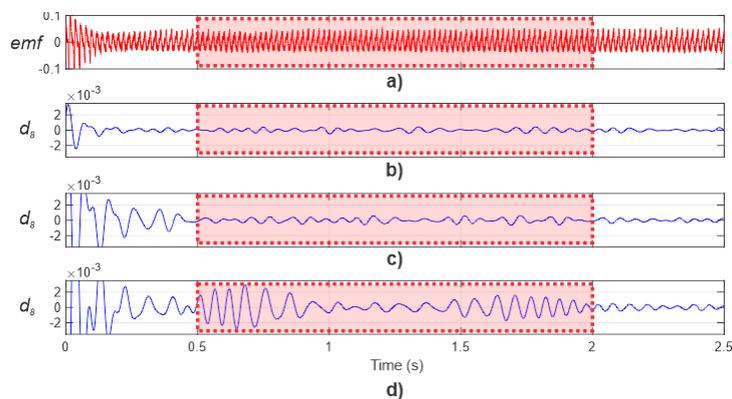


Figura 33. Análisis DWT de la señal fem inducida en el sensor de bobina cuando éste se coloca en la posición B: (a) señal fem total capturada durante el arranque; (b) señal d_8 para un motor sano; (c) señal d_8 para un motor con asimetría de rotor nivel dos (resistencia adicional de 1,6 veces la resistencia de fase del rotor); y (d) señal d_8 para un motor con asimetría de rotor nivel cuatro (resistencia adicional de 1,9 veces la resistencia de fase del rotor) (Zamudio-Ramirez et al., 2020).

Por otro lado, la Figura 34 muestra los análisis de las señales del sensor de flujo durante el arranque, utilizando la STFT, para las tres posiciones (A, B y C) y para el caso de motor con asimetría en el rotor. Esta herramienta permite una visualización más clara del contenido armónico del mapa tiempo-frecuencia. A este respecto, nótese la aparición de las componentes de avería caracterizadas de acuerdo la

ecuación (1). Por un lado, la componente $(1+2 \cdot s) \cdot f$, la cual evoluciona desde una frecuencia inicial de 150 Hz y va decreciendo paulatinamente hasta aproximarse a la frecuencia fundamental. Por otro lado, la componente de avería $(1-2 \cdot s) \cdot f$, que evoluciona durante el arranque siguiendo el patrón en forma de “V” comentado anteriormente. Obsérvese también la presencia de la componente $s \cdot f$, de carácter axial, que también se ve amplificada por la asimetría del rotor. Ésta evoluciona durante el arranque desde la frecuencia fundamental (50 Hz) hasta cerca de 0 Hz en régimen permanente. Finalmente, también se detecta la evolución de una 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.

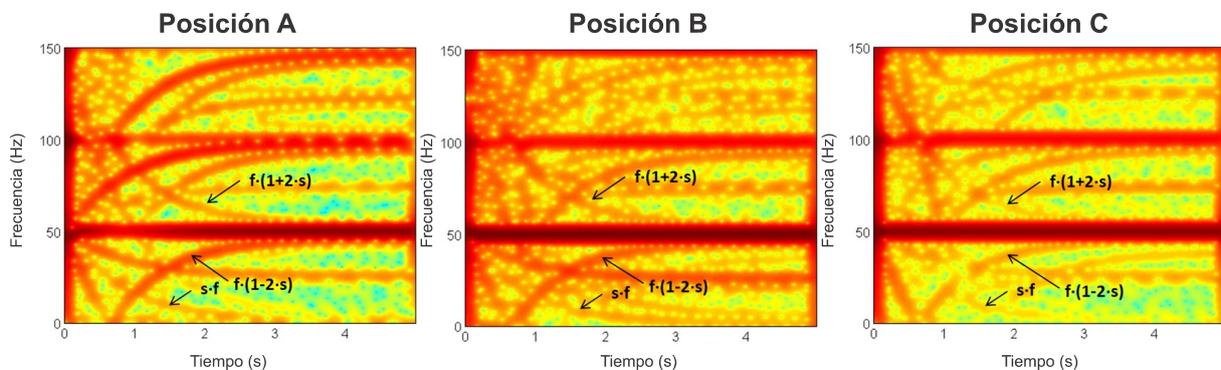


Figura 34. Análisis STFT de las señales del sensor de flujo capturadas durante el arranque del motor para la máquina con asimetría en el devanado del rotor y para las tres posiciones del sensor (el color denota la densidad de energía en cada punto del mapa de tiempo-frecuencia, el rojo indica la densidad más alta y el azul la densidad más baja) (Zamudio-Ramirez et al., 2020).

De forma similar, la Figura 35 muestra el análisis tiempo-frecuencia (utilizando la STFT) de las señales de emf capturadas durante el transitorio de arranque en tres condiciones diferentes del devanado del rotor, correspondientes al motor en estado sano, motor con una asimetría moderada (nivel 2: resistencia añadida $R_{add} = 1.6 R_R$ con $R_R =$ resistencia del rotor), y motor con un nivel severo de asimetría rotórica (nivel 4: resistencia añadida $R_{add} = 1.9 R_R$). Es de resaltar que, en dicha gráfica, el motor se encontraba operando sin carga; esto se hace 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. Por otro lado, la Figura 36 es equivalente a la Figura 35, 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 avería, 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 avería 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 35 y Figura 36.

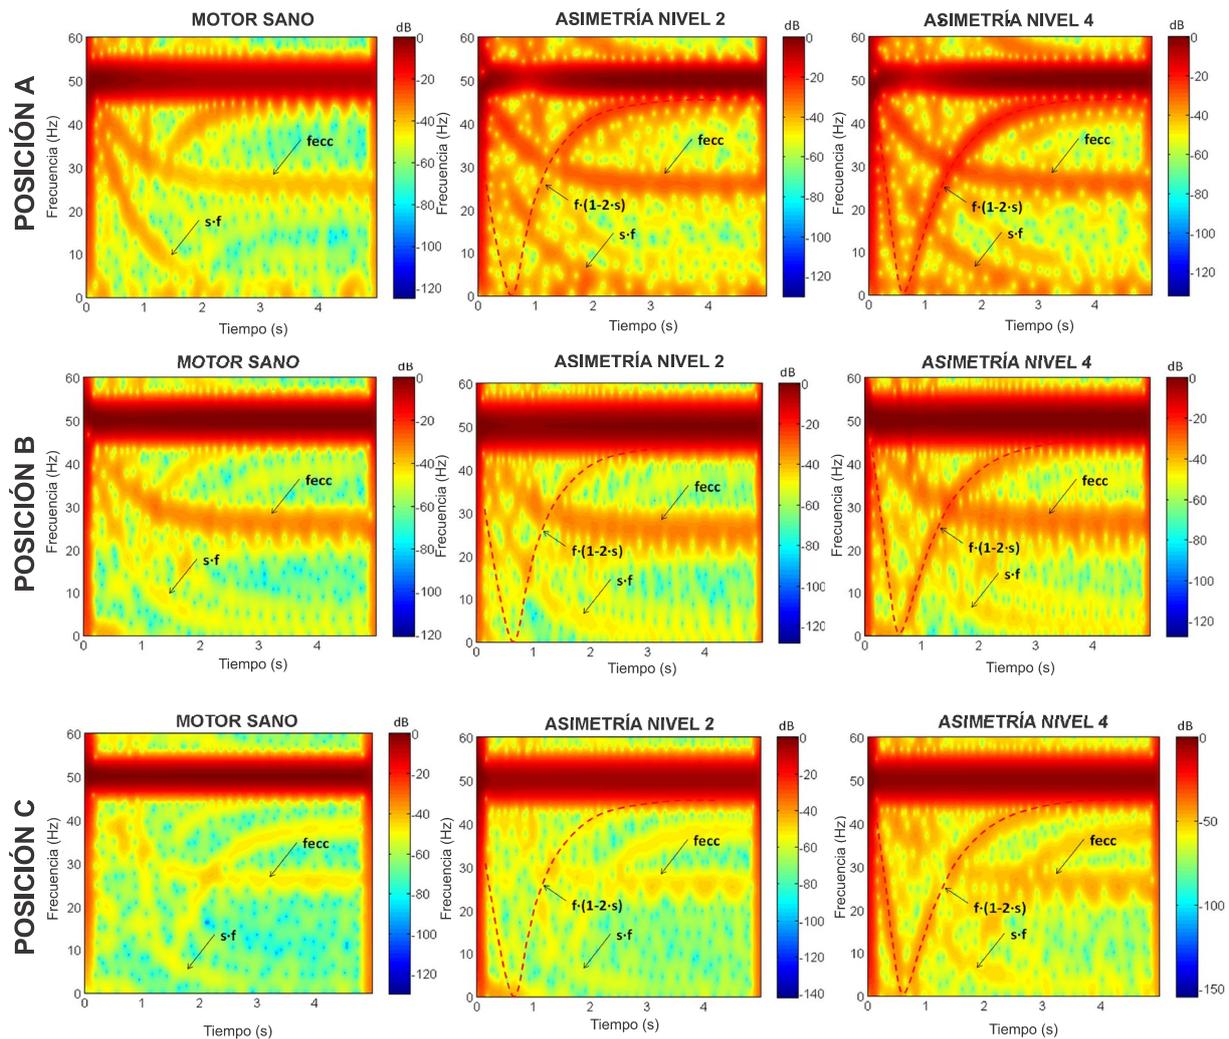


Figura 35. Análisis STFT de las señales del sensor de flujo capturadas durante el arranque del motor para la máquina con asimetría de rotor nivel dos y motor con asimetría de rotor nivel cuatro, para las tres posiciones consideradas del sensor. El motor funciona en condición sin carga (Zamudio-Ramirez et al., 2020)

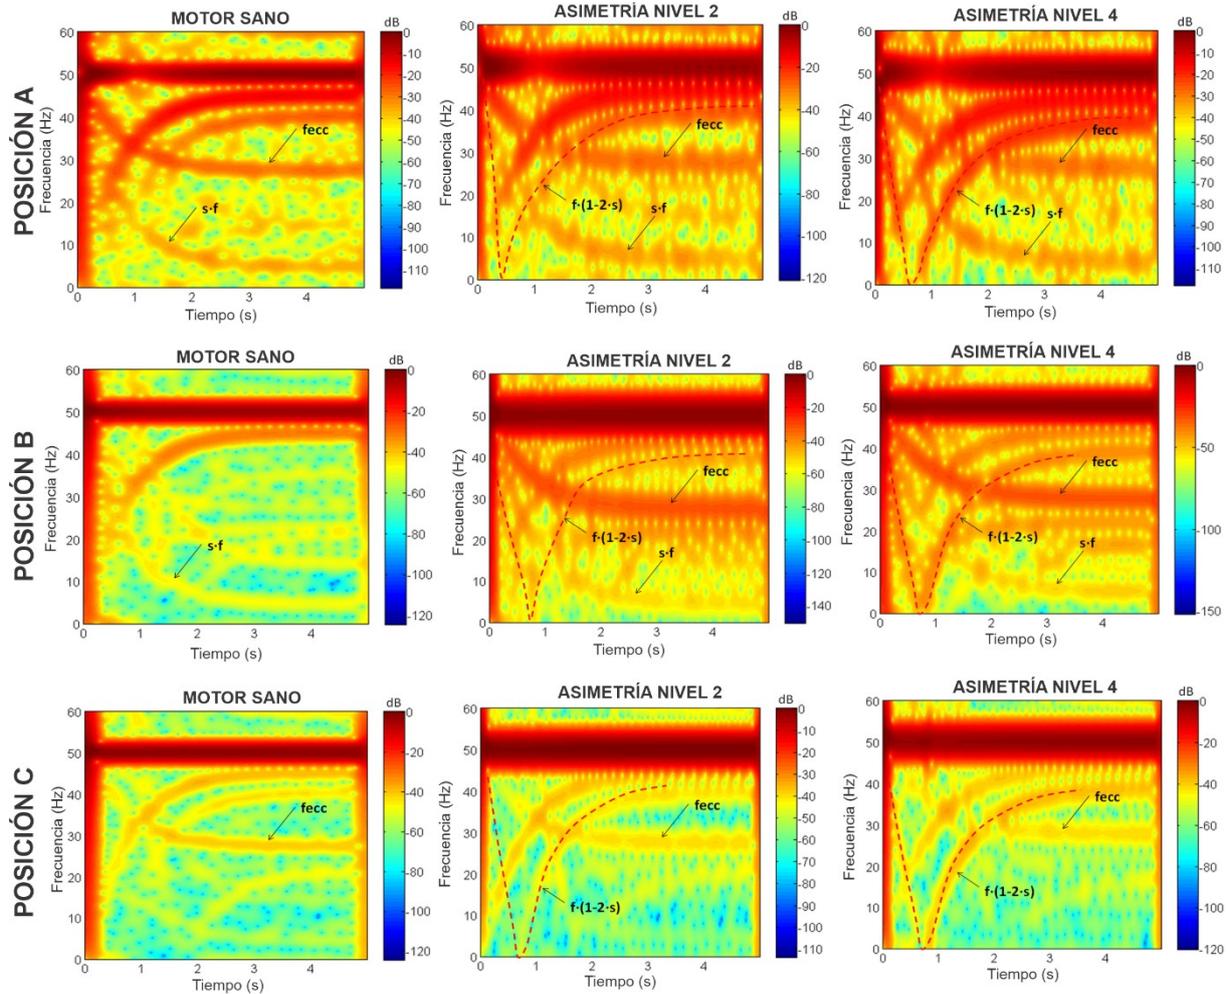


Figura 36. Análisis STFT de las señales del sensor de flujo capturadas durante el arranque del motor para la máquina con asimetría de rotor nivel dos y motor con asimetría de rotor nivel cuatro, para las tres posiciones consideradas del sensor. El motor funciona en condición con carga parcial (Zamudio-Ramirez et al., 2020).

Más concretamente, del análisis del gráfico de las Figuras 35 y 36 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 (densidad de energía) aumenta a medida que empeora la asimetría del devanado del rotor (aparece con muy baja intensidad en los casos sanos). Esto indica que esta componente resulta de gran utilidad para detectar la presencia de la asimetría y cuantificar su severidad, razón por la cual el indicador propuesto en este trabajo se basa en esta componente en concreto. Por otro lado, aunque esta componente tiene una naturaleza predominantemente radial, su evolución se observa para todas las posiciones del sensor, probablemente debido a su amplitud predominante y a que, en

toda posición del sensor, se capturó siempre una cierta porción del flujo radial (incluso en la posición A).

2. Por otro lado, también se observa claramente la evolución de la componente axial $s \cdot f$. Esta 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 avería) 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, obsérvese cómo, para cada posición específica del sensor, a pesar de que esta componente aumenta su intensidad a medida que aumenta la severidad del fallo, la componente es claramente observable incluso para motor sano. Esto se debe a que, como se comentó anteriormente, la amplitud de la componente $s \cdot f$ también se ve incrementada por la presencia de desalineaciones/excentricidades. Dado que el motor ensayado estuvo operando bajo cierto nivel de desalineación en todas las pruebas, esto conduce a un incremento en la amplitud de esta componente, incluso para las pruebas correspondientes a la condición sana del devanado del rotor.

Además, a fin de demostrar el potencial de la metodología propuesta para generar un diagnóstico automático de la asimetría rotórica en WRIM, la Figura 37 muestra los resultados logrados al calcular el indicador de severidad de fallo basado en la DWT de las señales de flujo. Se utiliza el indicador definido en (2), utilizando la señal wavelet $d8$ como base de tal indicador. Los resultados mostrados se obtienen utilizando el sensor tipo bobina, instalado en las tres diferentes posiciones consideradas del sensor (posiciones A, B y C de acuerdo con la Figura 18). En la Figura 39 se muestra que es posible detectar la severidad de la asimetría rotórica mediante el indicador propuesto; como se puede observar, el indicador, para el caso en que el motor está sano, muestra valores elevados, mientras que cuando la severidad de la asimetría aumenta, 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 estado sano y el motor con el máximo nivel de asimetría considerado 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. Como se observa, en la Figura 37, la posición B es la que muestra una tendencia más gradualmente decreciente, con diferencias significativas entre el estado sano y el averiado. Esta es la posición preferida del sensor de flujo en muchos trabajos que emplean sensores tipo bobina.

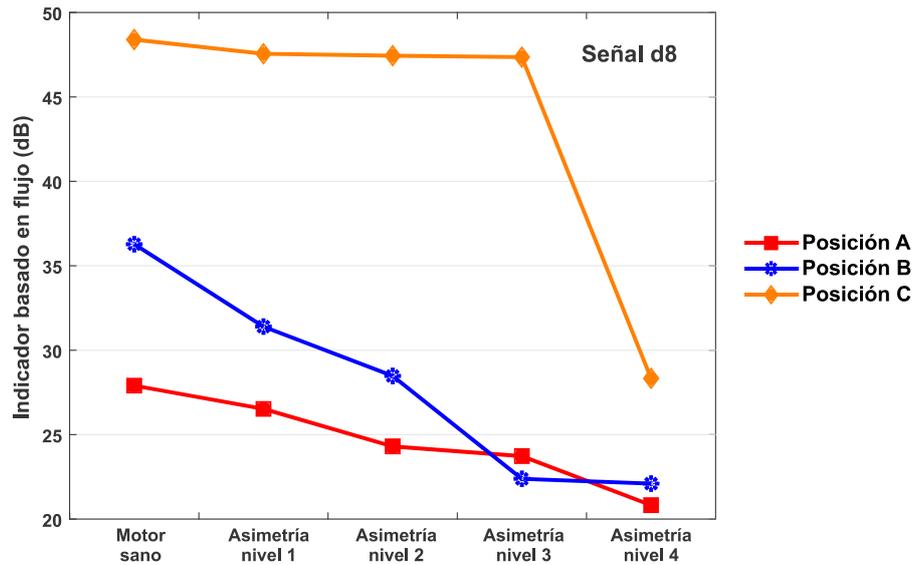


Figura 37. Valores del indicador γ_{DWT} basados en la energía de la señal wavelet d8, para un motor WRIM sano y para el motor con distintos niveles de asimetría en el devanado del rotor (Zamudio-Ramirez et al., 2020).

6.1.4 Conclusiones caso de estudio.

Mediante este caso de estudio se presenta un enfoque novedoso en el que se emplea la metodología propuesta en la presente tesis para el diagnóstico de fallas de asimetría del rotor en WRIM, un tipo de máquina que no ha sido ampliamente estudiada en el área de monitoreo de condición, pero que está ganando cada vez más atención debido a su uso en aplicaciones de gran potencia y como generador en turbinas eólicas en unidades generadoras. El método propuesto detecta patrones de falla que aparecen en los mapas de tiempo-frecuencia bajo el arranque del motor cuando la falla está presente utilizando dos técnicas de procesamiento de señales no invasivas: STFT y DWT. Se encontró que la metodología es efectiva para detectar fallas asimétricas del rotor en WRIM, incluso en condiciones sin carga donde los enfoques clásicos de estado estable pueden fallar. Los resultados también mostraron que la posición del sensor determinaba el tipo de componentes que se mostrarían en el espacio de tiempo-frecuencia, ya sea axial o radial, y que los patrones de falla eran detectables en presencia de desalineación entre el motor y la carga impulsada. El nivel de asimetría podría cuantificarse utilizando el indicador de gravedad de falla propuesto γ_{DWT} , que se basó en el DWT de las señales de flujo magnético de dispersión capturadas durante el transitorio de arranque. La técnica muestra un gran potencial para determinar la existencia de fallas en la máquina, con un valor umbral de 35 dB establecido para discriminar entre condiciones sanas y defectuosas para la posición específica del sensor analizado.



Cabe destacar que derivado de este caso de estudio se logró publicar un artículo de investigación en una de las revistas de mas prestigio en el área en la que se publican trabajos relacionados, ente otros tópicos, al diagnóstico de fallas en máquinas eléctricas. El trabajo resultante, obtenido mediante este caso de estudio quedó publicado bajo la siguiente referencia:

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: 8.162

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.

El presente caso de estudio se centra en el diagnóstico de roturas de barra y de desalineamiento en motores de inducción de rotor de jaula. En motores de menor potencia, con jaula de aluminio inyectado, la rotura de barras normalmente ocurre debido a la presencia de porosidad, la cual puede aparecer durante el proceso de inyección de aluminio durante la fabricación del rotor. Este tipo de fallo, si bien posible, es menos probable. Por el contrario, en motores grandes, con barras de cobre, éstas normalmente se encuentran soldadas a los anillos de cortocircuito. Dicho punto de unión entre barra y anillo es un punto especialmente propenso a la aparición de microgrietas, debido a los gradientes térmicos y esfuerzos electromecánicos a los que se ve sometido. Estas microgrietas, una vez aparecen, van agrandando su tamaño, hasta producirse finalmente una rotura completa de barra ([Lee et al., 2013](#)):

Más específicamente, de acuerdo con la literatura del área, se atribuyen los fallos en las barras a una combinación de diferentes esfuerzos actúan sobre 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 (DOL por su abreviatura en inglés, Direct OnLine) o sobrecarga que causan sobrecalentamiento de la jaula del rotor.
- Tensiones magnéticas debidas a fuerzas electromagnéticas, esfuerzos magnéticos desequilibrados, ruido electromagnético y vibraciones.
- Esfuerzos dinámicos como resultado de cargas mecánicas pulsantes (fluctuaciones de tensión, oscilaciones de par y fuerzas centrífugas).
- Esfuerzos mecánicos debido a laminaciones suelta, holguras y fallos en los rodamientos.
- Estrés ambiental por contaminación y abrasión del material del rotor debido a productos químicos o exposición a la humedad.

Cuando una barra se rompe completamente, deja de conducir corriente, sobrecargándose las barras adyacentes. Esto provoca mayores esfuerzos en dichas barras vecinas, las cuales pasan a ser las más propensas al fallo. De esta manera, la rotura va propagándose progresivamente a barras adyacentes. En el peor de los

casos, esta avería puede también dar lugar a efectos catastróficos inmediatos por desprendimiento de fragmentos de barras rotas, protrusión de barras, etc.. Algunos ejemplos de fallo catastrófico debido a roturas de barra se reportan en [Lee et al., 2013](#). Cuando el fallo ocurre de forma progresiva, la máquina normalmente no da síntomas externos evidentes de la presencia del fallo hasta que el nivel de severidad es elevado. De allí la importancia del desarrollo de técnicas adecuadas que permitan detectar la avería cuando se encuentra en estado incipiente.

Por otro lado, el fallo de desalineamiento ocurre cuando los ejes de motor y de la carga accionado no se encuentran perfectamente alineados. Existen diferentes tipos de desalineamiento (paralelo, angular). En cualquier caso, la presencia de desalineamiento provoca la aparición de esfuerzos desequilibrados que pueden traducirse en un nivel anormal de vibraciones y en un daño prematuro de los componentes del motor. Además, se ha demostrado que la presencia de un cierto nivel de desalineamiento disminuye el rendimiento del motor ([Garcia et al., 2019](#)).

En este caso de estudio se explora el análisis ponderado de diversas componentes de flujo magnético de dispersión capturado en la carcasa el motor bajo análisis (flujo de dispersión radial, axial y combinación de flujo dispersión axial y radial) mediante un sensor de flujo dispersión triaxial compacto, no invasivo, y de bajo coste, el cual se describe en la sección 4.3. Las señales son capturadas durante el arranque del motor y son analizadas a través de la transformada STFT. Posteriormente, se caracterizan los patrones específicos que aparecen cuando el motor se encuentra operando bajo condiciones de avería, utilizando parámetros estadísticos y no estadísticos, los cuales se emplean para alimentar 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 averías in-situ.

