



Universidad de Valladolid



PROGRAMA DE DOCTORADO EN INGENIERÍA INDUSTRIAL

TESIS DOCTORAL:

**DIAGNÓSTICO DE FALLOS EN
GENERADORES TIPO JAULA DE
ARDILLA DE TURBINAS EÓLICAS
MEDIANTE LA SEÑAL DE
CORRIENTE**

Presentada por **YURY HUMBERTO
MERIZALDE ZAMORA** para optar al grado de

Doctor por la Universidad de Valladolid

Dirigida por:

LUIS HERNÁNDEZ CALLEJO

AGRADECIMIENTOS

Para la redacción de esta tesis, durante los últimos cinco años ha sido necesario superar una gran cantidad de factores adversos que incluyen: alta carga laboral, falta de tiempo, falta de presupuesto, enfermedades, edad, problemas familiares, pandemia del COVID-19, entre otros. Pero, paralelamente a cada dificultad siempre existieron personas, especialmente de mi familia, docentes y amigos, que me ayudaron para seguir avanzando. A todos ellos, mis sinceros agradecimientos. Mis agradecimientos a la Universidad de Guayaquil, Universidad de Valladolid y CETASA. Especial agradecimiento al Dr. Óscar Duque Pérez y al Dr. Luis Hernández Callejo, tutor y al director de mi tesis respectivamente.

DEDICATORIA

Inicialmente quería dedicar este trabajo exclusivamente a Natalia y Humberto. Sin embargo, debido al contexto en que se finalizó la tesis, quisiera incluir a todas las víctimas del COVID-19.

MODALIDAD DE LA TESIS

Acorde la normativa vigente en la Universidad de Valladolid, esta tesis se presenta según la modalidad de compendio de publicaciones. A continuación, se describen las cuatro publicaciones que cumplen con los criterios de la Agencia Nacional de Evaluación de la Calidad y Acreditación (ANECA):

[1]. Y. Merizalde, L. Hernández-Callejo, J. Gracia-Bernal, O. Duque-Pérez, L. Bonilla-Morte, L. Zorita-Lamadrid and D. Morinigo-Sotelo, “Comparative Analysis Of Faults From Stall Controlled Wind Turbines With Asynchronous Generators And Pitch Controlled Wind Turbines With Synchronous Generators,” *DYNA*, vol. 93, pp. 541-548, 2018, doi: <http://dx.doi.org/10.6036/8741>

[2]. Y. Merizalde, L. Hernández-Callejo, J. Gracia-Bernal, E. Telmo-Martínez, O. Duque-Pérez, F. Sanchez and A. Llombart-Estpopiñán, “Wind Resource Assessment on Puná Island,” *Applied Sciences*, vol. 9, no. 14, 2019, doi: <https://doi.org/10.3390/app9142923>

[3]. Y. Merizalde, L. Hernández-Callejo, O. Duque-Pérez and R. López-Meraz, “Fault Detection of Wind Turbine Induction Generators through Current Signals and Various Signal Processing Techniques,” *Energies*, vol. 10, no. 21, 2020, doi: <https://doi.org/10.3390/app10217389>

[4]. Y. Merizalde, L. Hernández-Callejo, O. Duque-Pérez and V. Alonso-Gómez, “Diagnosis of broken bars in wind turbine squirrel cage induction generator. Approach based on current signal and Generative adversarial networks,” *Applied Sciences*, vol. 11, no. 15, 2021, doi: <https://doi.org/10.3390/app11156942>

Adicional a las cuatro publicaciones mencionadas previamente, también se han publicado las siguientes revisiones recopilatorias:

- [1]. Y. Merizalde, L. Hernández-Callejo and O. Duque-Pérez, “State of the Art and Trends in the Monitoring, Detection and Diagnosis of Failures in Electric Induction Motors,” *Energies*, vol. 10, no. 7, 2017, doi: <https://doi.org/10.3390/en10071056>
- [2]. Y. Merizalde, L. Hernández-Callejo, O. Duque-Pérez and L. Bonilla Morte, “Wind Turbine Maintenance. A review,” *DYNA*, vol. 93, pp. 435-441, 2018, doi: <http://dx.doi.org/10.6036/8622>
- [3]. Y. Merizalde, L. Hernández-Callejo, O. Duque-Pérez and V. Alonso-Gómez, “Maintenance Models Applied to Wind Turbines. A Comprehensive Overview,” *Energies*, vol. 12, no. 2, 2019, doi: <https://doi.org/10.3390/en12020225>
- [4]. Y. Merizalde, L. Hernández-Callejo, O. Duque-Pérez and V. Alonso-Gómez, “Diagnosis of wind turbine faults using generator current signature analysis: a review,” *Journal of Quality in Maintenance Engineering*, vol. 12, no. 2, 2019, doi: <https://doi.org/10.1108/JQME-02-2019-0020>

ABSTRACT

Among renewable energies, without considering hydroelectric energy, wind energy is among those that have demonstrated the greatest financial feasibility. Currently, the use of this type of energy has become globalized, and several European countries even plan to base their energy matrix on wind farms. This has been possible thanks to the application of advances in different fields of science and engineering that have allowed the construction of wind turbines (WTs) with increasing power and lower cost. However, one of the key factors to guarantee the viability of the wind industry is to minimize operating costs, especially those related to maintenance during the useful life of wind farms.

In relation to maintenance, the main strategy of the wind industry is predictive maintenance based on the constant monitoring of various types of signals obtained from the components of the WTs by means of sensors. As all dynamic equipment produces acoustic or ultrasound vibration, this type of signal is the most widely used for monitoring from the blades to the tower, and most of the existing references on fault detection and diagnosis use the vibration signal. However, there is a lack of publications on other types of signals, especially when it comes to field work. Due to what has been stated so far, this thesis is exclusively dedicated to the study of the current signal and its application to the maintenance of the squirrel cage induction generator used in WTs in operation. The research includes from the historical aspects of the use of the current signal, theoretical foundations on how the components associated with the faults are manifested in the current signal and the methodologies for detection and diagnosis, ranging from: techniques for signal processing From traditional artificial intelligence (AI) models, to deep learning models (Deep Learning-DL) that, due to their ability to handle uncertainty and lack of data, represent the state of the art in the maintenance of rotating electrical machines.

Although the thesis focuses on the squirrel cage induction generator (SCIG) used in wind turbines, the objective is that the theoretical framework built serves as references for the maintenance of the rotary induction machine by means of the signal of current and different methodologies based on signal processing and machine learning (ML). In addition, a methodology is proposed to detect and diagnose incipient broken bars in the SCIG of WTs

in operation, using the current signal and balancing the data set with synthetic samples generated by antagonistic neural networks (GANs).

The remainder of this thesis by compendium of publications is organized as follows. The first chapter provides a general environment on the evolution of wind energy, fundamentals of the induction generator, methods to determine the frequency components associated with the failure, methodologies based on signal processing techniques and artificial intelligence models to detect and diagnose the failures. In chapter two the objectives of the investigation are described. Chapter three describes the methodology used for the research in general and specifically for the proposal based on the current signal and GANs. Chapter four summarizes the published articles and their contribution to the research objectives. In chapter five the articles published as part of this research are reproduced in full. Finally, chapter six is devoted to conclusions and recommendations.

RESUMEN

Entre las energías renovables, sin considerar la energía hidráulica, la energía eólica está entre las que han demostrado mayor factibilidad financiera. Actualmente, el uso de la energía eólica se ha globalizado, e incluso varios países europeos proyectan basar su matriz energética, en parques eólicos. Esto ha sido posible gracias a la aplicación de los avances en distintos campos de la ciencia e ingeniería, los cuales han permitido la construcción de turbinas eólicas (TEs) cada vez de mayor potencia y menor costo. Sin embargo, uno de los factores claves para garantizar la viabilidad financiera de la industria eólica es minimizar los costos de operación relacionados al mantenimiento durante la vida útil de los parques eólicos.

En relación con el mantenimiento, la principal estrategia de la industria eólica es el mantenimiento predictivo basado en el monitoreo constante de varios tipos de señales obtenidas de los componentes de las TEs mediante sensores. Como todos los equipos dinámicos producen vibración acústica o ultrasonido, este tipo de señal es la que se utiliza generalmente para monitorear desde las palas hasta la torre, y la mayoría de las referencias existentes sobre detección y diagnóstico de fallos utilizan la señal de vibración. Sin embargo, existe una carencia de publicaciones sobre otro tipo de señales, especialmente cuando se trata de trabajos de campo. Por lo expuesto hasta aquí, esta tesis se dedica exclusivamente al estudio de la señal de corriente y su aplicación al mantenimiento del generador de inducción tipo jaula de ardilla utilizado en TEs. La investigación incluye desde los aspectos históricos del uso de la señal de corriente, fundamentos teóricos sobre cómo se manifiestan en el espectro de la señal las componentes asociadas a fallos y las metodologías para la detección y diagnóstico, abarcando desde las técnicas para procesamiento de señales y modelos de inteligencia artificial (IA) tradicionales, hasta los modelos de aprendizaje profundo (Deep Learning-DL), que representan el estado del arte en modelos de IA.

A pesar de que la tesis se centra en el generador de inducción tipo jaula de ardilla (GJJA) utilizado en turbinas eólicas, el objetivo es que, el marco teórico construido sirva de referencias para el mantenimiento de la máquina rotativa de inducción mediante la señal de corriente y distintas metodologías basadas en procesamiento de señales y modelos de

aprendizaje automático (Machine Learning-ML). Además, se propone una metodología para detectar y diagnosticar barras rotas incipiente en el generador eléctrico de TEs en operación, utilizando la señal de corriente y balanceando el conjunto de datos con muestras sintéticas obtenidas mediante redes neuronales antagonicas (Antagonistic Neural Networks-GANs).

Lo que resta de esta tesis por compendio de publicaciones se organiza como sigue. El primer capítulo proporciona un entorno general sobre la evolución de la energía eólica, fundamentos del generador de inducción, métodos para determinar componentes de frecuencia asociadas a fallos, metodologías de diagnóstico basadas en técnicas de procesamiento de señales y modelos de inteligencia artificial. En el capítulo dos se describen los objetivos de la investigación. El capítulo tres trata sobre la metodología utilizada en general y de manera específica para una propuesta basada en la señal de corriente y GANs. En el capítulo cuatro se resumen los artículos publicados y su aporte a los objetivos de la investigación. En el capítulo cinco se reproducen de manera íntegra los artículos publicados como parte de esta investigación. Finalmente, el capítulo seis se dedica a las conclusiones y recomendaciones.

ÍNDICE

AGRADECIMIENTOS	II
DEDICATORIA.....	III
MODALIDAD DE LA TESIS	IV
ABSTRACT.....	VI
RESUMEN.....	VIII
CAPITULO I. INTRODUCCIÓN	1
1.1 Perspectiva histórica del uso, desarrollo y evolución de la energía eólica	2
1.2 Fundamentos de la máquina de inducción jaula de ardilla y tipos de fallos	5
1.3 Fallos del generador de inducción jaula de ardilla	9
1.4 Fundamentos de la detección y diagnóstico de barras rotas mediante la señal de corriente. Estado del arte.	14
CAPÍTULO II. OBJETIVOS DE LA INVESTIGACIÓN	25
2.1 Objetivo General.....	26
2.2 Objetivos Específicos.....	27
CAPITULO III. METODOLOGÍA.....	29
CAPITULO IV. RELACIÓN DE ARTÍCULOS PUBLICADOS Y PERTINENCIA CON LA TESIS.....	34
4.1 Comparative Analysis Of Faults From Stall Controlled Wind Turbines With Asynchronous Generators And Pitch Controlled Wind Turbines With Synchronous Generators.....	34
4.2 Wind Resource Assessment on Puná Island.....	34
4.3 Fault Detection of Wind Turbine Induction Generators through Current Signals and Various Signal Processing Techniques	35
4.4 Diagnosis of broken bars in wind turbine squirrel cage induction generator. Approach based on current signal and Generative adversarial networks.....	36
CAPITULO V. ARTÍCULOS PUBLICADOS ELEGIBLES PARA TESIS POR COMPENDIO	37
CAPITULO VI. CONCLUSIONES Y RECOMENDACIONES	38

6.1 Conclusiones y aportes del Doctorando	38
6.2 Trabajos futuros	41
ABREVIATURAS	44
Bibliografía.....	46

ÍNDICE DE FIGURAS

Figura 1. Evolución de las características de TEs.....	3
Figura 2. Potencia eléctrica instalada proveniente de TEs.....	4
Figura 3. Proyección de la potencia eólica total, instalada a nivel mundial.....	4
Figura 4. Fallos según la potencia de motores y generadores	12
Figura 5. Porcentaje de fallos según las principales partes de los motores de inducción con potencia mayor a 150 kW.....	13

ÍNDICE DE TABLAS

Tabla 1. Causas que provocan los principales tipos de fallos.	10
Tabla 2. Esfuerzos que originan fallos, según partes del motor	10
Tabla 3. Fallos según partes del motor de inducción con potencia mayor a 150 kW	13
Tabla 4. Propuestas sobre mantenimiento de TEs mediante DL.	22
Tabla 5. Frecuencias de las componentes laterales obtenidas según Kliman et al	31
Tabla 6. Variables de entrada a los modelos de IA	32

CAPITULO I

INTRODUCCIÓN

Como resultado de: la necesidad de asegurar el aprovisionamiento de energía, combatir el cambio climático debido a la contaminación ambiental, abundancia de recursos eólicos, mejoras en la competitividad de las energías renovables, competencia por mantener el estatus financiero y tecnológico a nivel mundial, durante las últimas décadas la producción de energía mediante TEs ha mostrado un crecimiento constante. Sin embargo, este entorno favorable podría verse afectado si, entre otras cosas, no se desarrollan nuevas técnicas de mantenimiento que permitan disminuir los costos de generación y mejoren la confiabilidad de las TEs [1] y [2].

Investigar y desarrollar nuevas metodologías, técnicas y modelos de mantenimiento, será de gran aporte para reducir los costos y mejorar la competitividad a la industria eólica. En general, la tendencia actual es la aplicación del mantenimiento predictivo para la detección precoz de fallos y averías tanto mecánicas como eléctricas, que de acuerdo con Fleming and Probert [2], presenta las siguientes ventajas:

- Reducción de costos debido a mantenimiento, reparación y paras imprevistas,
- Incremento de la disponibilidad y vida útil de TEs,
- Mejor planificación de las actividades de mantenimiento,
- Detección de anomalías en estado incipiente, y
- Recolección de datos y supervisión remota, incluso en situaciones de climatología extrema.

En este contexto, una alternativa para determinar las condiciones de los componentes de las TEs y especialmente del generador, sería mediante la señal de corriente eléctrica, ya que, como expresan Tavner [3] y Benbouzid and Kliman [4], este tipo de señal se caracteriza por:

- Disponibilidad en todas las TEs,
- Ser una metodología no intrusiva y económica,
- Utilizar sensores robustos y con baja tasa de fallos,

- Prescindir de sensores mecánicos adicionales,
- Monitoreo y diagnóstico online y en tiempo real,
- Detección de fallos mecánicas y eléctricas, y
- Ser útil en máquinas eléctricas rotativas de corriente alterna (Alternating Current - AC) y corriente directa (Direct Current - DC) de cualquier potencia.

Profundizar en el uso de la corriente eléctrica y nuevos modelos de ML, utilizando datos reales, puede constituirse en un gran aporte, no solo para la industria eólica, sino también para la ciencia y tecnología en general [5]. En este capítulo se proporciona una breve perspectiva histórica del uso de la energía eólica, tipos de mantenimiento, fundamentos del GIJA, detección y diagnóstico de fallos en TEs mediante análisis de la señal de corriente y modelos de ML.

1.1 Perspectiva histórica del uso, desarrollo y evolución de la energía eólica

Desde los inicios de la humanidad, una de las principales preocupaciones del hombre ha sido disponer de la energía indispensable para garantizar la supervivencia. Para esto, a través de la historia se ha intentado utilizar una gran diversidad de recursos disponibles, siendo el viento, según Rossi et al. [6], el primer recurso no humano en ser aprovechado. Aunque existan discrepancias sobre fechas y lugares exactos, Kaldellis and Zafirakis [1] y Escudero López [7] manifiestan que, desde hace más de 2500 años antes de Cristo el hombre ha desarrollado varios mecanismos que basan su funcionamiento en la energía del viento, tales como: barcos, molinos de grano, bombas de agua y lo más reciente, TEs. El primer molino de viento que se utilizó para generar electricidad, según Kaldellis and Zafirakis [1], fue construido por Charles Brush en 1888 en la ciudad de Cleveland, Ohio. Este molino constaba de 144 palas fabricadas con madera de cedro, al igual que la torre. El área de barrido tenía un diámetro de 17 metros y por primera vez se utilizó una multiplicadora (relación 1:50) para proporcionar una velocidad de 500 revoluciones por minuto (RPM) a un generador DC de 12 kW. Según Fleming and Probert [2], las turbinas de eje horizontal, tal como las conocemos hoy, se desarrollarían en Dinamarca, en el año 1891. El diámetro del área de barrido de estas turbinas era de apenas 23 metros, utilizaban cuatro palas de perfil aerodinámico primitivo, la torre era de acero con 23 metros de alto y se obtenía hasta 25 kW.

A partir de aquí, el encarecimiento de los combustibles fósiles, la concientización sobre los efectos nocivos del carbono sobre el medio ambiente y los avances tecnológicos, crearon las condiciones propicias para lograr mejoras significativas en las características y eficiencia de las TEs, tales como uso de nuevos materiales, palas de mayor longitud, mayor potencia de los generadores eléctricos, control y operación mediante computadoras. El comportamiento de estas variables a través de los años (ver Figura 1), hace difícil pronosticar un límite para la evolución de las TEs.

