

TECNOLÓGICO NACIONAL DE MÉXICO
INSTITUTO TECNOLÓGICO DE AGUASCALIENTES



TECNOLÓGICO
NACIONAL DE MÉXICO®

Ciencia y
Tecnología

Secretaría de Ciencia, Humanidades,
Tecnología e Innovación



Instituto **Tecnológico**®
de Aguascalientes

DOCTORADO EN CIENCIAS DE LA INGENIERÍA

**"TÉCNICAS DE MONITOREO Y
DIAGNÓSTICO DE FALLAS EN UN
GENERADOR SÍNCRONO DE IMANES
PERMANENTES APLICADO A UNA
TURBINA EÓLICA".**

Tesis de Doctorado
para obtener el título de:
Doctor en Ciencias de la Ingeniería

Presenta:

JOSÉ ANTONIO ALVAREZ SALAS

Director

DR. FRANCISCO JAVIER VILLALOBOS PIÑA

Co-Director

DR. MARIO ARTURO GONZÁLEZ GARCÍA

Asesores

**DR. J. RAFAEL MOLINA CONTRERAS
DR. ADRIÁN BONILLA PRETRICIOLET
DR. CARLOS HUMBERTO SAUCEDO ZÁRATE**

Aguascalientes, Ags., México
Mayo 2026



HOJA EN BLANCO



Instituto Tecnológico de Aguascalientes
División de Estudios de Posgrado e Investigación

Aguascalientes, Ags., 14/mayo/2026

No. De Oficio: 022/2026

Asunto: **Autorización de Tesis de Grado Para su Impresión**


**M.C. JOSÉ ANTONIO ÁLVAREZ SALAS
PRESENTE**

Los abajo firmantes, miembros del Jurado para Examen de Grado de Doctorado, hacemos **CONSTAR** que, habiendo revisado el Trabajo de Tesis desarrollado por Usted, bajo el título: "**TÉCNICAS DE MONITOREO Y DIAGNÓSTICO DE FALLAS EN UN GENERADOR SINCRÓNICO DE IMANES PERMANENTES APLICADO A UNA TURBINA EÓLICA**". hemos dictaminado que éste es de aceptarse, por lo que se autoriza su impresión.


ATENTAMENTE

*Excelencia en Educación Tecnológica®
Ingenio, Cultura y Saber, que conducen a la Excelencia®*

PRESIDENTE


DR. FRANCISCO JAVIER VILLALOBOS PIÑA


SECRETARIO


DR. J. RAFAEL MOLINA CONTRERAS

VOCAL



DR. ADRIÁN BONILLA PRETRICIOLET

VOCAL


DR. CARLOS HUMBERTO SAUCEDO ZÁRATE

VOCAL


DR. MARIO ARTURO GONZÁLEZ GARCÍA



ccp. Archivo



Av. Adolfo López Mateos # 1801, Fracc. Bona Gens. C.P. 20256 Aguascalientes, Ags.

Tel. : 449 9105002 ext. 127

Email: principal@itaguascalientes.mx

Página web: www.itaguascalientes.mx



Instituto Tecnológico de Aguascalientes
División de Estudios de Posgrado e Investigación

Aguascalientes, Ags., **14/abril/2026**
Asunto: Autorización de uso de derechos

JOSÉ ANTONIO ÁLVAREZ SALAS, mayor de edad, con domicilio ubicado en **Pabellón de Arteaga 329, San José del Arenal, 20130, Aguascalientes, Aguascalientes** en mi calidad de titular y autor de la tesis denominada **"TÉCNICAS DE MONITOREO Y DIAGNÓSTICO DE FALLAS EN UN GENERADOR SINCRÓNICO DE IMANES PERMANENTES APLICADO A UNA TURBINA EÓLICA"**. quien para todos los fines del presente documento se denominará **EL AUTOR Y/O TITULAR**, suscribo el presente documento de autorización de uso de derechos patrimoniales de autor a favor del Tecnológico Nacional de México/Instituto Tecnológico de Aguascalientes el cual se registrá por las cláusulas siguientes:

PRIMERA – AUTORIZACIÓN: **EL AUTOR Y/O TITULAR**, mediante el presente documento autoriza la utilización de los derechos patrimoniales de autor al Tecnológico Nacional de México/Instituto Tecnológico de Aguascalientes, de la tesis denominada **"TÉCNICAS DE MONITOREO Y DIAGNÓSTICO DE FALLAS EN UN GENERADOR SINCRÓNICO DE IMANES PERMANENTES APLICADO A UNA TURBINA EÓLICA"**, a través del Repositorio Institucional del Tecnológico Nacional de México (en lo sucesivo TecNM) y en el Repositorio Nacional, que puede ser consultado en la liga electrónica: (www.repositorionacionalcti.mx/).

SEGUNDA – OBJETO: Por medio del presente escrito, **EL AUTOR Y/O TITULAR** autoriza al Tecnológico Nacional de México/Instituto Tecnológico de Aguascalientes, a través del Repositorio Institucional del TecNM y del Repositorio Nacional para que de conformidad con la Ley Federal del Derecho de Autor y la Ley de la Propiedad Industrial, use los derechos del documento antes referido, con fines exclusivamente académicos.

TERCERA – TERRITORIO: Los derechos aquí autorizados se dan sin limitación geográfica o territorial alguna.

CUARTA – ALCANCE: La presente autorización se da tanto para formato o soporte material, y se extiende a la utilización en medio óptico, magnético, electrónico, en red, mensajes de datos o similar conocido o por conocer, del ejemplar o número respectivo de la publicación.

QUINTA – EXCLUSIVIDAD: La autorización de uso aquí establecida no implica exclusividad en favor del Tecnológico Nacional de México/Instituto Tecnológico de Aguascalientes. Por lo tanto, **EL AUTOR Y/O TITULAR** en su carácter de autor de la obra objeto del presente documento se reserva el derecho de publicar directamente, u otorgar a cualquier tercero, autorizaciones de uso similares o en los mismos términos aquí acordados.





Instituto Tecnológico de Aguascalientes
División de Estudios de Posgrado e Investigación

SEXTA – DERECHOS MORALES (Créditos y mención): La Autorización de los derechos antes mencionados no implica la cesión de los derechos morales sobre los mismos por cuanto en conformidad con lo establecido en los artículos 18, 19, 20, 21, 22 y 23 de la Ley Federal de Derechos de Autor, dada la cuenta que estos derechos son inalienables, imprescriptibles, irrenunciables e inembargables. Por lo tanto, los mencionados derechos seguirán radicados en cabeza de EL AUTOR Y/O TITULAR, y siempre deberá mencionarse su nombre cuando se utilice la obra.

SÉPTIMA – AUTORÍA: EL AUTOR Y/O TITULAR, declara y ratifica que el material objeto de la presente fue realizado por él o por ella sin violar o usurpar derechos de Propiedad Intelectual de terceros.

ATENTAMENTE

Excelencia en Educación Tecnológica®

Ingenio, Cultura y Saber, que conducen a la Excelencia

JOSÉ ANTONIO ÁLVAREZ SALAS
AUTOR DE LA TESIS

Vo.Bo.

DR. FRANCISCO JAVIER VILLALOBOS PIÑA
DIRECTOR DE LA TESIS

ccp. Archivo



2026
año de
Margarita Maza





HOJA EN BLANCO

Resumen

El monitoreo y diagnóstico de fallas en el generador síncrono de imanes permanentes (GSIP) es crucial para asegurar la continuidad y la confiabilidad del sistema en el que opere la máquina. Recientes avances en el área de monitoreo y diagnóstico han introducido técnicas no invasivas para detectar fallas mecánicas y eléctricas en la máquina. Sin embargo, el reto de estas técnicas es utilizar algoritmos simples para procesar las señales y clasificar las fallas eléctricas y mecánicas más incipientes en el GSIP. Su implementación permitiría el diagnóstico de fallas en la máquina en tiempo real.

En este trabajo se utilizaron las transformadas ondeletas Haar y Duabechies como extractores de características, y el modelo de clasificación binario que emplea los siguientes algoritmos: el perceptrón, la regresión logística, el perceptrón multicapa, los árboles de decisión y los bosques aleatorios. La combinación del extractor de características y el clasificador binario se emplea para identificar las fallas de cortocircuito (c.c.) entre vueltas del estator del GSIP que forma parte de una turbina eólica.

En el procesamiento de las corrientes de línea del GSIP se obtienen los datos con los que el extractor de características suministra información al clasificador binario. El extractor de características procesa las corrientes mediante la transformada ondeleta, de la cual se obtienen los valores eficaces de sus coeficientes, que, junto con la función objetivo, se utilizan para formar los datos que recibe el clasificador binario en el proceso de entramiento y validación.

Ante distintas condiciones de falla de c.c. en el estator del GSIP, se utilizan las métricas de exactitud, la matriz de confusión y las curvas ROC para validar el desempeño de los

modelos del clasificador binario. Adicionalmente, se emplearon técnicas de optimización que mejoraron el desempeño de los modelos de aprendizaje automático, entre ellas la validación cruzada, el ajuste de hiperparámetros en cuatro de los algoritmos, la técnica de muestreo por reemplazo y la agregación de predicciones para el quinto algoritmo de clasificación binaria.

Mediante la validación de los modelos de clasificación, se buscó detectar la falla de c.c. más incipiente en el estator del GSIP. Para lo anterior, se adecuaron dos GSIP de 400 W y 600 W, con derivaciones que permitan emular la falla de c.c. en el estator. En ambos GSIP se dispusieron diferentes combinaciones de vueltas en c.c. Con los datos de las corrientes de línea del GSIP de 400 W, en Matlab y Python se procesaron los coeficientes del extractor de características y los diferentes modelos de clasificación binaria. Los resultados obtenidos permiten evaluar la factibilidad de la técnica no invasiva para la detección de fallas de c.c. en el GSIP en análisis.

Dedicatoria

A mi esposa, Sofía; a mis hijos, Aldo y Nicolás; a mis padres, Antonio y Ma. Rosenda; y a mis hermanos, Ricardo, Laura y Claudia:

A mi esposa e hijos, por la paciencia, comprensión y apoyo incondicional brindados a lo largo de estos años, los cuales han sido una fuente constante de motivación para la culminación de este proyecto. A mis padres, quienes, aunque ya no se encuentran físicamente con nosotros, dejaron enseñanzas que constituyen el referente fundamental que guía mis acciones y aspiraciones en la vida. A mis hermanos, quienes, pese a haber formado cada uno su propia familia y seguir su propio camino, han estado presentes con su apoyo y consejos en los momentos en que se requiere. Todos ustedes han sido mi inspiración constante, mi fortaleza y el motivo principal para cerrar este ciclo e iniciar otra etapa.