6.2.2 Desarrollo de los 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 38a. 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 a una tensión de 220 V a 60Hz. El motor se carga mediante un alternador ordinario siendo el nivel de carga, aproximadamente, el 25% de la carga nominal del motor. Las señales de flujo de dispersión (medidas sobre la carcasa del motor) se adquieren usando el sensor triaxial de flujo magnético

propuesto en el presente trabajo y descrito en la sección 4.3. Este sensor es colocado en la placa de características (posición A), tal y como se muestra en la Figura 38b. El sistema de adquisición de datos (DAS por su abreviatura en inglés, Data Acquisition System) se configura con una frecuencia de muestreo de 5 kHz y una longitud de registro de 30 segundos, que es suficiente para capturar el transitorio de arranque del motor. En primer lugar, el motor de inducción se prueba en estado sano, a fin de establecer un nivel de referencia para las condiciones de fallo que se forzarán a continuación. Posteriormente, se fuerza un nivel de desalineamiento leve (3.5°) a fin de estudiar el efecto de esta avería sobre las señales de flujo analizadas. A continuación, se ensayan los casos de una barra de rotor rota (1 BRB) y dos barras de rotor rotas (2 BRB), ambos con presencia de desalineamiento (MAL). Esto permite estudiar dos esquemas de averías combinadas diferentes: 1 BRB + MAL y 2 BRB + MAL, evaluando su efecto sobre las señales de flujo.

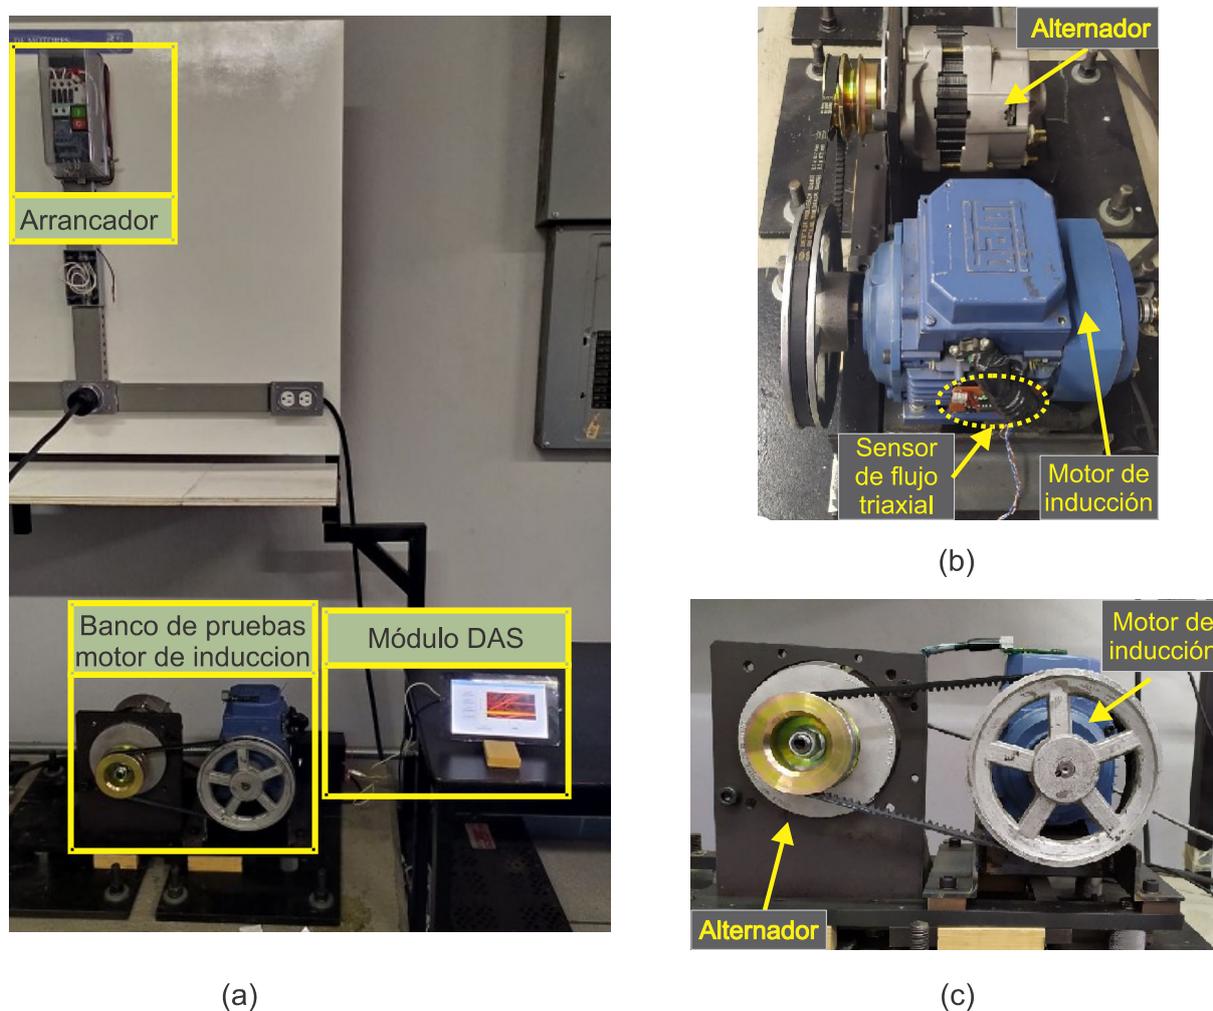


Figura 38. Configuración experimental: (a) banco de pruebas de motor de inducción, (b) vista lateral del banco de pruebas, (c) vista frontal del banco de pruebas.

En los ensayos desarrollados, el desalineamiento se llevó a cabo desplazando hacia adelante la polea del motor, de modo que los ejes transversales de rotación del motor y la carga no estuvieran alineados, formando un ángulo de separación β como se muestra en la Figura 39b. Esta condición se puede observar claramente comparando el motor alineado (Figura 39a) y el motor desalineado (Figura 39b).

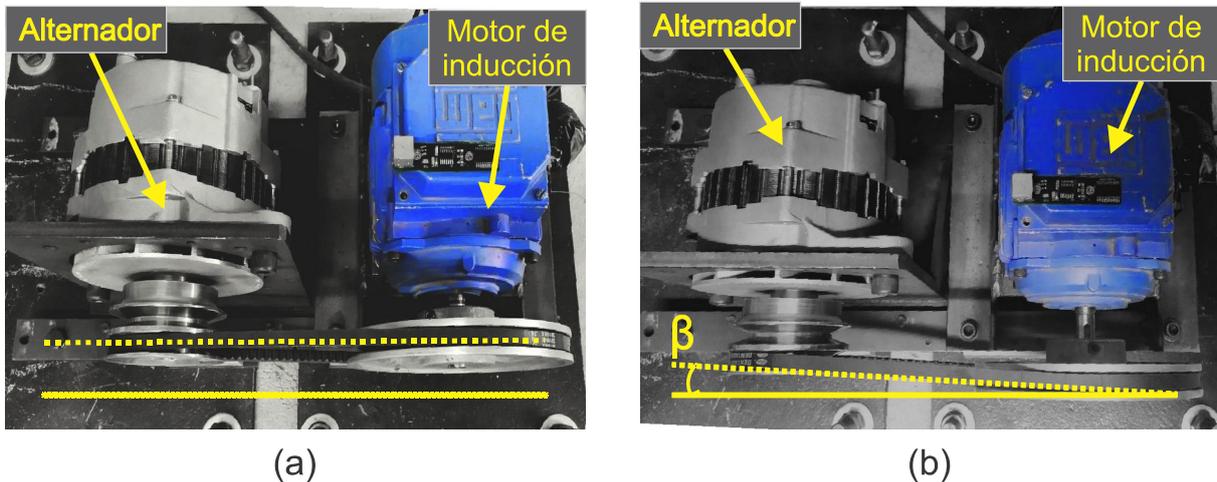


Figura 39. Banco de pruebas de motores: (a) Motor alineado. (b) motor desalineado.

Como segunda avería estudiada, se forzaron barras de rotor rotas en el motor y se combinaron simultáneamente con un cierto nivel de desalineamiento. En primer lugar, se analizó el motor con dos barras de rotor rotas y desalineamiento. Posteriormente, para demostrar que también se pueden diagnosticar fallas de menor severidad, se ensayó el caso de una barra de rotor rota en combinación con desalineación. Para producir las roturas de barra artificialmente, se perforaron orificios de 2,0 mm de diámetro en una y dos barras del rotor, respectivamente, sin dañar el eje del rotor. La Figura 40a muestra el rotor con dos barras de rotor rotas, mientras que la Figura 40b muestra una barra de rotor rota realizada en un segundo rotor que se utilizó durante la prueba.

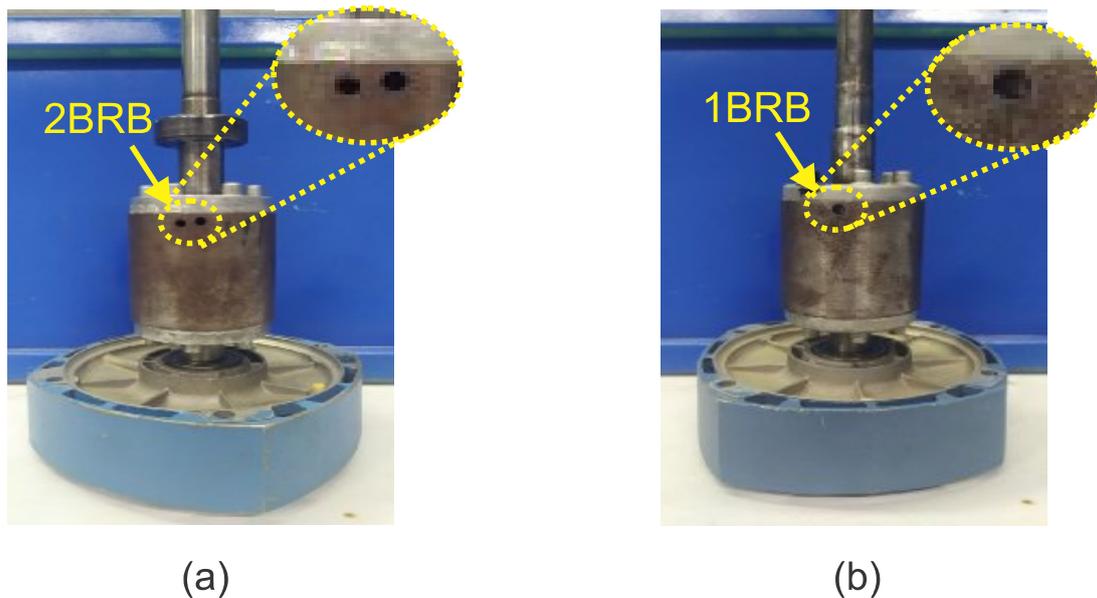


Figura 40. Banco de pruebas de motores: (a) Rotor con dos barras rotas; (b) Rotor con una barra rota.

6.2.3 Resultados y discusión del caso de estudio.

Primeramente, las componentes axial, radial y combinada (axial + radial) del flujo de dispersión se obtienen mediante el sensor triaxial de flujo de dispersión antes descrito. Posteriormente, se obtienen los mapas tiempo-frecuencia del transitorio de arranque utilizando la STFT, con una ventana del tipo Hamming que tiene una longitud de tiempo de 1024 puntos de datos que, a la frecuencia de muestreo utilizada (5 kHz), representa una anchura 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, empleándose 4096 puntos para el cálculo de la FFT para cada ventana. Estos valores se eligen con el fin de tener una resolución correcta en el dominio del tiempo ya que el transitorio de arranque en motores eléctricos tiene una duración variable dependiente de ciertos factores (inercia, carga) y que, en ciertos casos, puede ser bastante corto. 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 (en este caso, 60 Hz), ya que en esta región evolucionan la mayoría de los armónicos de más interés ligados a las averías 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 41.

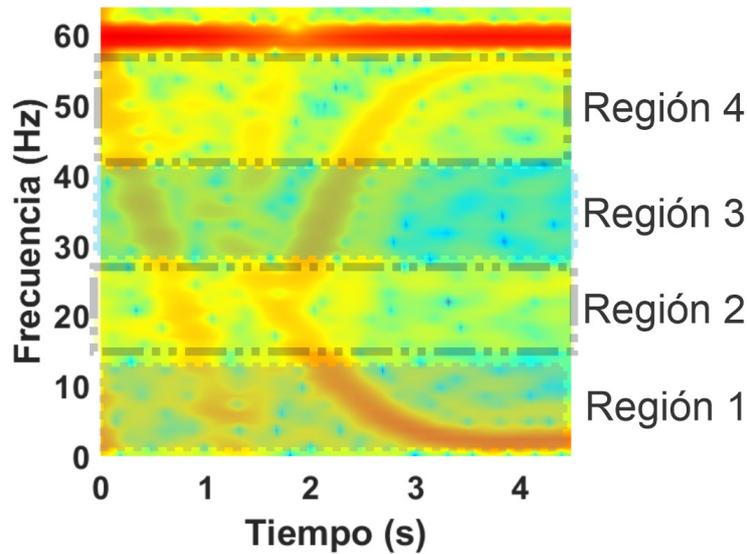


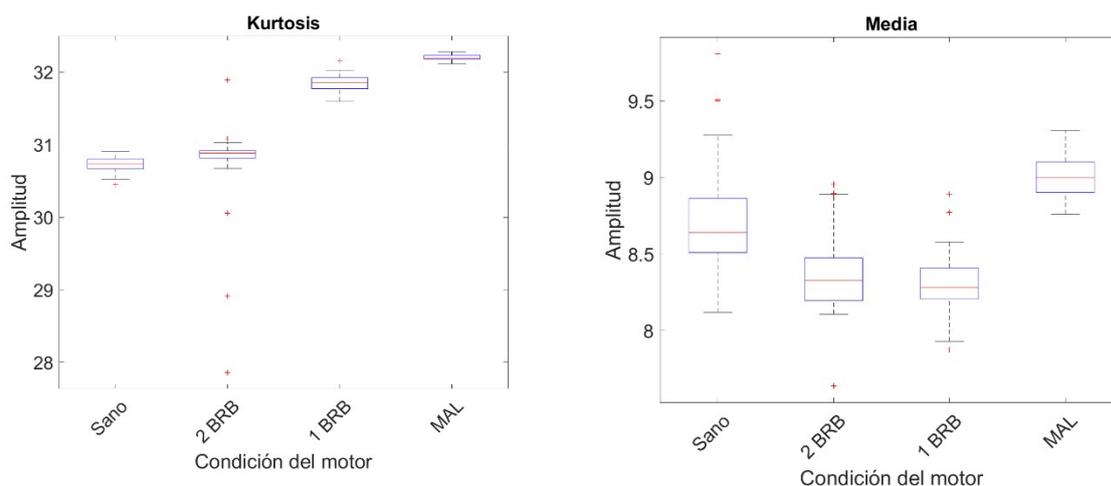
Figura 41. Bandas de frecuencia consideradas para los análisis y caracterización de los mapas STFT.

Una vez se dividen en áreas los mapas de tiempo-frecuencia, se procede a obtener 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. La Tabla 3 (localizada en la sección 3.1.2 de la presente tesis) 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; además, su cálculo implica un coste computacional reducido.

Una vez obtenidos esos parámetros, se genera una matriz de entradas, sobre la cual se aplica el proceso LDA para la reducción de características. A este respecto, el número de parámetros de entrada al LDA es 120 (=10 (parámetros estadísticos) x 4 (bandas de frecuencia) x 3 (sensores)), las cuales se reducen a 3 características significativas (F1, F2, F3); esta reducción permite para obtener una representación visual de las diferentes condiciones de fallo estudiadas aquí.

A continuación, se entrena la FFNN a fin de separar entre clases de las averías estudiadas. Este módulo se entrena primero a través del algoritmo de Levenberg-Marquardt, para identificar o bien la condición sana (HLT) en el motor de inducción o bien la presencia de las diferentes averías consideradas. Para ello, se utilizan cuarenta señales reales muestreadas para cada condición del motor, dando como resultado un total de 160 muestras. En concreto, de las 40 pruebas obtenidas para cada caso de estudio, 32 fueron utilizadas para el entrenamiento de las FFNN y 8 para la validación de las mismas. 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 para cada condición considerada), que funcionan como indicadores de la condición del motor de inducción. Las Figuras Figura 42-Figura 45 muestran los resultados obtenidos al realizar un análisis de la varianza (ANOVA) de los indicadores más representativos aquí propuestos para todas las muestras obtenidas de flujo combinado (axial + radial), en las diferentes regiones previamente definidas de los mapas tiempo-frecuencia (regiones 1 a la 4, ver Figura 41). Se trata de 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 las respectivas distribuciones de los indicadores no se superponen. Esto hace posible el empleo de una técnica de inteligencia artificial (como 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.



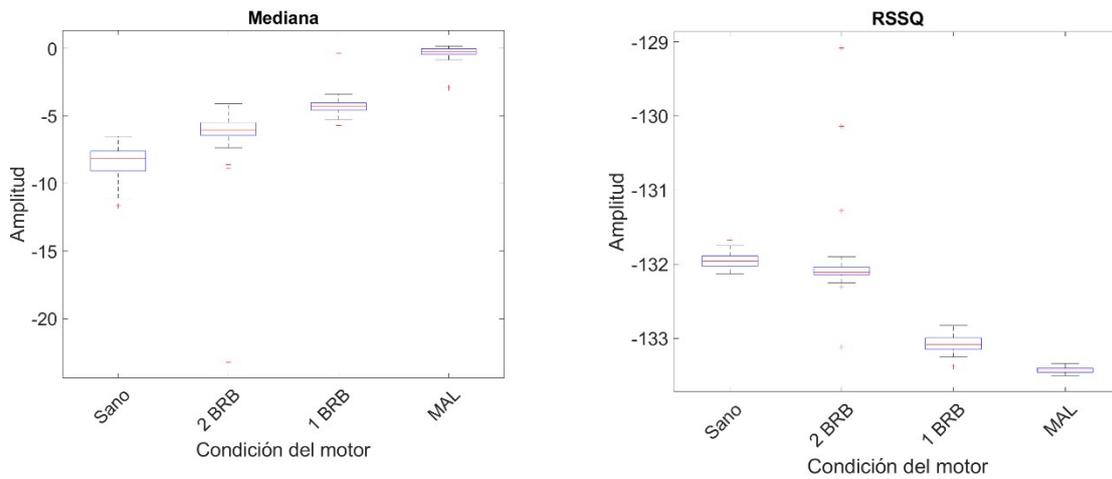


Figura 42. Análisis de la varianza para los distintos casos de estudio procesando la información de la región 4 del mapa tiempo-frecuencia para las señales de flujo combinado (axial +radial).

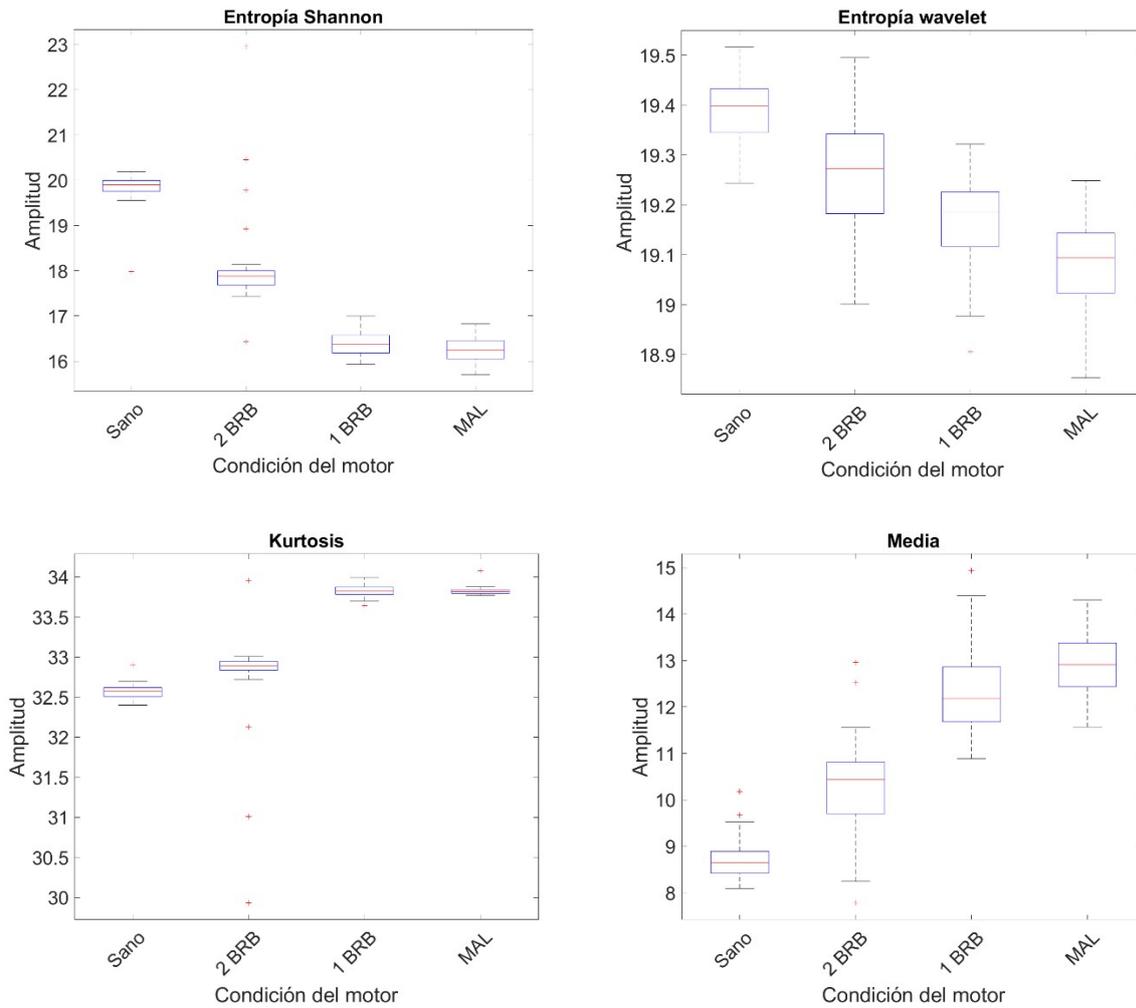


Figura 43. Análisis de la varianza para los distintos casos de estudio procesando la información de la región 3 del mapa tiempo-frecuencia para las señales de flujo combinado (axial +radial).