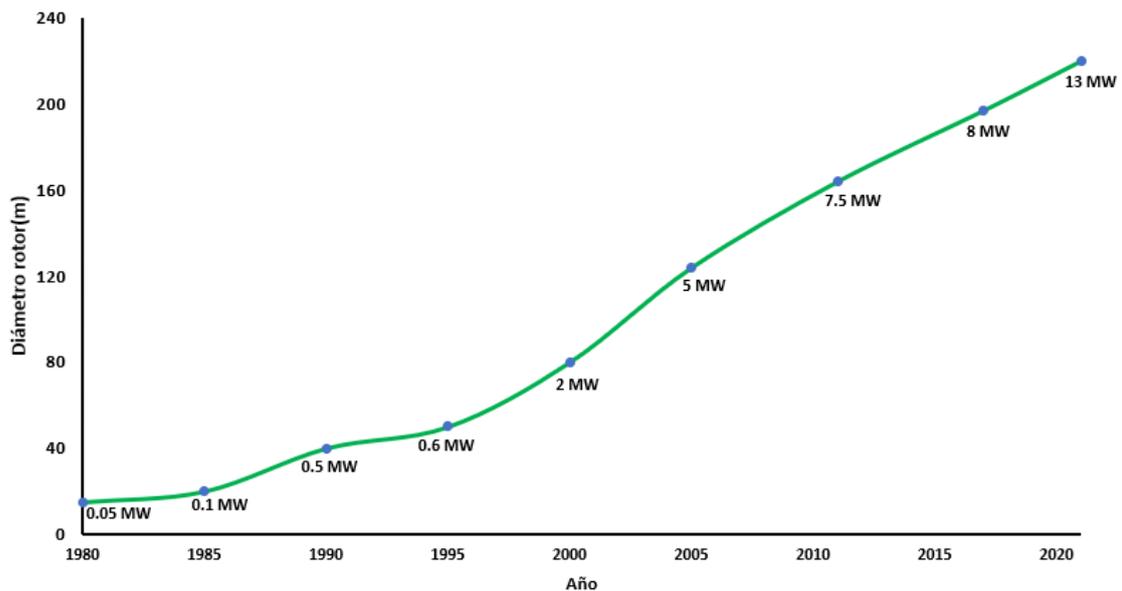


Figura 1. Evolución de las características de TEs. Fuente: [6]-[8], [9] y [10].

Desde su implementación, la producción de energía eléctrica mediante TEs ha mostrado un crecimiento constante. De 11.13 GW instalados en el año 2015 pasó a 87 GW en el 2020, mientras que la capacidad instalada total pasó de 73.96 GW en el año 2000 a 743 GW en el 2020 [11] y [12]. En la Figura 2 se puede observar que, a partir del año 2005 el crecimiento ha sido casi exponencial [13]. Basándose en los datos de la Figura 2 y utilizando tres tipos de tasa de crecimiento [14], en la Figura 3 se presenta la proyección de la potencia eólica instalada hasta el año 2030. En el escenario más pesimista, que es la proyección obtenida con un polinomio de grado dos, la potencia total instalada se duplicaría, lo cual es similar a los resultados obtenidos por Arshad [9].

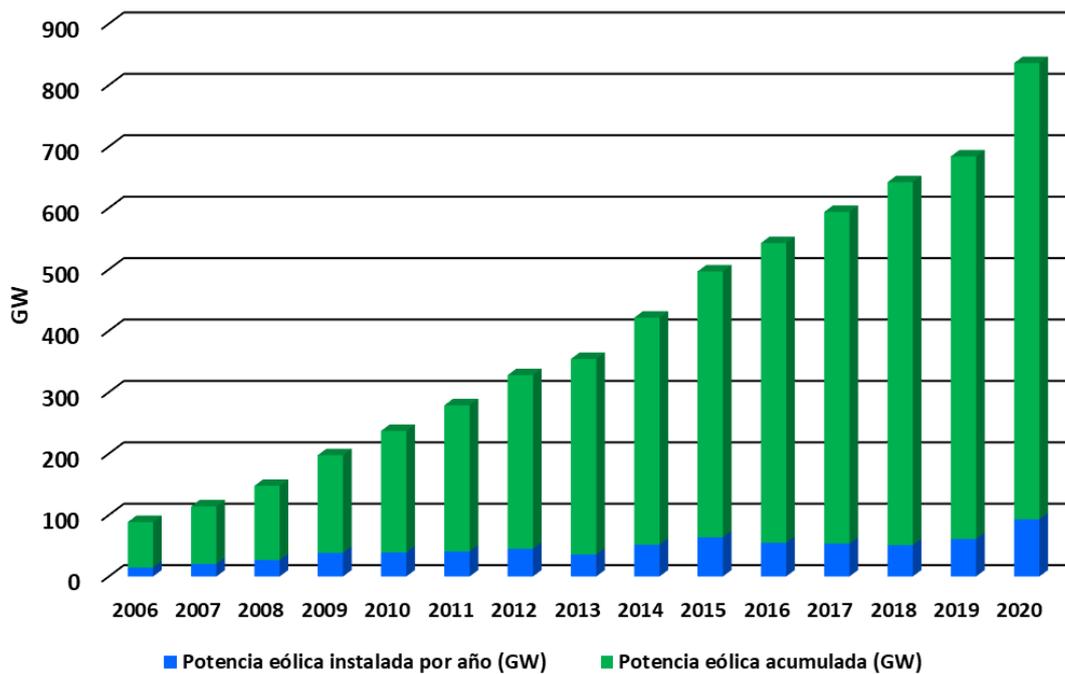


Figura 2. Potencia eléctrica instalada proveniente de TEs [8], [10], [11] y [12].

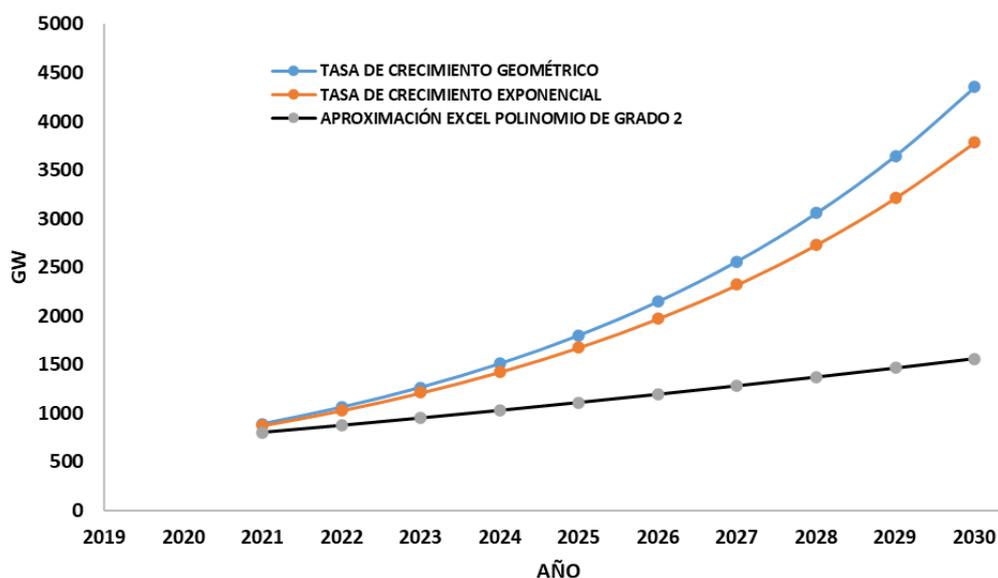


Figura 3. Proyección de la potencia eólica total, instalada a nivel mundial, [9] y [14].

La innovación en la industria eólica ha permitido constantemente establecer nuevos hitos. Así, en el año 2018, la energía eólica lidero la transformación de la matriz energética mundial, que es uno de los principales objetivos para detener los efectos del cambio climático. Se estima que, en el año 2020, el 5% de la energía consumida en el mundo provino de TEs, y según la Agencia Internacional de Energía, para el año 2040 la participación de la

energía eólica alcanzaría entre el 18% y 24% del consumo mundial, debido principalmente a la contribución de India, China, África y Oriente Medio. También se proyecta que más de un tercio de la inversión en generación eléctrica mediante energías renovable sea en energía eólica, siendo Europa el continente que más contribuirá a esta cifra [12]. Independientemente de la exactitud de las proyecciones, debido al entorno en que se desenvuelve nuestro planeta, se puede afirmar que la transición de energías fósiles a renovables será irreversible, al igual que el incremento de la participación de la energía eólica en la matriz energética mundial.

Desde el punto de vista conceptual, uno de los componentes más importantes para producir energía mediante TEs, es el generador eléctrico. Por esto, la investigación se centra en el mantenimiento del generador de inducción tipo jaula de ardilla, y todo lo relacionado a sus principios de funcionamiento, tipos de fallos, tipos de mantenimiento y metodologías para detectar y diagnosticar los fallos.

1.2 Fundamentos de la máquina de inducción jaula de ardilla y tipos de fallos

Aunque existen varios tipos de máquinas eléctricas rotativas, debido a la sencillez constructiva, durabilidad y bajo costo, a nivel industrial, comercial y doméstico predomina el uso de la máquina rotativa de inducción. De acuerdo con AETS [15], una tercera parte del consumo mundial de electricidad se destina para el funcionamiento de motores eléctricos de inducción tipo jaula de ardilla utilizados en bombas, ventiladores, compresores, elevadores y otras aplicaciones donde se convierte energía eléctrica en energía mecánica. Para Stroker [16], en Estados Unidos los motores de inducción consumen el 60% de la energía que se produce.

Inicialmente el tipo de máquina eléctrica rotativa utilizada en las TEs fue el alternador DC [1], hasta que en 1940 la empresa Morgan Smith Company puso en operación una TE diseñada por Palmer Putman, la cual utilizaba un generador sincrónico AC [2]. En la actualidad, Stavrakakis [17] afirma que, el 14% de TEs instaladas utiliza GIJA, superado solamente por el generador de inducción doblemente alimentado (GIDA) que ocupa el primer lugar con el 73%. Es decir, aproximadamente el 87% de TEs utilizan generadores de inducción.

La máquina rotativa de inducción basa su funcionamiento en las leyes de inducción electromagnética de Faraday y Biot-Savart. Tal como sucede entre el primario y secundario de un transformador, cuando el estator de un motor de inducción se alimenta con una tensión, se crea un campo magnético giratorio (teorema de Ferraris) que atraviesa el rotor y le induce una tensión que es directamente proporcional al campo magnético y a la velocidad de variación del flujo magnético que atraviesa su superficie. Matemáticamente, estos principios físicos se resumen con la ecuación de Maxwell para la ley de Faraday (1). La tensión inducida (fem) en el rotor, ecuación (2), origina la aparición de corrientes cuya magnitud dependerá de la resistencia de los conductores, y que según la ley de Biot-Savart, producirán otro campo magnético dado por la ecuación (3) que se opone al del estator. La interacción entre los campos del estator y rotor dan como resultado en el entrehierro un campo neto (B_{net}) constante en el tiempo, que gira a velocidad constante e interactúa con las corrientes del rotor para producir una fuerza (de Lorentz) cuya magnitud está dada por la ecuación (4). Esta fuerza, al actuar en la misma dirección del campo, provoca la rotación del rotor (efecto Laplace). La propiedad de la fuerza para hacer girar el rotor se conoce como torque inducido (τ_{ind}) y su magnitud se la obtiene con la ecuación (5) [18] y [19].

$$\oint_C \vec{E} \cdot d\vec{l} = -\frac{d}{dt} \int_S \vec{B} \cdot d\vec{A} = -\frac{d\Phi}{dt} \quad (1)$$

$$V_{br} = l \cdot (\vec{v}_r \times \vec{B}) \quad (2)$$

$$\vec{B}_r = \frac{\mu_0}{4\pi} \oint \frac{(I d\vec{l}) \times \vec{u}_r}{r^3} \quad (3)$$

$$\vec{F} = i \cdot (\vec{l} \times \vec{B}_{net}) = ilB \sin \beta \quad (4)$$

$$\tau_{ind} = \frac{l}{\mu_0(r_s - r_r)} \int_S r_m B_n B_{tan} dS = \pi \frac{p}{2} l r_m B F \sin(\frac{\pi}{2} + \varphi_r) \quad (5)$$

En general, las principales características de funcionamiento de la máquina de inducción (torque máximo, par de arranque y rendimiento) será función de los parámetros de diseño (resistencia, inductancia, frecuencia, tensión, corriente, deslizamiento). Para que la máquina de inducción pueda operar como motor o generador, es necesario que exista un deslizamiento (s) o diferencia entre la velocidad del campo magnético estático y la velocidad del rotor, según la ecuación (6). En el motor la velocidad del rotor es inferior a la de sincronismo y s es positivo, pero sí de alguna manera, tal como sucede cuando la velocidad del viento

transmite un torque al eje de una TE, entonces la velocidad del rotor es superior a la sincrónica, s se convierte en negativo, y el sentido de la fuerza electromotriz y corriente del rotor se invierten. En estas condiciones la máquina no consume potencia activa, sino que entrega energía a la red, es decir, se ha convertido en generador. Sin embargo, para que esto último suceda, es necesario una corriente de magnetización (potencia reactiva) que produzca un campo magnético giratorio en el estator, lo que se consigue conectando el generador a la red eléctrica o mediante un banco de capacitores que excite el generador (cuando el generador opera de forma aislada) [20] y [21]. Si el GIJA está acoplado a una red eléctrica, su tensión terminal y frecuencia serán iguales a las de la red, mientras que la frecuencia del rotor (f_r) y la velocidad de su campo (respecto al rotor) creado por las corrientes están dados por las ecuaciones (7) y (8) respectivamente [17], [22] y [23].

$$s = \frac{\omega_s - \omega_{mr}}{\omega_s} \quad (6)$$

$$f_r = s * f_s = (\omega_s - \omega_{mr}) \frac{p}{60} \quad (7)$$

$$\omega_r = 2\pi \frac{f_r}{p} = 2\pi \frac{sf_s}{p} = s\omega_s \quad (8)$$

Según el principio de Faraday, la corriente de magnetización del estator origina en el rotor una tensión y corriente cuyo campo magnético variable induce en el estator una fuerza electromotriz (fem). La fem del estator aumenta la tensión, corriente y campo magnético del rotor, lo cual incrementa nuevamente la fem del estator, y así sucesivamente hasta alcanzar el par resistente máximo. Durante el arranque, la corriente del rotor y su flujo asociado que se oponen al del estator, es máximo, y como la impedancia del rotor es baja, su corriente alcanza valores altos que provocan huecos de voltaje, parpadeos transitorios y demanda de potencia reactiva. A medida que el rotor se acerca a la velocidad sincrónica, decrece su corriente y flujo, así como la impedancia de los devanados del estator [19], [24] y [25].

En teoría, mientras mayor sea s , mayor será el campo magnético, tensión, corriente y potencia entregada a la red. Sin embargo, como el consumo de potencia reactiva, las pérdidas eléctricas y mecánicas del GIJA son directamente proporcionales a la potencia activa generada, existe un punto a partir del cual no es posible aumentar la eficiencia. Es decir, la potencia y el par son proporcionales al deslizamiento solo dentro de un rango estrecho muy cercano a la velocidad de sincronismo. Cuando se sobrepasa este pequeño rango, a medida

que aumenta s disminuye el par resistente, el generador se sobrecalienta y aumentan las pérdidas. Para Polinder et al. [26], el generador desarrolla el máximo par resistente cuando el deslizamiento llega al 20 %. Según Chapman [19], s no debe ser mayor al 7%, a juicio de Tomasello [20] s debe estar entre 4 y 6% en generadores pequeños, y entre 1,5 y 2% en generadores de grandes potencias. A juicio de Stavrakakis [17], en las TEs de gran potencia equipadas con GIJA, la máxima eficiencia se alcanza con un s inferior al 1%.

Como la velocidad del viento es variable, para mantener constante el torque de las TEs que utilizan GIJA, se tendría que variar la resistencia del rotor. Si la velocidad del viento aumenta se debe incrementar la resistencia, mientras que si la velocidad del viento decrece (pero sin llegar a la velocidad de sincronismo), entonces se debe disminuir la resistencia del rotor. Los generadores de inducción doblemente alimentado aprovechan este principio y para extraer siempre la máxima potencia del viento controlan la impedancia del rotor mediante la frecuencia alimentada por los convertidores de potencia [27], [28] y [29]. Sin embargo, en los GIJA la resistencia del rotor es fija y solo pueden operar en un rango estrecho de velocidades. Por esto, la orientación de la TE se controla en función de la velocidad del viento y la potencia de salida del generador, para tratar de mantener constante la velocidad del eje principal. Para aprovechar la energía del viento en un rango más amplio de velocidades, en los GIJA de TEs se podría aplicar alguna de las siguientes alternativas [17] y [30]:

- Utilizar dos generadores independientes, uno para bajas velocidades y otro de mayor potencia para velocidades altas. Se tendrían dos multiplicadoras.
- Utilizar un solo generador que tenga dos bobinados independientes.
- Reconectar el bobinado del estator, de tal forma que se cambie el número de polos, velocidad a la cual se genera y potencia de salida.
- Conexión a la red mediante un convertidor que permita variar la frecuencia de la tensión de excitación, de tal forma que se cambia la velocidad de sincronismo según la velocidad del viento.

Una de las mayores dificultades de los GIJA es su incapacidad para mantener constante la frecuencia y tensión cuando varían las cargas y/o la velocidad del rotor, por lo que existe el peligro latente de auto excitación o aparición de picos de voltajes muy altos cuando el

generador opera sin carga, no está conectado a la red, se producen huecos de tensión (voltage sag) o parpadeos de voltaje (flicker). En todos estos casos, la compensación de la potencia reactiva mediante el banco de capacitores juega un papel fundamental, y su regulación, así como el par y las corrientes durante su acoplamiento a la red, se lo hace mediante convertidores de potencia, capaces de responder en milisegundos a los eventos que se presentan en el sistema [31], [32], [33] y [34].