Agradecimientos

- Al **Dr. Francisco Javier Villalobos Piña** y al **Dr. Mario Arturo González García**, por haber aceptado la asesoría de esta tesis, por el apoyo, las enseñanzas y conocimientos compartidos durante el desarrollo del proyecto de tesis.
- A los **miembros del comité de revisión de tesis**, por su tiempo y aportaciones en cada una de las revisiones semestrales del proyecto doctoral.
- Al **Dr. J. Ascensión Guerrero Viramontes** y al **Dr. Ricardo Mendoza González** como Coordinadores del Programa de Doctorado en Ciencias de la Ingeniería, por sus servicios y atenciones durante el transcurso de estos años del proyecto de tesis.
- Al **M.C. José Alejandro Morones Alba** por su disponibilidad para el trabajo experimental en el generador que se utilizó en el proyecto de tesis.
- Al **TecNM/Instituto Tecnológico de Aguascalientes** por el soporte institucional brindado para la realización y conclusión de este proyecto doctoral.
- A la **Facultad de Ingeniería de la UASLP**, por las facilidades laborales otorgadas durante la realización de este proyecto de tesis.

Índice general

Resumen	ii
Índice de figuras	vi
Índice de tablas	ix
1. Introducción	1
1.1 Estado del arte.....	1
1.2 Planteamiento del problema.....	7
1.3 Hipótesis.....	7
1.4 Objetivo general.....	8
1.5 Objetivos particulares.....	8
1.6 Justificación.....	8
1.7 Alcances y limitaciones.....	9
2. Fallas en el generador síncrono de imanes permanentes	10
2.1 Fallas en el GSIP.....	10
2.1.1 Fallas mecánicas.....	10
2.1.2 Fallas eléctricas.....	10
2.2 Modelo del GSIP considerando las fallas en el estator.....	15
2.3 Pruebas en los GSIPs modificados en el estator.....	21
2.3.1 GSIP de 600 W con derivaciones en el estator.....	21
2.3.2 GSIP de 400 W con derivaciones en el estator.....	26
3. Transformadas ondeletas	34
3.1 Transformadas ondeletas aplicadas al diagnóstico de fallas en el GSIP.....	34
3.2 Transformada ondeleta Haar.....	35
3.3 Transformada ondeleta Daubechies.....	37
3.4 Análisis multiresolución.....	40
3.5 Análisis de las transformadas ondeletas Haar y Daubechies 4 aplicadas al diagnóstico de fallas.....	41
4. Métodos de aprendizaje automático	51
4.1 Métodos de aprendizaje automático para el diagnóstico de fallas del GSIP aplicado a una turbina eólica.....	51
4.2 El perceptrón y la regresión logística.....	53
4.3 Perceptrón multicapa.....	56
4.4 Árboles de decisiones y bosques aleatorios.....	58
4.5 Métodos de ajuste en los métodos de aprendizaje automático.....	62
4.5.1 Entrenamiento de los algoritmos de los clasificadores binarios.....	63

4.5.2 Validación cruzada.....	64
4.5.3 Optimización de los algoritmos de los clasificadores binarios.....	65
4.6 Métricas de medición en el aprendizaje automático.....	66
5. Resultados	69
5.1 Formulación de los datos del extractor de características.....	69
5.2 Análisis del desempeño de los modelos del clasificador binario.....	75
5.3 Modelo del clasificador binario con el algoritmo de la regresión logística y el algoritmo del perceptrón.....	80
5.4 Modelo del clasificador binario con el algoritmo perceptrón multicapa.....	86
5.5 Modelo del clasificador binario con los algoritmos de un árbol de decisiones y los bosques aleatorios.....	91
5.6 Comparación del desempeño en los modelos del clasificador binario.....	97
6. Conclusiones y trabajos futuros	98
6.1 Conclusiones.....	98
6.2 Trabajos futuros.....	99
6.3 Artículos publicados.....	100
Apéndice A	102
A1. GSIP de 600 W.....	102
A2. GSIP de 400 W.....	107
Apéndice B	109
B1. Banco de pruebas del GSIP de 400 W.....	109
Referencias	111

Índice de figuras

1.1 Técnica de diagnóstico de fallas basada en un modelo.....	2
1.2 Técnica de diagnóstico de fallas basada en procesamiento de señales.....	3
1.3 Técnica de diagnóstico de fallas basada en patrones o datos.....	3
2.1 Bobina con falla.....	11
2.2 Distribución del devanado del estator en condiciones simétricas.....	14
2.3 Distribución del devanado del estator en condiciones de falla de c.c.....	14
2.4 Comportamiento de la rapidez del viento de una estación meteorológica.....	15
2.5 Modelo de un GSIP con falla en el estator.....	17
2.6 Voltajes simétricos del circuito del estator del GSIP.....	20
2.7 Voltajes con una falla de vueltas en c.c. del 7% en una fase del GSIP.....	21
2.8 Voltajes con una falla de vueltas en c.c. del 15% en una fase del GSIP.....	21
2.9 Derivaciones del GSIP de 600 W.....	22
2.10 Conexión de prueba en el GSIP de 600 W.....	23
2.11 Señales de los voltajes de fase a fase del GSIP de 600 W.....	23
2.12 Voltajes de fase a fase en vacío del GSIP de 600 W.....	24
2.13 Voltajes de fase a fase con carga del GSIP de 600 W.....	24
2.14 Corrientes del GSIP de 600 W.....	24
2.15 Derivaciones de la fase "c" vs. del neutro.....	25
2.16 Derivaciones de la fase "c" vs. derivaciones de la fase "c".....	26
2.17 Imagen de las derivaciones del GSIP de 400 W.....	27
2.18 Voltajes de fase del GSIP de 400 W.....	27
2.19 Voltajes de fase a fase del GSIP de 400 W.....	28
2.20 Voltajes de fase en vacío.....	28
2.21 Voltajes de fase a fase en vacío.....	29
2.22 Voltajes de fase a neutro con carga de 16.3Ω	29
2.23 Voltajes de fase a neutro con carga de 1.0Ω	30
2.24 Voltajes de fase a fase con falla de 4 vueltas en c.c.....	30
2.25 Corrientes del GSIP con dos cargas diferentes a 400 rpm.....	31
2.26 Corrientes del GSIP con carga de 16.3Ω	31
2.27 Corrientes del GSIP con carga de 1.0Ω	31
2.28 Derivaciones de la fase "a" vs. del neutro.....	32
2.29 Derivaciones de la fase "a" vs. derivaciones de la fase "a".....	33
2.30 Derivaciones de la fase "b" vs. del neutro.....	33
3.1 Descomposición de la función $f(n)$ con un banco de filtros.....	40
3.2 Señal sinusoidal distorsionada.....	42
3.3 Coeficientes de las tendencias del nivel 1 de la señal de prueba.....	42
3.4 Coeficientes de las tendencias del nivel 2 de la señal de prueba.....	42
3.5 Coeficientes de las tendencias del nivel 3 de la señal de prueba.....	43
3.6 Coeficientes de las tendencias del nivel 4 de la señal de prueba.....	43
3.7 Señales trifásicas sinusoidales.....	44
3.8 Señales trifásicas no sinusoidales.....	44

3.9 Módulo del vector instantáneo de Park de las funciones trifásicas.....	45
3.10 Módulo del cuadrado de las funciones trifásicas.....	45
3.11 Bandas de frecuencia de los coeficientes de la ondeleta Haar y Daubechies 4.....	46
3.12 Índice de falla de la ondeleta Haar con señales sinusoidales.....	48
3.13 Índice de falla de la ondeleta Haar con señales no sinusoidales.....	48
3.14 Índice de falla de la ondeleta Daub 4 con señales sinusoidales.....	49
3.15 Índice de falla de la ondeleta Daub 4 con señales no sinusoidales	49
3.16 Energía de los coeficientes de las aproximaciones Haar a diferentes frecuencias y amplitudes.....	49
3.17 Energía de los coeficientes de las aproximaciones Daubechies 4 a diferentes frecuencias y amplitudes.....	49
3.18 Energía de los coeficientes de las aproximaciones Haar a diferentes frecuencias y amplitudes.....	50
3.19 Energía de los coeficientes de las aproximaciones Daubechies 4 a diferentes frecuencias y amplitudes.....	50
4.1. Diagrama básico de un perceptrón.....	54
4.2 Curva sigmoide.....	55
4.3 Diagrama básico de un perceptrón con regresión logística.....	56
4.4 Diagrama de un perceptrón multicapa.....	57
4.5 Diagrama de un árbol de decisiones.....	58
4.6 Diferencia entre parámetros e hiperparámetros.....	60
4.7 Diagrama de un bosque aleatorio.....	61
4.8 Distribución del conjunto de datos con validación convencional.....	64
4.9 Distribución del conjunto de datos con validación cruzada con reserva.....	64
4.10 Distribución del conjunto de datos con validación cruzada.....	65
4.11 Matriz de confusión.....	67
4.12 Funciones de probabilidad y la relación con la curva ROC.....	68
5.1 Diagramas de bloques del proceso de clasificación de fallas para el GSIP.....	69
5.2 Corrientes del GSIP de 400 W, considerando una falla de 1 vuelta en c.c.....	70
5.3 Corrientes del GSIP de 400 W, considerando una falla de 7 vueltas en c.c.....	70
5.4 Estimación de la exactitud $\pm$ desviación con 20 pliegues.....	75
5.5 Estimación de la exactitud $\pm$ desviación con 10 pliegues.....	76
5.6 Ajuste de los datos en la regresión logística y el perceptrón multicapa.....	77
5.7 Ajuste de los datos de un árbol de decisión y del bosque aleatorio.....	78
5.8 Curvas de aprendizaje para la regresión logística y el perceptrón multicapa.....	78
5.9 Curvas de aprendizaje para el árbol de decisión y los bosques aleatorios.....	78
5.10 Exactitud con 10% de datos de prueba a 200 rpm.....	81
5.11 Exactitud con 20% de datos de prueba a 200 rpm.....	81
5.12 Exactitud con 30% de datos de prueba a 200 rpm.....	81
5.13 Exactitud con 10% de datos de prueba y velocidad variable.....	82
5.14 Exactitud con cambios de los datos de prueba y velocidad variable.....	82
5.15 Curvas ROC considerando una falla de 1 vuelta en la fase A.....	83
5.16 Curvas ROC considerando una falla de 2 vueltas en la fase A.....	83
5.17 Curvas ROC considerando una falla de 4 vueltas en la fase A.....	83