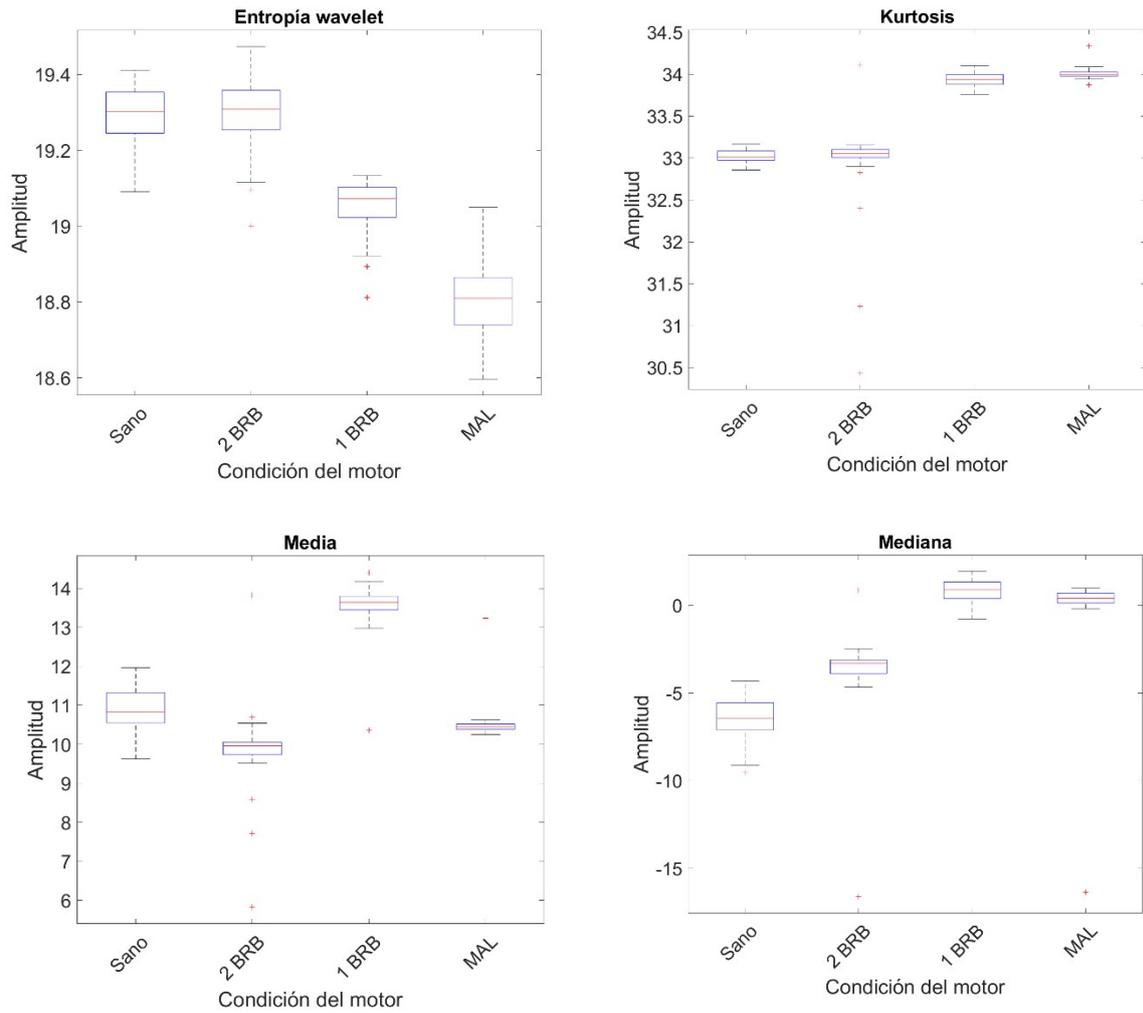
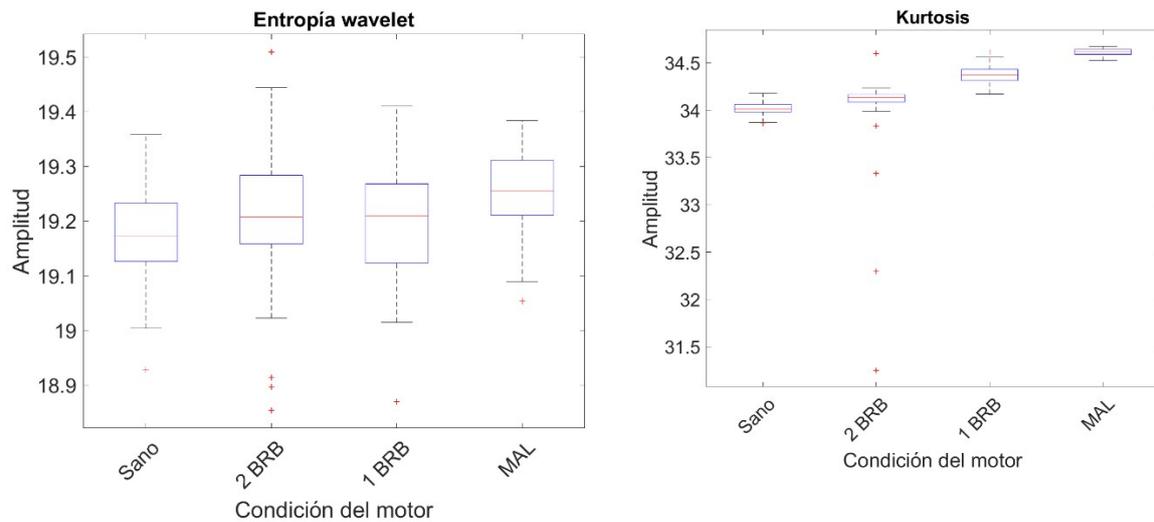


Figura 44. Análisis de la varianza para los distintos casos de estudio procesando la información de la región 2 del mapa tiempo-frecuencia para las señales de flujo combinado (axial +radial).



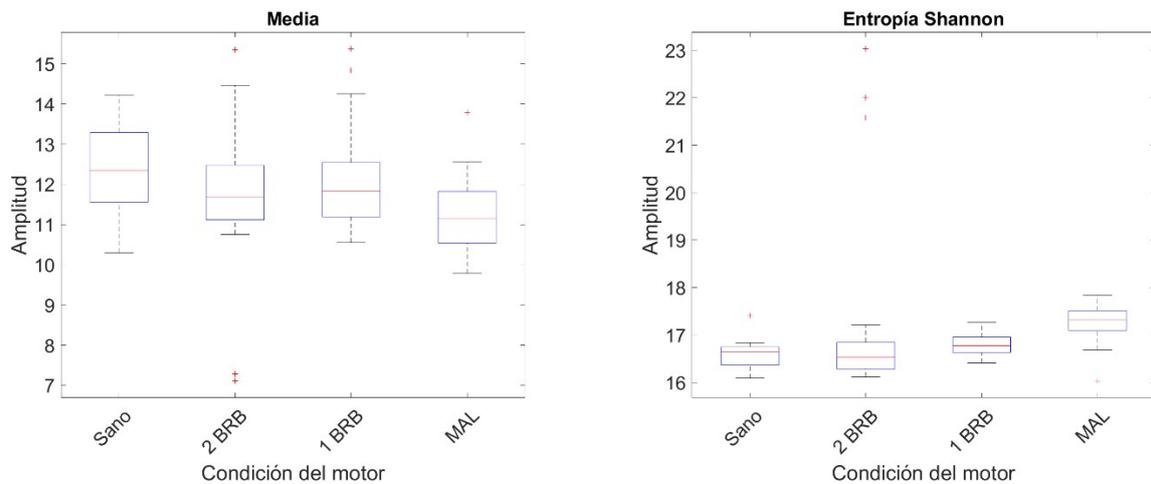


Figura 45. Análisis de la varianza para los distintos casos de estudio procesando la información de la región 1 del mapa tiempo-frecuencia para las señales de flujo combinado (axial +radial).

Debido a que en este caso de estudio se empleó por primera vez el sensor triaxial propuesto (descrito en la sección 4.3) para capturar las diferentes componentes magnéticas del flujo de dispersión desde un solo punto, la Figura 46 muestra una gráfica de dichas señales en el dominio del tiempo, para el caso de motor con dos barras rotas.

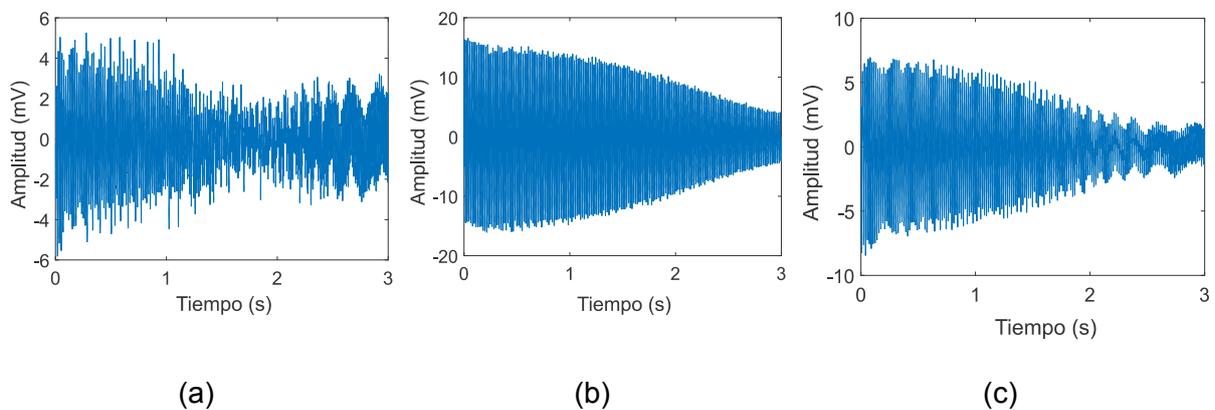


Figura 46. Señales en el dominio del tiempo capturadas por el sensor de flujo de dispersión triaxial propuesto: (a) flujo de dispersión axial; (b) combinación del flujo de dispersión combinado (axial + radial); (c) flujo de dispersión radial.

En la Figura 49, se muestran los mapas tiempo-frecuencia obtenidos con la técnica STFT al procesar las señales capturadas con el sensor triaxial de flujo propuesto, 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. En esta figura se pueden

observar las evoluciones de las componentes de avería previstas por la teoría, a saber:

- Por un lado, la componente axial en $s \cdot f$ es claramente visible, especialmente cuando se analizan las señales proporcionadas por los sensores primarios 1 y 2, los cuales capturan el flujo de dispersión axial, y el flujo combinado (axial+ radial), respectivamente,
- Por otro lado, el armónico lateral inferior amplificado por el fallo en el rotor ($f \cdot (1 - 2 \cdot s)$) es especialmente visible en el sensor primario 3, el cual captura principalmente el flujo de dispersión radial.

En síntesis, a través del sensor de flujo magnético de dispersión triaxial propuesto en esta tesis, es posible capturar las señales de flujo necesarias para obtener posteriormente las evoluciones de los armónicos de fallo (mediante herramientas especializadas de descomposición tiempo-frecuencia). Este sensor tiene la ventaja de poder capturar, en un solo punto de la carcasa, las tres componentes del flujo de dispersión. Ello redundará en una abundante cantidad de información para el diagnóstico, ya que cada componente se puede analizar independientemente con las correspondientes herramientas tiempo-frecuencia. Esto queda ilustrado en la Figura 49, en la cual se constata que:

- Para el sensor primario 1 (Figura 49a), se observa claramente el incremento de la componente axial, $s \cdot f$ que es amplificada ante ambos tipos de fallos primarios considerados (MAL y BB). Cuando el nivel de fallo en el rotor es severo (2BB) también es visible la componente radial ($f \cdot (1 - 2 \cdot s)$), si bien está es más claramente visible en otros sensores primarios que capturan mayor cantidad de flujo radial.
- La Figura 49b revela que el análisis tiempo-frecuencia de la señal del sensor primario 2 permite identificar las evoluciones de ambas componentes ($s \cdot f$ y ($f \cdot (1 - 2 \cdot s)$)), ya que este sensor captura el flujo combinado. Ambas aumentan de amplitud (densidad de energía) cuando aumenta la severidad del correspondiente fallo.
- El análisis tiempo-frecuencia del sensor primario 3 permite identificar principalmente la evolución en V de la componente radial ($f \cdot (1 - 2 \cdot s)$), siendo algo discernible la axial.

Todos estos hechos prueban que el sensor triaxial propuesto, es capaz de obtener de forma sencilla y práctica, una abundante cantidad de información para el diagnóstico, asociada a las diferentes componentes del flujo de dispersión. Todo

ello, con unos requerimientos de volumen y coste mínimos en comparación con otras soluciones.

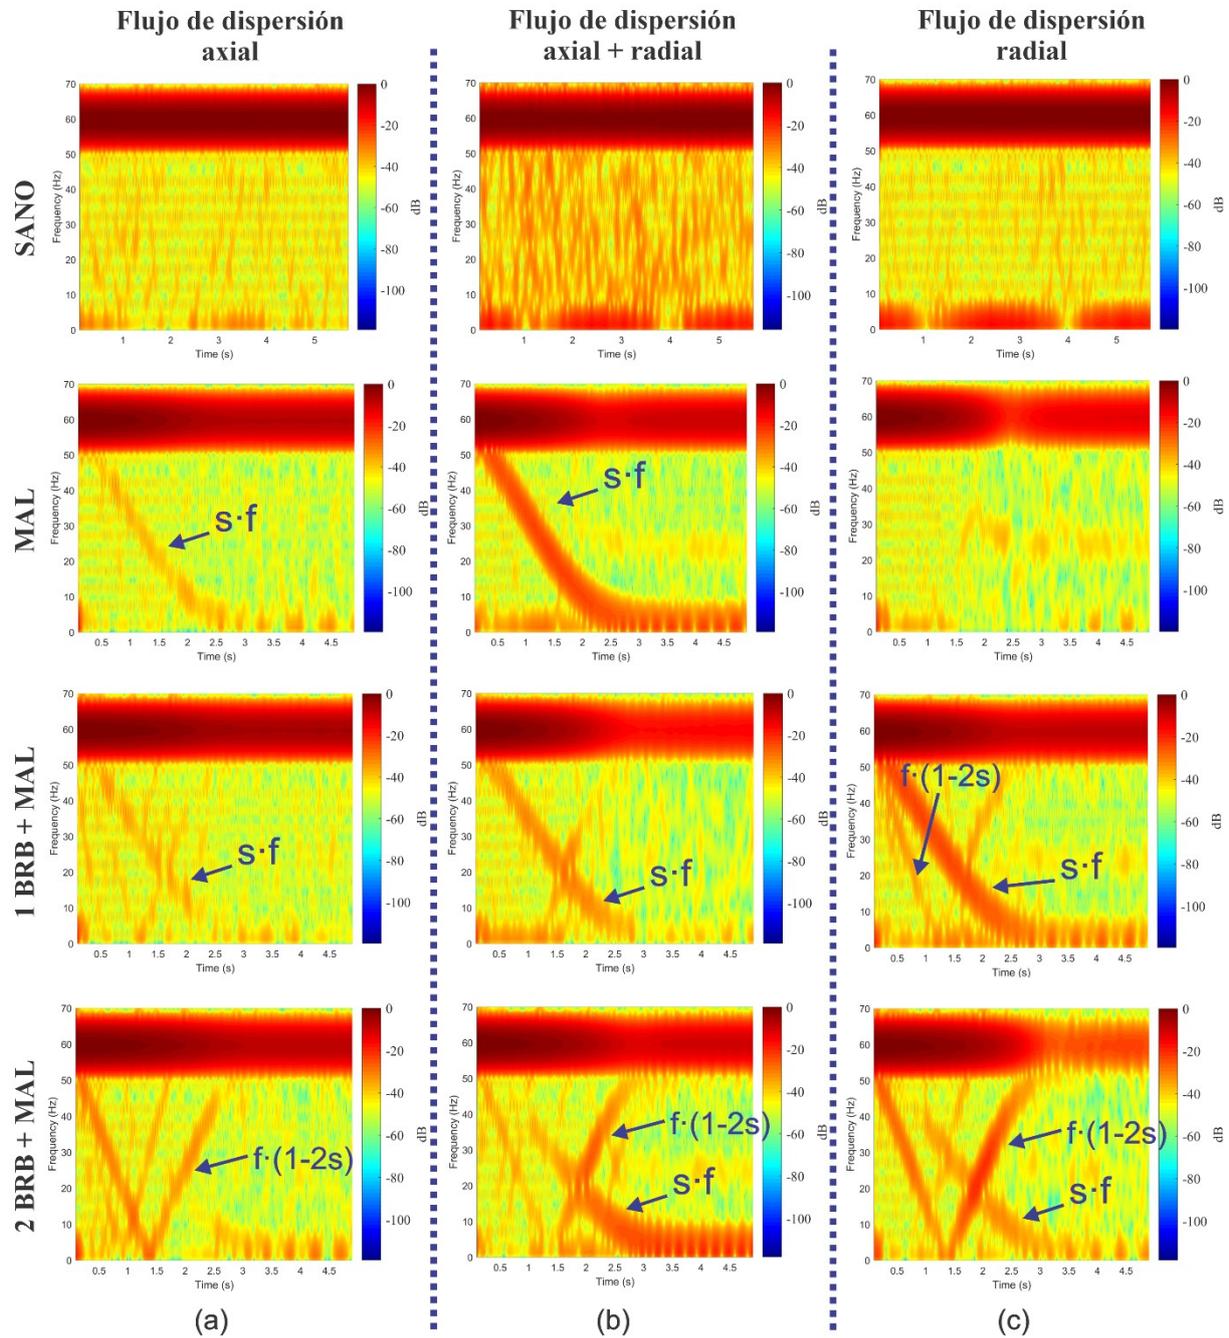


Figura 47. Análisis STFT obtenidos para cada una de las condiciones de fallo consideradas al procesar las señales proporcionadas por el sensor triaxial de flujo dispersión al instalarlo en la posición A: (a) sensor primario 1; (b) sensor primario 2; (c) sensor primario 3.

La Tabla 8 muestra los resultados obtenidos al seguir la metodología propuesta para la identificación del estado del motor de inducción. Se realizaron 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 la técnica y sus capacidades para proporcionar un diagnóstico oportuno en línea. Los resultados incluyen la identificación del estado sano, desalineamiento leve y la combinación de una y dos barras rotóricas rotas con un desalineamiento leve, 1 BRB + MAL y 2 BRB + MAL, respectivamente.

Tabla 8. Efectividad de la metodología propuesta en la identificación de las condiciones de falla del motor de inducción estudiadas aquí. HLT, motor saludable; MAL, desalineación; 1 BRB + MAL, 1 barra de rotor rota y desalineación; 2 BRB + MAL, 2 barras de rotor rotas y desalineación.

Condición del motor de inducción	Efectividad (%)
Sano	100
Desalineamiento	99.1
1 BRB + MAL	97
2 BRB + MAL	100

En este sentido, la Figura 48a 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 48b 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 b. Como se observa, con la metodología propuesta, es posible clasificar correctamente los casos de fallo considerados con elevadas efectividades, a saber: del 81,3% cuando el motor se encontraba trabajando bajo una barra rota (1 BRB), del 96,9% para el caso de dos barras rotas (2 BRB) y del 96,9% 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).

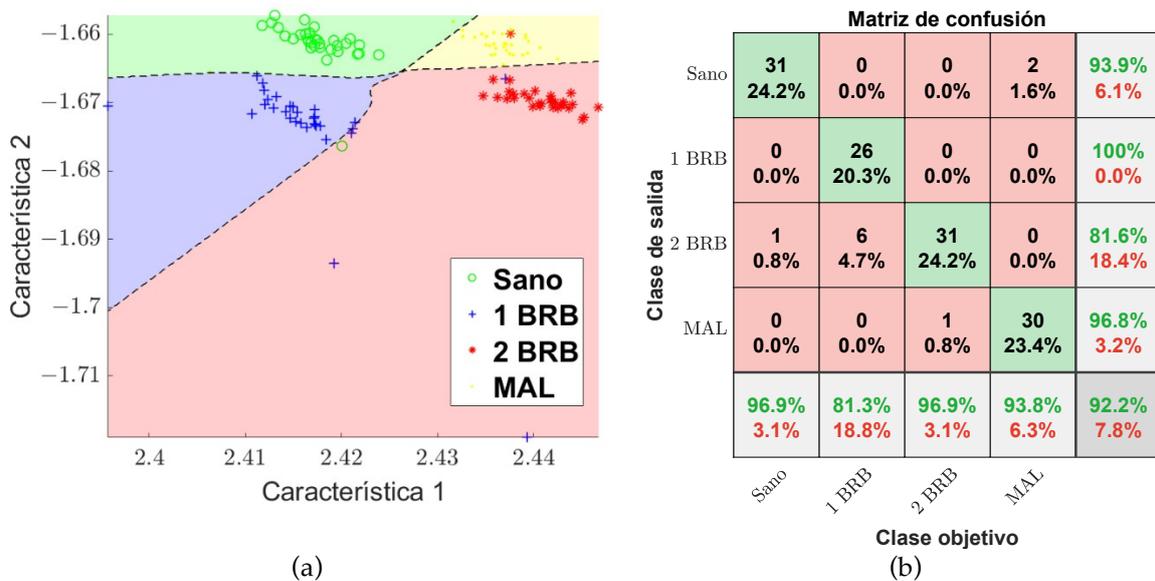


Figura 48. Resultados de clasificación de la metodología propuesta obtenidos para señales de flujo magnético de dispersión (a) Regiones de decisión resultantes modeladas por el clasificador basado en la red neuronal artificial propuesto sobre el espacio bidimensional; (b) Eficacia de clasificación.

6.2.4 Conclusiones caso de estudio.

En este caso de estudio, se empleó la metodología propuesta para el diagnóstico automatizado de fallas de barras de rotor rotas y desalineamientos en motores de inducción durante el transitorio de arranque. Se utilizó un sensor de flujo magnético de dispersión triaxial que ha sido propuesto durante el desarrollo de la presente tesis. Este sensor tiene diversas ventajas respecto a los sensores tipo bobina que han sido comúnmente para capturar las señales de flujo magnético al exterior de la máquina. La capacidad de colocar el sensor prácticamente en cualquier lugar del bastidor de la máquina es una ventaja importante, ya que proporciona flexibilidad en cuanto a la colocación y permite una integración más sencilla en los sistemas existentes. Esto es particularmente importante en situaciones donde el espacio es limitado o donde el acceso a ciertas áreas de la máquina es difícil. Adicionalmente, la capacidad de capturar los diferentes componentes del flujo errante también es crucial, ya que proporciona una visión más completa del estado de la máquina. Al capturar múltiples componentes del flujo de dispersión, el sensor puede proporcionar información sobre una gama más amplia de problemas potenciales, lo que permite un diagnóstico de problemas más preciso y efectivo. Adicionalmente, mediante este caso de estudio se demostró que el sensor triaxial puede visualizar de manera efectiva las condiciones de falla en los motores eléctricos a través de mapas de tiempo-frecuencia, de acuerdo con las expectativas teóricas. El armónico $f_s(1-2 \cdot s)$, que se amplifica en caso de barras de rotor rotas, se observa mejor a través del flujo

de dispersión radial, mientras que el armónico $s \cdot f$, que indica desalineaciones mecánicas y barras de rotor rotas, es más visible en los mapas tiempo-frecuencia del flujo magnético de dispersión axial y combinado. Un diagnóstico automatizado de fallas es posible a través de un análisis discriminante lineal y una red neuronal artificial, que consideran el peso de diferentes componentes de flujo magnético de dispersión. La metodología desarrollada puede identificar, caracterizar y diagnosticar fallas rápidamente, con la capacidad de adaptarse a otros tipos de fallas.

Es importante mencionar que como resultado de este estudio de caso, se logró publicar un artículo de investigación en una revista con alto factor de impacto en el campo de la detección de fallos en máquinas eléctricas y otros temas relacionados. El trabajo resultante obtenido a través de este estudio de caso se publicó bajo la siguiente referencia:

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*, 20(5), 1477.