1.3 Fallos del generador de inducción jaula de ardilla

Como la máquina rotativa de inducción puede trabajar como motor o generador, ambos tipos de máquina comparten los principios de funcionamiento y las técnicas aplicadas para el diagnóstico de fallos. Durante su operación, la máquina de inducción rotativa está sujeta a una combinación de varios esfuerzos que actúan de forma simultánea en el estator, rotor, rodamientos y eje. En teoría, mientras la magnitud de estos esfuerzos se mantengan dentro de los parámetros de diseño, no deberían ocurrir fallos, sin embargo, cuando la diferencia es significativa se produce la disminución de la vida útil o incluso el colapso [35]. Los fallos se las podría clasificar de varias formas, así, según lo estudiado en [36], [37], [38], [39], [40] y [41], los principales tipos de fallos del GIJA y los esfuerzos que las provocan, se resumen en las tablas 1 y 2. El proceso en que se producen los fallos, se describen en las referencias mencionadas.

Tabla 1. Causas que provocan los principales tipos de fallos. [36]-[41].

Estator	Rotor	Eje	Rodamientos
1) Laminación 2) Falla de aislamiento del núcleo. Daños de la carcasa 3) Amarras dañadas, contaminación del aislamiento por humedad, aceites, suciedad, conexiones, agrietamiento del aislamiento, desplazamiento de conductores, cortocircuitos entre espiras. 4) Daño de aislamiento entre espiras o bobinas 5) Daño de conductores.	Rotura de barras y anillos de corto circuito Falla de aislamiento del núcleo y bobinado Integridad mecánica del rotor	Pérdida de holguras Excentricidad de las barras Agrietamiento Desalineación	Peladuras/descamación Fracturas /Grietas Abolladuras Picaduras Desgaste Deslizamiento Atoramiento Corrosión por corrientes Moho y corrosión Daño de la jaula Defectos de montaje

Tabla 2. Esfuerzos que originan fallos, según partes del motor.[36]-[41].

Esfuerzos	Estator	Rotor	Eje	Rodamientos
Eléctricos	Envejecimiento del dieléctrico Efecto corona Transientes	Envejecimiento del dieléctrico Efecto corona Transientes		Acoplamiento electrostático Cargas estáticas
Magnético		Ruido Vibración Saturación del hierro Corrientes parásitas	Cargas laterales Arranques y paradas. Desfases	

Tabla 2. (Continuación)

Esfuerzos	Estator	Rotor	Eje	Rodamientos
Mecánico	Movimiento de bobinas Golpes y/o choques de objetos Defectos del núcleo	Variaciones de la fundición Pérdida de laminación Ajustes incorrecto Fatiga o rotura Desalineación	Sobrecargas Cargas Torsionales y axiales	Pérdida de holguras Desalineación Mal ensamblaje Vibraciones y choque por cargas acopladas
Esfuerzo Residual	Procesos de fabricación y reparación	Concentración de esfuerzos Variación de esfuerzos en las barras	Procesos de fabricación y reparación	
Dinámico/ Estático		Vibración Roces Exceso de velocidad Esfuerzos cíclicos Fuerzas Centrifuga	Choques cíclicos	Radial Axial Precarga
Medio ambiente	Falta de ventilación Humedad Corrosión Abrasión	Contaminación Abrasión Partículas extrañas Falta de ventilación Exceso de temperatura	Corrosión Humedad Erosión Cavitación Desgaste	Condensación Materiales extrañas Exceso de temperatura ambiental Falta de ventilación
Térmico	Envejecimiento térmico Variación de tensión Cargas cíclicas Ventilación Temperatura ambiental	Sobrecarga térmica Desbalance Pérdidas en el cobre Puntos calientes Chispas	Variaciones de temperatura	Fricción Lubricación Temperatura ambiental
Otros		Uso incorrecto Mal diseño y manufactura Pérdidas en barras y núcleo Variaciones de torque Dirección de giro equivocada		

Además de los factores que originan los fallos, la frecuencia de ocurrencia también puede estar influenciada por el tipo de máquina, tensión de alimentación, potencia y modelo, tal como muestran las estadísticas de la Figura 4. Aunque por diversas razones, los porcentajes de fallo suelen variar según la investigación consultada, sin embargo, existe consenso sobre los componentes que más contribuyen a los fallos. Así, de acuerdo con Blodt et al. [42], entre el 40% y 50% de todas los fallos se deben a los rodamientos, Kliman et al. [43] manifiestan que entre el 30 y 40 % de fallos corresponden al estator, a juicio de Siddique et al. [40], el estator representa el 37 % de los fallos, mientras que, según Joksimovic and Penman [44], aproximadamente el 75% de los fallos en el motor de inducción tipo jaula de ardilla se deben a los rodamientos y bobinado del estator. IEEE [45] y Bonnett [37] sostienen que los fallos en los motores de inducción, se distribuyen según la Figura 5 y Tabla 3. En lo que respecta a la industria eólica, la robustez y confiabilidad que caracteriza a la máquina rotativa de inducción se confirma mediante la investigación de Merizalde et al. [46] sobre los fallos de los GIJA utilizados en TEs,

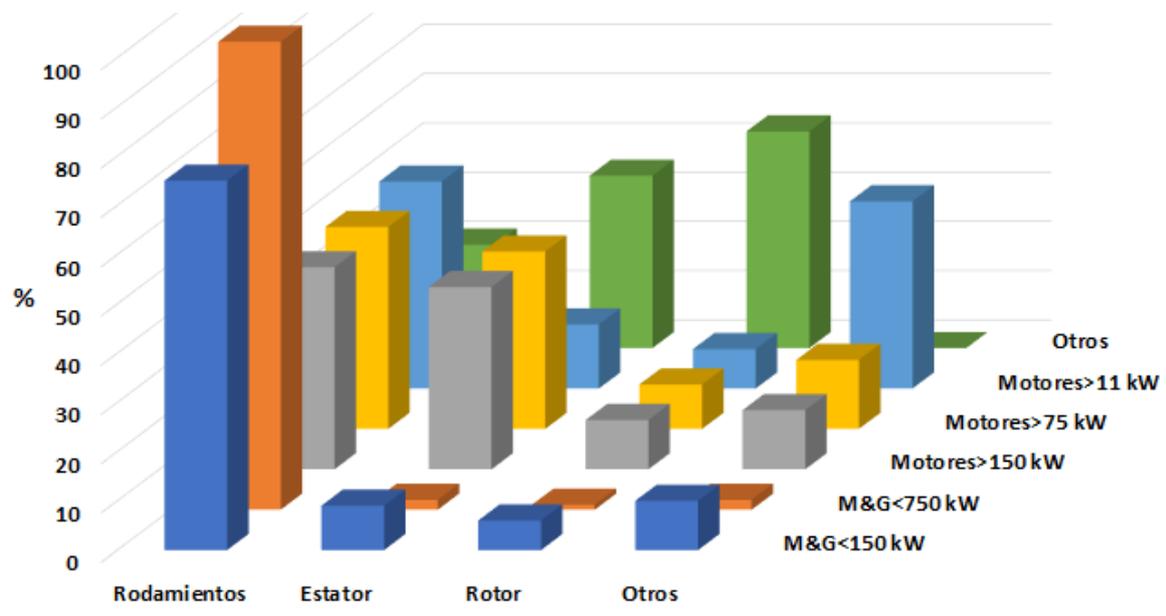


Figura 4. Fallos según la potencia de motores y generadores, [3] y [37].

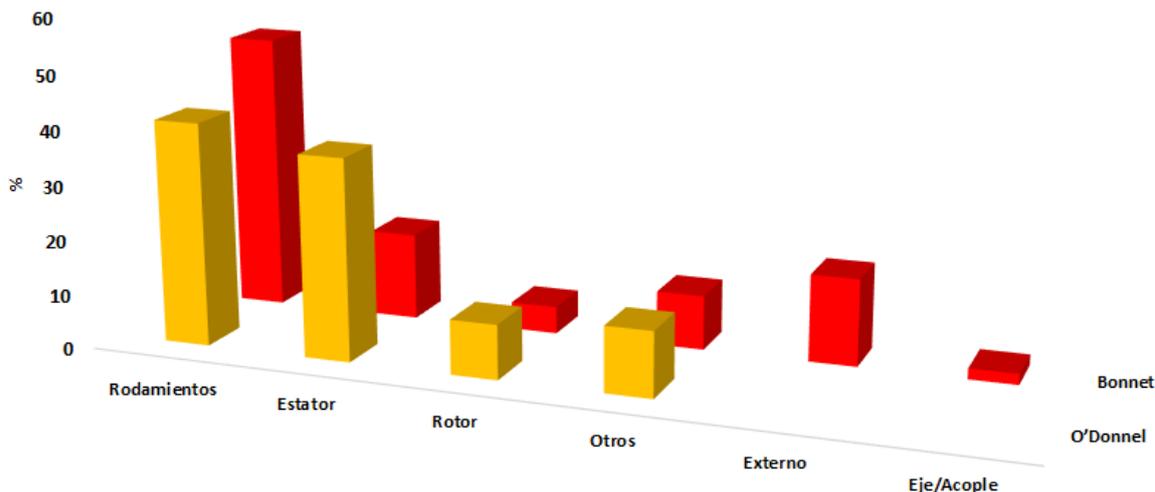


Figura 5. Porcentaje de fallos según las principales partes de los motores de inducción con potencia mayor a 150 kW, [37] y [45].

Tabla 3. Fallos según partes del motor de inducción con potencia mayor a 150 kW [45].

ESTATOR	%	RODAMIENTOS	%	ROTOR	%
Contacto a tierra	23	Cojinete de deslizamiento	16	Jaula de ardilla	5
Aislamiento entre espiras	4	Esferas	8	Eje	2
Amarras	3	Sellos	6	Núcleo	1
Cuñas	1	Cojinete giratorio	5		
Carcasa	1	Pérdida de aceite	3		
Núcleo	1	Otros	15		
Otros	4				

Una de las estrategias del enfoque clásico de mantenimiento es que, para controlar las condiciones de los equipos, estos se deberían someter a determinadas pruebas periódicamente. Por ejemplo, la medición del nivel de aislamiento de los devanados ha sido una de las técnicas más usadas para indicar el grado de deterioro, localización específica de fallos y mecanismo o forma en que se produce el proceso de degradación [47]. La desventaja de este tipo de metodologías es que algunas deben hacerse con la máquina fuera de servicio, por lo que sería necesario esperar las paradas por mantenimiento o fallos. Para superar estas desventajas, y sin descartar el uso de técnicas tradicionales, la norma actual es aplicar el enfoque predictivo basado en la medición, tratamiento, procesamiento de señales obtenidas

en tiempo real y modelos de inteligencia artificial, para detectar, diagnosticar y predecir fallos mientras la máquina se encuentra funcionando [48]. A continuación, se describen las estrategias mencionadas, haciendo énfasis en el caso de barras rotas, debido a que su diagnóstico puede ser complicado y una vez que aparece esta falla es difícil reparar. Además, como esta falla no aparece de manera repentina, aunque aparentemente el generador esté sano, es muy probable es la existencia de este tipo de falla en estado incipiente.

1.4 Fundamentos de la detección y diagnóstico de barras rotas mediante la señal de corriente. Estado del arte.

Cuando el estator de la máquina de inducción se alimenta con una tensión, se produce una corriente cuyo espectro y la amplitud de sus componentes estará influenciado por los parámetros de diseño [18]. Desde el punto de vista de Penman et al. [49], la corriente del estator crea un flujo en el entrehierro que induce las corrientes del rotor, cuyo espectro, en el caso de una máquina trifásica con paso polar completo y alimentada con una frecuencia balanceada, está dado por la ecuación (9). Puede decirse también que esta ecuación representa la distribución espacial de las armónicas de la fuerza magneto motriz con referencia al rotor. La corriente del rotor crea su propio campo que se refleja en el estator, por lo tanto, el espectro de este es la resultante de las componentes de la corriente de alimentación y las del rotor.

$$\begin{aligned} \Phi_s = & \Phi_1 \cos(s\omega_s t - p\theta_r) + \Phi_5 \cos((6 - 5s)\omega_s t + 5p\theta_r) \\ & - \Phi_7 \cos((7s - 6)\omega_s t - 7p\theta_r) + \Phi_{11} \cos((12 - 11s)\omega_s t + 11p\theta_r) \dots \dots \end{aligned} \quad (9)$$

En condiciones normales de operación, el espectro de la señal tendrá componentes definidas, sin embargo, las asimetrías propias del generador y de las cargas acopladas a este (multiplicadora, palas), transmitirá vibraciones torsionales que actúan sobre el rotor, provocando variaciones de: velocidad, torque, flujo magnético del entre hierro y corriente de las barras. A juicio de Bonnett [37], otros esfuerzos que ejercen un torque sobre el rotor incluyen: fuerzas dinámicas desbalanceadas, vibración torsional, torques transitorios, fuerzas magnéticas causadas por flujos de dispersión sobre las ranuras, excentricidad del entrehierro, fuerzas centrífugas, esfuerzos térmicos causado por calentamiento del anillo de

cortocircuito, calentamiento de las barras durante el arranque (skin effect), fuerzas residuales debido a fundición, maquinado y soldadura. Esto significa que los fallos mecánicos y eléctricos se manifestarán como componentes laterales de la onda fundamental. La amplitud y cantidad de las componentes dependerá de la severidad de la falla [50] y [51].

Aunque en las máquinas rotativas de inducción se pueden presentar una variedad de fallos, sin embargo, debido a la dificultad para su reparación, una de las más importantes son las barras rotas del rotor. Kliman [52], plantea que por una barra defectuosa circulará una corriente con sentido opuesto a la corriente en estado sano, y dicho con palabras de Kral et al. [53], la componente de la onda de la fuerza magnetomotriz que gira en sentido contrario induce un voltaje/corriente a una frecuencia dada por la ecuación (10).

$$f_l = f_s - 2f_r = f_s - 2sf_s = (1 - 2s)f_s \quad (10)$$

Las armónicas (f_l) que aparecen en el espectro del estator debido a las barras rotas del rotor, inducen en el rotor un nuevo (doble o segundo) espectro de frecuencia en el torque del rotor ($f_t = 2f_r$), lo cual provoca pulsaciones en la potencia eléctrica. Es decir, es como si el par motor tuviera dos espectros de frecuencia superpuestos, uno debido a la frecuencia de alimentación (f_s) y otro debido a las armónicas inducidas en el estator por la corriente de falla en la barra rota. Además, la interacción entre la inercia de la máquina y las oscilaciones del torque induce en el espectro armónicas laterales derecha o superior, cuyas frecuencias están dadas por la ecuación (11).

$$f_u = f_s + 2f_r = f_s + 2sf_s = (1 + 2s)f_s \quad (11)$$

Las barras rotas ocasionan que alrededor de las armónicas primas aparezcan componentes laterales cuyas frecuencias vendrían dadas por: $f_{l,u}(k) = (1 \pm 2ks)f_s$, donde $k = 1, 2, 3$, es el número ordinal de la armónica específica de la falla. Por lo expuesto, en caso de haber una barra rota, alrededor de cada componente del espectro de la señal de corriente (1, 5, 7, 11, 13, 17, ...) aparecerá esta familia de componentes, aunque para el diagnóstico generalmente solo se considera la diferencia de magnitud entre la componente fundamental y sus componentes laterales cuando $k=1$.

Se podría pensar que lo visto hasta ahora sería suficiente para diagnosticar una barra rota, sin embargo, como expresa Kliman [52], el inconveniente radica en que, las asimetrías

geométricas de la máquina, problemas de alineación, calidad del rotor y la orientación magnética de las láminas producen alrededor de la onda fundamental, espectros tan similares al producido por barras rotas, que resulta difícil distinguirlos. Por esto, para diagnosticar barras rotas es necesario recurrir a las armónicas espaciales de orden superior, es decir:

- quinta armónica: $f_{l,u}(k) = (5 \pm 2s)f_s$,
- séptima armónica: $f_{l,u}(k) = (7 \pm 2s)f_s$,
- décima tercera armónica: $f_{l,u}(k) = (11 \pm 2s)f_s$, y así sucesivamente

Analizados los métodos para determinar las frecuencias del espectro asociadas a barras rotas y la forma en que estas se originan, la siguiente etapa en el proceso de diagnóstico es determinar las metodologías apropiadas para encontrar dichas frecuencias de interés. Das [48] manifiesta que los modelos utilizados para la detección y diagnóstico de fallos se pueden agrupar como base de datos, conocimiento previo y modelos híbridos. Desde el punto de vista práctico y a modo de resumen, se puede decir que las metodologías utilizadas son las basadas en procesamiento de señales, modelos de inteligencia artificial y una combinación de ambos.

El análisis más básico de una señal y quizás el primero en ser utilizado es el estudio en el dominio del tiempo, que consiste básicamente en el uso de los parámetros: valor pico, raíz media cuadrática (Root Mean Square - RMS), kurtosis, factor de forma y desviación estándar [54]. Aunque el análisis en el dominio del tiempo podría ser de utilidad para monitoreo, no es suficiente para: diagnosticar con precisión a qué tipo de falla obedece la forma de onda, cuáles son las frecuencias asociadas a cada falla y análisis en estados transitorios [55]. Sin embargo, en la actualidad varias propuestas para diagnóstico de fallos basadas en IA utilizan los parámetros en el dominio del tiempo mencionados para entrenar los modelos.