5.18 Curvas ROC considerando una falla de 7 vueltas en la fase A.....	84
5.19 Curvas ROC con una falla de 7 vueltas en la fase A y 2 vueltas en la fase B.....	84
5.20 Exactitud del perceptrón multicapa a 200 rpm.....	87
5.21 Exactitud del perceptrón multicapa con 30% de datos de prueba a 200 rpm.....	87
5.22 Exactitud del perceptrón con 10% de datos de prueba y velocidad variable.....	88
5.23 Exactitud del perceptrón multicapa con cambios en los datos de prueba y velocidad variable.....	88
5.24 Curvas ROC del perceptrón multicapa con 1 y 2 vueltas en c.c.....	89
5.25 Curvas ROC del perceptrón multicapa con 4 y 7 vueltas en c.c.	89
5.26 Curvas ROC del perceptrón multicapa con 7 vueltas en c.c. de la fase A y 2 vueltas en c.c. de la fase B.....	89
5.27 Exactitud del árbol y de los bosques con cambios de velocidad.....	91
5.28 Exactitud del árbol y de los bosques a 200 rpm.....	92
5.29 Exactitud del árbol y de los bosques con cambios de 200 a 400 rpm.....	93
5.30 Exactitud del árbol y de los bosques con velocidad variable.....	93
5.31 Curvas ROC con una falla de 1 vuelta en la fase A.....	94
5.32 Curvas ROC con una falla de 2 vueltas en la fase A.....	94
5.33 Curvas ROC con una falla de 4 vueltas en la fase A.....	94
5.34 Curvas ROC con una falla de 7 vueltas en la fase A.....	95
5.35 Curvas ROC con las fallas de 7 vts. en la fase A y 2 vts. en la fase B.....	95
A1 Secciones de las fases del circuito del estator.....	102
A2 Bobinas que conforman una sección de una fase.....	103
A3 Molde para la construcción de las bobinas.....	103
A4 Bobinas construidas con derivaciones.....	103
A5 Acomodo el papel aislante en las ranuras del núcleo.....	105
A6 Montaje de las bobinas modificadas en el núcleo.....	105
A7 Montaje de las bobinas modificadas en el núcleo.....	105
A8 Estructura del devanado con sus derivaciones.....	105
A9 Estructura del devanado del estator después de la modificación.....	106
A10 Conexión del c.c. en la fase C.....	107
A11 Conexión del devanado de armadura con las derivaciones en las fases.....	108
B1 Banco de pruebas del GSIP de 400 W.....	109
B2 Imagen del banco de pruebas del GSIP de 400 W.....	110

Índice de tablas

1.1 Variables de estudio e indicadores.....	8
2.1 Valores nominales del GSIP de 600 W.....	22
2.2 Valores de las resistencias del GSIP de 600 W.....	25
2.3 Valores nominales del GSIP de 400 W.....	26
2.4 Valores de las resistencias del GSIP de 400 W.....	26
3.1 Valor eficaz de los coeficientes de tendencia.....	43
3.2 Valores de las señales sinusoidales simuladas.....	44
3.3 Desbalance de las magnitudes pico unitarias de las señales trifásicas.....	45
3.4 Valores rms de las tendencias de la transformada Haar de las senoidales.....	47
3.5 Valores rms de las tendencias de la transformada Haar de las senoidales distorsionadas.....	47
3.6 Valores rms de las tendencias de la transformada Daub 4 de las senoidales.....	47
3.7 Valores rms de las tendencias de la transformada Daub 4 de las senoidales distorsionadas.....	48
5.1 Bandas de frecuencia de las tendencias y fluctuaciones.....	71
5.2 Valores eficaces de los coeficientes de la ondeleta Haar sin falla 200 rpm.....	71
5.3 Valores eficaces de los coeficientes de la ondeleta Daub 4 sin falla a 200 rpm.....	72
5.4 Valores eficaces de los coeficientes de la ondeleta Daub 4 sin falla a 400 rpm.....	72
5.5 Valores eficaces de los coeficientes de la ondeleta Haar con fallas a 200 rpm.....	73
5.6 Valores eficaces de los coeficientes de la ondeleta Daub 4 con fallas a 200 rpm.....	73
5.7 Valores eficaces de los coeficientes de la ondeleta Daub 4 con fallas a 400 rpm.....	74
5.8 Ajuste de la exactitud del modelo con el algoritmo de la regresión logística.....	76
5.9 Ajuste de la exactitud del modelo con el algoritmo del perceptrón multicapa.....	77
5.10 Exactitud del modelo con ajuste de hiperparámetros en la regresión logística...	79
5.11 Exactitud del modelo con ajuste de hiperparámetros en el perceptrón.....	79
5.12 Exactitud del modelo con ajuste de hiperparámetros en el árbol de decisiones....	80
5.13 Matriz de confusión del perceptrón a 200 rpm.....	84
5.14 Matriz de confusión de la regresión logística a 200 rpm.....	85
5.15 Métricas del perceptrón a 200 rpm.....	85
5.16 Métricas del perceptrón a velocidad variable.....	85
5.17 Métricas de la regresión logística a 200 rpm.....	86
5.18 Métricas de la regresión logística a velocidad variable.....	86
5.19 Matriz de confusión del perceptrón multicapa a 200 rpm.....	90
5.20 Métricas del perceptrón multicapa a 200 rpm.....	90
5.21 Métricas del perceptrón multicapa a velocidad variable.....	90
5.22 Métricas del árbol de decisiones a 200 rpm.....	95
5.23 Métricas del árbol de decisiones a velocidad variable.....	95
5.24 Métricas de los bosques aleatorios a 200 rpm.....	96
5.25 Métricas de los bosques aleatorios a velocidad variable.....	96

5.26 Desempeño del modelo del clasificador binario a 200 rpm.....	97
5.27 Desempeño del modelo del clasificador binario a velocidad variable.....	97
A1 Distribución de las derivaciones en las fases del estator.....	104
A2 Derivaciones en las fases del devanado del estator.....	104
A3 Vueltas en c.c. entre la derivación y el neutro de la fase C.....	106
A4 Vueltas en c.c. entre las derivaciones de la fase C.....	106
A5 Valores del estator del GSIP de 400 W.....	107
A6 Derivaciones en las fases del GSIP de 400 W.....	108
A7 Vueltas en c.c. entre la derivación y el neutro de las fases A y B.....	108
A8 Vueltas en c.c. entre las derivaciones de las fases A y B.....	108
B1 Valores utilizados en el proceso de adquisición de las señales de corriente.....	110

Capítulo 1

Introducción

1.1 Estado del arte

Entre las máquinas eléctricas rotatorias de uso más general se encuentran las de inducción y las síncronas. La máquina síncrona de imanes permanentes, en los últimos años, ha diversificado sus aplicaciones, tales como sistemas eólicos, sistemas hidráulicos, embarcaciones marinas motorizadas, vehículos eléctricos, sistemas industriales de posicionamiento y mecanismos que requieren sistemas de control de velocidad, por su eficiencia, su relación potencia-volumen y la elevada relación par-corriente [1].

Generalmente las máquinas eléctricas rotatorias de mayor uso son las de inducción y las síncronas. Se emplean en diversas áreas de la industria y en distintas capacidades. La presencia de una falla imprevista puede provocar la pérdida de continuidad del proceso del que forma parte. La detección de fallas en las máquinas eléctricas ha generado la necesidad de establecer programas de mantenimiento que incluyan principalmente un sistema de monitoreo en línea de sus variables eléctricas y/o mecánicas [1]. El área de monitoreo y diagnóstico de fallas aplicada a máquinas eléctricas busca la continuidad y la confiabilidad del equipo dentro del sistema en el que se encuentran operando. El monitoreo ofrece información relevante tanto al área operativa como a la de mantenimiento. Se han desarrollado técnicas de diagnóstico para máquinas síncronas operando como motores o generadores, diagnosticando la parte eléctrica o mecánica e incluso la presencia de fallas en su convertidor estático. Las fallas incipientes son las más difíciles de detectar, por lo que desarrollar técnicas de diagnóstico eficaces en las máquinas síncronas ha sido una tarea relevante en los últimos años [2].

La temprana detección de fallas incipientes, con requerimientos mínimos de monitoreo de las máquinas eléctricas, es el propósito principal de un diagnóstico ideal. Las técnicas no invasivas se consideran las mejores para el monitoreo, ya que no requieren cambios en el diseño del sistema original [3]. La mejora de los algoritmos de control y el desempeño de las nuevas plataformas digitales han permitido que el diagnóstico de máquinas eléctricas, en conjunto con sus accionamientos, sea una de las tendencias de integración [4].

El proceso de diagnóstico usa las señales eléctricas, mecánicas o magnéticas de la máquina; los cambios en variables físicas deben ser detectados cuando la máquina opera en condiciones estacionarias o no estacionarias. En [5] se propone una clasificación basada en modelos matemáticos, análisis de señales, análisis de patrones o datos utilizados en el diagnóstico de fallas en máquinas eléctricas.

Las técnicas de diagnóstico basadas en modelos emplean modelos analíticos del equipo o del proceso para generar salidas que se comparan con la operación del sistema real y se obtienen variables residuales, que se emplean para la detección de fallas. Por lo general, los modelos utilizados pueden ser de tipo determinístico, como los modelos matemáticos de sistemas, o bien heurísticos basados en inteligencia artificial, redes neuronales, lógica difusa o algoritmos genéticos. Una vez entrenados estos modelos genéricos en condiciones con o sin falla, se encargan de generar los residuos para la detección de fallas [6].

En la Figura 1.1 se muestra cómo el modelo de la máquina se compara con su operación dinámica para obtener residuos y realizar el diagnóstico de fallas en el sistema. Generalmente se requiere un conjunto de parámetros para reducir el nivel de incertidumbre y mejorar la exactitud del diagnóstico. Esta tarea puede realizarse en línea mediante procesamiento digital en tiempo real, en el que el modelo reproduce el comportamiento dinámico de la máquina [7].




Figura 1.1. Técnica de diagnóstico de fallas basada en un modelo.

La técnica de diagnóstico basada en el análisis de señales es muy útil cuando no se puede obtener fácilmente un modelo y cuando la información de datos es abundante. La técnica es recomendable en equipos con pocas señales, pero con una idea clara de lo que ocurre en el proceso [8]. El diagnóstico basado en el procesamiento de señales ha tenido un importante desarrollo en la investigación en los últimos años, debido a que su implementación en plataformas de tiempo real se basa en el procesamiento de señales tales como: vibraciones, temperatura, ruido acústico, presión, voltajes, corrientes, flujos magnéticos, entre otros. En la Figura 1.2 se muestran las etapas que pueden experimentar las señales eléctricas o mecánicas que se adquieren para el diagnóstico de fallas. La elección de la plataforma digital para el diagnóstico basado en señales debe considerar el proceso de adquisición de los datos muestreados y el número de operaciones a realizar en el procesamiento de las señales [9].