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

6.3.1 Motivación del caso de estudio

Diversos estudios han demostrado que los fallos en rodamientos constituyen una de las averías más frecuentes en motores eléctricos (Bonnett et al., 2008) (Thomson et al., 2001). A pesar de las discrepancias que existen entre algunos de estos estudios en lo relativo a la tasa de ocurrencia atribuida a este tipo de fallo, todos ellos concuerdan en que se trata de uno de los más comunes e importantes y que, además, sus consecuencias pueden ser catastróficas para la integridad de la máquina. Los fallos en los rodamientos se suelen atribuir a diversas causas, como sobrecargas, lubricación inadecuada, contaminación externa, instalación incorrecta, circulación de corrientes, entre otras. Estas causas pueden provocar fallos localizados en componentes individuales del rodamiento o fallos distribuidos que pueden causar vibraciones no deseadas y disminución del rendimiento, incluso hasta un fallo catastrófico que provoque paradas de producción. Normalmente, se diagnostica este tipo de fallo mediante análisis de vibraciones, pero en casos en los que no se pueda instalar un acelerómetro o si el análisis de vibraciones no es concluyente. Además, las fallas de la pista exterior, que son cada vez más frecuentes con el uso de variadores de frecuencia como fuentes de alimentación, son una falla difícil de detectar debido a las señales relacionadas con fallas de baja amplitud. Actualmente no existe una metodología o estudio informado que diagnostique con precisión el desgaste gradual en la pista exterior de los rodamientos utilizando enfoques no invasivos sin información previa sobre los rodamientos.

En este caso de estudio, se presenta la implementación de la metodología propuesta para el diagnóstico del desgaste gradual de la pista exterior de rodamientos metálicos de bolas. Se muestra la capacidad de la metodología para clasificar la severidad del fallo (diámetro de la perforación en la pista exterior), a través de un análisis de las señales de flujo de dispersión registradas en la carcasa del motor. El análisis y caracterización de la respuesta de la cadena cinemática, ante la presencia del fallo, se realiza mediante indicadores estadísticos y no estadísticos en el dominio del tiempo. Posteriormente, se realiza un diagnóstico final de severidad del fallo mediante la aplicación de un análisis discriminante lineal (LDA) a las diversas características temporales obtenidas. Finalmente, se realiza una indicación automática mediante una red neuronal de avance (FFNN). Esta propuesta se basa en el hecho (según lo apuntado por la literatura técnica del área, y como se describe en la sección 2.2.1) de que los efectos del fallo en rodamiento sobre las señales de

vibración se traducen en una amplificación de ciertas frecuencias en la señal de corriente del estator, modificando también el flujo de dispersión alrededor del motor. 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 (consultar sección 4.3 para más detalle acerca del mismo).

6.3.2 Desarrollo de los experimentos.

La validación de la metodología propuesta 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 basado en correas y poleas y una carga mecánica consistente en un alternador, el cual representa, aproximadamente, el 25% de la carga nominal del motor (ver Figura 49c). El motor de inducción trifásico analizado (modelo WEG 00136APE48T) tiene 2 polos, 28 barras en el rotor y una potencia nominal de 0,746 kW. Se alimenta a 220 V y 60 Hz, a través de un arrancador, como se muestra en la Figura 49a. 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 (VFD por su abreviatura en inglés, Variable Frequency Drive) modelo WEG CFW08, el cual se puede observar en la Figura 49a.

Las señales de flujo de dispersión se capturan mediante el sensor de flujo de dispersión triaxial (que está compuesto esencialmente por tres transductores de efecto Hall individuales ubicados en ejes perpendiculares entre sí) que se instala en la placa de características, como se muestra en la Figura 49b. Las señales de flujo de dispersión se adquieren mediante un módulo propietario de sistema de adquisición de datos (DAS, por su abreviatura en inglés Data Acquisition System) y a continuación 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 régimen permanente. Con el fin de disponer de un número significativo de datos, se obtuvieron 7 señales diferentes para cada caso de estudio, como se indica en la Tabla 9. De este modo, se recolectan un total de 210 muestras durante las pruebas.

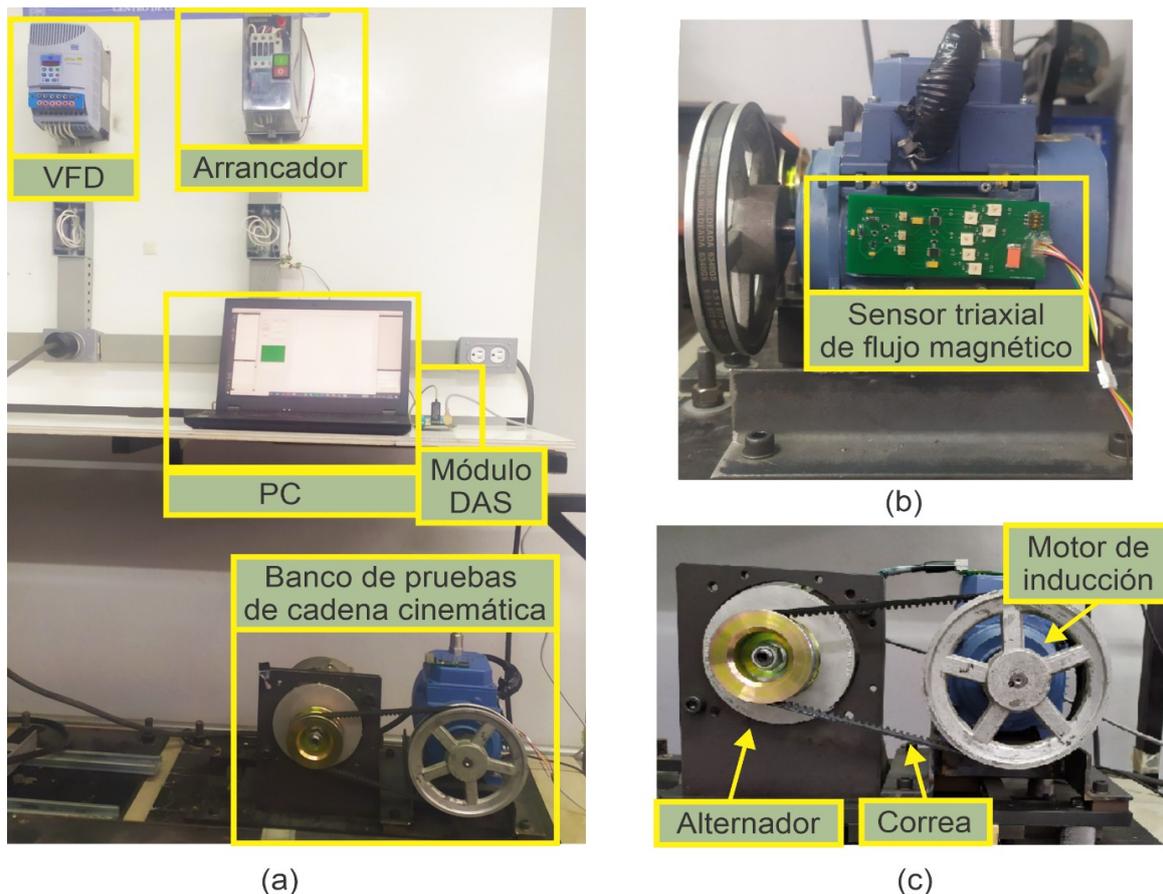


Figura 49. Configuración experimental: (a) Banco de pruebas de cadena cinemática. (b) Vista lateral del banco de pruebas. (c) Vista frontal del banco de pruebas

Tabla 9. Matriz de prueba 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	
	15 Hz VFD	7	
	50 Hz VFD	7	35
	60 Hz VFD	7	
	60 Hz arranque directo	7	
4 mm	5 Hz VFD	7	
	15 Hz VFD	7	
	50 Hz VFD	7	35
	60 Hz VFD	7	
	60 Hz arranque directo	7	
5 mm	5 Hz VFD	7	
	15 Hz VFD	7	
	50 Hz VFD	7	35
	60 Hz VFD	7	
	60 Hz arranque directo	7	
			Total = 210 pruebas

Los diferentes experimentos se realizan instalando diferentes rodamientos metálicos modelo 6203 2RS, como el que se muestra en la Figura 50. Este modelo de rodamiento tiene 8 bolas, 40 mm de diámetro exterior (D) y 17 mm de diámetro interior (d). El fallo en la pista exterior del rodamiento 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 forzando diferentes diámetros de orificio, a saber: 1 mm, 2 mm, 3 mm, 4 mm y 5 mm (ver Figura 51). En todas las averías consideradas, los experimentos se realizan sustituyendo el rodamiento sano por cada uno de los rodamientos dañados. De este modo, el único elemento del motor que es intercambiado para cada caso de estudio es el rodamiento, mientras se cuida que el motor quede perfectamente alineado cada vez que se monta.



Figura 50. Rodamiento metálico modelo 6203 2RS, utilizado durante la experimentación.

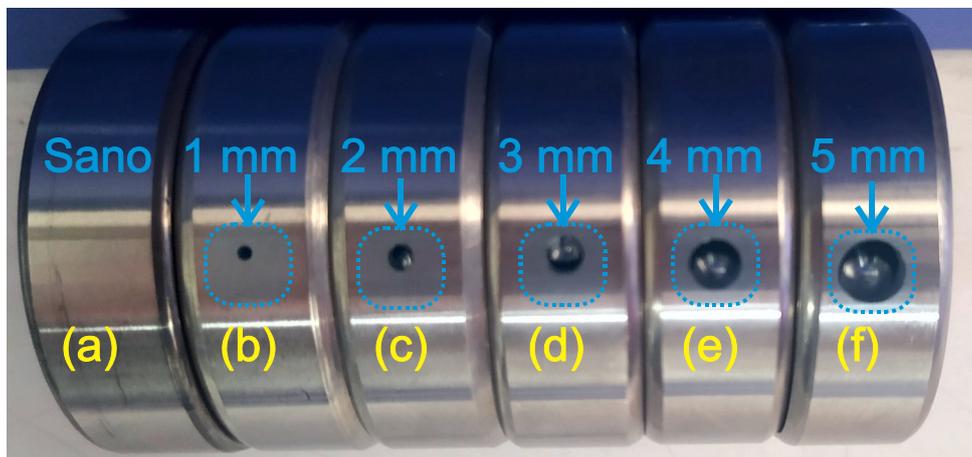


Figura 51. Rodamientos utilizados durante los experimentos. (a) Rodamiento sano. (b) Rodamiento con un daño de 1 mm en la pista exterior. (c) Rodamiento con un daño de 2 mm en la pista exterior. (d) Rodamiento con un daño de 3 mm en la pista exterior. (e) Rodamiento con un daño de 4 mm en la pista exterior. (f) Rodamiento con un daño de 5 mm en la pista exterior.

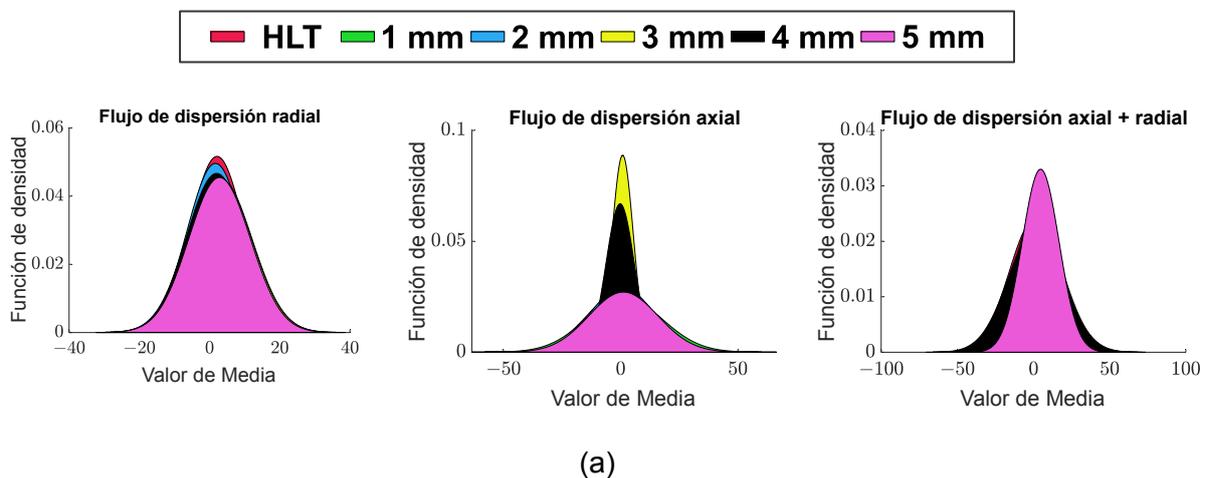
6.3.3 Resultados y discusión del caso de estudio.

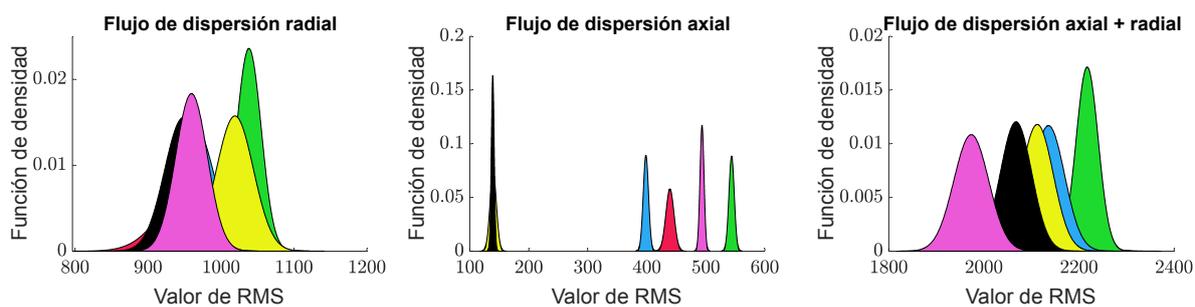
Siguiendo la metodología propuesta, se analizan las respuestas de las señales de flujo de dispersión para cada condición de rodamiento (es decir, rodamiento en estado sano y rodamiento con 1 mm, 2 mm, 3 mm, 4 mm y 5 mm de diámetro en la perforación provocada en la pista exterior). Adicionalmente, la metodología propuesta es validada tanto para funcionamiento con el motor directamente conectado a la red, como para accionamiento mediante variador de frecuencia, considerando diferentes frecuencias de alimentación proporcionadas por éste (60 Hz, 50 Hz, 15 Hz y 5 Hz). La Figura 52 muestra gráficamente las funciones de densidad normalizadas que definen las zonas de detectabilidad obtenidas mediante

los distintos indicadores calculados para el caso en que el motor se alimenta a 60 Hz bajo una conexión directa a la red, a saber: media aritmética, valor máximo, media cuadrática (SRM), raíz cuadrada media (RMS), desviación estándar (σ), varianza (σ^2), factor de forma RMS (SF_{RMS}), factor de forma SRM (SF_{SRM}), factor cresta (CF), factor de latitud (LF), factor de impulso (IF), oblicuidad (S_k), curtosis (k), quinto momento ($5_{th}M$), sexto momento ($6_{th}M$). Estos indicadores pueden ser calculados de acuerdo a las expresiones señaladas en la Tabla 3. De esta forma, la Figura 52a revela que el valor medio no proporciona ninguna información discriminativa, ya que los diferentes niveles de severidad del fallo se superponen, lo que evidencia que no existe ninguna relación entre el fallo y este indicador. De manera similar, la Figura 52b–d demuestra que los indicadores RMS, SMR, y σ pueden brindar información discriminatoria relevante para los diferentes niveles de severidad de fallo considerados (ya que hay escasa superposición entre ellos). Por otro lado, la Figura 52 muestra que por medio de las características de dominio en el tiempo RMS, SMR y σ es posible discriminar individualmente entre los casos de fallo correspondientes a rodamiento sano y con 1 mm, 2 mm y 5 mm de perforación, ya que prácticamente la superposición es nula en todos estos casos (al analizar el flujo de dispersión axial). Además, la Figura 53a–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 redes neuronales artificiales o alguna otra técnica específica para ello), ya que existe una superposición en todos los casos. Finalmente, la Figura 54a, c indica que hay datos discriminativos casi nulos en los indicadores del dominio de tiempo S_k y $5_{th}M$ cuando el motor se alimenta a 60 Hz bajo conexión directa a la red. No obstante, la Figura 54d 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 los diferentes niveles de severidad de fallo.

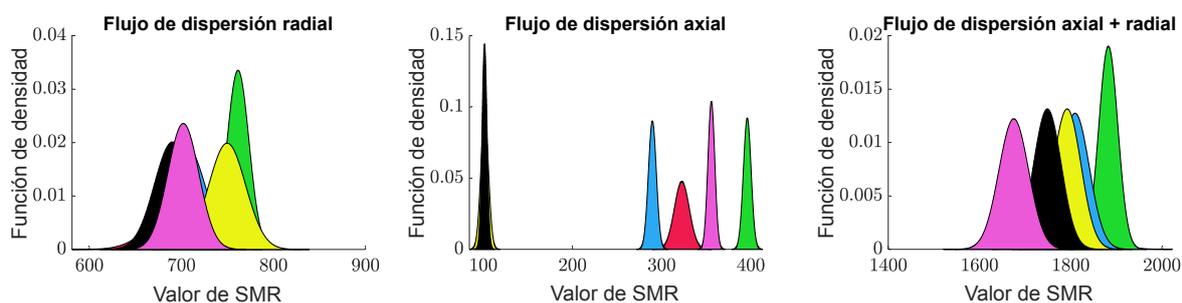
En vista a lo anterior, cabe señalar que no se puede realizar un diagnóstico final y confiable mediante la evaluación directa de un solo indicador estadístico y/o no estadístico, ya que se puede obtener una falsa indicación no deseada al obtenerse una superposición entre diferentes severidades de falla. 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 con el fallo bajo estudio. Por otra parte, es de notar que no todos los indicadores muestran un valor discriminativo que permita distinguir entre los diferentes niveles de severidad de fallo, 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, para seleccionar el conjunto de indicadores más discriminativo, 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; posteriormente, se concatenan los mismos tres indicadores para el flujo de dispersión axial, radial y axial +radial). A continuación, estos subconjuntos se evalúan a través del puntaje de Fisher, el cual se calcula aplicando (23), y se selecciona la mejor combinación, es decir, el subconjunto con los valores de puntaje de Fisher más altos. La Tabla 10 resume los subconjuntos de indicadores calculados en el dominio del tiempo y el indicador de dimensión fractal de Katz con los valores más altos del puntaje de Fisher. Se puede observar claramente que la combinación de σ , k , KFD , SF_{RMS} , SF_{SRM} , $5_{th}M$, $6_{th}M$ y SMR funciona mejor para discriminar los casos de fallo considerados cuando el motor impulsor se alimenta a 60 Hz estando directamente conectado a red. De manera similar, la mejor combinación de características para diagnosticar los casos de fallo en la pista exterior considerados cuando el motor impulsor es alimentado a 60 Hz mediante un variador de frecuencia (VFD) es la basada en los indicadores RMS , SRM , σ , SF_{RMS} , SF_{SRM} , KFD , y media aritmética. Por otro lado, también se observa 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 Tabla 10. De manera similar, la Tabla 11 recopila los mejores conjuntos de indicadores que proporcionan información más discriminatoria para el diagnóstico de los fallos considerados en los rodamientos cuando se alimenta el motor a 15 Hz y 5 Hz.

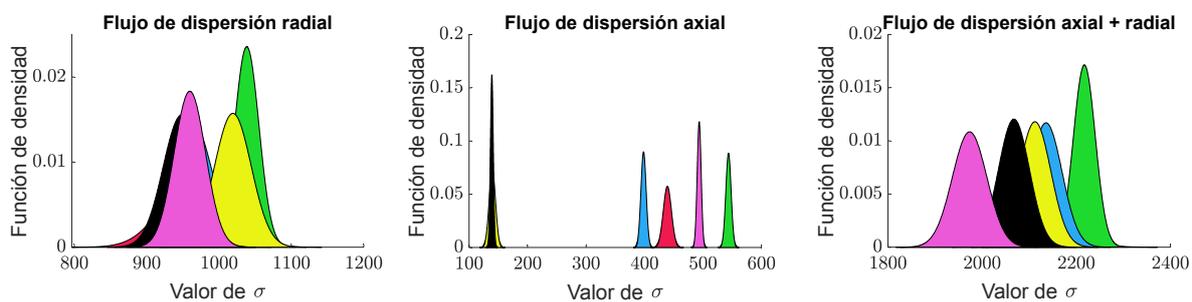




(b)

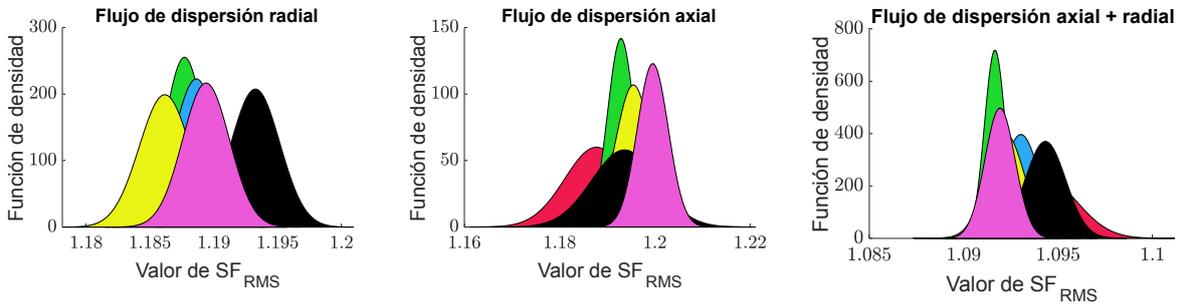


(c)

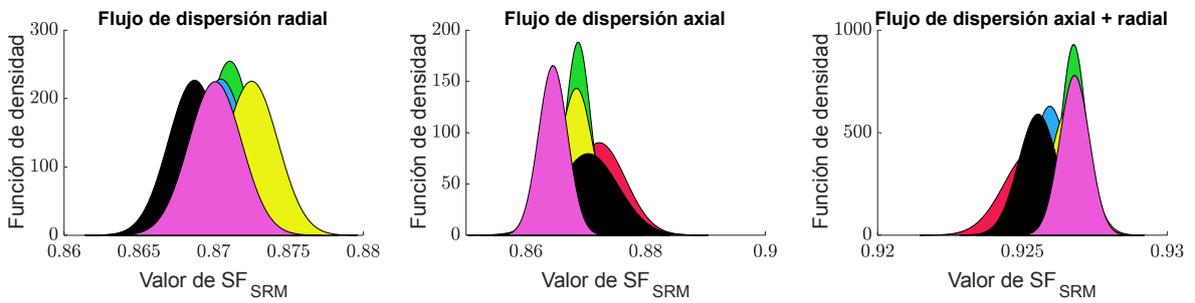


(d)

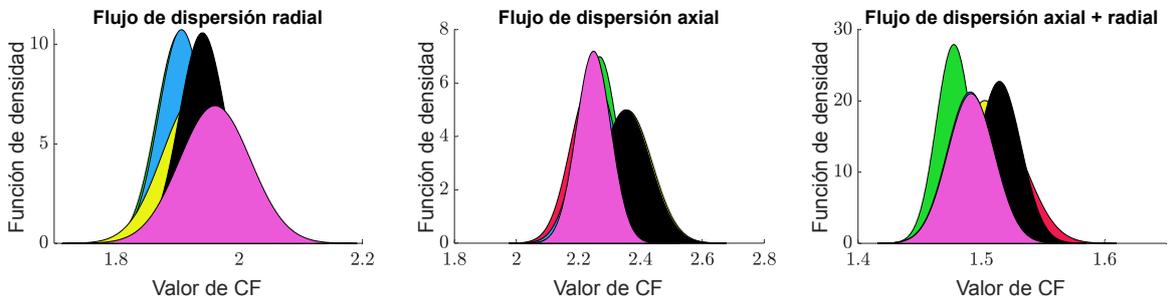
Figura 52. Funciones de densidad normalizadas que definen las zonas de detectabilidad obtenidas por los diferentes indicadores estadísticos y no estadísticos aquí propuestos para las diferentes componentes del flujo de dispersión utilizando: (a) Valor medio. (b) valor RMS. (c) valor SMR. (d) valor de σ .