Para contrarrestar las limitaciones del análisis en el dominio del tiempo, surge el análisis espectral de la señal en el dominio de la frecuencia. El procesamiento y análisis de la señal eléctrica para diagnosticar fallos en los motores, según Thomson and Culbert [5], se remonta a los años 70, cuando se la utilizó para detectar los fallos de los motores instalados en plantas nucleares, que, además de ser de difícil acceso, representaban un peligro para el ser humano. Citando a Haynes and Eissenberg [56], la metodología que actualmente se conoce a nivel mundial como análisis espectral de la corriente del motor (Motor current signature Analysis

- MCSA), fue desarrollada y patentada por Oak Ridge National Laboratory en el año 1986. En una publicación del año 1992, Kliman and Stein [55], resumen la metodología del MCSA, que a esa fecha se basaba casi exclusivamente en la transformada de Fourier (TF). Según el estudio mencionado, las asimetrías del rotor debido a barras rotas se caracterizan por girar a la misma velocidad del eje y por perturbar el flujo del entrehierro, pero, como las oscilaciones de carga producen un efecto similar, para identificar las componentes de frecuencia asociadas a barras rotas, es necesario medir de forma precisa la frecuencia de deslizamiento. De acuerdo con Kliman et al. [52], mientras la presencia de barras rotas provoca la aparición de grandes armónicos superiores, las asimetrías debido a rodamientos, excentricidad estática y dinámica, los disminuye. Ambos tipos de fallos producen un espectro con bandas laterales similares, sin embargo, cuando se trata de barras rotas, la cantidad y magnitud de las armónicas de orden superior será mayor que en el caso de fallos debido a rodamientos, excentricidad estática y dinámica.

Debido a que el deslizamiento de los GIJA de TEs es inferior al 1 %, se podría decir que la velocidad es prácticamente constante, y por lo tanto el espectro de la señal de corriente no se alteraría significativamente [57] y [58]. Sin embargo, se debe considerar que, las variaciones de la velocidad del viento y el sistema de control que compensa las variaciones de carga pueden contaminar la señal. Por otra parte, aunque el número de armónicas y magnitud se incrementa con los fallos, en su estado inicial estas se manifiestan en frecuencias y amplitudes muy pequeñas, ya que son atenuadas por las frecuencias naturales de los componentes de la TE [59] y [60]. Además, como el comportamiento de la máquina de inducción depende del porcentaje de carga o del estado de operación (estable o transitorio), entonces se requieren técnicas de análisis acorde las condiciones de operación de la máquina [61] y [62].

Las condiciones o el contexto en que se realiza el proceso de diagnóstico determinan la metodología y modelos matemáticos a seguir. En estado estable (deslizamiento constante), se puede aplicar el análisis espectral básico mediante la transformada rápida de Fourier. Si el deslizamiento es alto se utiliza el periodograma, mientras que con deslizamiento bajo se han desarrollado técnicas denominadas de alta resolución, tales como: Media Móvil autorregresiva (AutoRegressive Moving Average-ARMA), Media Móvil Integrada de Regresión Automática (AutoRegressive Integrated Moving Average-ARIMA),

Clasificación de Señal Múltiple (multiple signal classification-MUSIC) y Estimación de los Parámetros de la señal mediante la Técnica de Invariancia Rotacional (Estimation of signal parameters via rotational Invariance Technique-ESPRIT). Si la velocidad, deslizamiento y frecuencias varían a través del tiempo, es necesario analizar el comportamiento del espectro en el dominio tiempo-frecuencia. Para los estados transitorios, si el deslizamiento es alto se utiliza el espectrograma y las wavelets, mientras que para deslizamiento bajo (como es el caso de los GIIA utilizados en TEs) se acostumbra utilizar las técnicas de Wigner-Ville, Pseudo Wigner Ville y distribución de Zao-Atlas Marks [4], [63] y [64].

Aunque se podría decir que las técnicas y metodologías utilizadas son las mismas que para el motor de inducción, pueden existir particularidades en función del tipo de generador eléctrico. Cuando se estudia el GIDA, se tienen dos fuentes de corriente (estator y rotor), por lo que, tal como plantea Cheng et al. [65], existen varias señales que se pueden utilizar, dependiendo del tipo de falla, su ubicación y la técnica a utilizar [66]. Mediante el análisis de la corriente del estator, en la publicación de Williamson and Djurović [59] se incluye la deducción de las ecuaciones analíticas para obtener las componentes debido a varias condiciones de alimentación y desbalances del bobinado tanto del estator y del rotor cuando se opera en estado estable. El modelo utilizado es el de elementos finitos, que considera los armónicos superiores del campo del entrehierro y la distribución precisa de los conductores en el bobinado (según la teoría de acoplamiento de circuitos). Estos conceptos son incorporados en las ecuaciones electromagnéticas y mecánicas que forman el modelo matemático del GIDA, para deducir las ecuaciones de onda y sus componentes, tanto en la ausencia de fallos como en la presencia de estas.

Para Al Ahmar et al. [67], la detección de los fallos de excentricidad mediante la propuesta de Williamson and Djurović [59] requiere el conocimiento detallado del modelo del generador, por lo que recomienda hacerlo mediante el espectro de la corriente del estator, donde las frecuencias de los fallos están definidas por ecuaciones. Entre las técnicas de procesamiento de señales que se pueden utilizar, el análisis tiempo-frecuencia (escalograma) y espectrograma dan mejores resultados que la densidad de potencia espectral (periodograma) basada en la transformada discreta de Fourier.

Según plantean Williamson and Djurović [59] y Al Ahmar et al. [67], la pequeña magnitud de las componentes asociadas a los fallos dificulta su extracción. Para superar este

inconveniente una de las técnicas más sugeridas es la demodulación de la señal (del estator o rotor) modulada por los fallos. Desde el punto de vista de Amirat et al. [68], para demodular la señal es preferible usar la transformada de Hilbert, debido a su fortaleza para manejar el ruido. Según esta propuesta, mientras no existan fallos la amplitud de la envolvente será constante en el tiempo y su varianza será cero, caso contrario, si la varianza es mayor a un umbral preestablecido, entonces existiría una asimetría. Aunque la propuesta de Amirat et al. [68] es sencilla e implementada en un pequeño banco de prueba, sin embargo, es un punto de partida para la aplicación de una variedad de modelos.

Kia [50] afirma que las barras rotas en las máquinas de inducción se pueden detectar mediante la transformada wavelet discreta (TWD), sin usar el deslizamiento. Sin embargo, desde el punto de vista de Ibrahim et al. [69] la transformada de wavelet continua (TWC) y técnicas como la TF discreta localizada iterativa tienen desventajas, especialmente cuando el análisis se hace durante la operación con cargas pequeñas o cerca de la velocidad de sincronismo. Por esta razón propone un método basado en filtros Kalman extendidos, que según el autor sería más efectivo en la detección de los fallos y su evolución a través del tiempo, a la vez que es más eficiente computacionalmente.

La mayoría de las propuestas sobre detección y diagnóstico de fallos en TEs utilizando la señal de corriente y técnicas de procesamiento de señales, se centran en los rodamientos y engranajes de la multiplicadora [70], [71], [72], [73], [74] y [75]. Los estudios específicos sobre el generador eléctrico son poco frecuentes.

Basándose en el estudio de Yacamini [76] para cargas mecánicas acopladas a motores eléctricos, en Gong and Qiao [57] se hace una propuesta similar para detectar fallos de excentricidad en TEs de eje directo. Según los autores, la variabilidad de la frecuencia haría difícil aplicar el análisis espectral clásico y el análisis de bicoherencia para diferenciar en el espectro del generador fallos provocadas por otros componentes, mientras que con el análisis tiempo-frecuencia y demodulación de la amplitud no se puede identificar fallos de excentricidad cuando existen interferencias que tienen espectros similares, por lo que proponen primero normalizar la señal mediante la amplitud instantánea obtenida con la transformada de Hilbert y luego, demodular la señal del estator de un generador sincrónico de imanes permanentes (permanent magnet synchronous generator - PMSG) o del rotor si se trata de un GIDA, aplicando el método *phase locked loop*. Las frecuencias estimadas a

velocidad variable son procesadas mediante algoritmos de remuestreo, de tal forma que se obtiene un valor constante, sobre cuyo espectro se puede aplicar el análisis espectral clásico.

El método utilizado por Gong and Qiao [57] para diagnosticar fallos de rodamientos de un PMSG, es utilizado por Gong and Qiao [77] para analizar también fallos en las palas. En ambos casos, haciendo el análisis espectral de la amplitud modulada a una frecuencia fija, el desbalance de las palas se manifiesta mediante el aumento de la amplitud de la componente de 10 Hz, mientras que la falla por rodamientos se manifiesta a los 3.95 y 6.05 Hz.

Pese al aporte que han representado las técnicas de procesamiento de señales en el campo del mantenimiento de las máquinas eléctricas rotativas, también existen desventajas y limitaciones, por ejemplo, cuando las condiciones de operación no son estables. Varios de los modelos vistos hasta ahora ameritan el conocimiento de la velocidad mecánica del rotor y/o deslizamiento, datos del generador (ranuras, barras, etc.) y otras variables que generalmente no están disponibles. También, cuando se utilizan las diversas técnicas de procesamiento y análisis de señales, es necesario hacer el estudio por cada fase y por cada registro a la vez, por lo que, considerando todas las TEs de un parque eólico, el trabajo se complicaría mucho y podría inducir a errores. Para tratar de contrarrestar los inconvenientes mencionados, surgen las metodologías basadas en modelos de IA.

Un sistema de IA es un modelo de caja negra construido mediante un conjunto de modelos de caja gris y blanca, que pueden trabajar de manera individual o combinada para intentar imitar la inteligencia humana [78]. En la actualidad, la IA está presente en casi todas las actividades del ser humano y el mantenimiento industrial, no es la excepción [79]. Con base en lo investigado, se puede decir que, la norma en la industria eólica es la aplicación del mantenimiento predictivo basado en el monitoreo online de las condiciones, detección, diagnóstico y predicción de fallos, pero aplicando técnicas de inteligencia artificial [78], [80] y [81]. Entre los modelos de IA utilizados inicialmente se pueden mencionar: Fuzzy logic, redes neuronales artificiales (artificial neural network-ANN), análisis de componentes principales (principal component análisis-PCA), k vecinos más cercanos(k nearest neighbors-kNN), máquina de soporte de vectores (Support vector machine-SVM), lógica difusa (Fuzzy Logic), algoritmos genéticos, etc., [82].

En la propuesta de Ibrahim et al. [83] se muestrea la señal de corriente de un PMSG tanto en la presencia de fallos como en ausencia de estas, a 5 kHz durante 300 segundos, a velocidades que oscilan entre 924 y 937 rpm. Para que la señal pueda ser procesada, la desviación estándar de la velocidad de cada rango tiene que estar dentro de un límite predefinido, por esto, la señal se divide según rangos de velocidades definidos por un límite inferior y otro superior. Cada muestra de señal tiene una duración de 2 segundos, y mediante la transformada de Fourier de cada muestra se obtienen 250 componentes que alimentan la red neuronal correspondiente a cada rango de velocidad. Según esta propuesta, la ANN alcanza una efectividad del 98% en diagnosticar la excentricidad del rotor.

Hichem and Tahar [84] utilizan el valor *rms* de las corrientes del estator y rotor de un GIDA, para alimentar un sistema Fuzzy, donde las amplitudes de las corrientes son interpretadas como variables lingüísticas (muy pequeño, pequeño, medio y grande). Mediante las funciones de membresía del modelo se determina si el estator y/o rotor se encuentran: sanos, con indicio de corto circuito, con daño grave o con una fase abierta. Sin embargo, el generador, señal de corriente y fallos, son obtenidas en Simulink.

Pese al aporte significativo de los modelos tradicionales de aprendizaje automático, Zhang et al. [85] manifiesta que los modelos tales como: ANN, PCA, kNN, SVM y Fuzzy Logic, basan su aprendizaje en funciones creadas por las personas y muchas veces proporcionan resultados difíciles de interpretar, además de requerir personal experto para definir las características idóneas del modelo y la interpretación de los resultados. Desde el punto de vista de Zhang et al. [85], en comparación con los modelos de IA tradicionales, los modelos de aprendizaje profundo (DL) tales como: red neuronal convolucional (convolutional neural network-CNN), autoencoder (AE), red de creencias profundas (deep belief network-DBN), red neuronal recurrente (recurrent neural network-RNN), Memoria a Corto y Largo plazo (Long Short Term memory-LSTM), autocodificador (Autoencoder-AE), autocodificador variacional (Variational autoencoder-VAE) y redes generativas antagónicas (generative adversarial network-GANs), son superiores en la extracción de características, pueden trabajar con conjuntos de datos mucho más grandes, requieren menos manipulación de los datos, proporcionan mejores resultados y reducen la necesidad de personas expertas para hacer el diagnóstico.

La mayoría de las propuestas sobre mantenimiento de TEs mediante modelos de DL utilizan la señal de vibración, y los componentes más analizadas son los rodamientos y engranajes de la multiplicadora [85] y [86]. Ver Tabla 4.

Tabla 4. Propuestas sobre mantenimiento de TEs mediante DL.

Modelo utilizado	Componente	Señal	Referencia
DBN	Rodamientos	Vibración	[87] [88]
Autocodificador	Multiplicadora	Vibración	[89]
		Temperatura	[90]
CNN	Multiplicadora	Vibración	[91]
RNN/LSTM	Varios componentes	Vibración	[92][93]

Las referencias basadas en la señal de corriente son escasas. Según Cheng et al [94], una red neuronal normal tiene muy pocas capas y no puede extraer todas las características de los datos de entrada, por lo que, para diagnosticar los fallos de la multiplicadora de una TE utilizando la señal de corriente, propone un modelo no supervisado compuesto por un codificador automático apilado (Stacked autoencoder-SAE) y una SVM multiclase. Mientras un AE es una ANN de tres capas (entrada, intermedia y salida) cuyo objetivo es reproducir los datos originales de entrada en base a la información comprimida en el espacio de variables latentes, un SAE es una ANN profunda compuesta por múltiples AE.

En la propuesta de Cheng et al. [94] la señal de corriente del rotor de un generador de inducción doblemente alimentado es muestreada a 5 kHz, y como la velocidad de la TE es variable, para obtener la envolvente que contiene las frecuencias, la señal se demodula mediante la transformada de Hilbert. Luego, con el método denominado remuestreo angular, la envolvente es remuestreada de acuerdo con las frecuencias de rotación instantánea del eje estimadas de la señal de corriente, de tal manera que las componentes variables asociadas a los fallos se conviertan en constantes y pueden ser identificadas mediante la densidad espectral de potencia (Power Spectrum Density-PSD). De cada fase del generador se extraen cuatro características en el dominio del tiempo y tres en el dominio de la frecuencia. Las 21 características constituyen la entrada del modelo SAE de tres capas, en el que la salida del primer AE se convierten en la entrada del siguiente AE. Cada nueva capa del SAE tiene menos neuronas que la capa anterior, de tal manera que, a medida que los datos pasan desde

la primera hasta la última capa, el modelo aprende las relaciones no lineales de los datos de entrada y logra entregar a la salida las características de alto nivel asociadas a los fallos. La salida del SAE alimenta el clasificador multiclase constituido por una SVM capaz de identificar cinco tipos de fallos en la multiplicadora.

Jiang et al. [95] propone diagnosticar los fallos de la multiplicadora de una TE fusionando las señales de vibración y corriente. La estructura del modelo se la puede resumir en dos bloques, una entrada formada por dos DBN y la salida compuesta por otra DBN. Las dos DBN de la entrada son, una para la señal de vibración y otra para la señal de corriente. Para inicializar los parámetros de las DBN, cada red RBN es entrenada separadamente y sin supervisión. El proceso de entrenamiento capa por capa de las DBN de entrada hace posible extraer las características que alimentan otra DBN que clasifica los fallos encontrados en la multiplicadora. Aunque la propuesta de Jing et al. [96] no hace mención a las TEs, sin embargo, es un ejemplo de lo que podría ser el enfoque práctico utilizado en la industria eólica. Jing et al. [96] fusionan las señales de sensores de corriente, vibración, audio y encoder óptico, en un modelo de DL para diagnosticar los fallos de una multiplicadora. Los datos obtenidos directamente de los sensores, sin aplicar ninguna técnica de procesamiento de señales, alimentan las CNNs, una por cada tipo de señal y la salida de las cuatro CNNs son la entrada de otra CNN que clasifica los fallos. La fusión de señales provenientes de diferentes sensores es otro de los avances que ha sido posible gracias a la capacidad de los modelos de aprendizaje profundo para aprender y extraer características complejas a partir de datos originales. Sin embargo, la mayoría de las propuestas existentes se centran en fusionar la señal de vibración de sensores instalados en diferentes partes del equipo.

Aunque las investigaciones [94] y [95] hacen referencias a TEs, ambos estudios son realizados en pequeños bancos de prueba, igual que la referencia [96]. No se han encontrado publicaciones sobre mantenimiento del GIJA de TEs mediante la señal de corriente y modelos de DL. Llegados a este punto, a manera de resumen general se puede decir que existe una cantidad significativa de publicaciones relacionadas sobre detección y diagnóstico de fallos del motor de inducción utilizando la señal de vibración y/o modelos de IA clásicos. Pero a medida que nos centramos en propuestas basadas en la señal de corriente, generador de inducción tipo jaula de ardilla utilizado en TEs, aplicación de modelos de aprendizaje profundo, y estudios de campo, la cantidad de publicaciones que cumplen estos criterios se

va reduciendo paulatinamente, hasta llegar a un punto que existen muy pocas referencias [97] y [98].