Figura 1.2. Técnica de diagnóstico de fallas basada en el procesamiento de señales.

Las técnicas de procesamiento digital de señales aplicadas al monitoreo y al diagnóstico de máquinas eléctricas pueden clasificarse en las categorías: frecuencia, tiempo, tiempo-frecuencia y tiempo-escala [10].

En el monitoreo de las máquinas eléctricas se han implementado sistemas de reconocimiento de patrones y clasificadores para el diagnóstico de diversas fallas. Los métodos basados en patrones generalmente utilizan plantillas o patrones para distinguir la operación aceptable o inaceptable de la máquina. Las plantillas o patrones pueden ser determinados por especificaciones en el desempeño de la máquina, por observaciones basadas en la operación con falla, por conocimiento experto o por cualquier análisis o simulación de un modelo del sistema [11]. Una vez entrenado el sistema, es posible que reconozca y clasifique las fallas en la máquina. Sin embargo, una de las desventajas que presenta el reconocimiento de patrones es la dependencia de una gran cantidad de datos para el proceso de entrenamiento y diagnóstico [12]-[13]. En la Figura 1.3, se indica la extracción de características debido a las condiciones de falla en las señales de entrada y su tarea de clasificación para emitir el diagnóstico de la máquina eléctrica [14].




Figura 1.3. Técnica de diagnóstico de fallas basada en patrones o datos.

El análisis de las señales en el dominio del tiempo permite diagnosticar fallas en máquinas eléctricas a través de algoritmos como la raíz media cuadrática, el factor de forma y el factor de cresta. Estos algoritmos pueden implementarse en señales de corriente, de voltaje o de flujo. También pueden considerarse los registros de datos de las variables antes mencionadas para el diagnóstico, utilizando herramientas estadísticas como la media, la desviación estándar, la oblicuidad o la curtosis, entre otras [3].

Actualmente, en el diagnóstico de las máquinas eléctricas se utilizan más de una técnica de las mencionadas anteriormente para proporcionar robustez y confiabilidad en la detección de fallas. Cabe destacar que la detección de fallas simultáneas en una máquina se mejora significativamente mediante técnicas complementarias [15]-[16].

También se han implementado técnicas de diagnóstico invasivas en la máquina síncrona para detectar fallas entre vueltas del estator, de acuerdo con lo especificado

en [17]-[18]. Este tipo de técnicas utiliza herramientas analíticas y de simulación numérica, como la función de devanado y el método de elementos finitos, para el cálculo de los parámetros de la máquina [19]. Se estiman los parámetros de la máquina, que se utilizan en modelos extendidos que incorporan las fallas presentes en la máquina, como se indican en [20]-[21]. Otros ejemplos de este tipo de técnicas que se han utilizado para diagnosticar fallas en el estator de la máquina síncrona operando como generador o motor son, el diseño de modelos modificados por medio de los acoplamientos magnéticos y la teoría de redes eléctricas [22], la estimación paramétrica que utiliza un filtro de Kalman [23], o un filtro de Kalman extendido [24], las componentes simétricas de las corrientes y la técnica de oscilación pendular del campo magnético [25], las componentes simétricas del voltaje y el cambio de fase de la señal [26] y la componente de secuencia cero en el voltaje del estator de una máquina síncrona operando como motor [27]. Empleando mapas de flujos magnetostáticos [28] o mediante la técnica de estimación paramétrica de optimización por enjambre de partículas junto con el análisis de elementos finitos [29], permiten la detección de fallas en el estator de un motor síncrono de imanes permanentes. Una técnica que permite precisar la posición y severidad de la falla en el estator de una máquina síncrona emplea la variación del voltaje que se produce en las bobinas de búsqueda colocadas entre las fases de la máquina [30]. Las técnicas de diagnóstico invasivas generalmente demandan el uso de modelos analíticos extendidos, conocimiento de la estructura de los devanados, simulaciones numéricas complejas o mediciones de las variables. Los modelos de la máquina síncrona se han combinado con procesamiento de las señales y métodos de aprendizaje automático como se indica en [3], la señal de corriente se adquiere para ser procesada y transformada en un modelo con un factor que incluye la falla en el estator en el marco de referencia d-q y con la extracción de la amplitud del segundo armónico de corriente por medio de la transformada de Fourier se compara con un método de extracción armónico basado en la red neuronal Adeline. Sin embargo, el método de diagnóstico basado solo en señales es muy útil cuando no se puede obtener fácilmente un modelo y los datos son abundantes [31].

En el motor de inducción trifásico el diagnóstico de fallas del estator se ha realizado a través del método de mínimos cuadrados de Prony y las componentes simétricas de la señal de corriente del motor [32], también el uso de la secuencia negativa de una señal de corriente modificada por medio de un convertidor en el motor detecta fallas en cualquier parte del estator [33], empleando el módulo complejo de las tres corrientes instantáneas en vacío o con diferentes condiciones de carga [34].

Las técnicas de diagnóstico no invasivas utilizan principalmente el procesamiento de señales de la máquina y, en algunos casos, el uso de clasificadores mediante el aprendizaje automático. No requiere información de modelos extendidos o de la

configuración interna de los devanados. Las técnicas de diagnóstico no invasivas típicamente incluyen tres partes: el sensor o transductor, el extractor de características y el clasificador [13],[35]. El procesamiento de señales ha tenido un importante desarrollo en los últimos años, debido a la posibilidad de implementarlo en plataformas de tiempo real, empleando señales tales como vibraciones mecánicas, temperatura, ruido acústico, presión, voltajes, corrientes, flujos magnéticos, entre otros [10]. Entre las señales más utilizadas en este tipo de diagnóstico se encuentran las corrientes, ya que son de fácil acceso y con un buen nivel de confiabilidad. La medición de las corrientes emplea transductores o sensores como: transformadores de corriente, sondas de corriente y sensores de efecto Hall. Los clasificadores se agrupan en función de la forma en que se manipulan los datos o la información proveniente del extractor de características para obtener las condiciones de separabilidad. Un modelo de redes neuronales artificiales considera un conocimiento implícito de la información que le proporciona el extractor de características. Un modelo basado en reglas probabilísticas supone un conocimiento explícito de la información que le proporciona el extractor de características [8]. La complejidad de los algoritmos utilizados en el extractor de características y el clasificador ha permitido diagnosticar diversas fallas eléctricas o mecánicas en la máquina síncrona de imanes permanentes. Se ha reportado el uso de solo la etapa del extractor de características por medio de la transformada ondeleta del par y la velocidad para diagnosticar fallas en el estator del GSIP en una operación no estacionaria [36].

En [37] se emplea un procesamiento de las señales de corrientes en el extractor de características, a través de la transformada de Fourier de tiempo corto y la transformada ondeleta discreta, que permite identificar fallas entre espiras del estator en un motor síncrono de imanes permanentes. La utilización de las dos transformadas, permite un análisis tiempo-frecuencia que mejora la detección de las frecuencias características asociadas a la falla. Como complemento en las tareas del control predictivo aplicado a un motor síncrono de imanes permanentes en [38], se ha utilizado la transformada ondeleta para extraer las características de la falla de la función de costo del controlador predictivo, lo que permite realizar el diagnóstico de fallas en el estator. Considerando la integración del extractor de características y el clasificador, en [28] se emplea la transformación de Park de las señales de corriente para posteriormente extraer la amplitud del segundo armónico de corriente por medio de la transformada de Fourier. Como clasificador se emplea una red neuronal Adaline para detectar las fallas en el devanado del estator de un motor síncrono de imanes permanentes. En la implementación de un clasificador más complejo se emplea, en [39], una red neuronal convolucional, que recibe información de un análisis biespectral de las corrientes que alimentan un motor síncrono de imanes permanentes para la detección de fallas en el estator. La posibilidad de detección de

fallas múltiples es posible de acuerdo con lo que se reporta en [31], a través de la ondeleta empaquetada en el extractor de características y una red neuronal de convolución 1-D profunda en el clasificador, se diagnostican fallas eléctricas y mecánicas en un motor síncrono de imanes permanentes.

La evolución en el diagnóstico de máquinas eléctricas tanto síncronas como de inducción ha permitido establecer la confiabilidad de los algoritmos que se han utilizado en el extractor de características como se indica en [40], [41]. Sin embargo, con la integración del aprendizaje automático a las tareas del diagnóstico de fallas en las máquinas eléctricas se han alcanzado predicciones más precisas en las diferentes fallas eléctricas, mecánicas y mixtas [42]. Como una subdivisión del aprendizaje automático se tiene el aprendizaje supervisado, el cual se ha utilizado en tareas en el diagnóstico de fallas eléctricas y mecánicas de la máquina síncrona, como se indica en [43]. Algoritmos de aprendizaje automático como la regresión logística, el árbol de decisiones, los bosques aleatorios, las máquinas de vectores de soporte (SVMs), los k-vecinos más cercanos (kNN) y las redes neuronales han sido empleados en tareas de clasificación [44], [45].

En este trabajo a través de los datos y procesamiento de las corrientes de un GSIP de 400 W se diagnostican fallas de c.c. en el devanado del estator. El objetivo del trabajo es desarrollar un sistema de diagnóstico de fallas con un carácter no invasivo que dependa solo de las mediciones de las corrientes y pueda diagnosticar fallas incipientes. Como primera etapa en la selección y desarrollo de los algoritmos de diagnóstico, se presentan los resultados de un clasificador binario a través de los algoritmos como son el perceptrón y la regresión logística (siendo uno de los algoritmos más simples que se han utilizado en el aprendizaje automático). De acuerdo con los resultados en la validación de estos algoritmos, se emplearon algoritmos más complejos con base en redes neuronales o algoritmos probabilísticos con tareas de clasificación. La selección del extractor de características consideró señales en estado permanente o transitorio, de ahí la necesidad de emplear las ondeletas Haar y/o Daubechies 4 con una estructura relativamente simple en su cálculo. Una vez seleccionada la combinación del extractor de características y el clasificador, en una siguiente etapa se validaron los algoritmos a través de las métricas que registrarán el diagnóstico de la falla más incipiente.