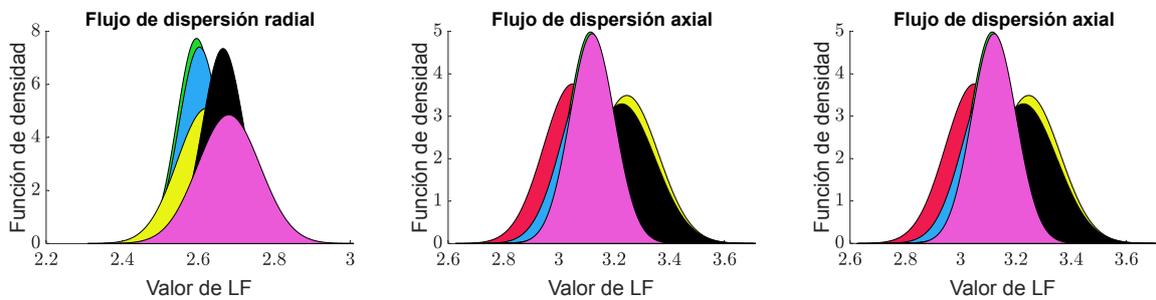
(a)



(b)

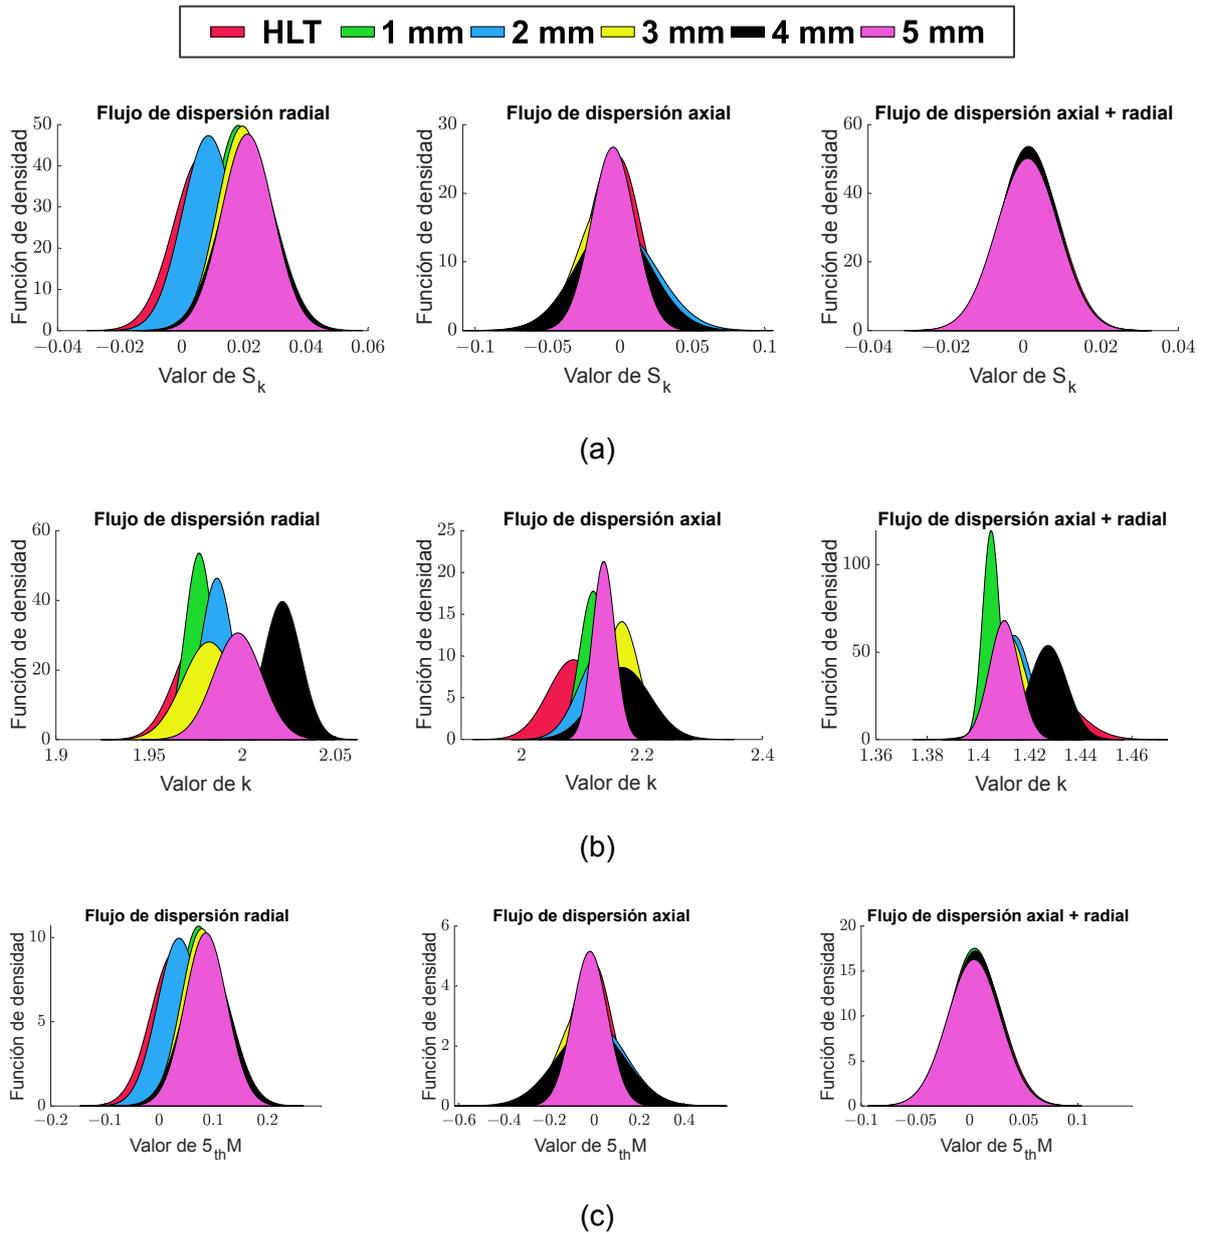


(c)



(d)

Figura 53. Funciones de densidad normalizadas que definen las zonas de detectabilidad obtenidas por los diferentes indicadores estadísticos y no estadísticos aquí propuestos para las diferentes componentes del flujo de dispersión utilizando: (a) valor SF_{RMS} . (b) Valor SF_{SRM} . (c) Valor CF. (d) Valor LF.



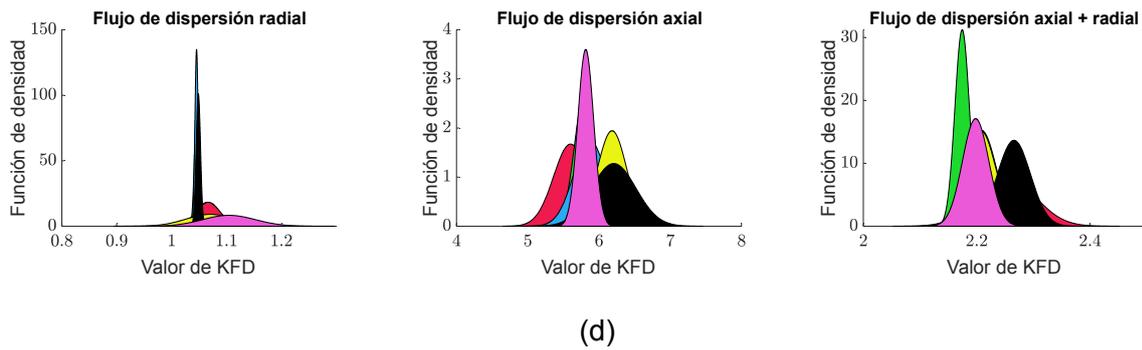


Figura 54. Funciones de densidad normalizadas que definen las zonas de detectabilidad obtenidas por los diferentes indicadores estadísticos y no estadísticos aquí propuestos para las diferentes componentes del flujo de dispersión utilizando: (a) valor S_k . (b) Valor k . (c) Valor $5_{th}M$. (d) Valor KFD.

Tabla 10. 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 60 Hz y 50 Hz.

		Frecuencia de operación				
		60 Hz arranque directo	60 Hz VFD		50 Hz VFD	
Severidad de fallo en el rodamiento	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 11. 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 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

Finalmente, en la última etapa de la metodología propuesta, se realiza un proceso de reducción de características mediante un análisis discriminante lineal. Mediante esta técnica todos los indicadores estadísticos seleccionados se proyectan en un pequeño subconjunto, de cara a maximizar la separación lineal entre diferentes clases al combinar la información proporcionada por 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 55a muestra las regiones de decisión para la clasificación resultantes, y que son obtenidas tras el entrenamiento y prueba del clasificador, basado en una red neuronal, para los diferentes niveles de fallo considerados, cuando el motor se alimenta a 60 Hz directamente conectado a red. Además, la Figura 55b proporciona una vista ampliada de una zona crítica (en la que la separación entre clases es menor). A partir de esta figura, se puede observar claramente que la dispersión obtenida para las diferentes severidades de fallo es mínima, mientras que la separación entre clases es grande. De manera similar, la Figura 56a 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 mediante un VFD a 60 Hz. Además, la Figura 56b (que es una vista ampliada de la zona del rectángulo negro que se encuentra en la Figura 56a) revela que no hay superposición ni clasificación errónea entre los fallos de 3 mm y 4 mm de

gravedad, a pesar de estar en una regió cercana. Resultados similares se pueden observar en las Figura 57 y Figura 58.

Con respecto a los límites de decisión y la proyección obtenida cuando el motor impulsor se alimenta a 5 Hz, la Figura 59 muestra que existe una clasificación errónea entre el rodamiento sano y el rodamiento defectuoso para 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 los atributos temporales utilizados 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 tienen un comportamiento lineal con respecto a la severidad del fallo. Además, se a partir de los resultados obtenidos, se concluye que diferentes subconjuntos de características en el dominio del tiempo brindan información discriminatoria relevante para diagnosticar fallos en los rodamientos para las diferentes frecuencias de suministro de energía estudiadas aquí. Sin embargo, las características totales utilizadas para discriminar todas las severidades de fallo en los rodamientos bajo diferentes frecuencias de suministro de energía se limitan a los siguientes indicadores: σ , k , KFD , $SF_{S_{RM}}$, SF_{RMS} , $5_{th}M$, $6_{th}M$, SMR , RMS y σ^2 , tal como se indica en las Tablas Tabla 10 y Tabla 11. Adicionalmente, la información mostrada en las Tablas Tabla 10 y Tabla 11 revela que la dimensión fractal de Katz y σ resultan indispensables para una correcta clasificación de la severidad del fallo, ya que estos indicadores se encuentran en casi todos los subconjuntos que tienen mayores valores en la puntuación de Fisher.

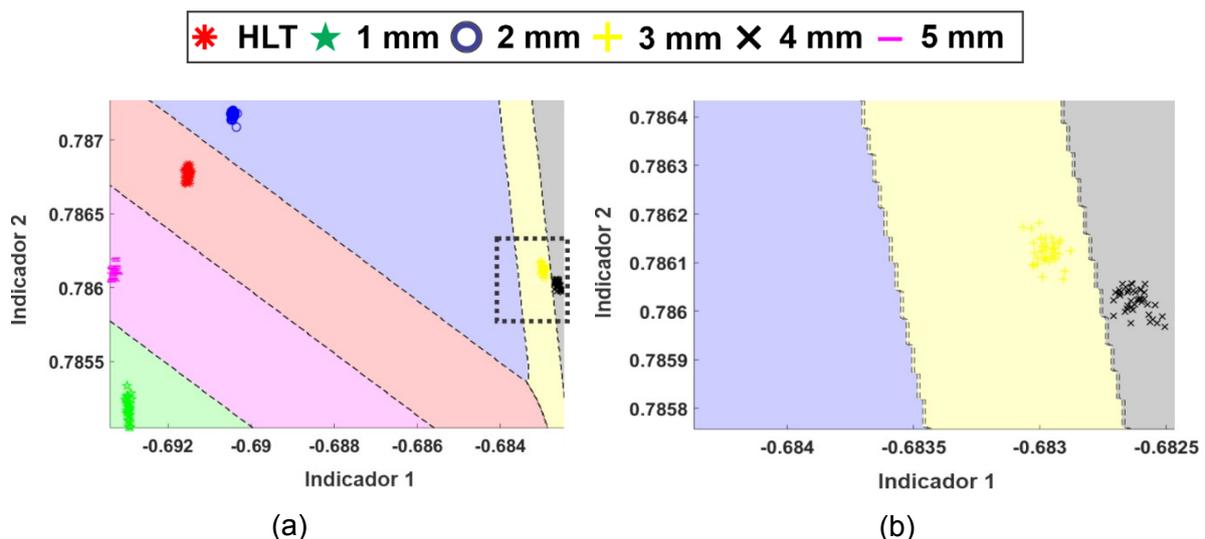


Figura 55. Proyección de las regiones de decisión para la clasificación de fallos múltiples calculada mediante el clasificador basado en la red neuronal artificial propuesto cuando el motor de inducción funciona a 60 Hz bajo un arranque directo: (a) Vista completa de la proyección. (b) Vista ampliada de la zona del rectángulo negro.

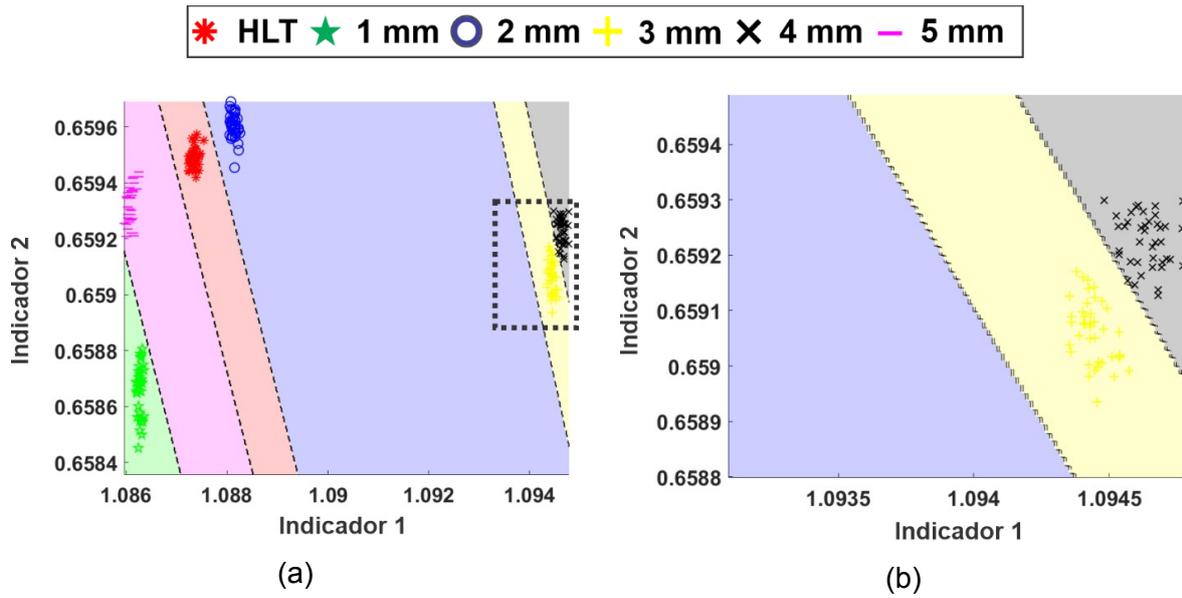


Figura 56. Proyección de las regiones de decisión para la clasificación de fallos múltiples calculada mediante el clasificador basado en la red neuronal artificial propuesto cuando el motor de inducción funciona a 60 Hz bajo un arranque empleando un variador de frecuencia: (a) Vista completa de la proyección. (b) Vista ampliada de la zona del rectángulo negro.

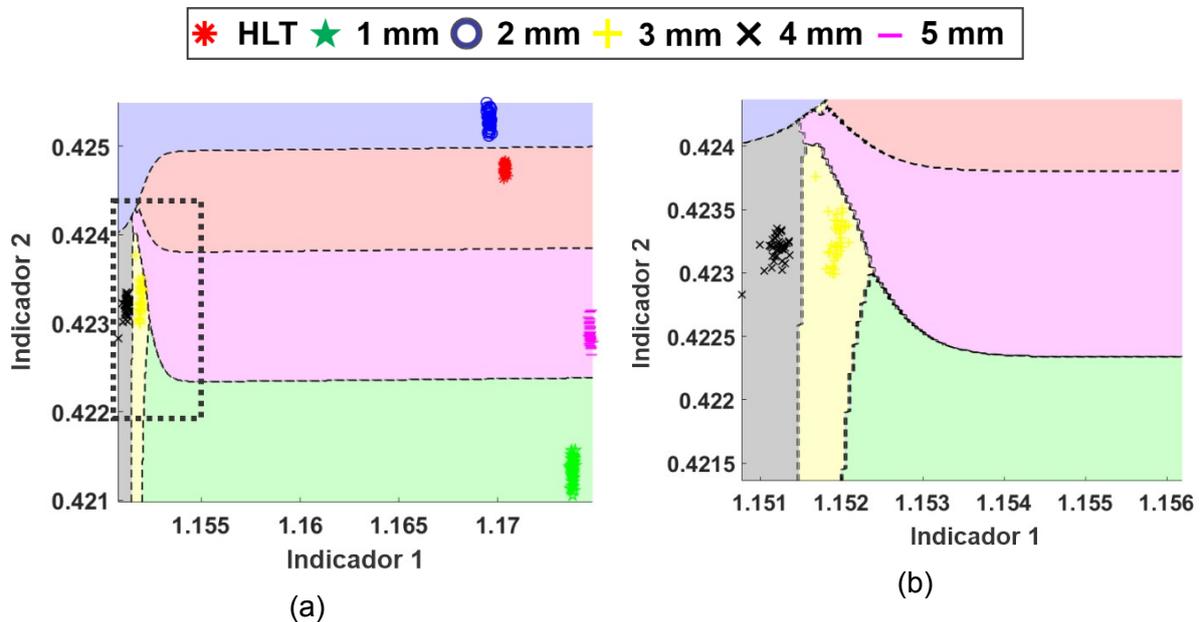


Figura 57. Proyección de las regiones de decisión para la clasificación de fallos múltiples calculada mediante el clasificador basado en la red neuronal artificial propuesto cuando el motor de inducción funciona a 50 Hz bajo un arranque empleando un variador de frecuencia: (a) Vista completa de la proyección. (b) Vista ampliada de la zona del rectángulo negro.

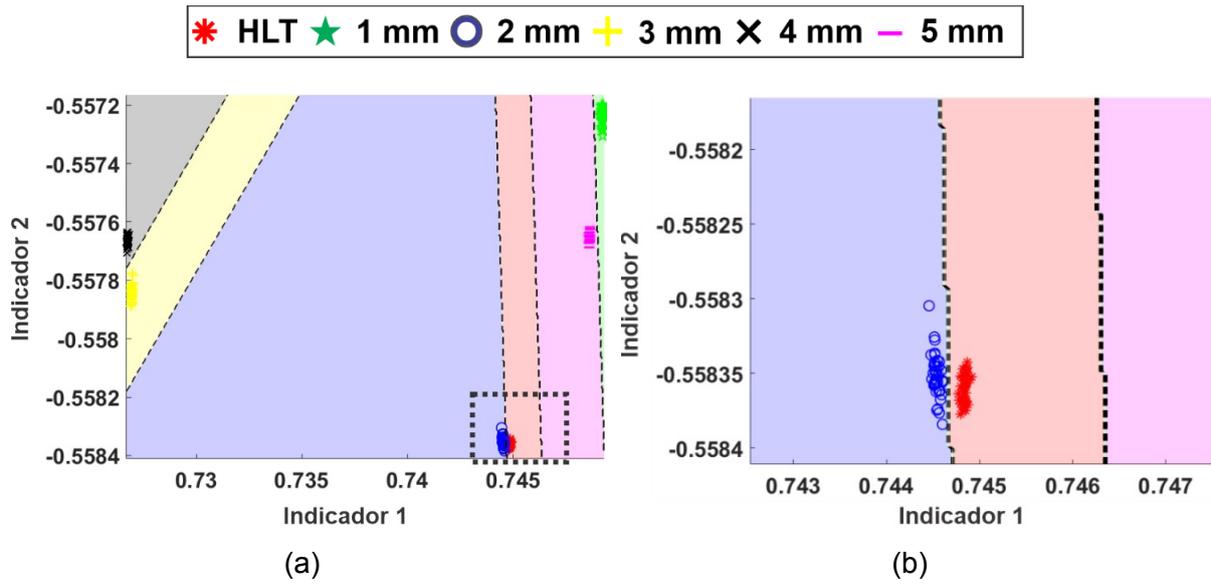


Figura 58. Proyección de las regiones de decisión para la clasificación de fallos múltiples calculada mediante el clasificador basado en la red neuronal artificial propuesto cuando el motor de inducción funciona a 15 Hz bajo un arranque empleando un variador de frecuencia: (a) Vista completa de la proyección. (b) Vista ampliada de la zona del rectángulo negro.

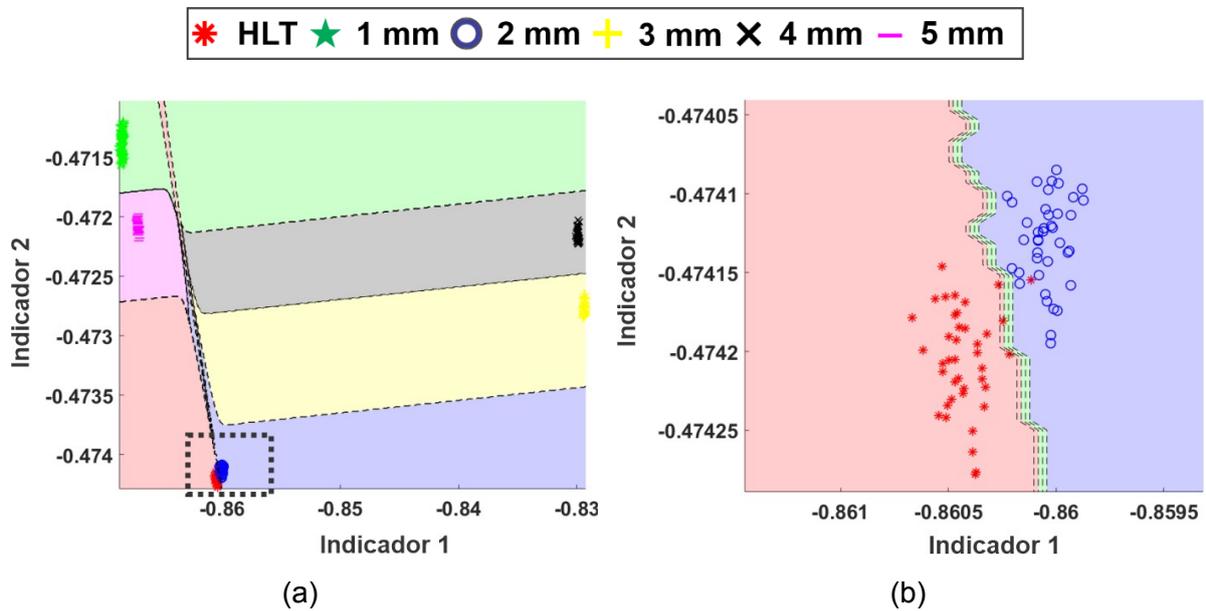


Figura 59. Proyección de las regiones de decisión para la clasificación de fallos múltiples calculada mediante el clasificador basado en la red neuronal artificial propuesto cuando el motor de inducción funciona a 5 Hz bajo un arranque empleando un variador de frecuencia: (a) Vista completa de la proyección. (b) Vista ampliada de la zona del rectángulo negro.