CAPÍTULO II

OBJETIVOS DE LA INVESTIGACIÓN

Luego de los costos asociados a las etapas necesarias para poner en marcha un proyecto de generación eólica, los costos del mantenimiento (personal administrativo, mano de obra, equipos, repuestos, tiempos improductivos) representa el componente más importante del costo de producción, tal como se puede apreciar en la ecuación (12). Según Walford [99], el costo de mantenimiento puede representar entre 10 y 20% del costo de la energía producida, equivalente a entre 0,005 y 0,022 \$/kWh aproximadamente. Para IRENA [100], los costos de operación y mantenimiento representan entre el 20 y 25% del costo promedio de la energía (Levelized costo of energy - LCOE). Mientras que según Costa [101], los costos de operación y mantenimiento significan el 28% del total de los costos de explotación de un parque eólico.

$$COE = \frac{ICC*FCR+LCC}{AEP_{GROSS}*Disponibilidad*(1-perdidas)} + O\&M \quad (12)$$

Debido a que intervienen una gran cantidad de variables, algunas de las cuales son difíciles de predecir, las operaciones de mantenimiento se caracterizan por su elevado coste y complejidad. Por esto, es necesario aplicar técnicas que permitan predecir el estado de los componentes de las TEs antes de que ocurra un fallo de manera imprevista. El objetivo es garantizar el suministro energético de manera continua y con calidad, pero al mismo tiempo, minimizar los costos totales para maximizar la rentabilidad [102]. En este contexto, previamente se ha mencionado que en la industria eólica predomina el uso de la señal de vibración, y según García Márquez et al. [103], cuando se utiliza esta señal, para bajas frecuencias se requieren transductores, para frecuencias medias se utilizan sensores de velocidad, mientras que, para frecuencias altas se emplean acelerómetros. Debido a la cantidad y tipo de sensores utilizados, el sistema de monitoreo basado en la señal de vibración podría ser complejo y costoso. Desde el punto de vista de Walford [99] y Qiao and Lu [104], otras desventajas de este tipo de señal serían:

- La instalación y calibración de los sensores requiere métodos intrusivos y difíciles,

- Los equipos son costosos,
- La señal se contamina fácilmente,
- Los sensores pueden fallar y/o proporcionar falsas alarmas.
- La efectividad del diagnóstico es sensible a la localización del sensor.

Una alternativa a lo expuesto en esta sección es usar la señal de corriente eléctrica del generador, que además de ser el principal producto de una TE, puede contener la información necesaria para intentar detectar, diagnosticar y predecir no solo fallos del generador eléctrico, sino de cargas acopladas inclusive. Sin embargo, a pesar de la existencia de estudios sobre el uso de la señal eléctrica, la mayoría se enfocan en motores de inducción y como afirman Thomson and Culbert [5], solo el 2% de los artículos publicados tratan sobre casos reales de la industria. Cuando se trata de la industria eólica, la cantidad de investigaciones sobre el uso de la corriente para detección y diagnósticos de fallos es mucho menor, y una vez más, las propuestas son básicamente teóricas, probadas en máquinas de pequeña potencia y/o simuladores.

2.1 Objetivo General

Según lo visto hasta ahora, la mayoría de las publicaciones sobre detección de fallos en la industria eólica se basa en el uso de la señal de vibración. A pesar de las ventajas de la señal de corriente, existe una carencia de referencias sobre propuestas de mantenimiento de TEs mediante la señal del generador eléctrico. Cuando se trata de estudios basados en datos reales o estudios de campo, uso de la señal de corriente y aplicación de modelos de DL, la cantidad de referencias es mucho menor [105]. Solo las propuestas de Artigao et al. [105], Cheng et al. [70], Zhang and Neti [106], Gómez-Lázaro [107] y Jeffries et al. [108] se basan en datos recogidos de TEs reales en operación. Sin embargo, la mayoría se refieren a detección de fallos en la multiplicadora (rodamientos y engranajes), y solo el trabajo de Artigao et al. [105] trata sobre fallos del generador eléctrico. No se han encontrado referencias de investigaciones basadas en datos reales, sobre el GIJA.

Casi la totalidad de propuestas existentes sobre detección y diagnóstico de fallos, utilizan como referencia una señal muestreada cuando la máquina está libre de falla y otra

señal que incluye una falla provocada a propósito. En estas condiciones, si comparamos los espectros no resultaría difícil identificar las componentes asociadas a fallos. Sin embargo, no siempre se puede seguir este procedimiento, ya que, en casos tales como esta investigación, no es posible provocar una falla en una TE para luego muestrear su señal. Además, cuando los fallos son incipientes, los modelos de ML tradicionales no serían eficientes debido a los datos desbalanceados o escasos indicios de fallos.

Por lo expuesto, el objetivo principal de esta tesis es investigar, analizar y sintetizar el marco teórico sobre el uso de la señal de corriente para el mantenimiento de la máquina rotativa de inducción, y especialmente del generador de inducción tipo jaula de ardilla utilizado en TEs. Además, para contrarrestar los inconvenientes descritos hasta ahora, parte del objetivo principal es proponer una metodología para detectar y diagnosticar fallos del GIJA utilizando la señal de corriente de TEs en operación y un modelo de aprendizaje profundo recientemente desarrollado.

2.2 Objetivos Específicos

Esta investigación se basa en tres objetivos específicos, cuyo cumplimiento se refleja mediante los artículos publicados. A continuación, se describen los objetivos mencionados.

1. El primer objetivo específico planteado consiste en describir y analizar el entorno en que se desenvuelve el mantenimiento en la industria eólica. Para esto, en los primeros cuatro artículos publicados se hace una revisión de los antecedentes del uso de la energía eólica, tipos de generadores eléctricos utilizados, principales tipos de fallos en TEs, tipos de mantenimiento aplicados, tipos de señales utilizadas para el monitoreo de las condiciones y metodologías para detectar y diagnosticar fallos de la máquina rotativa de inducción.
2. La mayoría de las publicaciones relacionadas sobre detección de fallos en las TEs, utilizan la señal de vibración. Por esto, el segundo objetivo es determinar el estado del arte relacionado con el uso de la señal de corriente, la cual puede ser una excelente alternativa para la detección y diagnóstico de fallos del generador de inducción tipo jaula de ardilla utilizado en TEs. Aquí se investigará la forma en que los fallos se

manifiestan en el espectro de la señal de corriente, tipos de fallos que se pueden detectar, técnicas de procesamiento de señal y modelos de inteligencia artificial utilizados. Como la mayoría de los fallos no ocurren de manera imprevista, y lo más probable es que, en TEs cuya vida útil se acerca al final, pueda existir algún tipo de falla en estado incipiente, entonces, para comprobar la efectividad de las técnicas de procesamiento de señales, parte del objetivo es medir la señal de corriente de TEs en operación, y aplicar varias técnicas de procesamiento de señales.

3. Las técnicas de procesamiento de señales y los modelos de aprendizaje automático tradicionales son insuficientes cuando los fallos son incipientes, las componentes de frecuencia asociadas a los fallos están muy cerca de la componente fundamental, no se dispone de registros de señal con indicios de falla y en estado sano. Además, la mayoría de las propuestas se desarrollan en bancos de prueba y existe una carencia de trabajos de campo. Por esto, el tercer objetivo es proponer una metodología para detectar y diagnosticar barras rotas incipientes en GIJA de TEs en operación, utilizando la señal de corriente, técnicas de procesamiento de señales y un modelo de aprendizaje profundo que contrarreste la problemática descrita en esta investigación.

CAPITULO III

METODOLOGÍA

La investigación se organiza en tres fases. La primera es una investigación bibliográfica para conocer el entorno en que se desenvuelve el mantenimiento en la industria eólica en general, y más específicamente lo relacionado a tipos de generadores eléctricos utilizados en las turbinas eólicas, tipos de mantenimiento, principales fallos que se presentan, tipos de señales utilizadas para el monitoreo de los equipos y técnicas para detectar y diagnosticar los fallos. El objetivo más importante de esta parte es identificar una brecha en el estado del arte relacionado con el mantenimiento de turbinas eólicas.

Con la finalidad de probar las ventajas, desventajas y eficiencia de las principales técnicas de procesamiento de señales estudiadas en la primera parte de la tesis, la segunda fase consiste en una investigación de campo para medir la señal de corriente de turbinas eólicas en operación. Para esto, se logró el permiso de una empresa propietaria de un parque eólico instalado en la región de Castilla y León, España. El parque eólico en mención está formado por TEs equipadas con generadores de inducción tipo jaula de ardilla que constan de dos bobinados, uno para alta velocidad y otro para baja velocidad. En el tablero principal de las TEs, en las tres fases del bobinado de alta velocidad se colocaron cintas amperimétricas flexibles que están conectadas a un osciloscopio PicoScope 5442D. La frecuencia de muestreo seleccionada fue de 10 kHz y la duración de cada muestra de señal es dos segundos [81] y [93]. El osciloscopio almacena las muestras en la computadora donde se realiza el procesamiento mediante Matlab.

Con base en el conocimiento adquirido en las etapas iniciales de la tesis, podemos decir que en la máquina rotativa de inducción uno de los fallos más difíciles de reparar y detectar es la debida a barras rotas. Cuando se cuenta con los datos necesarios el diagnóstico no es difícil, pero, si no disponemos de muestras de señal adquiridas mientras el generador eléctrico presentaba una falla, las frecuencias asociadas a la falla están muy cerca a la componente fundamental y los fallos están en estado incipiente, entonces la falta de datos hace disminuir la eficacia de las técnicas para procesamiento de señales y modelos de IA

tradicionales. Por lo expuesto, la última parte de esta investigación consiste en proponer un método para detectar barras rotas del generador de inducción tipo jaula de ardilla utilizado en turbinas eólicas operativas, mediante la señal de corriente y modelos de aprendizaje profundo.

Debido al contexto en que se realiza la detección y diagnóstico, en esta tesis se propone el uso de las redes neuronales antagónicas. Las GANs, desarrolladas por Goodfellow et al. [109] en el año 2014, es uno de los modelos de DL desarrollados más recientemente. El modelo consta de dos ANN que compiten entre sí, una denominada generador y otra llamada discriminador. La ANN generadora produce muestras sintéticas para intentar confundir al discriminador que trata de distinguir si las muestra son reales o sintéticas. Conforme avanza el entrenamiento, el discriminador mejora su rendimiento y proporciona información a la ANN generadora, de tal manera que esta intenta mejorar los datos sintéticos para engañar al discriminador. El equilibrio se alcanza cuando el discriminador no puede distinguir entre muestras reales y sintéticas.

La capacidad de las GANs para generar datos sintéticos similares a muestras originales, ha hecho que sean aplicadas a varios campos del conocimiento [110]. En lo que se refiere a la detección de fallos en la máquina rotativa de inducción, la mayoría de las propuestas existentes tienen los siguientes factores comunes: la máquina analizada es el motor, la señal utilizada es la vibración, el componente estudiado son los rodamientos, uso de GANs para generar datos sintéticos que permitan completar conjuntos de datos desbalanceados y utilización del discriminador de las GANs como clasificador [111], [112], [113], [114] y [115]. Entre las pocas referencias que utilizan la señal de corriente se puede mencionar a Lee et al. [116].

Para diagnosticar fallos del rotor y rodamientos de un motor de inducción, en Lee et al. [116] se propone un modelo cuya entrada está compuesta por dos GANs, una para la señal del motor con barras rotas y otra para la señal con fallos de rodamientos. La salida de las GANs alimenta una red neuronal profunda que clasifica los tipos de fallos. La señal de corriente del motor libre de fallos es muestreada a 1 kHz y procesada con un filtro pasa bajos para eliminar el ruido. Para simular los fallos, a la señal filtrada se le añade componentes espectrales asociadas a barras rotas y rodamiento defectuoso. Luego, mediante la transformada de Hilber-Huang de cada señal se obtienen siete funciones de modo intrínseco

(intrinsic mode functions-IMF) y sus correspondientes espectros de energía. De cada señal se escogen las cuatro IMF que muestran las mayores diferencias con el estado sano, para que alimenten el generador de la GAN correspondiente a cada tipo de falla. Previo al entrenamiento, las ANNs discriminadoras son pre-entrenadas con datos minoritarios reales, de tal manera que se comporten como un clasificador binario capaz de distinguir entre datos minoritarios reales y los sintéticos producidos por las ANNs generadoras.

No se han encontrado publicaciones relacionadas con el mantenimiento del GIJA de turbinas eólicas mediante la señal de corriente y GANs, lo cual es una de las motivaciones para proponer su uso en esta investigación. Como la eficiencia de un modelo de IA depende de la cantidad y calidad de los datos, en esta investigación se trata de fusionar varios escenarios que pueden ser útiles para el diagnóstico. El generador de inducción funciona en un rango pequeño de deslizamiento y la duración de cada muestra de señal es de solo dos segundos, por lo que se podría asumir que el espectro es constante, sin embargo, debido a la frecuencia de muestreo y el intervalo de frecuencia en el cual se manifiestan los fallos debido a barras rotas, la señal de corriente se descompone mediante la transformada de wavelets.

Para construir el conjunto de datos con el cual se entrenan los modelos de ML, las primeras variables que se consideran son las componentes laterales de las armónicas de orden superior asociadas a barras rotas, que se obtienen mediante la ecuación (13). Ver Tabla 5, [52]. Habiendo muestreado la señal, en Matlab se aplica el periodograma de Welch para calcular la densidad espectral de potencia. Con la función *findpeaks* se obtienen los valores pico de la frecuencia fundamental y las bandas laterales de armónicas primas 5, 7, 11, 13...

$$f_{bb} = \left[\left(\frac{k}{p}\right)(1 - s) \pm s\right]f_s \quad (13)$$

Tabla 5. Frecuencias de las componentes laterales obtenidas según Kliman et al [52].

k/p	Banda lateral superior (Hz)	Banda lateral inferior (Hz)
1	50,67	49,33
5	248,86	247,99
7	347,99	347,32
11	546,65	545,98
13	645,98	645,31
17	844,64	843,97
19

Para establecer una primera asignación de clase, de cada muestra se obtiene la diferencia entre la prominencia del pico de la frecuencia fundamental y su componente lateral. Según la magnitud de la diferencia, se asigna la clase sano o barra rota [117] y [118]. Además, como la señal se muestreo a 10 kHz, para hacer el análisis en el rango de frecuencia en el que se manifiestan las componentes asociadas a barras rotas, en Matlab se aplica las wavelets para descomponer la señal en 8 niveles [119]. Del nivel db8, se obtiene la potencia de la señal y para aumentar el número de variables, de la potencia de la señal se obtiene: la mediana, media, desviación estándar, varianza y valor RMS. Estas características se suman a las componentes de la Tabla 5, por lo que, en total se utilizan 16 características y una clase, ver Tabla 6.

Tabla 6. Variables de entrada a los modelos de IA

#	Nombre	Descripción	Tipo
1	Motor	Identificador de la máquina	Catagórica
2	Fase	Fase A/B/C	Catagórica
3	Archivo	Identificador del Archivo de Muestra	Catagórica
4-9	pot_sbi	Frecuencias Laterales Izquierda/derecha	Continua
10	Energía	Energía del nivel db8	Continua
11	Máximo	Valor máximo de la energía del nivel db8	Continua
12	Mínimo	Valor máximo de la energía del nivel db8	Continua
13	Moda		Continua
14	Media		Continua
15	Desviación		Continua
16	Varianza		Continua
17	Clase	Etiqueta de la Muestra	Catagórica

La representación de los datos se basa en números reales, NaNs y valores infinitos que posteriormente son filtrados e interpretados según la señal analizada. Por cada fase se obtiene un archivo, y luego son unidos mediante consola para formar el *data frame* que alimenta los modelos de IA. Los datos son escalonados entre 0 y 1 mediante el escalador *MinMaxScaler* de Python. Aplicando modelos tales como ANN y *kmeans*, se logra clasificar el 98 % de las muestras como libre de fallos y apenas el 2% con indicios de barras rotas, lo que concuerda en gran porcentaje con el sistema de control, según el cual, los GIJA están libre de fallos.

Debido a la uniformidad de los datos y la existencia de pocos datos atípicos, todos los modelos de inteligencia artificial tradicionales muestran un alto porcentaje de convergencia, sin embargo, no son muy eficientes para clasificar los registros con indicios de fallos, debido principalmente a lo desbalanceado de los datos. Entonces, para superar este inconveniente y mejorar la eficacia en el diagnóstico de fallos incipientes, en este estudio se propone generar datos sintéticos mediante GANs, pero, con un enfoque diferente a las publicaciones [110] al [116].

En Python se instala la librería CTGAN que permite generar datos tabulares condicionales basado en un modelo de Mixtura Gaussiana Multivariante [120]. La GAN es entrenada con los datos minoritarios obtenidos mediante *kmeans*, de tal manera que se generan 100 datos sintéticos, que se añaden a las 3018 muestras originales. Además, para mejorar la eficiencia del diagnóstico, todos los datos asociados a fallos se agrupan en una categoría denominada barras rotas. El conjunto de datos obtenido según lo descrito alimenta una red neuronal profunda que clasifica las muestras. Para garantizar la independencia de los datos de entrenamiento y de prueba, la red se entrena empleando 5 Folders de *CrossValidation*. El optimizador utilizado es *Adam*. La estructura restante y los hiperparámetros del clasificador, son los siguientes:

- 1 capa de Entrada para las 17 Características de la Señal. Se utiliza la función de activación *relu*,
- 2 capas ocultas de 15 neuronas cada una. (Con dos capas, el modelo converge)
- 1 capa de Salida con neuronas correspondientes a las Clases. Para la clasificación se emplea la función *softmax*,
- *epochs*: 100,
- *BatchSize*: 10,
- Como función de pérdida se utiliza la entropía cruzada, y
- Como métrica de resultados, el accuracy.

En comparación con los modelos de aprendizaje automático tradicionales, la metodología propuesta basada en modelos de aprendizaje profundo y generación de datos sintéticos mediante GANs, logra mejorar la eficiencia para la detección de datos atípicos asociados a barras rotas.

CAPITULO IV

RELACIÓN DE ARTÍCULOS PUBLICADOS Y PERTINENCIA CON LA TESIS

Esta tesis por compendio puede considerarse un resumen de todas las publicaciones realizadas. A continuación, se describe brevemente la relación y pertinencia con la tesis de las publicaciones que, según la ANECA son elegibles. Las revisiones recopilatorias que se han publicado para complementar esta investigación se incluyen en la sección de anexos.