En el capítulo 1 se revisa el estado del arte en el área de diagnóstico de fallas aplicados a la máquina síncrona, además, se plantea el problema de la investigación, la hipótesis, alcances y limitaciones del proyecto. En el capítulo 2 se describen los tipos de fallas eléctricas en el GSIP, así como algunas pruebas a los GSIP modificados en voltaje, corriente y resistencia, para verificar las posibles combinaciones de experimentos de c.c. en los devanados del estator. En el capítulo 3 se describen los fundamentos de las transformadas ondeletas Haar y Daubechies-4 y el análisis multiresolución en las transformadas ondeletas. En el capítulo 4 se describe la

estructura básica de los cinco algoritmos de aprendizaje automático aplicados al clasificador binario. Se justifica el uso de métodos de optimización en los modelos para que, al validarse mediante métricas, se obtenga un mejor desempeño. En el capítulo 5 se presentan los resultados de la valoración del extractor de características con base en la transformada ondeleta y en los cinco algoritmos que utiliza el modelo de clasificación binaria. En el capítulo 6 se presentan las conclusiones, trabajos futuros y los artículos que se han publicado durante el desarrollo del proyecto.

1.2 Planteamiento del problema

Una de las aplicaciones de las máquinas síncronas de imanes permanentes es el uso en los aerogeneradores, cuya integración en los sistemas eléctricos de potencia ha significado la evolución paulatina de la producción de energía eléctrica a nivel global, desde las fuentes primarias convencionales hacia las no convencionales. Existen diversos esfuerzos para incrementar la capacidad instalada de los aerogeneradores en los sistemas eléctricos modernos.

Hoy en día, es importante ofrecer confiabilidad en la operatividad de los equipos que integran los aerogeneradores. Los ciclos de trabajo en los que operan son intermitentes, principalmente debido a la variabilidad de las condiciones ambientales en las que se encuentran instalados. Típicamente, reciben perfiles de viento que producen variación de velocidad en los sistemas mecánicos y eléctricos que los componen.

Se observa la necesidad de desarrollar un algoritmo de diagnóstico que identifique las fallas eléctricas en el GSIP bajo condiciones de velocidad constante y variable. La integración de este algoritmo debe permitir procesar las señales eléctricas de la máquina y extraer características que permitan identificar la falla. También, con base en los datos generados por las diferentes mediciones de la máquina, con y sin la falla, se realiza una clasificación según los distintos niveles de severidad de la falla.

1.3 Hipótesis

Los métodos de diagnóstico basados en señales de tiempo-frecuencia/tiempo-escala, utilizados en motores trifásicos de inducción o síncronos, en complemento con los métodos de aprendizaje automático, permiten la detección, el análisis y la clasificación de las fallas eléctricas en un GSIP aplicado a una turbina eólica.

En la Tabla 1.1 se presentan las variables de estudio propuestas en la hipótesis del proyecto. El diagnóstico de fallas en el GSIP depende del método de diagnóstico, ya sea para la detección incipiente u oportuna. También se desglosan los indicadores asociados a cada una de las variables con los que se pretende trabajar en el proyecto.

Tabla 1.1. Variables de estudio e indicadores.

Variable	Indicadores
Métodos de diagnóstico de fallas basados en señales de tiempo-frecuencia/tiempo escala y los métodos de aprendizaje automático (independientes)	Vector de Park Transformada ondeleta Haar Transformada ondeleta Daubechies Regresión logística Redes neuronales artificiales Árboles de decisiones Bosques aleatorios
Fallas eléctricas (dependientes)	Fallas de cortocircuito (c.c.) entre vueltas o espiras de una fase Fallas de cortocircuito (c.c.) entre vueltas o espiras de fases diferentes

1.4 Objetivo general

Desarrollar un método de diagnóstico de fallas basado en señales de tiempo-escala, en complemento de un método de aprendizaje automático, para la detección de fallas eléctricas de un GSIP, con aplicación en una turbina eólica.

1.5 Objetivos particulares

- Analizar, desarrollar e implementar técnicas de diagnóstico basadas en señales.
- Analizar, desarrollar e implementar técnicas de diagnóstico basadas en clasificadores.
- Evaluar la sensibilidad de las técnicas de diagnóstico para detectar fallas incipientes en el GSIP.
- Analizar la factibilidad de las combinaciones entre el extractor de características y el clasificador binario.

1.6 Justificación

Las fallas eléctricas en el GSIP bajo régimen de velocidad variable requieren un análisis detallado de las señales de la máquina para un diagnóstico confiable. La combinación de métodos de diagnóstico basados en señales con métodos de aprendizaje automático permitirá la identificación, el análisis y la clasificación de las fallas presentes en el GSIP. El desarrollo de un algoritmo que identifique las fallas eléctricas de c.c. en el estator del GSIP implementará un sistema de monitoreo y diagnóstico confiable considerando su aplicación en la generación eólica.

1.7 Alcances y limitaciones

- Diseño e implementación de un algoritmo de diagnóstico que identifique fallas eléctricas en el GSIP.
- Resultados en el procesamiento de las señales de las corrientes que validen el esquema de diagnóstico de fallas propuesto en el GSIP.
- Publicación de resultados en congreso en revistas arbitradas e indexadas.
- Las limitaciones del proyecto implicarían el número y tipos de fallas a diagnosticar en la máquina, así como las señales de la máquina que se emplearían en el monitoreo de las fallas.

Capítulo 2

Fallas en el generador síncrono de imanes permanentes

2.1 Fallas en el GSIP

Las fallas en las máquinas eléctricas se clasifican en dos categorías [46]:

2.1.1. Fallas mecánicas.

Algunas condiciones que pueden causar una falla mecánica son: falta de lubricación, sobrecargas, sobrecalentamiento, desalineamiento, desbalances, fatigas en los rodamientos y fallas en los sistemas de enfriamiento. Cualquiera de estas condiciones puede conducir a la falla mecánica en la máquina eléctrica:

- Flecha de la máquina flexionada debido al rozamiento entre rotor y estator
- Fallas en rodamientos o caja de engranes
- Excentricidad estática y dinámica
- Desbalances en el rotor

2.1.2. Fallas eléctricas.

Mala calidad en el suministro de potencia, corriente de carga excesiva, desbalance resistivo o de impedancias, fallas en el aislamiento y sobrecalentamiento en los devanados pueden conducir a una falla eléctrica en la máquina. Cualquiera de estas condiciones puede conducir a la falla eléctrica en la máquina eléctrica:

- Fallas relacionadas con el devanado del rotor
- Falla entre vueltas del devanado
- Falla de línea a tierra
- Conexión atípica del devanado del estator
- Fallas en el circuito de campo del rotor

El proceso de deterioro del aislamiento en el devanado del estator de una máquina síncrona o de inducción, como generador o motor, lo ocasiona la combinación de una sobrecarga térmica, el movimiento de las bobinas y la contaminación en el devanado. La degradación y el envejecimiento del aislamiento del devanado eventualmente conducen a fallas de cortocircuito (c.c.) entre vueltas en las cuales circulan grandes corrientes de falla [37]. El aumento de la temperatura por tiempos prolongados afecta severamente el aislamiento de los devanados de la máquina y, por consiguiente, la reducción de su vida útil. Los GSIPs para aplicaciones en turbinas eólicas e hidráulicas de baja potencia son máquinas que pueden ser muy

compactas y que, generalmente, no utilizan sistemas de ventilación o enfriamiento, además de operar a velocidad variable. En condiciones normales de operación, la alta potencia de este tipo de máquinas puede provocar un aumento considerable de la temperatura en algunos componentes críticos, como los imanes y los devanados [47].

En la Figura 2.1 se muestra la presencia de una falla entre vueltas de la misma bobina. Se generan trayectorias paralelas a las vueltas de la bobina, lo que implica modificar los parámetros resistivos e inductivos de la fase donde se localiza la falla. Las dos corrientes, la corriente de la fase y la que circula en la falla, producen fuerzas magnetomotrices opuestas; por lo tanto, la falla tiene un efecto acumulativo en las vueltas cercanas a ella. Primero, cuando ocurre un cortocircuito, el devanado de la fase tiene menos vueltas y, por lo tanto, menos fuerza magnetomotriz. Segundo, la fuerza magnetomotriz de la corriente de falla es opuesta a la fuerza magnetomotriz del devanado de la fase [48].




Figura 2.1 Bobina con falla.

Las fallas en el estator típicamente pueden ser: en el devanado o las bobinas del estator y en las laminaciones del núcleo del estator. El mayor porcentaje de fallas en el devanado del estator se debe a las bobinas. Las laminaciones del núcleo del estator solo pueden dañarse por una reducción del entrehierro debido a un desbalance mecánico que afecte el espacio entre el rotor y el estator. Las fallas en el devanado del estator pueden clasificarse en: cortocircuito en las vueltas de una misma fase, cortocircuito entre dos fases (falla de fase a fase), cortocircuito entre bobinas de la misma fase (falla de bobina a bobina), circuito abierto y bobina aterrizada [41].

La condición de falla de vuelta a vuelta es el inicio de las demás fallas que se producen en el devanado. Sin embargo, una falla de vuelta a vuelta es difícil de reconocer debido a la naturaleza destructiva de las condiciones finales de la falla [49], [50]. Aunque no hay datos experimentales que indiquen cuánto tarda el aislamiento en fallar entre las vueltas de una bobina, es probable que el cambio no sea instantáneo. Por lo tanto, la detección temprana de una falla entre vueltas

durante la operación debería eliminar la posibilidad de un daño mayor entre las bobinas adyacentes del devanado de la máquina eléctrica [51].

La mayoría de las fallas se deben a varios esfuerzos durante el devanado del estator; en general, se clasifican en cuatro grupos: térmicos, eléctricos, mecánicos y ambientales. A menos que la temperatura sea demasiado elevada, el efecto del envejecimiento térmico es que el sistema de aislamiento se vuelve vulnerable a otros esfuerzos que contribuyen a la falla del devanado. Una vez que el sistema de aislamiento se ha dañado, no podrá resistir los esfuerzos dieléctricos, mecánicos y ambientales que puedan aplicarse [52].

El aumento de la temperatura durante períodos prolongados afecta severamente el aislamiento de los devanados de la máquina eléctrica y, por consiguiente, reduce su vida útil. Los GSIPs para aplicaciones en turbinas eólicas de baja potencia son máquinas que operan en un rango variable de velocidad, pueden ser muy compactas y, generalmente, no utilizan sistemas de ventilación o enfriamiento. En condiciones normales de operación, la elevada densidad de potencia de este tipo de máquinas puede provocar un aumento considerable de la temperatura en componentes críticos, como los imanes y los devanados [53].