En la Tabla 12 se muestran los resultados de la clasificación, así como el porcentaje de efectividad de la metodología propuesta cuando el motor es alimentado a 60 Hz (conexión directa a red), y a 60 Hz, 50 Hz y 15 Hz por medio de un 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 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. Estos resultados demuestran la pertinencia de la propuesta ya que se obtiene una correcta clasificación de la severidad de la falla del 100%, incluso para fallas incipientes. De igual manera, la Tabla 13 muestra la matriz de confusión obtenida para el caso en que el motor es alimentado mediante un VFD a 5 Hz. Este caso especial revela que la propuesta tiene una efectividad del 97,5% para clasificar los fallos en los rodamientos en etapas incipientes, incluso cuando la frecuencia de alimentación es muy reducida. 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 de diagnóstico online que deban poseer la capacidad de detectar fallos incipientes. La principal limitación de la propuesta radica en la necesidad de disponer de datos suficientes para los diferentes casos de estudio, a fin de realizar un adecuado entrenamiento del método.

Tabla 12. Porcentaje de efectividad de la metodología propuesta (matriz de confusión) al analizar todas las condiciones de rodamiento consideradas para una alimentación directa desde la red a 60 Hz, y para una alimentación mediante VFD a 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 13. Porcentaje de efectividad de la metodología propuesta (matriz de confusión) al analizar todas las condiciones de rodamiento consideradas para una alimentación mediante VFD a 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

6.3.4 Conclusiones caso de estudio.

En este caso de estudio se emplea la metodología propuesta para diagnosticar de forma automática el desgaste gradual de las fallas de los rodamientos de la pista exterior utilizando señales de flujo magnético de dispersión. Se demostró que la combinación de información de diferentes indicadores estadísticos y de la dimensión fractal de Katz (KFD) mediante el análisis discriminante lineal (LDA) puede clasificar y diagnosticar de forma fiable diferentes grados de desgaste sin necesidad de conocimientos previos sobre la velocidad de rotación del rodamiento o del rotor, uno de los inconvenientes mas comunes en metodologías convencionales. La metodología propuesta demostró una efectividad del 100 % en el diagnóstico de diferentes gravedades de fallas en rodamientos para motores accionados a 60 Hz, 50 Hz y 15 Hz y una clasificación correcta del 97,5 % para motores accionados a 5 Hz. La metodología propuesta es adecuada y fiable para la detección automática de daños en rodamientos por desgaste gradual, sin que los resultados se vean afectados debido a señales y componentes de falla de baja amplitud. La metodología propuesta puede tener una amplia aplicabilidad en esquemas de diagnóstico de fallas de forma automática y en línea con la capacidad de detectar fallas incipientes.

Cabe destacar que derivado de este caso de estudio se logró publicar un artículo de investigación en una de las revistas de mas prestigio en el área en la que se publican trabajos relacionados, ente otros tópicos, al diagnóstico de fallas en máquinas eléctricas. El trabajo resultante, obtenido mediante este caso de estudio quedó publicado bajo la siguiente referencia:



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: 2.69

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.

Aunque se han propuesto diversas metodologías para el diagnóstico de fallas en motores, pocas se han enfocado en generar un diagnóstico automático basado en el transitorio de arranque. El análisis de señales capturadas durante el transitorio de arranque puede generar un diagnóstico más confiable y evitar falsos diagnósticos, ya que las metodologías convencionales pueden amplificar o cancelar frecuencias debido a fenómenos no relacionados con la falla. El análisis tiempo-frecuencia de señales capturadas a partir del motor bajo análisis es una metodología más confiable ya que se basa en la identificación de patrones específicos debido a la evolución de la frecuencia amplificada durante el arranque del motor. La técnica de STFT se ha empleado mayormente debido a sus ventajas, pero tiene un fuerte inconveniente en lo que respecta a la resolución tiempo-frecuencia obtenida, especialmente cuando las frecuencias de interés se encuentran muy cercanas entre sí, o las componentes de falla evolucionan de forma adyacente a la componente fundamental (de gran amplitud), misma que puede enmascarar las componentes de falla si no se obtiene una resolución tiempo-frecuencia óptima. Es posible disminuir o mitigar este problema mediante 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, que permite evidenciar solo componentes de frecuencia de mayor amplitud y mitiga los efectos del procesamiento de señales ruidosas.

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 desarrollaron 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 60). 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 61. Las tres posiciones consideradas del sensor fueron las representadas en la Figura 18 (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 posteriormente fueron analizadas.

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 62). A priori se desconocía el estado exacto de este motor, por lo que sirvió para validar si la aplicación de la metodología basada del flujo magnético de dispersión funcionaba bien a la hora 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.

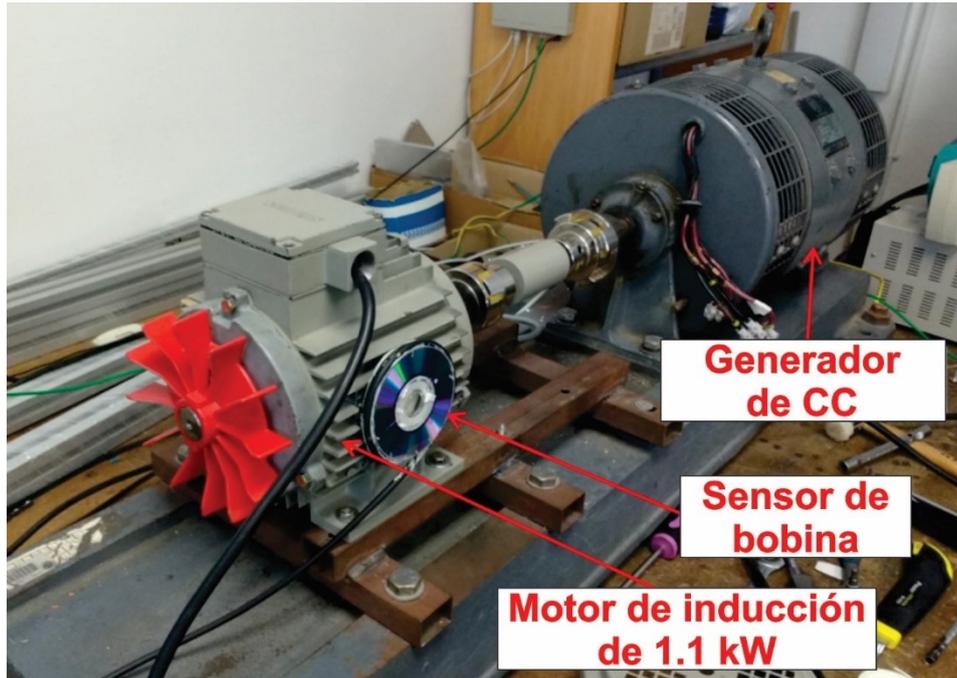


Figura 60. Banco de pruebas de laboratorio (motor 1)

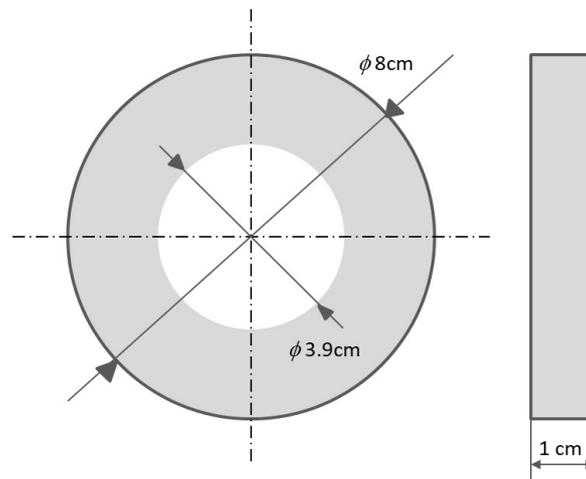


Figura 61. Dimensiones del sensor de bobina empleado durante los experimentos del presente caso de estudio.



Figura 62. 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 63 muestra los análisis MUSIC de la señal fem 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 (Parks 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 de 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, et a 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 63. 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 f_{em} de 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.

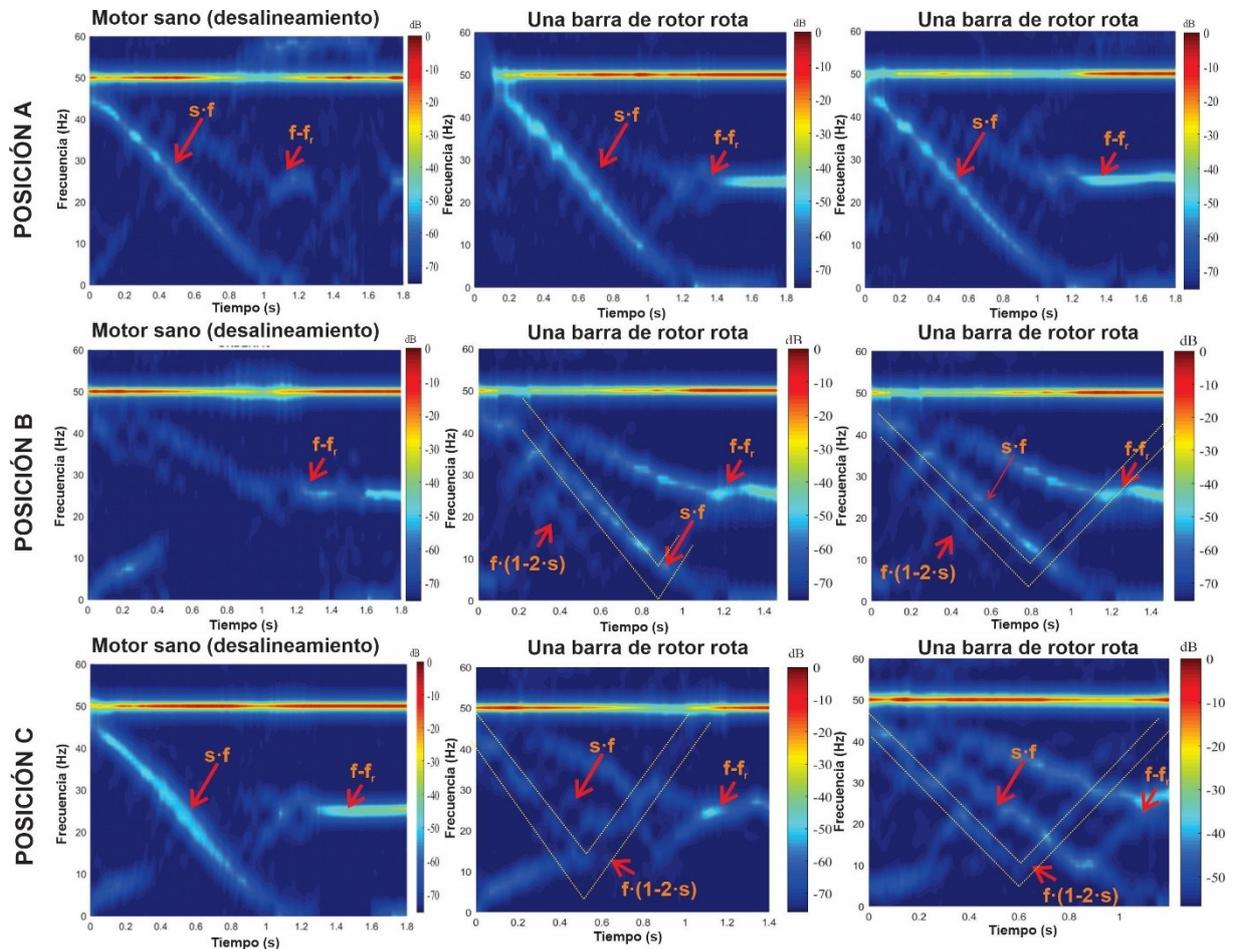


Figura 63. Análisis MUSIC de las señales de f_{em} capturadas durante el arranque del motor 1 para el sensor en las posiciones A, B y C y para las diferentes condiciones de falla, a saber, motor saludable (con desalineación inherente), motor con una barra rota y motor con dos barras rotas.

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 64. 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, después de 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).

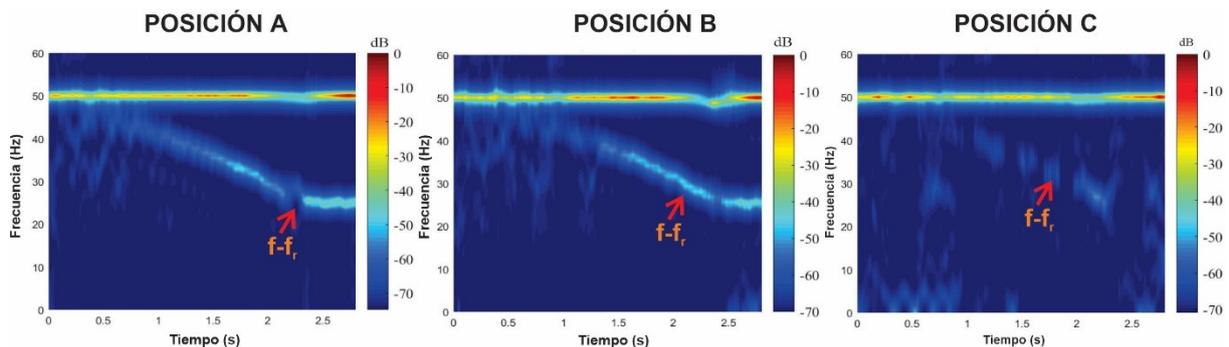


Figura 64. Análisis MUSIC de las señales de f_{em} capturadas por el sensor de bobina durante el arranque del motor 2 para el sensor en las posiciones A, B y C.

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. Para esto, 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 amplificados 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 65.

Posteriormente 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.

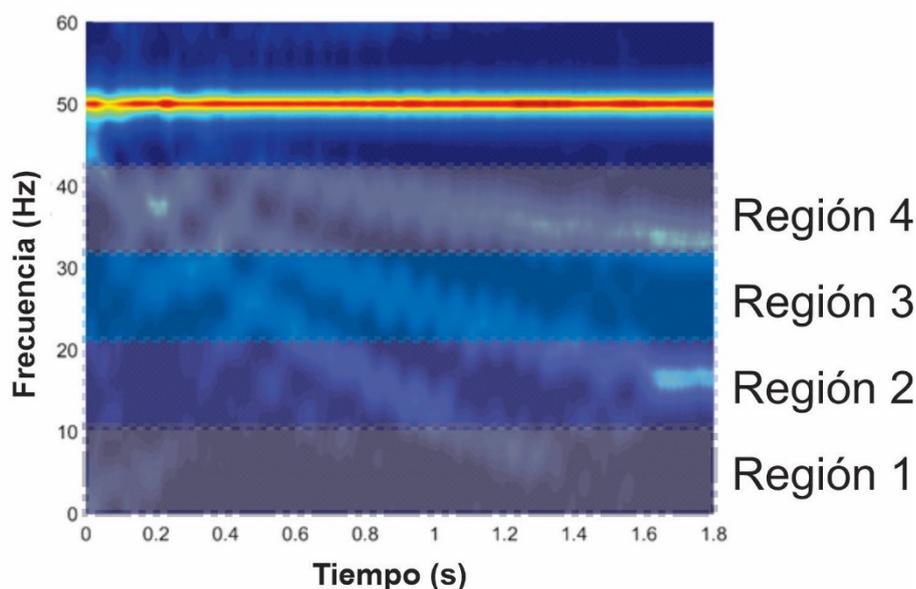


Figura 65. Regiones consideradas en los mapas tiempo-frecuencia MUSIC para la automatización de la técnica.

La Figura 66 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 retropropagación 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 bajo análisis (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 de cada una de estas 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 de 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. Tenga 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.

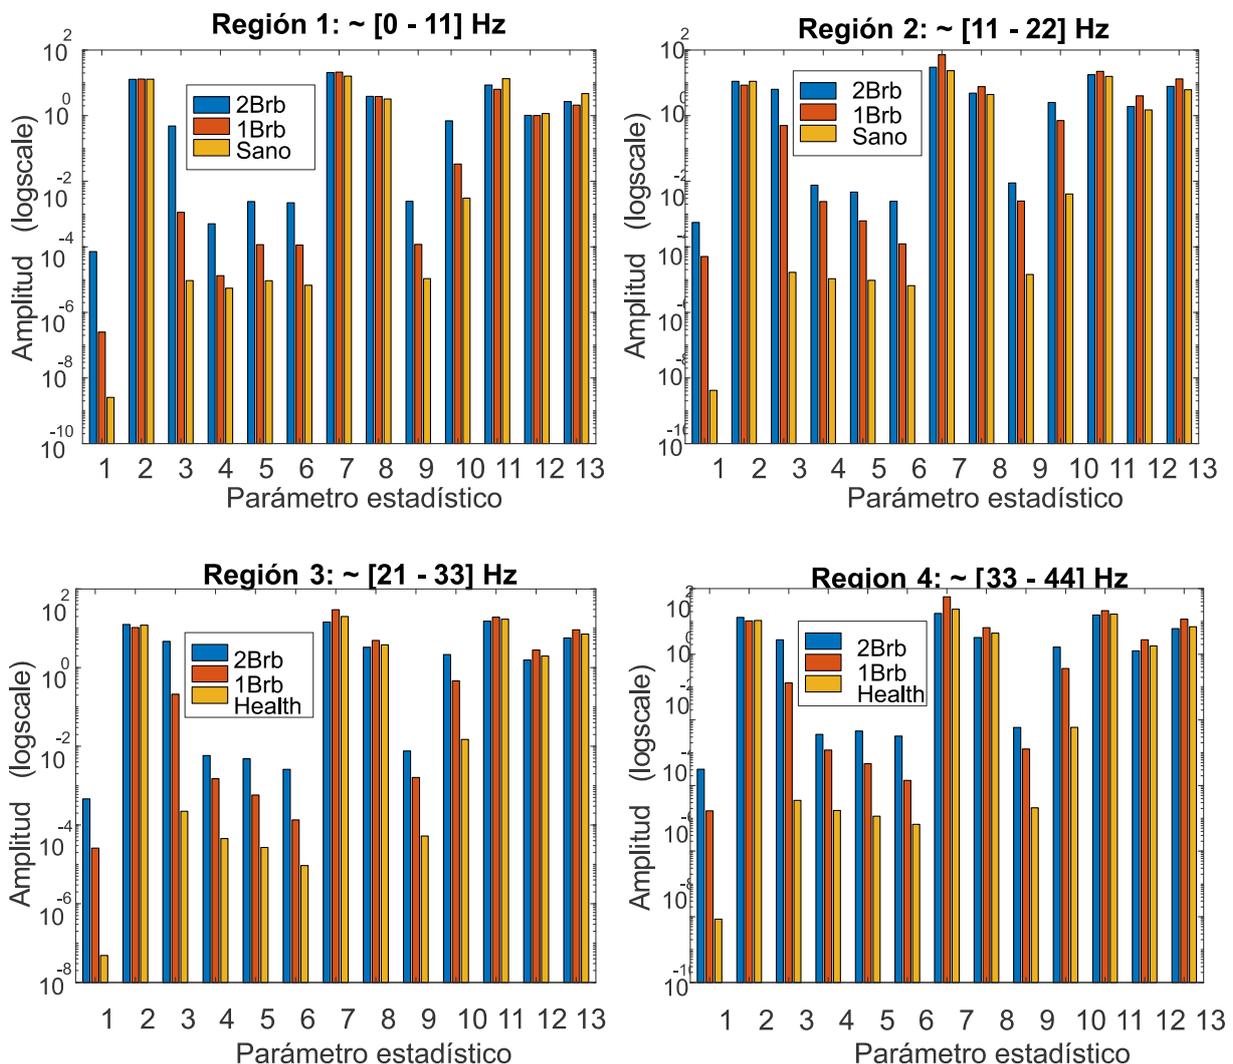


Figura 66. Cálculo de parámetros estadísticos y no estadísticos (entradas de la red neuronal artificial) para las diferentes regiones de los análisis MUSIC de las señales de flujo de dispersión capturadas para las diferentes condiciones de falla (posición B del sensor).

6.4.4 Conclusiones caso de estudio.

En este caso de estudio se emplea la metodología propuesta en este trabajo de tesis para el diagnóstico de fallas en el rotor, y se hace uso del análisis MUSIC de las señales de flujo magnético de dispersión capturadas durante el arranque del motor. La metodología ha demostrado ser útil para el diagnóstico oportuno y de forma automática de averías en el rotor, y que tiene la gran ventaja de discriminar este tipo de fallas inclusive en transitorios de arranque de muy corta duración (menor a 1.5 s) donde técnicas convencionales, como aquellas que se basan en la STFT podrían tener problemas, ya que las componentes de fallo evolucionan en un corto periodo de tiempo, lo que termina causando que sean indeterminables debido a la baja resolución tiempo-frecuencia que ofrece la técnica STFT. En contraste, la técnica MUSIC permite detectar la amplificación de diferentes componentes en los mapas de tiempo-frecuencia, inclusive en casos donde el transitorio de arranque es menor a 1 s. En condiciones normales de operación, se pueden observar trazas de los armónicos atribuidos a la desalineación del motor y a un nivel de asimetría inherente al rotor, respectivamente. Sin embargo, cuando hay una falla en el rotor (como barras rotas), se produce una amplificación de la componente axial en $s \cdot f_s$, lo que es especialmente evidente en la Pos. A y Pos. B del sensor. Además, la componente radial $f_s \cdot (1 - 2 \cdot s)$ también se amplifica, siendo más evidente cuanto peor es la falla. Finalmente, cabe destacar que la metodología propuesta en la presente tesis permite un diagnóstico automático y confiable, y no requiere un usuario experto para identificar patrones de fallas y llegar a una conclusión de diagnóstico. La posición del sensor de la bobina afecta la naturaleza de los componentes inducidos y los análisis MUSIC correspondientes, pero el sistema desarrollado combina información de todas las posiciones del sensor para un diagnóstico más confiable. Este método tiene ventajas sobre la literatura anterior y puede ser una herramienta valiosa para el monitoreo de la condición del motor de inducción.

Derivado de este caso de estudio se logró publicar un artículo de investigación en una de las revistas de mas prestigio en el área en la que se publican trabajos relacionados, ente otros tópicos, al diagnóstico de fallas en máquinas eléctricas. El trabajo resultante, quedó publicado bajo la siguiente referencia:

Zamudio-Ramirez, I., Ramirez-Núñez, 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.