4.1 Comparative Analysis Of Faults From Stall Controlled Wind Turbines With Asynchronous Generators And Pitch Controlled Wind Turbines With Synchronous Generators

Aprovechando la estancia en una empresa propietaria de parques eólicos formados por TEs con regulación de potencia por pérdida aerodinámica y equipadas con GIJA y TEs con control de potencia por cambio del ángulo de paso y equipadas con generadores sincrónicos, se hace un análisis estadístico de las paradas registradas en el sistema SCADA, para comparar los fallos de ambos tipos de máquinas. El análisis de los tipos de fallos y frecuencia de ocurrencia permite concluir que, en comparación con las TEs equipadas con GIJA y regulación por pérdida aerodinámica, las TEs equipadas con generadores sincrónicos y control de potencia por cambio del ángulo de paso presentan un mayor porcentaje de fallos debido principalmente a que, este tipo de TEs están compuestas por muchas más partes. El estudio permite corroborar porque, a pesar de la sencillez de su construcción, la máquina rotativa de inducción tipo jaula de ardilla es la de mayor uso a nivel mundial.

4.2 Wind Resource Assessment on Puná Island

La isla Puná, ubicada en el océano Pacífico frente a las costas de Ecuador, es el lugar de asentamiento de aproximadamente seis mil habitantes descendientes de la cultura Punaes, que se la reconoce por su resistencia a la invasión de los Incas. Como actualmente la isla se abastece de energía eléctrica mediante generadores estacionarios que funcionan con diésel, entonces, como parte de las actividades de investigación, en cooperación entre la

Universidad de Guayaquil, Universidad de Valladolid y la empresa CETASA, se realiza un proyecto para determinar el potencial eólico de la isla con miras a generar electricidad y prescindir del uso de combustibles fósiles.

Los resultados de esta investigación, obtenidos con base en los datos capturados con los equipos instalados en una torre anemométrica de cuarenta metros de alto, se resumen en el artículo **“Wind Resource Assessment on Puná Island,”** y entre las principales conclusiones se puede destacar la factibilidad de obtener energía eléctrica, pero, mediante el uso de TEs de eje ancho, debido a que la velocidad promedio del viento no supera los 5 m/s.

4.3 Fault Detection of Wind Turbine Induction Generators through Current Signals and Various Signal Processing Techniques

En la investigación publicada en el artículo **“Diagnosis of wind turbine faults using generator current signature analysis: a review,”** se ha verificado la carencia de estudios sobre detección de fallos del GIJA utilizando señal de corriente y datos reales. Por esto, basándonos en las revisiones recopilatorias publicadas: **“State of the Art and Trends in the Monitoring, Detection and Diagnosis of Failures in Electric Induction Motors,”** **“Wind turbine maintenance. A review,”** y **“Maintenance Models Applied to Wind Turbines. A Comprehensive Overview,”** se hace una investigación de campo para medir la señal de TEs en operación, y luego aplicar varias técnicas de procesamiento y análisis de señales tales como: transformada de Fourier, transformada de Wavelets, transformada de Hilbert y distribución de Wigner-Ville. El objetivo es analizar el comportamiento de las técnicas mencionadas para detectar y diagnosticar fallos. Los resultados se resumen en la publicación **“Fault Detection of Wind Turbine Induction Generators through Current Signals and Various Signal Processing Techniques.”** Con base en los resultados obtenidos, se puede decir que, a pesar de su contribución significativa, las técnicas para procesar señales tienen algunas limitaciones cuando se trata de fallos en estado incipiente o las componentes de frecuencia asociadas a los fallos se ubican muy cerca de la componente fundamental.

4.4 **Diagnosis of broken bars in wind turbine squirrel cage induction generator. Approach based on current signal and Generative adversarial networks.**

Generalmente la detección y diagnóstico de los fallos se basa en el tratamiento y comparación de una señal en estado sano y otra señal que contiene fallos provocadas a propósito. En estas condiciones, la detección es relativamente sencilla, sin embargo, cuando solo se dispone de la señal de la máquina en operación, la falla es incipiente o la componente asociada a la falla está muy cerca de la frecuencia fundamental, entonces las técnicas de procesamiento de señales y los métodos de aprendizaje automático tradicionales pierden efectividad. Como esta pérdida de efectividad se debe principalmente a la falta de muestras atípicas, entonces para balancear el conjunto de datos se propone generar datos sintéticos mediante GANs. Como las GANs es un modelo de aprendizaje profundo caracterizado por reproducir muestras tan similares entre sí, que resulta difícil distinguirlas, entonces los escasos datos con indicios de fallos se pueden reproducir de tal manera que el modelo de ML disponga de suficientes datos para aprender y mejorar su eficacia. Esta parte de la investigación se publica en el artículo **“Diagnosis of broken bars in wind turbine squirrel cage induction generator. Approach based on current signal and Generative adversarial networks,”** donde se comprueba la utilidad de las GANs en el contexto explicado en esta investigación.

CAPITULO V

ARTÍCULOS PUBLICADOS ELEGIBLES PARA TESIS POR COMPENDIO

Publicaciones que cumplen con los criterios de la ANECA y son elegibles para esta tesis por compendio:

1. <http://dx.doi.org/10.6036/8741>
2. <https://doi.org/10.3390/app9142923>
3. <https://doi.org/10.3390/app10217389>
4. <https://doi.org/10.3390/app11156942>

Revisiones publicadas que, según la ANECA no son elegibles para esta tesis por compendio:

1. <https://doi.org/10.3390/en10071056>
2. <http://dx.doi.org/10.6036/8622>
4. <https://doi.org/10.3390/en12020225>
6. <https://doi.org/10.1108/JQME-02-2019-0020>

CAPITULO VI

CONCLUSIONES Y RECOMENDACIONES

6.1 Conclusiones y aportes del Doctorando

La investigación sobre *Detección de fallos del generador de inducción tipo jaula de ardillas de turbinas eólicas* se basó en tres objetivos. A continuación, se describe el aporte realizado para cumplir los objetivos mencionados.

En relación con el **primer objetivo**, análisis del entorno en que se desenvuelve el mantenimiento en la industria eólica, se puede decir que, exceptuando la energía hidráulica, la energía eólica es una de las energías renovables que mayor difusión ha tenido en los últimos años. Uno de los factores claves para garantizar la rentabilidad de la industria eólica es minimizar los costos asociados al mantenimiento, que, en los parques eólicos se caracteriza por la complejidad de las operaciones e involucrar equipos, repuestos y recursos humanos que pueden ser muy costosos. Por esto, la programación adecuada del mantenimiento es fundamental, de tal manera que se optimice el uso de los recursos y minimice los costos debido a fallos imprevistos, paralizaciones y cambio de los componentes de las TEs.

Aunque existe una literatura muy extensa sobre mantenimiento a nivel estratégico, táctico y operativo, sin embargo, a modo de resumen, se puede decir que, debido a que las TEs pueden superar los 80 metros de altura y se instalan en lugares remotos, el tipo de mantenimiento que predomina es el predictivo o basado en las condiciones. Este tipo de mantenimiento se sustenta en el registro y gestión mediante el sistema SCADA de diversos tipos de señales tales como vibración, torque, esfuerzo, ondas de sonido, temperatura, parámetros del aceite y pruebas no destructivas (rayos X, termografía infrarroja, escaneo ultrasónico) obtenidas mediante sensores instalados en los componentes más importantes de las TEs. Debido a que todos los equipos en movimiento producen vibración, en la industria

eólica predomina el uso de esta señal, y, por lo tanto, la mayoría de las publicaciones sobre detección y diagnóstico de fallos se basan en la señal de vibración.

Aproximadamente el 80% de TEs utilizan generador de inducción, ya sea tipo jaula de ardilla o doblemente alimentado. Aunque el tipo de fallos y su frecuencia dependerá del tipo de TEs, sin embargo, se puede decir que, en promedio, los componentes con mayor porcentaje de fallos son: la multiplicadora, palas y generador. En lo que tiene que ver con el generador de inducción, en este tipo de máquina el componente con mayor porcentaje de fallos es el estator, seguido de los rodamientos y el rotor.

Las metodologías para detección y diagnóstico de fallos se basan en técnicas para procesamiento de señales y modelos de IA. Existe una gran cantidad de publicaciones sobre esta temática, sin embargo, la mayoría se centran en el motor, señal de vibración, y demostración de las propuestas en pequeños bancos de pruebas. Esta tendencia se mantiene en la industria eólica, especialmente en lo relacionado con el generador de inducción tipo jaula de ardilla, ya que existe una carencia de trabajos basados en datos reales o estudios de campo, tipos de señales diferente a la vibración y modelos de aprendizaje profundo.

Aunque el uso de la señal de vibración para el mantenimiento de TEs es un estándar en la industria eólica, sin embargo, este tipo de señal tiene algunas desventajas. Por esto, y considerando lo expuesto en el párrafo anterior, el **segundo objetivo** trata **sobre la aplicación de la señal de corriente para detección de fallos del GIJA de TEs en operación**. A diferencia de la señal de vibración, con la señal de corriente se pueden detectar fallos eléctricos y mecánicos, los sensores de corrientes son más económicos, robustos y fáciles de instalar. Según las referencias, el uso de la señal de corriente para monitorear el estado de los motores eléctricos se remonta a los años 70 y la metodología para detectar y diagnosticar los fallos del motor de inducción, conocida como Motor Current Signature Analysis (MCSA) se patentó en el año 1986.

En condiciones normales de operación, la señal de corriente de la máquina de inducción rotativa tendrá un espectro acorde los parámetros de diseño, sin embargo, cuando ocurre algún tipo de falla, esta ejerce un torque sobre el rotor provocando variaciones de velocidad, torque, flujo magnético del entre hierro y corriente de las barras. Los fallos provocan que en el espectro original de la señal aparezcan nuevas componentes, cuya cantidad y magnitud

depende del tipo de falla y de su severidad. Las primeras metodologías para detección y diagnóstico se basaban en las técnicas de procesamiento de señales, inicialmente en el dominio del tiempo, luego en el dominio de la frecuencia y tiempo-frecuencia. A pesar del aporte significativo de las técnicas de procesamiento de señales, la detección y diagnóstico se complica debido a que en el caso de fallos tales como barras en mal estado, fallos de rodamientos, engranajes fisurados o rotos, las frecuencias asociadas son de pequeña amplitud y están muy cerca a la frecuencia fundamental. En estas condiciones, las técnicas de análisis de señales pierden eficacia y el diagnóstico se complica, tal como se lo pudo comprobar mediante el trabajo de campo publicado como parte del segundo objetivo de esta tesis.

Finalmente, sobre la **propuesta de una metodología para detectar y diagnosticar barras rotas incipientes en GIJA de TEs en operación**, que corresponde al **tercer objetivo**, se ha podido comprobar que, con el paso del tiempo las técnicas de procesamiento y análisis de señales han sido remplazadas por lo menos en parte, primero por propuestas basadas en modelos de IA tradicionales y luego por los modelos de aprendizaje profundo. Mientras los modelos de IA tradicionales necesitan un conjunto de datos balanceados y personas expertas para preparar los datos, construir los modelos e interpretar los resultados, los modelos de aprendizaje profundo permiten utilizar los datos sin necesidad de procesarlos previamente y además tienen la capacidad de extraer las características más complejas, lo cual disminuye la necesidad de personal experto.

Inicialmente con el mismo modelo de IA tradicional se extraían y clasificaban las características de los datos de entrada, en la actualidad, no solo que los modelos de DL prevalecen sobre los modelos de IA tradicionales, sino que, el enfoque es utilizar un modelo de DL para extraer de los datos las características más complejas e importantes, y luego, clasificar dichas características con otro modelo de DL que no siempre es igual al primero. Otra tendencia actual es la fusión en un mismo modelo de varias señales, ya sean diferentes tipos de señales o del mismo tipo de señal, pero de distintos sensores. El estado del arte en el mantenimiento de las máquinas rotativas de inducción es la detección y diagnóstico mediante modelos de aprendizaje profundo.

La mayoría de las propuestas existentes sobre detección y diagnóstico de fallos mediante la señal de corriente utilizan muestras de señal libre de falla y muestras de señal que contiene

una falla provocada a propósito. En estas condiciones el diagnóstico no resulta complicado, pero, cuando solo se cuenta con la señal de la máquina en operación, las componentes asociadas a los fallos están muy cerca a la frecuencia fundamental, y los fallos están en estado incipiente, el diagnóstico se complica debido a la falta de datos para entrenar los modelos de ML. Para contrarrestar los inconvenientes mencionados, en esta tesis se ha propuesto la detección y diagnóstico de barras rotas del GIJA de TEs en operación, mediante la señal de corriente y GANs. Las GANs es uno de los modelos de aprendizaje profundo aparecido más recientemente y se caracterizan por su capacidad para generar datos sintéticos que pueden ser utilizados para completar conjuntos de datos desbalanceados.

Los resultados que avalan el cumplimiento del tercer objetivo se resumen en una de las publicaciones que forman parte de esta tesis. La metodología propuesta ha demostrado su utilidad para mejorar la eficacia en la detección de fallos atribuidas a barras defectuosas del GIJA, utilizando solo la señal de corriente de TEs.

6.2 Trabajos futuros

Una de las conclusiones de esta investigación es que las estrategias y metodologías aplicadas para detección y diagnóstico de fallos en la máquina rotativa de inducción han evolucionado constantemente a través del tiempo. Así, del mantenimiento correctivo aplicado cuando las maquinas o sus componentes cumplían determinado tiempo de funcionamiento o presentaban alguna falla diagnosticada de manera visual, se ha pasado a la estrategia del mantenimiento preventivo y predictivo. En lo que tiene que ver con las metodologías se ha transitado desde las cartas de control, análisis de señales en el dominio del tiempo, análisis de señales en el dominio de la frecuencia, análisis de señales en el dominio tiempo-frecuencia, modelos de inteligencia artificial clásicos hasta los modelos de aprendizaje profundo que representan el estado del arte.

En esta tesis se ha cumplido con el objetivo principal de proporcionar un marco conceptual sobre el uso de la señal de corriente para detectar y diagnosticar fallos en la máquina rotativa de inducción, con énfasis en el GIJA de TEs en operación. También se ha hecho una propuesta para detectar barras rotas utilizando GANs. Sin embargo, el uso de las

GANs es un área de estudio en desarrollo y es necesario nuevas investigaciones tendientes a profundizar en la construcción de modelos para el diagnóstico de fallos combinando las GANs con otros modelos, probando con otros tipos de señales tales como acústica o térmica. Aunque en esta tesis se ha generado datos sintéticos tabulares, también se podría intentar el diagnóstico mediante imágenes.

En la actualidad, la fortaleza de las GANs ha hecho que sean utilizadas en combinación con otros modelos de IA para construir modelos de aprendizaje profundo muy poderosos tales como: GauGAN2 de NVIDIA que utiliza el modelo GPT-3 de Google para producir imágenes a partir de texto, GLIDE de OpenAI que es un modelo de 3.5 billones de parámetros entrenado para editar y generar imágenes, StyleGAN3 para generar imágenes y videos, y GANformer que combina GANs y Transformadores para generar imágenes. La adaptación de estos modelos para el mantenimiento de la maquina rotativa de inducción, podría representar una nueva línea de investigación.

Con los modelos de IA tradicionales, para que el modelo pueda aprender de forma correcta era necesario construir minuciosamente el conjunto de entrenamiento. Posteriormente, el aprendizaje profundo permitió utilizar los datos sin necesidad de procesamiento previo y el modelo se encarga de aprender y extraer las características más complejas del conjunto de entrenamiento. Sin embargo, este enfoque de entrenamiento y aprendizaje ha cambiado, ya que, en la actualidad, con los modelos de aprendizaje reforzado no es necesario el entrenamiento con datos históricos, sino que el modelo explora el entorno y aprende de forma autónoma hasta optimizar el objetivo para el cual fue creado. Por esto, las nuevas investigaciones sobre detección y diagnóstico de fallos del GIJA deberían centrarse en la última tendencia de la inteligencia artificial, que es la construcción de sistemas de aprendizaje reforzado o aprendizaje autónomo que representan un gran avance hacia la inteligencia artificial general.

Las nuevas investigaciones sobre detección y diagnóstico de fallos basadas en aprendizaje reforzado deberían ser capaces de integrar la mayor cantidad de señales tales como: vibración, acústica, olfato, visión, tacto, temperatura, eléctrica y campo magnético para desarrollar sistemas de diagnóstico cada vez más autónomos, hiperautomatizados, con menos intervención del ser humano, pero más efectivos e integrados en un robot que puede ser el mismo motor y que ejecute la mayoría de operaciones relacionadas con el diseño y

mantenimiento, es decir: modelar el generador eléctrico, deducir sus parámetros de construcción, detectar los distintos tipos de falla, predecir el tiempo de vida útil o tiempo a la falla, decidir entre reparar o sustituir, programar el mantenimiento, desmontar e instalar el equipo.