Los enlaces de flujo de la máquina dependen de la distribución sinusoidal por fase en las ranuras "n", del número de polos "P", con una posición "φ" relativa al estator, y del número "N" de conductores [54].

$$n_a(\varphi) = N \sin\left(\frac{P\varphi}{2}\right) \quad (2.1)$$

$$n_b(\varphi) = N \sin\left(\frac{P\varphi}{2} - 120\right) \quad (2.2)$$

$$n_c(\varphi) = N \sin\left(\frac{P\varphi}{2} + 120\right) \quad (2.3)$$

A partir de la distribución de los devanados es posible obtener una función continua, la cual describe cuántas veces un devanado enlaza el flujo en una posición.

$$W^x(\varphi) = - \int_0^\varphi n(\varphi) d\varphi + \frac{1}{2} \int_0^{2\pi/P} n(\varphi) d\varphi \quad (2.4)$$

$$W_a(\varphi) = \frac{2N_s}{P} \cos\left(\frac{P\varphi}{2}\right) \quad (2.5)$$

$$W_b(\varphi) = \frac{2N_s}{P} \cos\left(\frac{P\varphi}{2} - 120\right) \quad (2.6)$$

$$W_c(\varphi) = \frac{2N_s}{P} \cos\left(\frac{P\varphi}{2} + 120\right) \quad (2.7)$$

Se obtienen las fuerzas magnetomotrices de la máquina debidas a los devanados del estator.

$$F_s(\varphi) = W_a i_a + W_b i_b + W_c i_c \quad (2.8)$$

Aplicando la ley de Ampere se tiene

$$F_g(\varphi) = \int_{rotor}^{estator} H r \varphi dl \quad (2.9)$$

Asumiendo una componente radial de intensidad de campo magnético se tiene que $F_g(\varphi) = H_g(\varphi)g(\varphi)$ donde $g(\varphi)$ es el entrehierro y $B = \mu H$

$$B_g(\varphi) = \mu \frac{F_g(\varphi)}{g(\varphi)} \quad (2.10)$$

El flujo magnético a través de una pequeña área incremental en el entrehierro

$$\phi(\varphi) = B(\varphi) l r d\varphi \quad (2.11)$$

Entonces la contribución del enlace de flujo de un devanado a través de su área incremental

$$W^x(\varphi) B(\varphi) l r d\varphi \quad (2.12)$$

Sumando todas las áreas incrementales en las direcciones x-y

$$\lambda_m^x = \int_0^{2\pi} W^x(\varphi) B(\varphi) l r d\varphi \quad (2.13)$$

$$\lambda_m^{xy} = \left[\mu r l \int_0^{2\pi} \frac{W^x(\varphi) B(\varphi) l r d\varphi}{g(\varphi)} \right] i_y \quad (2.14)$$

En general, los enlaces de flujo que se producen en un devanado de armadura dependen de la distribución de flujo magnético, su geometría y espacio del entrehierro de la máquina.

En las Figuras 2.2 y 2.3 se muestra gráficamente la distribución del devanado trifásico de un circuito del estator de cualquier máquina eléctrica rotatoria. En la Figura 2.2 se muestra la condición simétrica de los devanados de un circuito trifásico de bobinas, distribuidas espacialmente en la estructura de su núcleo. En la Figura 2.3 se muestra una disminución del número de vueltas en las bobinas de la fase b del devanado trifásico, por la presencia de una falla en esta fase.




Figura 2.2. Distribución del devanado del estator en condiciones simétricas.




Figura 2.3. Distribución del devanado del estator en condiciones de falla de c.c.

2.2 Modelo del GSIP considerando las fallas en el estator.

Los modelos de orden reducido son utilizados para representar la turbina eólica en la simulación dinámica de los sistemas eléctricos y también son útiles para analizar el impacto de los sistemas eólicos de potencia, en los cuales es necesario hacer algunas simplificaciones y tomar en cuenta ciertas consideraciones en la formación del modelo:

- Modelo del viento
- Modelo de la turbina eólica
- Modelo del GSIP

El modelo matemático del viento reproduce el comportamiento de la velocidad del viento como una secuencia de velocidad. Esta secuencia puede ser una colección de datos, pero muchas veces esta colección de datos no toma un rango completo de características típicas del viento tales como rango de velocidad e intensidad de turbulencia que la turbina eólica experimenta. Una aproximación típica del modelo del viento considera una escala de tiempo pequeña y una sola dirección horizontal que contempla cuatro componentes [53].

- Componente promedio de velocidad: v_g
- Componente rampa: v_{rp}
- Componente ráfaga: v_{rf}
- Componente de turbulencia: v_t

La ecuación que integra estas componentes está dada por

$$v = v_g + v_{rp} + v_{rf} + v_t \quad (2.15)$$

donde la componente ráfaga y la componente de turbulencia, generalmente son difíciles de estimar. En la Figura 2.4 se muestra el perfil del viento respecto al número de sus registros de una estación meteorológica.




Figura 2.4. Comportamiento de la rapidez del viento de una estación meteorológica.

Para el modelo de la turbina eólica se considera la potencia producida por la siguiente ecuación

$$P_t = 0.5\rho AC_p(\lambda, \beta)v^3 \quad (2.16)$$

donde $\lambda = \frac{\omega_m R}{v}$

ρ	densidad del aire
A	área de los alabes
C_p	coeficiente de potencia de la turbina
v	velocidad del viento
ω_m	velocidad mecánica del rotor
R	radio del rotor

La velocidad de la turbina depende de la velocidad del viento y el radio del rotor. Un cambio de la velocidad de la turbina depende de un cambio en la velocidad del viento y un cambio en el coeficiente C_p determina la potencia convertida en la turbina [55].

En diversas publicaciones se han utilizado modelos del GSIP, que se emplean para tareas de análisis, control o diagnóstico de fallas de la máquina. Los modelos asociados a técnicas de control generalmente emplean una representación en el marco d-q e incluyen el modelo de la turbina y los convertidores que la conectan con el sistema eléctrico de potencia [56].

Respecto a las publicaciones que han utilizado modelos del GSIP, consideran modelos en el marco *a-b-c*, con versiones extendidas o modificadas de su modelo para tratar de identificar fallas en devanados, en los imanes o fallas mecánicas [57].

Para el modelo del GSIP se considera una máquina trifásica de corriente alterna. Los devanados del estator de la máquina se asume una distribución sinusoidal del flujo por fase con P polos en el rotor.

Las fallas debido al cortocircuito en el estator en las máquinas de imanes permanentes representan un problema, debido a que esta falla puede producir mayor demanda del campo magnético y por lo tanto la desmagnetización permanente de los imanes y como consecuencia un daño mayor a la máquina. Sin embargo, la temprana detección de la falla en el devanado de armadura permite evitar la desmagnetización de los imanes.

El modelo dinámico del GSIP con fallas en el devanado de armadura, considera modificaciones en las inductancias tanto propias como mutuas tal como se muestra en el circuito de la Figura 2.5 [21].




Figura 2.5. Modelo de un GSIP con falla en el estator.

$$e_a = Ri_a + L_{aa} \frac{di_a}{dt} + L_{ab} \frac{di_b}{dt} + L_{ac} \frac{di_c}{dt} + L_{asc} \frac{di_{sc}}{dt} + v_a \quad (2.17)$$

$$v_a = R_{carga} i_a + L_{carga} \frac{di_a}{dt} \quad (2.18)$$

$$e_b = Ri_b + L_{ba} \frac{di_a}{dt} + L_{bb} \frac{di_b}{dt} + L_{bc} \frac{di_c}{dt} + L_{bsc} \frac{di_{sc}}{dt} + v_b \quad (2.19)$$

$$v_b = R_{carga} i_b + L_{carga} \frac{di_b}{dt} \quad (2.20)$$

$$e_c = Ri_c + L_{ca} \frac{di_a}{dt} + L_{cb} \frac{di_b}{dt} + L_{cc} \frac{di_c}{dt} + L_{csc} \frac{di_{sc}}{dt} + v_c \quad (2.21)$$

$$v_c = R_{carga} i_c + L_{carga} \frac{di_c}{dt} \quad (2.22)$$

$$e_{sc} = R_{sc} i_{sc} + L_{sca} \frac{di_a}{dt} + L_{scb} \frac{di_b}{dt} + L_{scc} \frac{di_c}{dt} + L_{scsc} \frac{di_{sc}}{dt} + 0 \quad (2.23)$$

La fuerza electromotriz es

$$e_a = \pi^2 (Dl) f \sum_{n=1}^{\infty} N_a B \cos[n(\omega t)] \quad (2.24)$$

$$e_b = \pi^2 (Dl) f \sum_{n=1}^{\infty} N_b B \cos \left[n \left(\omega t - \frac{2\pi}{3} \right) \right] \quad (2.25)$$

$$e_c = \pi^2(Dl)f \sum_{n=1}^{\infty} N_c B \cos \left[n(\omega t + \frac{2\pi}{3}) \right] \quad (2.26)$$

$$e_{sc} = \pi^2(Dl)f \sum_{n=1}^{\infty} N_{sc} B \cos[n(\omega t)] \quad (2.27)$$

donde

N_a es el número de vueltas de la fase a

N_b es el número de vueltas de la fase b

N_c es el número de vueltas de la fase c

N_{sc} es el número de vueltas de la fase en cortocircuito

R es la resistencia de fase en Ω

F es la frecuencia de operación Hz

D es el diámetro del estator en m

l es la longitud del apilamiento

B es la densidad de flujo en Wb/m²

El cálculo de las corrientes en el modelo del generador se describe en la expresión

$$\begin{bmatrix} \frac{di_a}{dt} \\ \frac{di_b}{dt} \\ \frac{di_c}{dt} \\ \frac{di_{sc}}{dt} \end{bmatrix} = \begin{bmatrix} L_{aa} & L_{ab} & L_{ac} & L_{asc} \\ L_{ba} & L_{bb} & L_{cb} & L_{bsc} \\ L_{ca} & L_{cb} & L_{cc} & L_{csc} \\ L_{sca} & L_{scb} & L_{scc} & L_{scsc} \end{bmatrix}^{-1} \begin{bmatrix} e_a \\ e_b \\ e_c \\ e_{sc} \end{bmatrix} - \begin{bmatrix} Ri_a \\ Ri_b \\ Ri_c \\ R_{sc}i_{sc} \end{bmatrix} - \begin{bmatrix} v_a \\ v_b \\ v_c \\ 0 \end{bmatrix} \quad (2.28)$$