Factor de impacto de revista: 4.079

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 las cajas de engranes son temas importantes en la industria debido a su papel crucial en la transmisión de potencia mecánica. Aunque diversas investigaciones se han enfocado en detectar fallas discretas, como dientes rotos o astillados, pocos trabajos han explorado el uso de señales de flujo magnético de dispersión para el diagnóstico de fallas en etapas tempranas, como el desgaste uniforme de los dientes. Aunque algunos métodos basados en la característica de armónicos de falla específicos han demostrado ser efectivos, su precisión se ve comprometida por la presencia de señales ruidosas y fuertes interferencias en entornos hostiles. Se necesita más investigación en el diagnóstico y la identificación de fallas en etapas tempranas para evitar interrupciones inesperadas y pérdidas de producción.

Mediante este caso de estudio, en el que se aplica la metodología propuesta en este trabajo de tesis, se demuestra su eficacia para diagnosticar fallas incipientes en la caja de engranajes, como el desgaste uniforme de los dientes mediante el estudio de las señales de flujo magnético de dispersión (esto es flujo de dispersión axial, radial, y axial + radial) capturadas mediante el sensor triaxial aquí propuesto (descrito en la sección 4.3) instalado en el marco del motor propulsor. 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 los diferentes componentes magnéticos del flujo parásito (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.

6.5.2 Puesta en marcha de experimentos.

El método propuesto se evalúa con 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, 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 mediante un variador de frecuencia (VFD). 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 67. 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; el transductor de flujo de dispersión triaxial es elaborado a partir de tres sensores primarios basados en el efecto Hall instalados en ejes perpendiculares entre sí, como se describe en la sección 4.3 de este trabajo. 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) patentado (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 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 68a a la Figura 68d, 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.

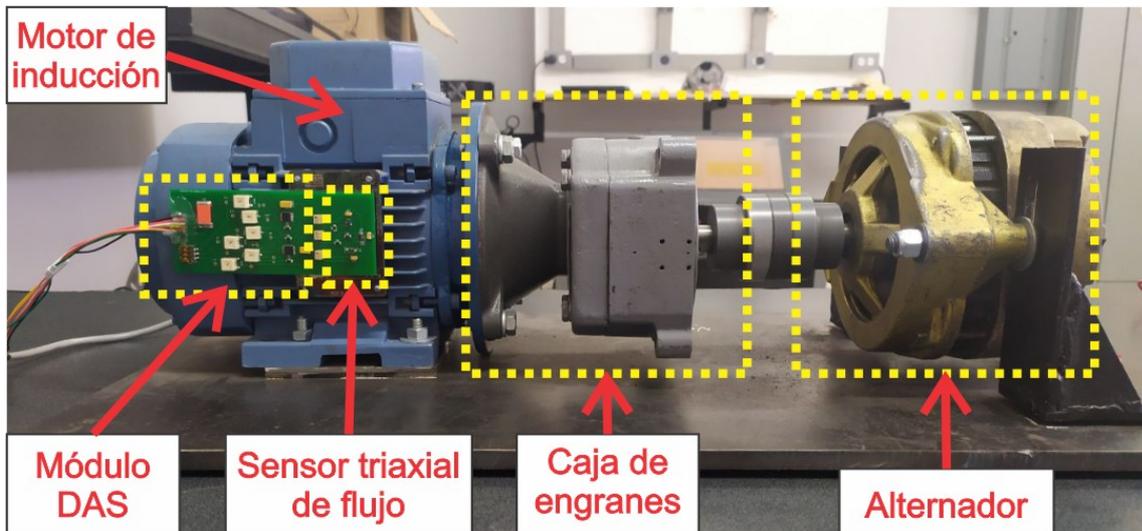


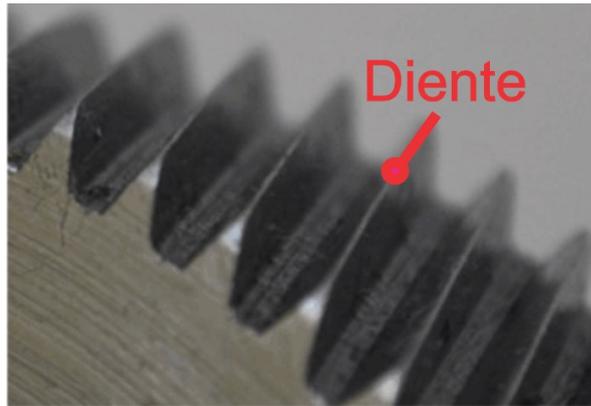
Figura 67. Banco de pruebas de laboratorio basado en una cadena cinemática para la evaluación experimental de diferentes niveles de desgaste en los dientes de engranajes de una caja de cambios.



(a)



(b)



(c)

Figura 68. Engranés utilizados durante la experimentación: (a) engrane sano, (b) 25 % y (c) 75 % de desgaste uniforme de los dientes.

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 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 3). Así entonces, se analiza la distribución de los datos para todas las condiciones evaluadas. La Tabla 14 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 14. 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 (LDA, por su abreviatura en inglés Linear Discriminant Analysis) (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 69; 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.

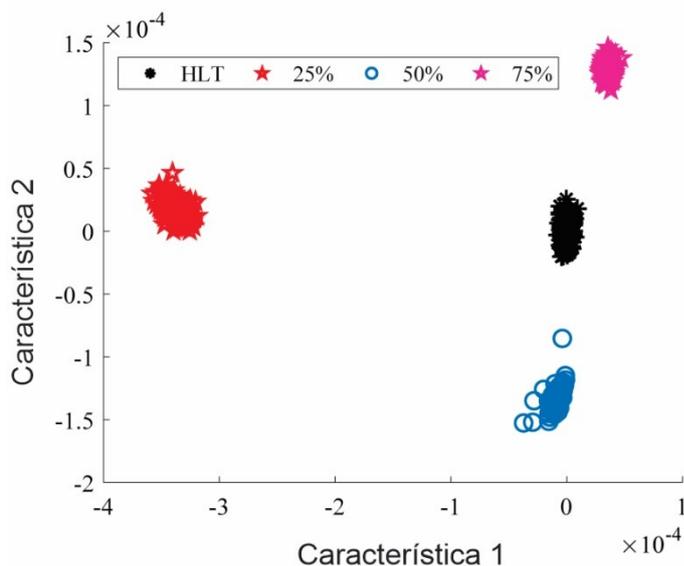


Figura 69. Representación bidimensional resultante obtenida aplicando la técnica de análisis discriminante lineal a las matrices de indicadores estadísticos para todas las condiciones consideradas.

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. Además, el clasificador basado en redes neuronales artificiales se entrena y prueba bajo un esquema de validación cruzada de k -veces, con $k=5$, para obtener resultados estadísticamente significativos. 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, por su 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 15; se debe considerar que solo se produce un error de clasificación errónea 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 15. 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 70 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.

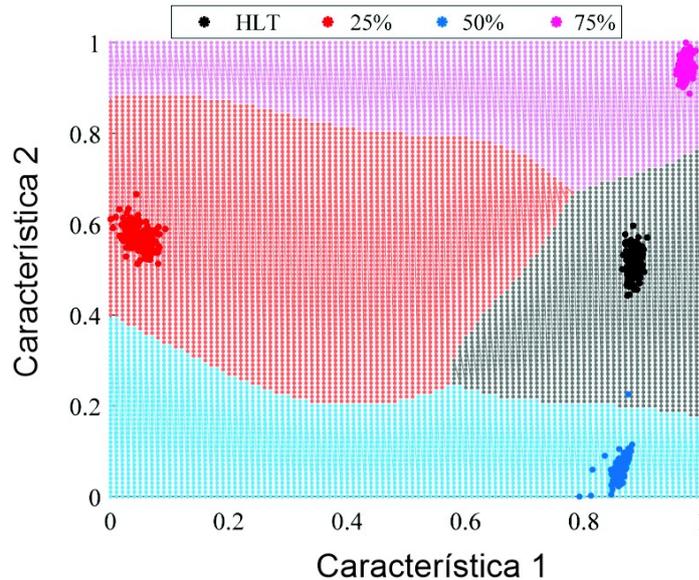


Figura 70. Regiones de decisión resultantes modeladas por el clasificador basado en redes neuronales artificiales aquí propuesto sobre el espacio bidimensional donde se representan todas las condiciones consideradas.

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 71 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 71 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 16 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.

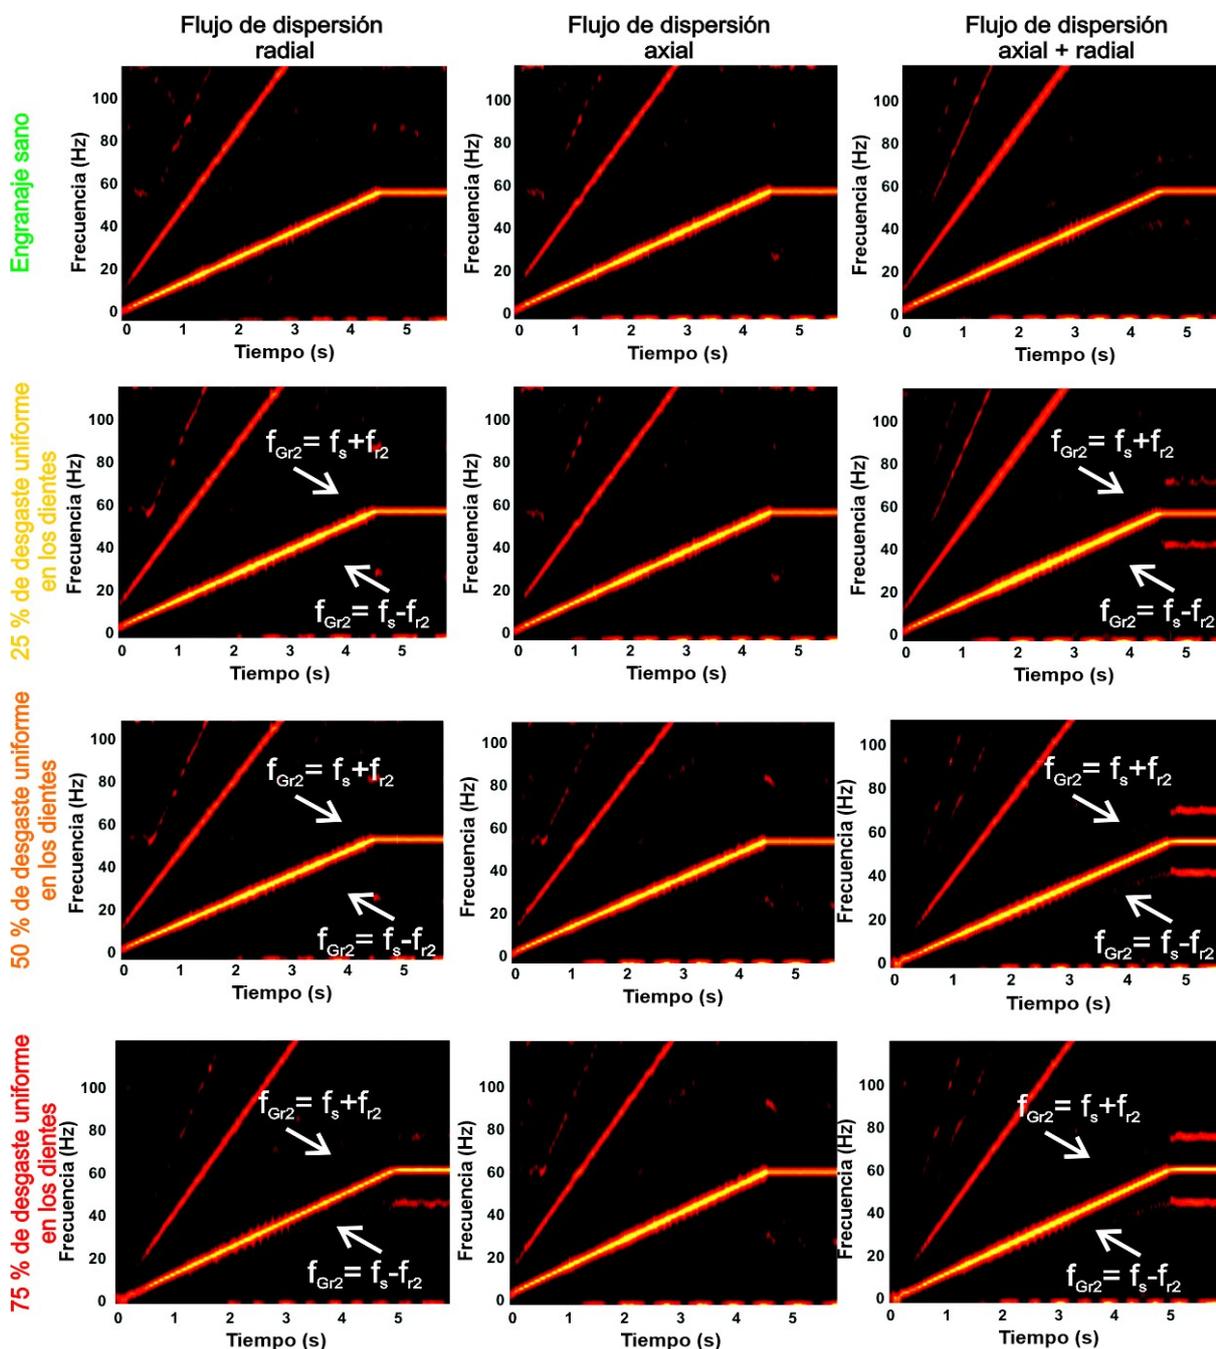


Figura 71. Análisis MUSIC de las señales de flujo magnético de dispersión capturadas durante el arranque del motor para las diferentes condiciones de falla: engranaje sano y tres condiciones de falla de desgaste uniforme en los dientes del engranaje 25%, 50% y 75%.

Tabla 16. 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 que deben destacarse. 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%.

6.5.4 Conclusiones caso de estudio.

Este caso de estudio presenta un nuevo enfoque para el monitoreo de la condición de una caja de engranajes bajo condiciones de falla incipiente de desgaste uniforme en los dientes, empleando la metodología aquí propuesta. Hay tres aspectos clave del enfoque que lo distinguen de trabajos relacionados. En primer lugar, el enfoque propuesto es superior en la identificación de fallas incipientes, como el desgaste uniforme en los dientes del engranaje, en comparación con trabajos que analizan fallas discretas, como dientes astillados o completamente rotos en un engranaje. En segundo lugar, las señales de flujo magnético de dispersión se caracterizan mediante la estimación de un conjunto significativo de características estadísticas basadas en el dominio del tiempo, lo que lleva a una caracterización de patrones de características de alto rendimiento de diferentes condiciones evaluadas. En tercer

lugar, el conjunto estimado de características se analiza a través de PCA, lo que facilita la determinación del número mínimo de dimensiones requeridas para representar el espacio de características original sin pérdida de información. El uso de la técnica LDA también se emplea para obtener una representación 2-D donde todas las condiciones consideradas están claramente separadas. La estructura clasificadora basada en reedes neuronales artificiales se utiliza para tareas de clasificación y logró una tasa de clasificación superior al 99,8 %. En general, el método propuesto es efectivo y adecuado para su implementación como una herramienta de diagnóstico no invasiva para aplicaciones industriales en programas de mantenimiento basados en condiciones.

Derivado de este caso de estudio se logró publicar un artículo de investigación en una de las revistas de mas prestigio en el área en la que se publican trabajos relacionados, ente otros tópicos, al diagnóstico de fallas en máquinas eléctricas. El trabajo resultante, quedó publicado bajo la siguiente referencia:

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.

Factor de impacto de revista: 4.079

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 optimización de los procesos de fabricación en la industria manufacturera es importante para lograr beneficios económicos y mejorar la calidad del producto. Los costos de herramientas de corte, electricidad, eficiencia del mecanizado y calidad de la superficie mecanizada son factores clave que influyen en los gastos de fabricación. Para reducir los costos y mejorar la tasa de producción, es necesario desarrollar sistemas de monitorización del estado de las herramientas de corte. Aunque la mayoría de las metodologías de monitorización se centran en la extracción de información de diferentes magnitudes físicas, hay pocas investigaciones centradas en el motor del husillo. La instalación de sensores cerca del área de trabajo representa una limitación para las metodologías indirectas, por lo que es importante explorar técnicas emergentes no invasivas para superar esta limitación. El análisis del flujo magnético de dispersión ha demostrado producir resultados comparables a los de los métodos bien establecidos con alta confiabilidad, por lo que es relevante explorar esta técnica para el diagnóstico del desgaste de herramientas de corte. Aunque no se han realizado investigaciones sobre el impacto del desgaste de las herramientas de corte en el flujo magnético de dispersión capturado alrededor del motor del husillo, resulta importante explorar esta cantidad y aplicar metodologías utilizadas en el análisis de máquinas eléctricas al diagnóstico del desgaste de 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 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 72a. 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 4.3) en el marco del motor del husillo, como se muestra en la Figura 72b. Estas señales se capturan y almacenan utilizando un módulo de adquisición de señales (DAS) propietario basado en un convertidor analógico / digital 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.

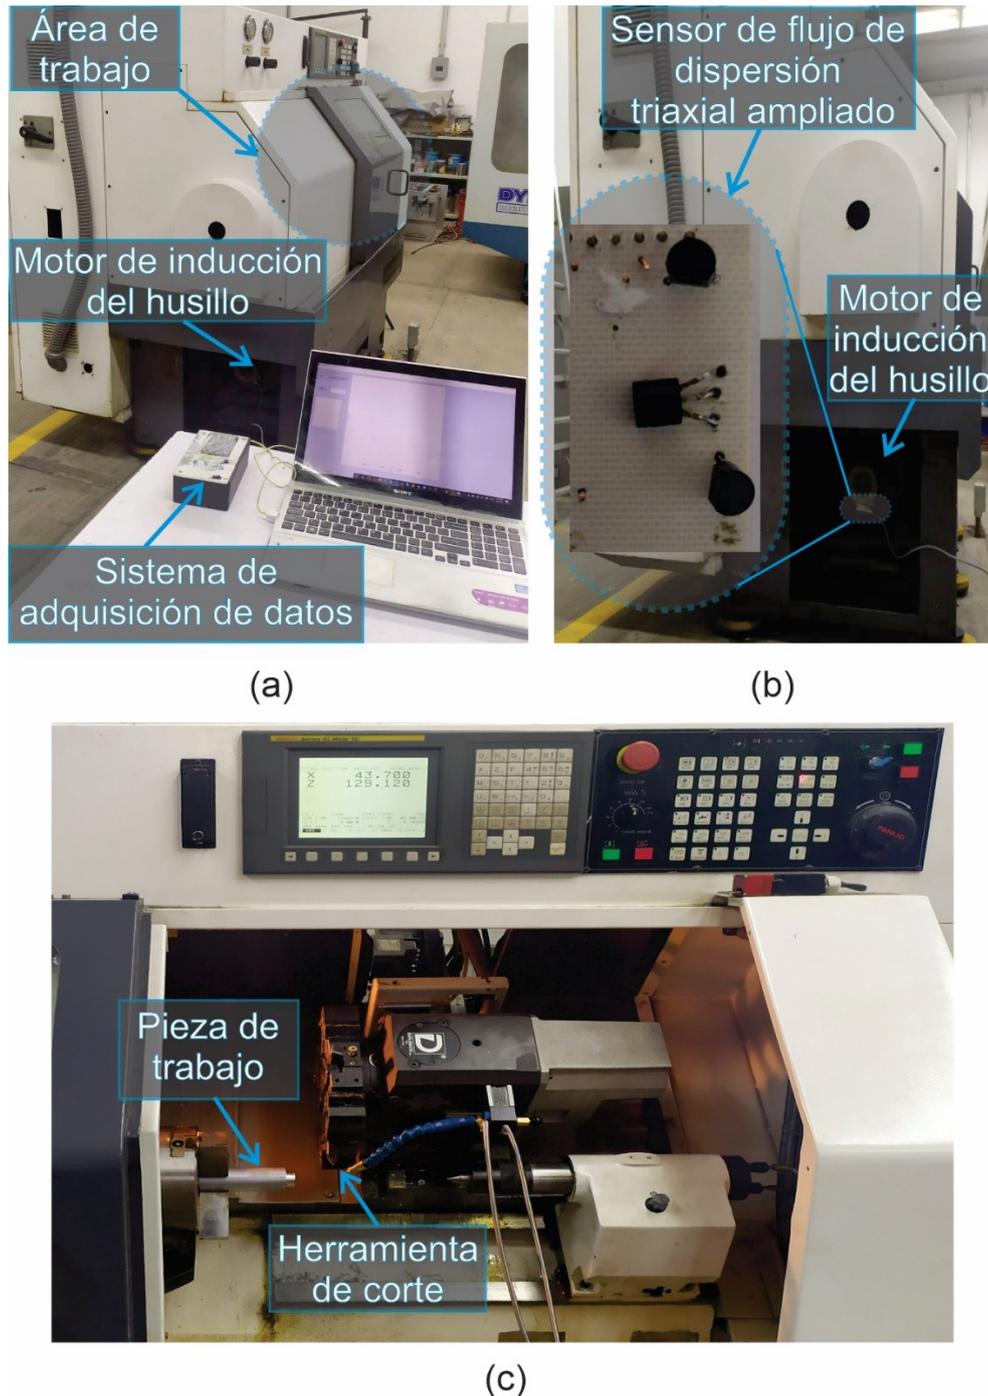


Figura 72. Configuración experimental: (a) banco de pruebas de máquinas CNC, (b) vista lateral del banco de pruebas de máquinas CNC y (c) área de trabajo.

Los diferentes estados de desgaste de la herramienta considerados en este caso de estudio se pueden observar en la Figura 73, a saber: herramienta de corte nueva (Figura 73a), herramienta de corte desgastada con un valor de área de desgaste de herramienta de $A_f=0.3149\text{mm}^2$ (Figura 73b), 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 73c).

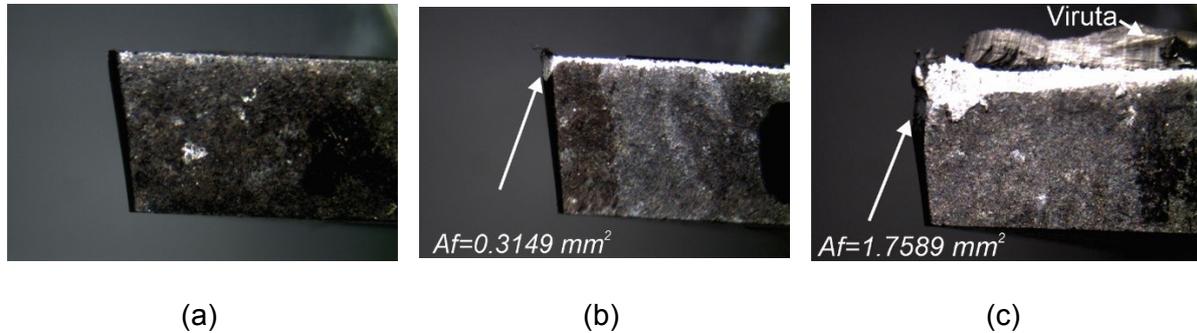


Figura 73. Estados de desgaste de la herramienta: (a) herramienta nueva, (b) herramienta desgastada y (c) herramienta rota.

La Figura 74 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 $\Delta=0,5\text{ mm}$.