ABREVIATURAS

AEP	=	Producción anual de energía (kWh/year)
AE	=	Autocodificador
AC	=	Corriente alterna
AGI	=	Inteligencia Artificial General
ARMA	=	Autorregresivo de media móvil
ARIMA	=	Autorregresivo integrado de promedio móvil
\vec{B}	=	Densidad de flujo
CNN	=	Red neuronal convolucional,
COE	=	Costo de la energía producida (\$/kWh)
DBN	=	Red de creencias profundas
\vec{E}	=	Campo eléctrico
ESPRIT	=	Estimación de los parámetros de la señal mediante la técnica de invariancia rotacional
\vec{F}	=	Fuerza sobre conductores sometidos a un campo
GAN	=	Redes generativas antagónicas,
GIJA	=	Generador de inducción jaula de ardilla
f	=	frecuencia fundamental
f_l	=	Componente lateral inferior o izquierda en la señal del estator, producida por barra rota del rotor
f_s	=	frecuencia del estator
f_r	=	Frecuencia del rotor
f_u	=	componente lateral superior o derecha en la señal del estator, producida por barra rota del rotor
FCR	=	Tasa de costo fijo (%/año)
I, i	=	corriente
IA	=	inteligencia artificial
ICC	=	Costo de capital inicial (\$)
l	=	longitud axial del conductor
LCOE	=	Costo promedio de la energía
LRC	=	costo promediado de reemplazo (\$/year)

LSTM = Memoria a Corto y Largo plazo
 MCSA = Análisis espectral de la señal de corriente
 MUSIC = Clasificación de señales múltiples
 O&M = Operación y mantenimiento (\$/kWh)
 p = pares de polos
 PMSG = Generador sincrónico de imanes permanentes
 RPM = Revoluciones por minuto
 RMS = Raíz media cuadrática
 RNN = Red neuronal recurrente
 r_s = radio del estator
 r_r = radio del rotor
 S = superficie de contorno arbitrario
 s = deslizamiento
 TE = Turbinas eólicas
 TF = Transformada de Fourier
 TWD = Transformada wavelet discreta
 TWC = Transformada de wavelet continua
 V_{br} = amplitud de tensión inducida en las barras del rotor
 VAE = autocodificador variacional
 β = ángulo formado entre el conductor y B
 φ = ángulo de desfase, carga o factor de potencia
 μ_0 = permeabilidad del vacío
 Φ_s = flujo del estator
 θ_r = desplazamiento del rotor
 Φ_s = flujo del estator
 ω_s = velocidad angular del campo del estator o velocidad de sincronismo
 ω_{mr} = velocidad mecánica del rotor
 $\omega_f = 2ks\omega_s$ = velocidad angular de la frecuencia de falla
 τ_{ind} = torque total inducido en el rotor

Bibliografía

- [1]. J. K. Kaldellis and D. Zafirakis, “The wind energy (r)evolution: A short review of a long history,” *Renew. Energy*, vol. 36, no. 7, pp. 1887–1901, 2011, doi: 10.1016/J.RENENE.2011.01.002
- [2]. P. D. Fleming and S. D. Probert, “The evolution of wind-turbines: An historical review,” *Appl. Energy*, vol. 18, no. 3, pp. 163–177, Jan. 1984, doi: 10.1016/0306-2619(84)90007-2
- [3]. P. J. Tavner, “Review of condition monitoring of rotating electrical machines,” *IET Electr. Power Appl.*, vol. 2, no. 4, pp. 215-247, July 2008, doi: 10.1049/iet-epa:20070280
- [4]. M. E. H. Benbouzid and G. B. Kliman, “What stator current processing-based technique to use for induction motor rotor faults diagnosis?,” *IEEE Trans. Energy Convers.*, vol. 18, no. 2, pp. 238–244, 2003, doi:10.1109/TEC.2003.811741
- [5]. W. T. Thomson and I. Culbert, *Current Signature Analysis for Condition Monitoring of Cage Induction Motors*. Hoboken, NJ, USA: John Wiley & Sons, Inc., 2016.
- [6]. C. Rossi, F. Russo, S. Savino, C. ROSSI, F. RUSSO, and S. SAVINO, “Windmills: Ancestors of the wind power generation,” *Front. Mech. Eng.*, vol. 12, no. 3, pp. 389–396, Sep. 2017
- [7]. J. M. Escudero López, *Manual de energía eólica: investigación, diseño, promoción, construcción y explotación de distinto tipo de instalaciones*. Madrid, España, Mundi-Prensa, 2003.
- [8]. IRENA, (2017). *Rethinking Energy 2017: Accelerating the global energy transformation*. [Online]. Available: <https://www.irena.org/publications/2017/Jan/REthinking-Energy-2017-Accelerating-the-global-energy-transformation>. [Accessed: 08-Oct-2019].
- [9]. M. Arshad, “Global status of wind power generation: theory, practice, and challenges,” *Int. J. Green Energy*, Article in Press, 2019, doi: 10.1080/15435075.2019.1597369

- [10]. GE Renewable Energy, “GE’s offshore wind farm technology,” [Online]. Available: <https://www.ge.com/renewableenergy/wind-energy/offshore-wind>. [Accessed: 28-Nov-2020].
- [11]. GWEC, “GLOBAL WIND REPORT 2018,” 2019. [Online]. Available: <https://gwec.net/global-wind-report-2018/>. [Accessed: 08-Oct.-2019].
- [12]. Renewable Energy Policy Network, “Global Status Report 2021,” 2021. [Online]. https://www.ren21.net/wp-content/uploads/2019/05/GSR2021_Full_Report.pdf, [Accessed: 12-Jul-2019].
- [13]. Y. Merizalde, L. Hernández-Callejo, and O. Duque-Perez, “State of the Art and Trends in the Monitoring, Detection and Diagnosis of Failures in Electric Induction Motors,” *Energies*, vol. 10, no. 7, Jul. 2017, doi: 10.3390/en10071056.
- [14]. A. Torres-Degró, “Tasas de crecimiento poblacional (r): Una mirada desde el modelo matemático lineal, geométrico y exponencial,” *CIDE Digit.*, vol. 2, no. 1, pp. 142–160, 2011. [Online]. Available: <https://revistas.upr.edu/index.php/cidedigital/article/view/11774>. [Accessed: 08-Oct.-2019].
- [15]. AETS Sudamérica, “Estudio de Mercado de Motores Eléctricos en Chile,” Santiago de Chile, 2010. [Online]. Available: [http://dataset.cne.cl/Energia_Abierta/Estudios/Minerg/10.Estudio%20Motores%20El%C3%A9ctricos%20en%20Chile_Final%20\(1045\).pdf](http://dataset.cne.cl/Energia_Abierta/Estudios/Minerg/10.Estudio%20Motores%20El%C3%A9ctricos%20en%20Chile_Final%20(1045).pdf). [Accessed: 08-Oct-2019].
- [16]. J. J. Stroker, “What’s the real cost of higher efficiency?” *IEEE Ind. Appl. Mag.*, vol. 9, no. 3, pp. 32–37, May 2003.
- [17]. G. S. Stavrakakis, “Electrical parts of wind turbines,” in *Comprehensive Renewable Energy*, vol. 2, pp. 269-328, 2012, doi: 10.1016/B978-0-08-087872-0.00211-0.
- [18]. J. Pyrhönen, T. Jokinen, and V. Hrabovcová, *Design of Rotating Electrical Machines*, West Sussex, United Kingdom, John Wiley & Sons, 2008.
- [19]. S. J. Chapman, *Máquinas Eléctricas*, México, D.F, McGraw-Hill, 2016.

- [20]. D. Tomasello, "Variable Speed for Induction Generator," M.S. thesis, University of Glasgow, Escocia, University Of Padova, Padova, Italia, 2012.
- [21]. J. F. Manwell, J. G. McGowan, and A. L. Rogers, *Wind Energy Explained: Theory, Design and Application*, West Sussex, United Kingdom, John Wiley & Sons Ltd., 2010.
- [22]. A. H. Bonnett and G. C. Soukup, "Rotor Failures in Squirrel Cage Induction Motors," *IEEE Trans. Ind. Appl.*, vol. 22, no. 6, pp. 1165–1173, Nov., 1986.
- [23]. L. Freris and D. Infield, *Renewable energy in power systems*, West Sussex, United Kingdom, John Wiley & Sons Ltd., 2008.
- [24]. M. Godoy and F. Farret, *Modeling and Analysis with Induction Generators*, Boca Raton, Florida, USA, CRC Press, 2015.
- [25]. V. P. Chandran and S. Vadhera, "Capacitance requirements of self excited induction generator for different operating conditions," in *Proceedings-International Conference on Energy, Automation and Signal*, Bhubaneswar, Odisha, India, pp. 614-619, Dec. 2011.
- [26]. H. Polinder, J. A. Ferreira, B. B. Jensen, A. B. Abrahamsen, K. Atallah, and R. A. McMahon, "Trends in wind turbine generator systems," *IEEE Power and Energy Society General Meeting*, Detroit, MI, United States, July 2011.
- [27]. R. Poore and T. Lettenmaier, "Alternative Design Study Report: WindPACT Advanced Wind Turbine Drive Train Designs Study, National Renewable Energy Laboratory's, Golden, Colorado, USA, Tech. Rep. NREL/SR-500-33196, 2003.
- [28]. F.D. Bianchi, H. de Batista and R. J. Mantz, *Wind Turbine Control Systems Principles, Modelling and Gain Scheduling Design*, London, England Springer Science & Business Media, 2006.
- [29]. D. Bourlis, "A Complete Control Scheme for Variable Speed Stall Regulated Wind Turbines," in *Fundamental and Advanced Topics in Wind Power*, 2011. [Online]. Available: <https://www.intechopen.com/books/fundamental-and-advanced-topics-in->

wind-power/a-complete-control-scheme-for-variable-speed-stall-regulated-wind-turbines. [Accessed: 08-Oct-2019], doi: 10.5772/17569

- [30]. W. Cao, Y. Xie, and Z. T, (2012), “Wind Turbine Generator Technologies,” in Advances in Wind Power, [Online]. Available: <https://www.intechopen.com/books/advances-in-wind-power/wind-turbine-generator-technologies>, [Accessed: 08-Oct-2019], doi: 10.5772/51780
- [31]. L. H. Hansen, L. Helle, F. Blaabjerg, E. Ritchie, and S. Munk-Nielsen, Conceptual survey of Generators and Power Electronics for Wind Turbines, Risø National Laboratory, Roskilde, Denmark, Tech. Rep., 2001.
- [32]. S. A. Papathanassiou, G. A. Vokas, and M. P. Papadopoulos, “Use of power electronic converters in wind turbines and photovoltaic generators,” in Proceedings of the IEEE International Symposium on Industrial Electronics, Dubrovnik, Croatia, pp. 254–259, July 1995, doi: 10.1109/ISIE.1995.496636.
- [33]. S. Chen, “Induction Machine Broken Rotor Bar Diagnostics Using Prony Analysis,” M.S. thesis, University of Adelaide, Australia, 2008.
- [34]. H. Wang, M. Liserre, and F. Blaabjerg, “Toward Reliable Power Electronics,” IEEE Ind. Electron. Mag., vol. 7, no. 2, June, pp. 17–26, June 2013.
- [35]. M. C. Garcia, M. A. Sanz-Bobi, and J. del Pico, “SIMAP: Intelligent System for Predictive Maintenance,” Comput. Ind., vol. 57, no. 6, pp. 552–568, Aug. 2006.
- [36]. A. H. Bonnett and G. C. Soukup, “Cause and Analysis of Stator and Rotor Failures in Three-Phase Squirrel-Cage Induction Motors,” IEEE Trans. Ind. Appl., Vol. 28, no. 4, Jul/Aug 1992, doi: 10.1109/28.148460
- [37]. A. H. Bonnett, “Root cause AC motor failure analysis with a focus on shaft failures,” IEEE Trans. Ind. Appl., vol. 36, no. 5, pp. 1435–1448, 2000, doi: 10.1109/28.871294.
- [38]. A. H. Bonnett and G. C. Soukup, “Analysis of Rotor Failures in Squirrel-Cage Induction Motors,” IEEE Trans. Ind. Appl., vol. 24, no. 6, pp. 1124 - 1130, Nov.-Dec. 1988, doi: 10.1109/28.17488.

- [39]. S. Nandi and H. A. Toliyat, "Novel frequency-domain-based technique to detect stator interturn faults in induction machines using stator-induced voltages after switch-off," in *IEEE Transactions on Industry Applications*, vol. 38, no. 1, pp. 101-109, Jan/Feb 2002, doi: 10.1109/28.980363.
- [40]. A. Siddique, G. S. Yadava, and B. Singh, "A review of stator fault monitoring techniques of induction motors," *IEEE Transactions on Energy Conversion*, vol. 20, no. 1, pp. 106-114, March 2005, doi: 10.1109/TEC.2004.837304.
- [41]. NSK (2016), "Bearing maintenance guide", [Online]. Available at: <http://www.nskamericas-literature.com/en/bearing-doctor/>, [Accessed: 08-Oct-2019].
- [42]. M. Blodt, P. Granjon, B. Raison, and G. Rostaing, "Models for bearing damage detection in induction motors using stator current monitoring," *IEEE Trans. Ind. Electron.*, vol. 55, no. 4, pp. 1813-1822, April 2008, doi: 10.1109/TIE.2008.917108
- [43]. G. B. Kliman, W. J. Premerlani, R. A. Koegl, and D. Hoeweler, "A new approach to on-line turn fault detection in AC motors," in *IEEE Industry Applications Conference Thirty-First IAS Annual Meeting*, San Diego, CA, USA, 6-10 Oct. 1996, doi: 10.1109/IAS.1996.557113
- [44]. G. M. Joksimovic and J. Penman, "The detection of inter-turn short circuits in the stator windings of operating motors," *IEEE Trans. Ind. Electron.*, vol. 47, no. 5, pp. 1078-1084, Oct 2000, doi: 10.1109/41.873216
- [45]. "Report of Large Motor Reliability Survey of Industrial and Commercial Installations, Part I," *IEEE Trans. Ind. Appl.*, vol. IA-21, no. 4, pp. 853-864, 1985, doi: 10.1109/TIA.1985.349532
- [46]. Y. Merizalde, L. Hernández-Callejo, J.G. Bernal, O. Duque-Perez, L. M. Bonilla, A. Zorita-Lamadrid and D. Morinigo-Sotelo, "Comparative analysis of faults from stall controlled wind turbines with asynchronous generators and pitch controlled wind turbines with synchronous generators," *Dyna*, vol. 93, no. 5, pp. 541-548, Sep. 2018, doi: <http://dx.doi.org/10.6036/8741>

- [47]. IEEE, IEEE guide for induction machinery maintenance testing and failure analysis. Institute of Electrical and Electronics Engineers, 2007, doi: 10.1109/IEEESTD.2007.357954
- [48]. A. Das, J. Maiti, and R. N. Banerjee, "Process monitoring and fault detection strategies: A review," *International Journal of Quality & Reliability Management*, vol. 29, no. 7, pp. 720-752, July 2012, doi: 10.1108/02656711211258508
- [49]. J. Penman, H. G. Sedding, and W. T. Fink, "Detection and Location of Interturn Short Circuits in the Stator Windings of Operating Motors," *IEEE Trans. Energy Convers.*, vol. 9, no. 4, pp. 652 - 658, 1994, doi: 10.1109/60.368345
- [50]. Kia, S., Henao, H., Capolino, G. Diagnosis of broken-bar fault in induction machines using discrete wavelet transform without slip estimation, *IEEE Transactions on Industry Applications*, vol. 45, no. 4, 1395-1404, 2009, doi: 10.1109/TIA.2009.2018975
- [51]. A. R. Mohanty and C. Kar, "Fault detection in a multistage gearbox by demodulation of motor current waveform," *IEEE Trans. Ind. Electron.*, vol. 53, no. 4, pp. 1285–97, 2006, doi: 10.1109/TIE.2006.878303
- [52]. G. B. Kliman, R. A. Koegl, J. Stein, R. D. Endicott, and M. W. Madden, "Noninvasive detection of broken rotor bars in operating induction motors," *IEEE Trans. Energy Convers.*, vol. 3, no. 4, pp. 873–879, 1988, doi: 10.1109/60.9364.
- [53]. C. Kral, H. Kapeller, J. Gragger, A. Haumer and B. Kubicek, "Phenomenon rotor fault — Multiple electrical rotor asymmetries in induction machines," *IEEE Transactions on Power Electronics*, Vol. 25, No. 5, pp. 1124-34, 2010, doi: 10.1109/TPEL.2009.2037502
- [54]. B. R. Nayana and P. Geethanjali, "Analysis of Statistical Time-DomIAN Features Effectiveness in Identification of Bearing Faults from Vibration Signal," *IEEE Sens. J.*, vol. 17, no. 17, pp. 5618–5625, Sep. 2017, doi: 10.1109/JSEN.2017.2727638

- [55]. G. B. Kliman and J. Stein, "Methods of Motor Current Signature Analysis," *Electr. Mach. Power Syst.*, vol. 20, no. 5, pp. 463–474, Sep. 1992, doi: 10.1080/07313569208909609
- [56] H. D. Haynes and D. M. Eissenberg, "Motor current signature analysis method for diagnosing motor-operated devices," Sep. 30, 1986.
- [57]. X. Gong and W. Qiao, "Imbalance Fault Detection of Direct-Drive Wind Turbines Using Generator Current Signals," *IEEE Trans. Energy Convers.*, vol. 27, no. 2, pp. 468–476, 2012, doi: 10.1109/TEC.2012.2189008
- [58]. B. K. Bose, *Modern power electronics and AC drives*, Upper Saddle River, USA, Prentice Hall PTR, 2002.
- [59]. S. Williamson and S. Djurović, "Origins of stator current spectra in DFIGs with winding faults and excitation asymmetries," 2009 IEEE Int. Electr. Mach. Drives Conf. IEMDC, Miami, Florida, United States, pp. 563–570, May 2009, doi: 10.1109/IEMDC.2009.5075262
- [60]. I. Attoui and A. Omeiri, "Fault Diagnosis of an Induction Generator in a Wind Energy Conversion System Using Signal Processing Techniques," *Electr. Power Components Syst.*, vol. 43, no. 20, pp. 2262–2275, 2015, doi: 10.1080/15325008.2015.108216
- [61]. M. E. H. Benbouzid, "A review of induction motors signature analysis as a medium for faults detection," *IEEE Trans. Ind. Electron.*, vol. 47, no. 5, Oct 2000, doi: 10.1109/41.873206
- [62]. G. A. Jiménez, A. O. Muñoz, and M. A. Duarte-Mermoud, "Fault detection in induction motors using Hilbert and Wavelet transforms," *Electr. Eng.*, vol. 89, no. 3, pp. 205–220, Jan. 2007, doi: 10.1007/s00202-005-0339-6
- [63]. V. Climente Alarcón, "Aportación al mantenimiento predictivo de motores de inducción mediante modernas técnicas de análisis de la señal," PhD Tesis, Universitat Politècnica de València, Valencia, España, 2012.