El cálculo de las inductancias propias y mutuas de la matriz de inductancias emplea la teoría de la función de devanado de acuerdo con [21]

$$L_{aa} = L_{bb} = L_{cc} = \frac{\mu_0 r l \pi N^2}{8g} \quad (2.29)$$

donde

μ_0 es la permeabilidad del aire, $4\pi \times 10^{-7}$ H/m

r es el radio del rotor en m

l es la longitud del apilamiento en m

g es el entrehierro

N es el número total de vueltas de la fase

Las inductancias mutuas entre las fases del circuito de armadura están dadas por

$$L_{ab} = L_{ba} = \frac{\mu_0 r l \pi N^2}{24g} \quad (2.30)$$

$$L_{bc} = L_{cb} = \frac{\mu_0 r l \pi N^2}{24g} \quad (2.31)$$

$$L_{ac} = L_{ca} = \frac{\mu_0 r l \pi N^2}{24g} \quad (2.32)$$

Las inductancias propias que consideran la falla son

$$L_{aa} = \frac{\mu_0 r l \pi N^2}{80000g} (3x^2 - 200x + 10000) \quad (2.33)$$

$$L_{bb} = L_{cc} = \frac{\mu_0 r l \pi N^2}{8g} \quad (2.34)$$

Las inductancias propias en la falla son

$$L_{scsc} = \frac{\mu_0 r l \pi N^2}{80000g} (3x^2) \quad (2.35)$$

$$L_{ab} = L_{ba} = \frac{\mu_0 r l \pi N^2}{2400g} (100 - x) \quad (2.36)$$

$$L_{ac} = L_{ca} = \frac{\mu_0 r l \pi N^2}{2400g} (100 - x) \quad (2.37)$$

Las inductancias mutuas entre el cortocircuito y la bobina de la fase *a* por

$$L_{sca} = L_{asc} = \frac{\mu_0 r l \pi N^2}{80000g} (3x^2 - 100x) \quad (2.38)$$

Las inductancias mutuas entre el cortocircuito en otras fases con respecto a ellas mismas y con respecto a las vueltas en falla se describen como

$$L_{scb} = L_{bsc} = - \frac{\mu_0 r l \pi N^2}{2400g} x \quad (2.39)$$

$$L_{scc} = L_{csc} = -\frac{\mu_0 r l \pi N^2}{2400g} x \quad (2.40)$$

$$L_{bc} = L_{cb} = -\frac{\mu_0 r l \pi N^2}{24g} \quad (2.41)$$

En la Figura 2.6 se muestran los voltajes inducidos en el generador en condiciones simétricas. Al ser un sistema simétrico en los devanados del estator, la matriz es simétrica respecto a la diagonal principal y los términos de las inductancias propias y mutuas de la falla no existen, por lo que las formas del voltaje inducido son simétricas.




Figura 2.6. Voltajes simétricos del circuito del estator del GSIP.

Los valores de las inductancias propias y mutuas se obtienen a través de la función de devanado en donde se procesan datos de la estructura del estator para calcular estos valores. Esta técnica ha sido empleada tanto para máquinas de inducción como para máquinas síncronas de acuerdo a lo que se indica [58]-[59].

En las Figuras 2.7 y 2.8 se muestran los voltajes inducidos con una proporción de falla del 7 y 15 % de las vueltas en una de las fases del GSIP. Como se observa, la amplitud del voltaje inducido donde se presenta la falla se reduce a medida que el número de vueltas de la bobina con falla se incrementa. La matriz de inductancias propias y mutuas se modifica en valores y aparecen los valores de las inductancias acopladas por la falla. Estos valores son muy pequeños comparados con las inductancias del estator, debido a la proporción reducida de las vueltas que se ponen en cortocircuito y generan trayectorias alternas a la corriente de falla como se indica en la Figura 2.5.




Figura 2.7. Voltajes con una falla de vueltas en c.c. del 7% en una fase del GSIP.




Figura 2.8. Voltajes con una falla de c.c. del 15% en una fase del GSIP.

2.3 Pruebas en los GSIPs modificados del estator.

En esta sección se describen las pruebas de voltaje y corriente realizadas a dos generadores de imanes permanentes con derivaciones que buscan emular una falla de cortocircuito entre espiras de las fases del estator.

2.3.1 GSIP de 600 W con derivaciones en el estator

En la Tabla 2.1 se indican los valores nominales del GSIP de 600 W. Este generador fue modificado en las fases B y C de su estator con algunas derivaciones como se indica en el apéndice A; en la Tabla A1 se muestran las derivaciones en las fases del

estator. En la Tabla A2 se indica el porcentaje de vueltas en cada una de las fases modificadas.

Tabla 2.1 Valores nominales del GSIP de 600 W.

Potencia (W)	Voltaje (V)	Conexión	Velocidad (rpm)	Tipo
600	48	trifásica	750	imanes permanentes

En la Figura 2.9 se muestra el GSIP de 600 W con sus derivaciones, para las pruebas de voltaje y corriente se ajustó el acoplamiento entre el generador y el motor a través de las poleas y la banda, de tal forma que el giro entre las máquinas no produzca oscilaciones en las formas de onda que se adquieren en las sondas de voltaje y corriente en el osciloscopio. La velocidad del GSIP se modifica a través de un convertidor cd-cd que ajusta el nivel de voltaje en las terminales del motor.




Figura 2.9 Derivaciones del GSIP de 600 W.

En la Figura 2.10 se muestra el diagrama a bloques de los elementos que conformaron el circuito de pruebas para el GSIP de 600 W. Una vez modificado el circuito del estator con las derivaciones en las fases, se realizaron mediciones de voltaje, corriente y resistencias en las terminales del GSIP.

La carga resistiva se conectó en estrella con resistencias de potencia en cada una de las fases de 16.13Ω . Se adquirieron las señales de voltaje y corriente a través de un osciloscopio de cuatro canales, con tres sondas diferenciales de voltaje y una sonda de corriente. Con la tarjeta de control del convertidor cd-cd, se modifica la velocidad del motor de corriente directa que a su vez modifica la velocidad del GSIP. En la Figura 2.11 se muestran los voltajes fase a fase o de terminales con carga a una velocidad de 750 rpm; se observa un leve desequilibrio entre las amplitudes de los voltajes del GSIP.




Figura 2.10 Conexión de prueba en el GSIP de 600 W.




Figura 2.11. Señales de los voltajes de fase a fase del GSIP de 600 W.

En las Figuras 2.12 y 2.13 se realizaron mediciones en intervalos de velocidad de 100 rpm, para observar el comportamiento de los voltajes en las fases del GSIP. En las gráficas de las Figuras 2.12 y 2.13 existe un desplazamiento entre las mediciones del voltaje AB respecto a las otras mediciones de los voltajes BC y CA. Este desequilibrio es más significativo en los voltajes de vacío del GSIP.

En la Figura 2.14 se muestran las mediciones de las corrientes de línea, sin conexión entre neutros del GSIP y la carga; la conexión de la carga se realizó en estrella con valores por fase de 16.13Ω . Las mediciones de las corrientes se realizaron a diferentes pasos de velocidad hasta el valor de 800 rpm.




Figura 2.12 Voltajes de fase a fase en vacío del GSIP de 600 W.




Figura 2.13 Voltajes de fase a fase con carga del GSIP de 600 W.




Figura 2.14 Corrientes del GSIP de 600 W.

Durante la modificación de la estructura del devanado del GSIP, se accedió al punto común de las fases del estator como se indica en la Figura A1, por lo que en la Tabla 2.2 se muestran las mediciones de la resistencia de las fases del GSIP de 600 W. Estos valores de medición en frío presentan una variación entre sus lecturas de fase, al igual que las mediciones de la resistencia entre fase a fase.

Tabla 2.2 Valores de las resistencias del GSIP de 600 W.

Resistencia de fase (Ω)	Resistencias fase a fase (Ω)
$R_a = 8.6$	$R_{ab} = 16.5$
$R_b = 8.3$	$R_{bc} = 16.2$
$R_c = 8.3$	$R_{ca} = 16.4$

Una vez que se realizaron las pruebas de voltaje y corriente del GSIP de 600 W, se procedió a medir la resistencia en frío entre las terminales y entre fase y neutro del GSIP, incorporando las fallas por c.c. especificadas en la Tabla A1. En la Figura 2.15 se indican las mediciones de las resistencias por fase; se observa un desbalance en sus valores sin fallas, por lo que las gráficas no presentan un punto común en el origen del eje. Sin embargo, a medida que se presenta la falla por c.c., la resistencia de la fase se va decrementando, mientras las otras fases se mantienen.

En la Tabla A3 se indica la combinación de derivaciones para generar un número mayor de vueltas en c.c. de la fase C. En la Figura A10 se muestra la conexión entre las derivaciones de las diferentes secciones de la fase C. En la gráfica de la Figura 2.16, la medición de las resistencias entre terminales presenta un decremento de sus valores en presencia del c.c.




Figura 2.15 Derivaciones de la fase "c" vs. del neutro.




Figura 2.16 Derivaciones de la fase "c" vs. derivaciones de la fase "c".

2.3.2 GSIP de 400 W con derivaciones en el estator

Se probó experimentalmente un segundo GSIP de 400 W con valores nominales que se muestran en la Tabla 2.3. En esta tabla, se indican los datos nominales y de construcción del GSIP bajo prueba.

Tabla 2.3. Valores nominales del GSIP de 400 W.

Potencia (W)	Voltaje (V)	Conexión	Velocidad (rpm)	Tipo
400	12	trifásica	4000	imanes permanentes

En la Tabla 2.4 se muestran las mediciones en frío de las resistencias de fase y de terminales del GSIP de 400 W. Estas mediciones se encuentran más balanceadas que las mediciones realizadas al GSIP de 600 W. Lo anterior implica que sus voltajes y corrientes presenten menos distorsión.

Tabla 2.4. Valores de las resistencias del GSIP de 400 W.

Resistencia de fase (Ω)	Resistencias fase a fase (Ω)
$R_a = 1.0$	$R_{ab} = 1.8$
$R_b = 1.0$	$R_{bc} = 1.8$
$R_c = 1.0$	$R_{ca} = 1.8$

En la Figura 2.17 se indica el circuito de prueba para el GSIP de 400 W. Este circuito de prueba es similar al que se utilizó en el GSIP de 600 W, como se esquematiza en la Figura 2.10, para obtener señales de voltaje y corriente del GSIP.




Figura 2.17 Imagen de las derivaciones del GSIP de 400 W.

En la Figura 2.18 se muestran los voltajes de fase del GSIP a la velocidad de 400 rpm. Debido a que el GSIP fue modificado en la unión de las fases, se pudo acceder al neutro para realizar mediciones de fase. En la Figura 2.19 se muestran los voltajes de fase a fase del GSIP y una señal de corriente. Al igual que en el otro GSIP, presentan distorsiones en las formas de onda de voltaje y un cierto nivel de desbalance entre sus fases cuando la máquina interactúa electromagnéticamente.




Figura 2.18 Voltajes de fase del GSIP de 400 W.




Figura 2.19 Voltajes de fase a fase del GSIP de 400 W.