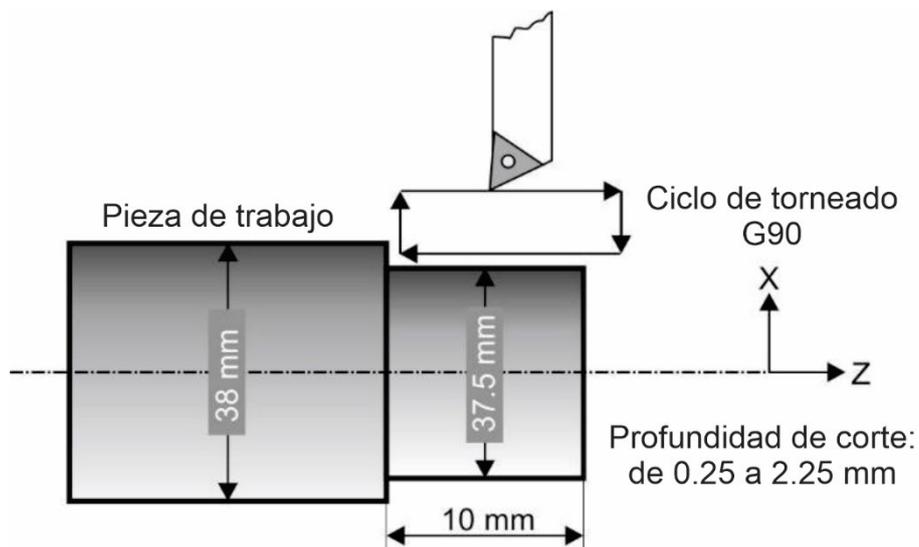


Figura 74. Ciclo de torneado ejecutado durante en los ensayos experimentales.

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 17 (solo se muestran las señales más relevantes para los análisis considerados).

Tabla 17. Bandas de frecuencia cubiertas por las señales wavelet más representativas, de acuerdo a la frecuencia de muestreo empleada de 5 kHz.

Señal de ondoleta	Banda de frecuencia cubierta
d6	~ [39-78] Hz
d5	~ [78-156] Hz
d4	~ [156-312] Hz
d3	~ [312-625] Hz

La Figura 75 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 76 muestra los resultados de FFT obtenidos en condiciones de mínima carga variable al procesar las señales ϕ_2 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 ϕ_2 , siendo mayor cuanto mayor es el desgaste de la herramienta de corte.

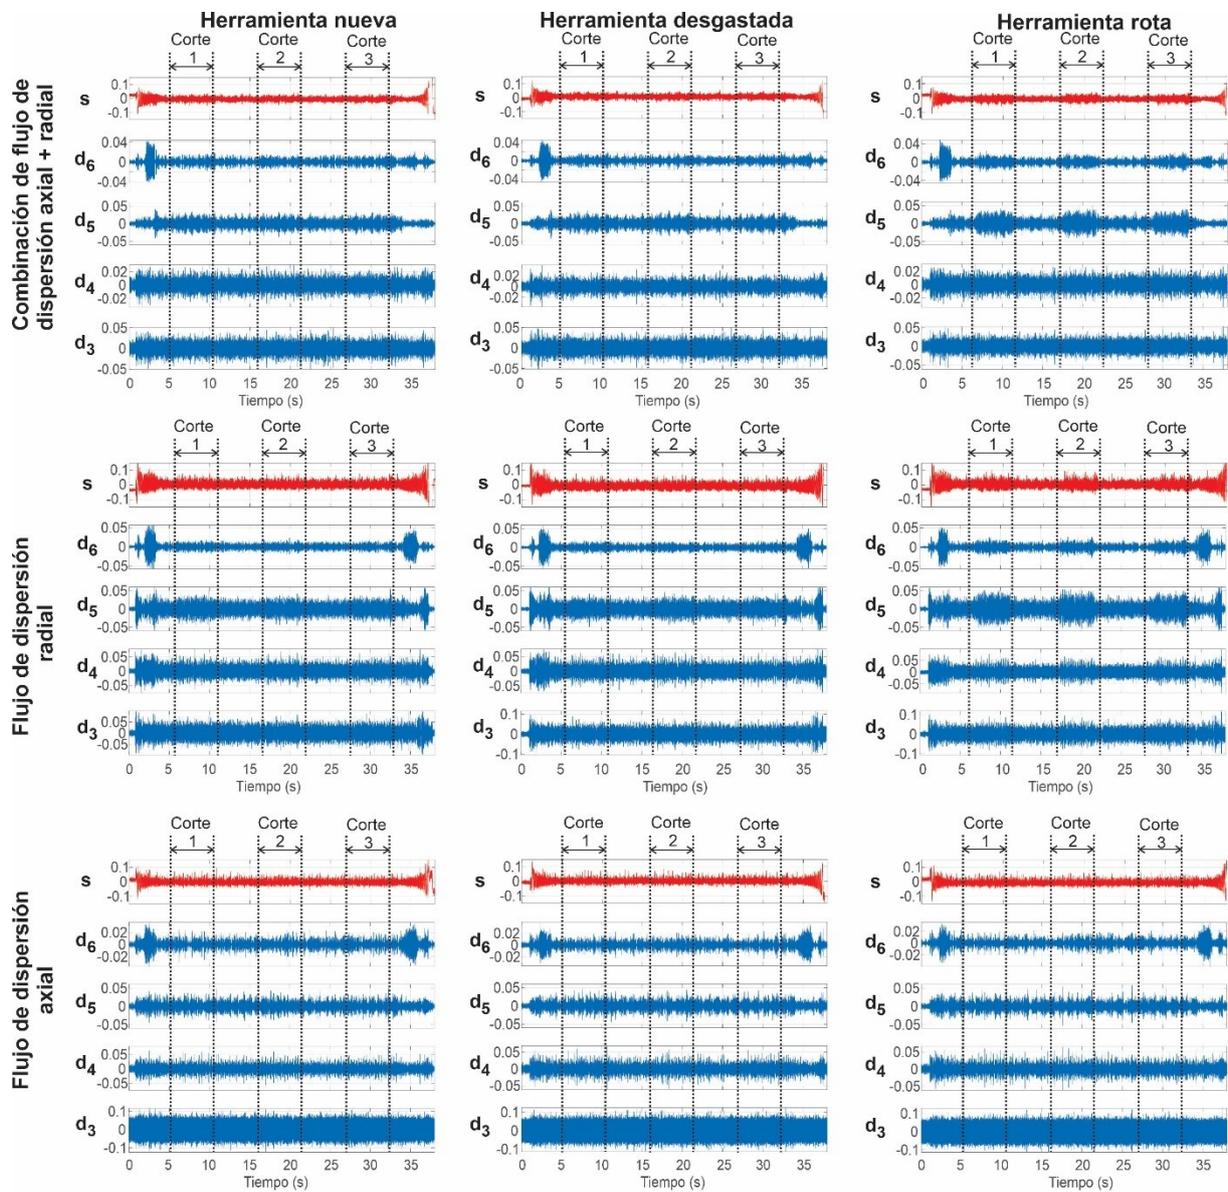


Figura 75. Análisis DWT de las diferentes señales de flujo magnético de dispersión para una profundidad de corte de 1,25 mm y para los tres niveles de desgaste de la herramienta de corte analizados en este trabajo.

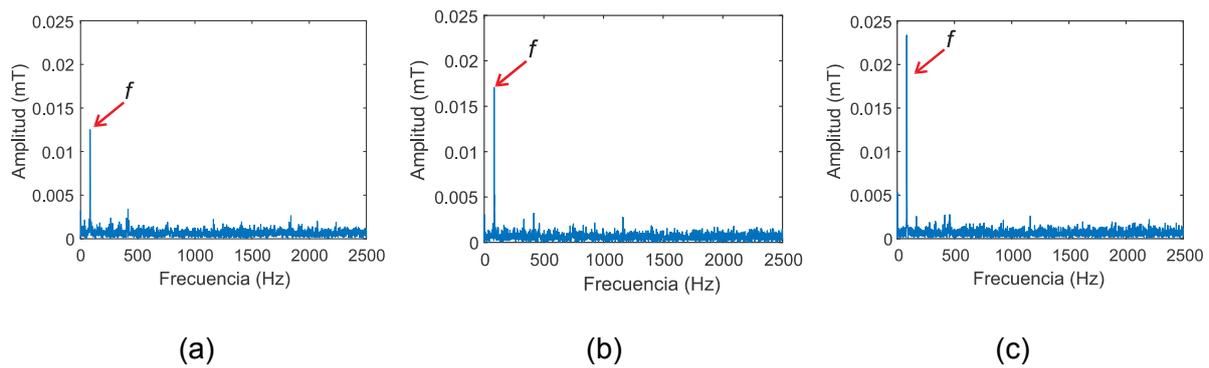


Figura 76. Análisis FFT para la combinación de flujo de dispersión axial y radial con una profundidad de corte de 1,25 mm para: (a) herramienta nueva, (b) herramienta desgastada y (c) herramienta rota.

La Figura 77 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.

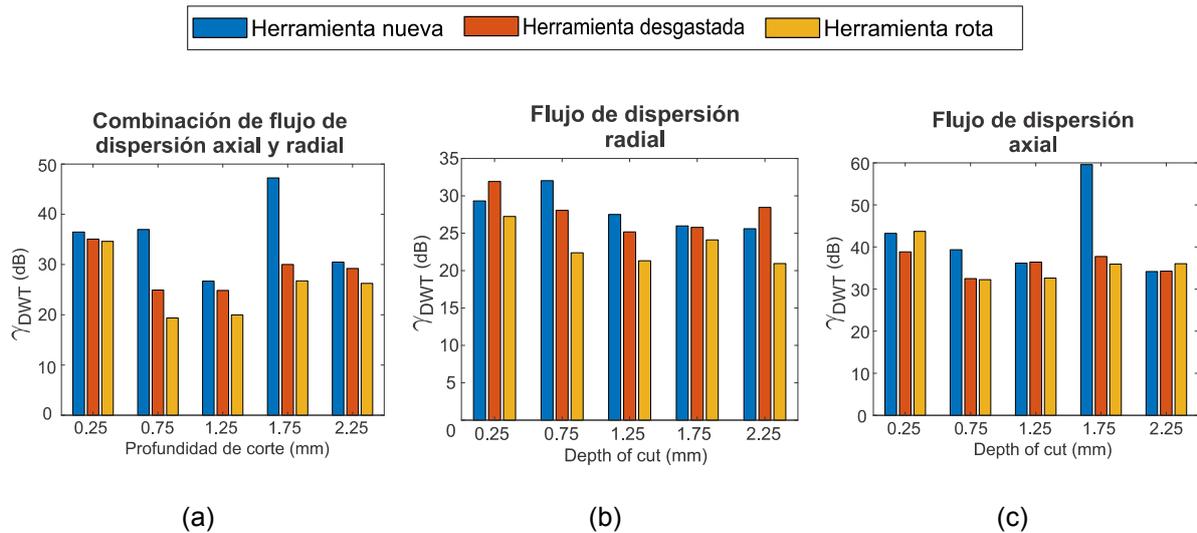


Figura 77. Valores del indicador γ_{DWT} para cada condición de desgaste de la herramienta de corte, diversas profundidades de corte, y para cada señal de las diferentes componentes del flujo de dispersión cuando se basa en la energía de la señal wavelet d_5 . (a) Flujo de dispersión axial + radial. (b) Flujo de dispersión radial. (c) Flujo de dispersión axial.

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 18 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 18 (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 18. 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

6.6.4 Conclusiones caso de estudio.

Este caso de estudio presenta un nuevo enfoque no invasivo para detectar y diagnosticar el nivel de desgaste en herramientas de corte utilizadas en máquinas CNC al emplear la metodología propuesta en la presente tesis.. El método consiste en analizar las señales de flujo perdido capturadas alrededor del motor del husillo de la máquina, utilizando el DWT para el análisis de descomposición de tiempo-frecuencia debido a las condiciones de carga variable de los procesos de la máquina CNC. Los resultados muestran que las amplitudes Y_{DWT} obtenidas mostraron una clara tendencia a generar valores más altos para herramientas de corte en mejores condiciones de salud según la profundidad de corte. Esto se debió a la naturaleza del indicador introducido ya que, a mayores magnitudes en la banda de frecuencias analizada, menor fue el índice obtenido, el cual estuvo altamente relacionado con el desgaste de la herramienta de corte. El estudio concluyó que la metodología propuesta fue efectiva para estimar y clasificar automáticamente el desgaste de la herramienta de corte, independientemente de la profundidad de corte utilizada en el proceso de mecanizado. Además, el estudio identificó los efectos que una herramienta de corte desgastada tenía sobre el flujo de dispersión del husillo-motor, incluyendo modificaciones en la amplitud del armónico de la fuente de alimentación, mayor sensibilidad al desgaste de la herramienta de corte al combinar flujo de dispersión axial y radial, menor sensibilidad al usar solo flujo de dispersión radial y muy baja sensibilidad al desgaste de la herramienta de corte cuando se utiliza flujo de dispersión axial. Así entonces, este caso de estudio ha mostrado las excelentes prestaciones de la metodología propuesta para la caracterización del comportamiento dinámico de diversas señales (específicamente de señales de flujo

magnético de dispersión) y su estrecha relación para la detección de anomalías en el comportamiento dinámico generado por diversas fallas.

Cabe destacar que derivado de este caso de estudio se logró publicar un artículo de investigación en una de las revistas de mas prestigio en el área en la que se publican trabajos relacionados, ente otros tópicos, al diagnóstico de fallas en máquinas rotativas. El trabajo resultante, obtenido mediante este caso de estudio quedó publicado bajo la siguiente referencia:

Zamudio-Ramírez, I., Antonino-Daviu, J. A., Trejo-Hernandez, M., & Osornio-Rios, R. A. (2020). Cutting tool wear monitoring in CNC machines based in spindle-motor stray flux signals. *IEEE Transactions on Industrial Informatics*, 18(5), 3267-3275.

Factor de impacto de revista: 11.648

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 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. 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 virtualmente 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 $f(1-2 \cdot s)$, 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 $f(1-2 \cdot s)$ durante el transitorio de arranque en todos las 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 las tres componentes magnéticas del flujo de dispersión mostraron la aparición y evolución de la componente de falla en $f(1+2 \cdot s)$ reportada en trabajos anteriores, donde los análisis se realizaron utilizando señales de corriente, demostrando que las componentes radial y axial del flujo magnético de dispersión es sensible a esta componente de falla.
- Para el caso de diagnóstico de fallas de asimetría en motores de inducción de rotor bobinado, los patrones de falla fueron detectables incluso en el caso de condiciones sin carga. En esta situación, los enfoques clásicos de estado estacionario pueden fallar debido a la superposición entre las bandas laterales en $f(1 \pm 2 \cdot s)$ y la componente fundamental en la frecuencia de alimentación.
- 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 eficaz en el diagnóstico del desgaste gradual de la pista exterior en rodamientos metálicos de bolas, a través del análisis de las señales del flujo magnético de dispersión capturadas por un sensor triaxial y el uso de indicadores estadísticos y no estadísticos en el dominio del tiempo, así como métodos de aprendizaje automático. Se encontró que ningún indicador individual era capaz de discriminar entre los diferentes grados de desgaste, pero combinando la información de varios indicadores y la dimensión fractal de Katz a través de un análisis discriminante lineal (LDA), se logró una clasificación confiable de los diferentes niveles de desgaste. La metodología no requiere información previa del rodamiento instalado ni de la velocidad de rotación del rotor, lo que la diferencia de los métodos convencionales. Los resultados obtenidos indican que la metodología propuesta es adecuada para la detección automática de



daños por desgaste gradual en rodamientos, con una efectividad del 100% en la detección de fallas en motores que operan a 60 Hz, 50 Hz y 15 Hz, y un 97,5% en motores que operan a 5 Hz. Además, la propuesta no se ve afectada por señales de baja amplitud y puede ser utilizada en esquemas en línea para la detección temprana de fallas.

- 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.



- El uso de LDA para reducir características simplifica la tarea de clasificación del clasificador de redes neuronales artificiales propuesto en la estructura clásica, lo que se traduce en una alta tasa de clasificación global superior al 99,8% para la detección de desgaste gradual en los dientes de engranajes de cajas de cambios. Esto demuestra la eficacia del método propuesto y lo convierte en una herramienta de diagnóstico no invasiva adecuada para su integración en programas de Mantenimiento Basado en la Condición para aplicaciones industriales.
- Se propone una 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. Se utiliza DWT para el análisis, ya que tiene una respuesta adecuada a las señales variables en el tiempo. Se evaluaron las amplitudes obtenidas para los casos de estudio y se observó que el índice presentó una clara tendencia a tomar valores más altos para herramientas de corte en mejores condiciones de salud según la profundidad de corte. Esto está muy relacionado con el desgaste de la herramienta de corte, ya que la amplitud del armónico fundamental es mayor cuanto mayor es el desgaste de la herramienta.
- Cuando la herramienta de corte se encuentra en estado de desgaste, la amplitud del armónico de la fuente de alimentación se modifica. A mayor desgaste en la herramienta de corte, mayor amplitud del armónico de la fuente de alimentación.
- La combinación de flujo de dispersión axial y radial muestra una mayor sensibilidad al desgaste de la herramienta de corte, de igual forma, el flujo de dispersión radial es sensible a este fenómeno, sin embargo, su sensibilidad es menor.
- De acuerdo con los resultados obtenidos en este trabajo, el flujo de dispersión axial presenta una sensibilidad muy baja al desgaste de la herramienta de corte.
- La metodología propuesta es eficaz para estimar y clasificar automáticamente el desgaste de la herramienta de corte, independientemente de la profundidad de corte utilizada en el proceso de mecanizado.

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.
- Una posible dirección de investigación futura podría implicar evaluar la viabilidad de estudiar el sistema de aislamiento de máquinas con bobinas formadas que funcionan a media tensión y analizar diversas patologías en máquinas de imanes permanentes utilizadas en tracción eléctrica mediante la metodología propuesta. Esto debido a la capacidad de la metodología propuesta para identificar y caracterizar el comportamiento dinámico de las señales relacionadas a este tipo de averías y máquinas. Al abordar estas áreas de investigación, se pueden lograr avances para mejorar la confiabilidad y el rendimiento de las máquinas eléctricas en aplicaciones de voltaje medio y sistemas de tracción eléctrica.

REFERENCIAS

- 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, ICEM 2018*, 2359–2364. <https://doi.org/10.1109/ICELMACH.2018.8506949>
- Antonino-Daviu, J., Quijano-López, A., Climente-Alarcon, V., & Garín-Abellán, C. Reliable Detection of Rotor Winding Asymmetries in Wound Rotor Induction Motors via Integral Current Analysis. *IEEE Transactions on Industry Applications*, vol. 53, no. 3, pp. 2040-2048, May-June 2017
- 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>
- Antonino-Daviu, J. (2006). “Diagnóstico de roturas de barra y otras averías electromecánicas en máquinas de inducción mediante el estudio del transitorio de arranque con la transformada Wavelet”, Tesis Doctoral, Universitat Politècnica de València, Sept. 2006.
- Antonino-Daviu, J., Razik, H., Quijano-Lopez, A., & Climente-Alarcon, V. (2017, October). Detection of rotor faults via transient analysis of the external magnetic field. In *IECON 2017-43rd Annual Conference of the IEEE Industrial Electronics Society* (pp. 3815-3821). IEEE.

- 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 assess 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., Bentrah, 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>
- Capolino, G. A., Romary, R., Hénao, H., & Pusca, R. (2019). State of the art on stray flux analysis in faulted electrical machines. In *2019 IEEE Workshop on Electrical Machines Design, Control and Diagnosis (WEMDCD)* (Vol. 1, pp. 181-187). IEEE.
- 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>
- Chernyavska, I., & Vítek, O. (2017). Analysis of air-gap eccentricity in inverter fed induction motor by means of motor current signature analysis and stray flux of motor. In *2017 IEEE 11th International Symposium on Diagnostics for Electrical Machines, Power Electronics and Drives (SDEMPED)* (pp. 72-76). IEEE.
- 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>
- Corral, J. (2018). Aportaciones al diagnóstico de averías en motores eléctricos basados en el análisis avanzado de corrientes. Tesis doctoral. Universitat Politècnica de Valencia.
- 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>
- Fatemi, S. R., Henao, H., & Capolino, G. A. (2008, May). Gearbox monitoring by using the stray flux in an induction machine based electromechanical system. In *MELECON 2008-The 14th IEEE Mediterranean Electrotechnical Conference* (pp. 484-489). IEEE.
- Feng, J., & Lu, S. (2019). Performance analysis of various activation functions in artificial neural networks. *Journal of Physics: Conference Series*, *1237*(2), 22030.
- Fernández Cabanas, M., García Melero, M., Alonso Orcajo, G., Cano Rodríguez, J.M., Solares Sariego, J, Técnicas para el mantenimiento y diagnóstico de máquinas eléctricas rotativas. Ed. Marcombo. 1998.
- 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., Albini, 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., Amezquita-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>
- Henao, H., Capolino, G. A., & Martis, C. (2003). On the stray flux analysis for the detection of the three-phase induction machine faults. In *38th IAS Annual Meeting on Conference Record of the Industry Applications Conference, 2003*. (Vol. 2, pp. 1368-1373). IEEE.
- 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.ymsp.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>

- Kumar, P. S., Xie, L., Halick, M. S. M., & Vaiyapuri, V. (2020). Stator end-winding thermal and magnetic sensor arrays for online stator inter-turn fault detection. *IEEE Sensors Journal*, 21(4), 5312-5321.
- 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>
- Lee, S.B., Stone, G., Antonino-Daviu, J.A., Gyftakis, K.N., Strangas, E.G., Maussion, P., Platero C.A., (2020) Condition Monitoring of Industrial Electric Machines: State of the Art and Future Challenges, in *IEEE Industrial Electronics Magazine*, vol. 14, no. 4, pp. 158-167, Dec. 2020. <https://doi.org/10.1109/MIE.2020.3016138>.
- Lee, S.B., Wiedenbrug, E., Younsi, K. (2013) Testing and Diagnostics of Induction Machines in an Industrial Environment, *ECCE 2013 Tutorial*, Sept. 15-19, 2013, Denver, CO, USA.
- 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>
- Muetze, A. & Binder, A. (2007), Calculation of Circulating Bearing Currents in Machines of Inverter-Based Drive Systems, in *IEEE Transactions on Industrial Electronics*, vol. 54, no. 2, pp. 932-938, April 2007,
- 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, ICEM 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>
- Pastor-Osorio, P. A., Antonino-Daviu, J., & Quijano-Lopez, A. (2019). Misalignment

- and rotor fault severity indicators based on the transient DWT analysis of stray flux signals. In *2019 IEEE Energy Conversion Congress and Exposition (ECCE)* (pp. 3867-3871). IEEE.
- 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., Amezcua-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., Lecoite, 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., & Bar, 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
- Soleimani, Y., Cruz, S. M., & Haghjoo, F. (2018). Broken rotor bar detection in induction motors based on air-gap rotational magnetic field measurement. *IEEE Transactions on Instrumentation and Measurement*, 68(8), 2916–2925.
- 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>
- Thomson, W.T., & Fenger, M. (2001). Current signature analysis to detect induction motor faults, in *IEEE Industry Applications Magazine*, vol. 7, no. 4, pp. 26-34, July-Aug. 2001,
- 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/https://doi.org/10.1016/S0007-8506\(07\)60621-0](https://doi.org/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., 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-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>
- 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>