- [64]. V. Fernandez-Cavero, D. Morinigo-Sotelo, O. Duque-Pérez and J. Pons Llinares, “A Comparison of Techniques for Fault Detection in Inverter-Fed Induction Motors in Transient Regime,” *IEEE Access*, vol. 5, pp. 8048–63, 2017, doi: 10.1109/ACCESS.2017.2702643
- [65]. F. Cheng, Y. Peng, L. Qu, and W. Qiao, “Current-Based Fault Detection and Identification for Wind Turbine drivetrain Gearboxes,” *IEEE Trans. Ind. Appl.*, vol. 53, no. 2, pp. 878–887, 2017, doi: 10.1109/TIA.2016.2628362
- [66]. A. Stefani, A. Yazidi, C. Rossi, F. Filippetti, D. Casadei, and G. A. Capolino, “Doubly fed induction machines diagnosis based on signature analysis of rotor modulating signals,” *IEEE Trans. Ind. Appl.*, vol. 44, no. 6, pp. 1711–1721, 2008, doi: 10.1109/TIA.2008.2006322
- [67]. E. Al Ahmar, V. Choqueuse, M.E.H. Benbouzid, Y. Amirat, J. El Assad, R. Karam, and S. Farah, “Advanced signal processing techniques for fault detection and diagnosis in a wind turbine induction generator drive train: A comparative study,” *IEEE Energy Convers. Congr. Expo. ECCE 2010*, Atlanta, GA, USA, pp. 3576–3581, Sept. 2010, doi: 10.1109/ECCE.2010.5617707
- [68]. Y. Amirat, V. Choqueuse, H. Benbouzid, and M. Benbouzid, “Wind Turbines Condition Monitoring and Fault Diagnosis Using Generator Current Amplitude Demodulation,” in *IEEE International Energy Conference*, Atlanta, GA, USA, pp. 310–315, Sept. 2010, doi: 10.1109/ECCE.2010.5617914
- [69]. Ibrahim, R., Watson, S., Djurović, S., Crabtree, C. An Effective Approach for Rotor Electrical Asymmetry Detection in Wind Turbine DFIGs, *IEEE Transactions on Industrial Electronics*, vol. 65, no. 11, 8872-81, 2018, doi: 10.1109/TIE.2018.2811373
- [70]. F. Cheng, L. Qu, W. Qiao, C. Wei, and L. Hao, “Fault Diagnosis of Wind Turbine Gearboxes Based on DFIG Stator Current Envelope Analysis,” *IEEE Trans. Sustain. Energy*, vol. 10, no. 3, pp. 1044–53, 2010, doi: 10.1109/tste.2018.2859764

- [71] X. Jin, F. Cheng, Y. Peng, W. Qiao, and L. Qu, "A comparative study on vibration and current-based approaches for drivetrain gearbox fault diagnosis," in Proc. 51st IEEE Ind. Appl. Soc. Annu. Meeting, Oct. 2016, pp. 1-8, doi: 10.1109/IAS.2016.7731964
- [72] D. Lu and W. Qiao, "Frequency demodulation-aided condition monitoring for drivetrain gearboxes," in Proc. IEEE Transportation Electrification Conf. Expo., Detroit, MI, USA, Jun. 2013, pp. 1–6, doi: 10.1109/ITEC.2013.6574526
- [73] D. Lu, W. Qiao, and X. Gong, "Current-based gear fault detection for wind turbine gearboxes," IEEE Trans. Sustainable Energy, vol. 8, no. 4, pp. 1453-1462, Oct. 2017, doi: 10.1109/TSTE.2017.2690835
- [74] Z. Feng and M. Liang, "Fault diagnosis of wind turbine planetary gearbox under nonstationary conditions via adaptive optimal kernel time frequency analysis," Renew. Energ., vol. 66, pp. 468–77, Jun. 2014, doi: <https://doi.org/10.1016/j.renene.2013.12.047>
- [75] P. Neti, P. Zhang, M. Shah, and K. Younsi, "Electrical signature analysis based online monitoring of drive-trains for doubly-fed wind generators," in Proc. 38th IEEE IECON, Montreal, QC, Oct. 25–28, 2012, pp. 1764–69, doi: 10.1109/IECON.2012.6388934
- [76]. R. Yacamini, K. S. Smith, and L. Ran, "Monitoring Torsional Vibrations of Electro-mechanical Systems Using Stator Currents," J. Vib. Acoust., vol. 120, no. 1, 72-79, 1998, doi: 10.1115/1.2893829
- [77]. X. Gong and W. Qiao, "Bearing fault diagnosis for direct-drive wind turbines via current-demodulated signals," IEEE Trans. Ind. Electron., vol. 60, no. 8, pp. 3419–3428, 2013, doi: 10.1109/TIE.2013.2238871
- [78]. Y. Merizalde, L. Hernandez, O. Duque and V. Alonso-Gómez, "Maintenance Models Applied to Wind Turbines. A Comprehensive Overview," Energies, vol. 12, no. 2, 2014, doi: <https://doi.org/10.3390/en12020225>

- [79]. K. Kobbacy and S. Vadera, "A survey of IA in operations management from 2005 to 2009", *Journal of Quality in Maintenance Engineering*, vol. 22, no. 6, pp. 706-33, 2011, doi: <https://doi.org/10.1108/17410381111149602>
- [80]. I. Alsyoufa and A. Alzghoulb, "Soft Computing Applications in Wind Power Systems: A Review And Analysis," *Eur. Offshore Wind 2009 Conf. Exhib.*, no. September, pp. 1–8, 2009.
- [81]. A. P. Verma, "Performance monitoring of wind turbines: a data- mining approach," PhD Thesis, University of Iowa, Iowa, USA, 2012.
- [82]. R. Liu, B. Yang, E. Zio, and X. Chen, "Artificial intelligence for fault diagnosis of rotating machinery: A review," *Mechanical Systems and Signal Processing*, vol. 108. Academic Press, pp. 33–47, 01-Aug-2018, doi: 10.1016/j.ymssp.2018.02.016
- [83]. R. K. Ibrahim, J. Tautz-Weinert, and S. J. Watson, "Neural networks for wind turbine fault detection via current signature analysis," *Present. Wind Eur.*, Hamburg, Germany, Sept. 2016. Available: <https://dspace.lboro.ac.uk/2134/23014>, accessed date: 06 de Octubre del 2019.
- [84]. M. Hichem and B. Tahar, "Fuzzy monitoring of stator and rotor winding faults for DFIG used in wind energy conversion system," *Int. J. Modelling, Identification and Control*, vol. 27, no. 1, Academic Press, pp. 49–57, 2017, doi: 10.1504/IJMIC.2017.082485
- [85]. S. Zhang, S. Zhang, B. Wang and T. Habetler, "Deep Learning Algorithms for Bearing Fault Diagnostics – A Comprehensive Review," *IEEE Access*, vol. 8, pp. 29857 - 81, 2020, doi: 10.1109/ACCESS.2020.2972859
- [86]. Y. Yang, M. Menul, D. Bai and W. Tang, "Fault Diagnosis of Electric Motors Using Deep Learning Algorithms and Its Application: A Review," *Energies*, vol. 14, no. 21, 2021, doi: <https://doi.org/10.3390/en14217017>
- [87]. H. Wang, H. Wang, G. Jiang, J. Li, and Y. Wang, "Early Fault Detection of Wind Turbines Based on Operational Condition Clustering and Optimized Deep Belief

- Network Modeling,” *Energies*, vol. 12, no. 6, 2019, doi: <https://doi.org/10.3390/en12060984>
- [88]. L. Wang, Y. Ma, R. and X. Rui, “Research on Fault Diagnosis Method of Wind Turbine Bearing Based on Deep belief Network,” *IOP Conference Series Materials Science and Engineering*, 6-10 Dec. 2019, doi: 10.1088/1757-899X/677/3/032025
- [89]. G. Jiang, H. He, P. Xi and Y. Tang, “Stacked Multilevel-Denoising Autoencoders: A New Representation Learning Approach for Wind Turbine Gearbox Fault Diagnosis,” *IEEE Transactions on Instrumentation and Measurement*, vol. 66, no. 9, pp. 2391-402, 2017, doi: 10.1109/TIM.2017.2698738
- [90]. P. Guo, J. Fu and X. Yang, “Condition Monitoring and Fault Diagnosis of Wind Turbines Gearbox Bearing Temperature Based on Kolmogorov-Smirnov Test and Convolutional Neural Network Model,” *Energies*, vol. 11, no. 9, 2018, doi: <https://doi.org/10.3390/en11092248>
- [91]. G. Jiang, H. He, J. Yan, and P. Xie, Multiscale convolutional neural networks for fault diagnosis of wind turbine gearbox. *IEEE Trans. Ind. Electron.* 2019, vol. 66, no. 9, pp. 3196–207, doi: 10.1109/TIE.2018.2844805
- [92]. J. Lei, C. Liu and D. Jiang, Fault diagnosis of wind turbine based on Long Short-Term memory networks, *Comput. Meas. Control*, 2019, vol. 133, pp. 422–32, doi: <https://doi.org/10.1016/j.renene.2018.10.031>
- [93]. L. Guo, N. Li, F. Jia, Y. Lei and Y. Lin, A recurrent neural network based health indicator for remaining useful life prediction of bearings, *Neurocomputing*, 2017, vol. 240, pp. 98–109, doi: <https://doi.org/10.1016/j.neucom.2017.02.045>
- [94]. F. Cheng, J. Wang, L. Qu and W. Qiao, Rotor current-based fault diagnosis for DFIG wind turbine drivetrain gearboxes using frequency analysis and a deep classifier. *IEEE Trans. Ind. Appl.* 2017, 54, 1062–71, doi: 10.1109/TIA.2017.2773426
- [95]. G. Jiang, J. Zhao, C. Jia, Q. He, P. Xie, and Z. Meng, Intelligent Fault Diagnosis of Gearbox Based on

Vibration and Current Signals: A Multimodal Deep Learning Approach, Prognostics and System Health Management Conference, Qingdao, China, 25-27 Oct., 2019, doi: 10.1109/PHM-Qingdao46334.2019.8942903

- [96]. L. Jing, T. Wang, M. Zhao, and P. Wang, “An adaptive multi-sensor data fusion method based on deep convolutional neural networks for fault diagnosis of planetary gearbox,” *Sensors*, vol. 17, no. 2, p. 414, 2017, doi: <https://doi.org/10.3390/s17020414>
- [97]. Y. Merizalde, L. Hernández-Callejo, O. Duque-Perez and V. Alonso-Gómez, “Diagnosis of wind turbine faults using generator current signature analysis: a review,” *Journal of Quality in Maintenance Engineering*, vol. 26, no. 3, pp. 431-58, 2019, doi: <https://doi.org/10.1108/JQME-02-2019-0020>
- [98]. Y. Merizalde, L. Hernández-Callejo, O. Duque-Perez and R. López-Meraz, “Fault Detection of Wind Turbine Induction Generators through Current Signals and Various Signal Processing Techniques,” *Energies*, vol. 10, no. 21, 2020, doi: <https://doi.org/10.3390/app10217389>
- [99]. C. Walford, (2006), “Wind turbine reliability: understanding and minimizing wind turbine operation and maintenance costs,” Sandia National Laboratories, Albuquerque, New Mexico, doi: <https://doi.org/10.2172/882048>
- [100]. IRENA, (2013), “<https://www.irena.org/publications/2013/Jan/Renewable-Power-Generation-Costs-in-2012-An-Overview>,” [Online]. Available: <https://www.irena.org/publications/2017/Jan/REthinking-Energy-2017-Accelerating-the-global-energy-transformation>. [Accessed: 08-Oct-2019].
- [101]. A. Costa, “Investigación de nuevas técnicas de mantenimiento de parques eólicos,” Ph.D. dissertation, Universidade da Coruña, La Coruña, España, 2012.
- [102]. J. Andrawus, “Maintenance optimisation for wind turbines,” PhD Thesis, Aberdeen University, Aberdeen, Escocia, 2008.
- [103]. F. P. García Márquez, A. M. Tobias, J. M. Pinar Pérez, and M. Papaelias, “Condition monitoring of wind turbines: Techniques and methods,” *Renew. Energy*, vol. 46, pp. 169–178, 2012, doi: 10.1016/j.renene.2012.03.003

- [104]. W. Qiao and D. Lu, "A Survey on Wind Turbine Condition Monitoring and Fault Diagnosis - Part II: Signals and Signal Processing Methods," *IEEE Trans. Ind. Electron.*, vol. 62, no. 10, pp. 6546–57, 2015, doi: 10.1109/TIE.2015.2422394
- [105]. E. Artigao, A. Honrubia-Escribano, and E. Gomez-Lazaro, "Current signature analysis to monitor DFIG wind turbine generators: A case study," *Renew. Energy*, vol. 116, pp. 5–14, 2018. Doi: 10.1016/j.renene.2017.06.016
- [106]. P. Zhang and P. Neti, "Detection of gearbox bearing defects using electrical signature analysis for doubly fed wind generators," *IEEE Trans. Ind. Appl.*, vol. 51, no. 3, pp. 2195–200, 2014, doi: 10.1109/TIA.2014.2385931
- [107]. E. Gómez-Lázaro, J. Carroll, E. Artigao, S. Koukoura, A. McDonald, and A. Honrubia-Escribano, "Current Signature and Vibration Analyses to Diagnose an In-Service Wind Turbine Drive Train," *Energies*, vol. 11, no. 4, p. 960, 2018, doi: 10.3390/en11040960
- [108]. W. Q. Jeffries, J. A. Chambers, and D. G. Infield, "Experience with bicoherence of electrical power for condition monitoring of wind turbine blades," *IEE Proc. - Vision, Image, Signal Process.*, vol. 145, no. 3, pp. 141-148, 2002, doi: 10.1049/ip-vis:19982013
- [109]. I. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville and Y. Bengio, *Generative Adversarial Nets*. arXiv 2016, arXiv:1406.2661. Available online: <https://arxiv.org/abs/1406.2661v1>, accessed on 26 July 2020
- [110]. A. Radford, L. Metz and S. Chintala, "Unsupervised representation learning with deep convolutional generative adversarial networks," arXiv 2016, arXiv:1511.06434. Available online: <https://arxiv.org/abs/1511.06434>, accessed on 27 Dec., 2015
- [111]. H. Liu, J. Zhou, Y. Xu, Y. Zheng, X. Peng, and W. Jiang, "Unsupervised fault diagnosis of rolling bearings using a deep neural network based on generative adversarial networks," *Neurocomput.*, vol. 315, pp. 412–24, 2018, doi: <https://doi.org/10.1016/j.neucom.2018.07.034>

- [112]. B. Zhang, W. Li, J. Hao, X.-L. Li, and M. Zhang, “Adversarial adaptive 1-D convolutional neural networks for bearing fault diagnosis under varying working condition,” eprint arXiv:1805.00778, May 2018.
- [113]. W. Mao, Y. Liu, L. Ding and Y. Li, “Imbalanced fault diagnosis of rolling bearing based on generative adversarial network: A comparative study,” *IEEE Access*, vol. 7, pp. 9515–30, 2019, doi: 10.1109/ACCESS.2018.2890693
- [114]. S. Suh, H. Lee, J. Jo, P. Lukowicz, and Y.-Oh Lee, “Generative Over sampling Method for Imbalanced Data on Bearing Fault Detection and Diagnosis,” *Appl. Sci.*, vol. 9, no. 4, pp. 746, 2019, doi: <https://doi.org/10.3390/app9040746>
- [115]. Y. Xie and T. Zhang, “Imbalanced learning for fault diagnosis problema of rotating machinery based on generative adversarial networks,” in *Proc. 37th Chinese Control Conf. (CCC)*, Wuhan, China, 2018, pp. 3248–53, doi: 10.23919/ChiCC.2018.8483334
- [116]. Y. Lee, J. Jo and J. Hwang, “Application of deep neural network and generative adversarial network to industrial maintenance: A case study of induction motor fault detection,” in *Proc. IEEE Int. Conf. Big Data*, Boston, MA, 2017, pp. 3248–53, doi: 10.1109/BigData.2017.8258307
- [117]. W. T. Thomson and M. Fenger, “Current signature analysis to detect induction motor faults,” *IEEE Ind. Appl. Mag.*, vol. 7, no. 4, pp. 26-34, 2001, doi: 10.1109/2943.930988
- [118]. N. Soto Salvá and F. de la Torre Silva, “Diagnóstico de problemas de asimetrías rotóricas en un motor de inducción de gran potencia. // Diagnostic of high power induction motors failures.,” *Ing. Mecánica*, vol. 10, no. 2, 2011. [Online]. Available:<http://www.ingenieriamecanica.cujae.edu.cu/index.php/revistaIam/article/view/127>. [Accessed: 14-Nov-2019]
- [119]. M. Riera-Guasp, J. Antonino-Daviu, M. Pineda-Sanchez, J. Perez-Cruz and R. Puche-Panadero, “A general approach for the transient detection of slip-dependent fault components base on the discrete wavelets transform,” *IEEE Transactions on Industrial Electronics*, 2008, vol. 55, no. 12, 4167-80, doi: 10.1109/TIE.2008.2004378

- [120]. Liu, Y., Li, Z., Zhou, C., Jiang, Y., Sun, J., Wang, M and He, X. Generative Adversarial Active Learning for Unsupervised Outlier Detection, IEEE Transactions on Knowledge and Data Engineering, 2020, 32, 8, 1517-28. doi: 10.1109/TKDE.2019.2905606