Para observar el comportamiento de los voltajes de vacío con respecto a la velocidad, se construyeron las curvas que aparecen en las Figuras 2.20 y 2.21. El GSIP de 400 W solo tiene acceso a tres de las terminales y no se dispone de un neutro. Por lo anterior, cuando se realizaron estas mediciones en valores de voltajes de fase a neutro, su desbalance entre las tres mediciones es significativo de acuerdo con lo que se muestra en la Figura 2.20. En las mediciones entre los voltajes de fase a fase en vacío, sus mediciones presentaron una mayor proximidad como se muestra en la Figura 2.21.




Figura 2.20 Voltajes de fase en vacío.




Figura 2.21 Voltajes de fase a fase en vacío.

Para probar el GSIP de 400 W se utilizaron dos cargas conectadas en estrella. La primera carga fue un grupo de resistencias de potencia de 16.13Ω y la segunda carga fue un grupo de tres resistencias conectadas en estrella con valor de 1.0Ω . En las Figuras 2.22 y 2.23 se presentan los voltajes por fase con las dos cargas, en ambas gráficas el desplazamiento entre las amplitudes de los voltajes a diferentes velocidades es menor que el desplazamiento que se presenta en el GSIP de 600 W, debido a la distribución balanceada de sus fases en el GSIP de 400 W.




Figura 2.22. Voltajes de fase a neutro con carga de 16.3Ω .




Figura 2.23. Voltajes de fase a neutro con carga de 1.0Ω .

En la Figura 2.24 se realizaron mediciones de voltajes fase a fase, incluyendo la presencia de una falla de 4 vueltas de la fase "a" conectada al neutro. Al existir el c.c. en parte de la fase, sus voltajes en las terminales se desplazan en dos de las tres mediciones de las gráficas de la Figura 2.24.

Al igual que en los voltajes, se probaron con las dos cargas especificadas las tres señales de corriente a diferentes intervalos de velocidad. En las Figuras 2.25(a) y 2.25(b) se indican las formas de onda de las corrientes del GSIP para las dos cargas.

En las Figuras 2.26 y 2.27 se muestra el aumento de la corriente conforme se incrementa la velocidad en el GSIP; las tres señales de corriente tienen amplitudes muy próximas, por lo que el nivel de desbalance es menor que en el GSIP de 600 W.




Figura 2.24 Voltajes de fase a fase con falla de 4 vueltas en c.c.




Figura 2.25 Corrientes del GSIP con dos cargas diferentes a 400 rpm.




Figura 2.26 Corrientes del GSIP con carga de 16.13 Ω .




Figura 2.27 Corrientes del GSIP con carga de 1.0 Ω .

Una vez que se realizaron las pruebas de voltaje y corriente del GSIP de 400 W, se procedió a realizar mediciones en frío de las resistencias entre terminales del GSIP de 400 W en las fases A y B. Cabe señalar que en el devanado del estator de este generador las derivaciones son de un menor número de vueltas de acuerdo con lo que se indica en la Tabla A11, su calibre es mayor y contiene menor cantidad de vueltas por fase que el GSIP de 600 W. Lo anterior permite elaborar experimentos en el GSIP de 400 W para diagnosticar fallas de c.c. más incipientes.

En la Figura 2.28 se muestran las gráficas de las derivaciones de la fase “a” vs. el neutro que aparecen en la Tabla A7; los valores de las dos resistencias de fase se mantienen y la tercera decrece conforme se incrementa el número de vueltas en c.c.




Figura 2.28 Derivaciones de la fase “a” vs. del neutro.

En la Figura 2.29 se muestran las gráficas entre derivaciones de la misma fase “a”. En este caso, como se indica en la Tabla A8, sólo se pueden realizar tres combinaciones, de ahí que la gráfica en la medición por fase presente un descenso y ascenso en relación con el número de vueltas involucradas en el c.c.

En la Figura 2.30 se presentan las gráficas de la fase “b” con sus derivaciones conectadas al neutro. A pesar de que el número de vueltas se reduce, la proporción del decremento en los valores de resistencia se mantiene como en la fase “a”. En los siguientes capítulos se analiza la integración de las transformadas ondeletas con algoritmos de aprendizaje automático, para la detección de fallas de c.c. entre vueltas del estator del GSIP por medio de las señales de las corrientes del GSIP.




Figura 2.29 Derivaciones de la fase "a" vs. derivaciones de la fase "a".




Figura 2.30 Derivaciones de la fase "b" vs. del neutro.

Capítulo 3

Transformadas ondeletas

3.1 Transformadas ondeletas aplicadas al diagnóstico de fallas en el GSIP

La detección temprana de fallas incipientes con mediciones mínimas es el principal requerimiento de un diagnóstico ideal. Las técnicas no invasivas son ampliamente utilizadas para monitorear diversas variables de las máquinas eléctricas. El análisis tiempo-escala es ampliamente usado para el diagnóstico de máquinas eléctricas. A través de la transformada ondeleta, se realiza el análisis de señales no estacionarias o transitorias, como las que pueden ocurrir en un generador síncrono de imanes permanentes con aplicación en turbinas eólicas con variación de sus parámetros eléctricos o mecánicos [60], [61].

La transformada ondeleta es función de la dilatación de la escala y de la traslación del tiempo. La función ondeleta es una onda que puede tener una forma irregular y una duración limitada en tiempo, en la cual se concentra la energía de la señal. De la señal en el dominio del tiempo se obtiene la señal en otra escala de tiempo para extraer información de la señal modificada. Existen diversas transformadas ondeletas, algunas son reales como la Meyer, Haar, Daubechies, Coiflet, Biortogonal, y otras complejas como la transformada de Morelet y Gabor [62]. En diversas áreas de la ciencia y la tecnología, algunas familias de ondeletas reales han tenido mejores resultados sobre las complejas para sus aplicaciones particulares [63].

La herramienta de análisis para señales con escalas de tiempo y frecuencias distintas es básicamente una transformación de la señal con funciones que cortan los datos con diferentes componentes de frecuencia para variar su resolución. A la familia de funciones matemáticas adecuadas para este fin se le conoce como transformada wavelet o transformada ondeleta y se obtiene a partir de una función base llamada ondeleta madre [35].

La función ondeleta es conocida como la ondeleta madre, dando origen a la familia de ondeletas que son trasladadas y dilatadas de la señal original. El método de la transformada ondeleta permite el análisis de señales no estacionarias; su forma continua está dada por la siguiente expresión [64].

$$W(u, s)_f = \int_{-\infty}^{\infty} f(t) \frac{1}{\sqrt{s}} \phi\left(\frac{t-u}{s}\right) dt \quad (3.1)$$

donde se define la s como la escala y la u como la traslación.

La descomposición tiempo-frecuencia que se ha empleado ampliamente para el diagnóstico de fallas en las máquinas eléctricas en condiciones de estado

permanente, no es recomendable cuando la señal a monitorear presenta una condición transitoria, velocidad o carga variable, en general en señales no estacionarias. Se prefiere describir las altas frecuencias sobre una duración de tiempo pequeña y las bajas frecuencias sobre una duración de tiempo grande. Este requerimiento dio paso a transformar una señal con escalas de tiempo y frecuencia distintas. [35].

La relación tiempo-escala es básicamente una transformación de una señal $y(t)$ con funciones que cortan los datos con diferentes componentes de frecuencia para variar la resolución. La transformada ondeleta se define como la convolución de la señal $y(t)$ con una familia de funciones y puede verse como la extensión de la transformada de Fourier de tiempo reducido.

3.2 Transformada ondeleta Haar

La función ondeleta es una onda que puede tener una forma irregular y una duración limitada en tiempo en la cual se concentra la energía de la señal. La Haar es el tipo más simple de ondeleta y sirve como punto de comparación para las otras ondeletas [65]. La transformada ondeta puede implementarse en tiempo discreto y se le denomina transformada ondeta discreta (TWD).

Una señal discreta es una función del tiempo con valores ocurriendo en instantes discretos

$$f = (f_1, f_2, f_3 \dots f_N) \quad (3.2)$$

estos valores son típicamente medidos de una señal analógica "g"

$$f_1 = g(t_1), f_2 = g(t_2) \dots f_N = g(t_N) \quad (3.3)$$

La transformada ondeleta Haar se descompone en dos subseñales discretas de la mitad de su longitud [65]:

- Una subseñal representa el promedio o la tendencia
- La otra señal representa la diferencia o fluctuación

la subseñal promedio se calcula de acuerdo con las siguientes ecuaciones

$$a_1 = \frac{f_1 + f_2}{\sqrt{2}} \quad a_2 = \frac{f_3 + f_4}{\sqrt{2}} \quad \dots \quad a_m = \frac{f_{2m-1} + f_{2m}}{\sqrt{2}} \quad (3.4)$$

la subseñal de fluctuación se calcula de acuerdo con las siguientes ecuaciones

$$d_1 = \frac{f_1 - f_2}{\sqrt{2}} \quad d_2 = \frac{f_3 - f_4}{\sqrt{2}} \quad \dots \quad d_m = \frac{f_{2m-1} - f_{2m}}{\sqrt{2}} \quad (3.5)$$

donde $m= 1, 2, 3, 4...N/2$

Las componentes quedan definidas como

$$a^1 = (a_1, a_2, a_3, \dots, a_{\frac{N}{2}}) \quad d^1 = (d_1, d_2, d_3, \dots, d_{\frac{N}{2}}) \quad (3.6)$$

con estas componentes se formula la transformada Haar de nivel 1

$$f_1 = (a^1, d^1) \quad (3.7)$$

La señal original se puede reconstruir a través de la transformada inversa mediante

$$f = \left(\frac{a_1 + d_1}{\sqrt{2}}, \quad \frac{a_1 - d_1}{\sqrt{2}}, \dots, \quad \frac{a_{\frac{N}{2}} + d_{\frac{N}{2}}}{\sqrt{2}}, \quad \frac{a_{\frac{N}{2}} - d_{\frac{N}{2}}}{\sqrt{2}} \right) \quad (3.8)$$

Las magnitudes de los valores de las fluctuaciones de las subseñales son más pequeñas que la magnitud del valor de la señal original.

La transformada Haar de niveles múltiples son:

primer nivel:	a^1, d^1
segundo nivel:	a^2, d^2
tercer nivel:	a^3, d^3
enésimo nivel:	a^n, d^n

La implementación de la transformada ondeleta discreta, se basa en las siguientes ecuaciones para los cuatro primeros niveles

$$a^1 = \frac{f[2m-1] + f[2m]}{\sqrt{2}} \quad d^1 = \frac{f[2m-1] - f[2m]}{\sqrt{2}} \quad (3.9)$$

$$a^2 = \frac{a^1[2m-1] + a^1[2m]}{\sqrt{2}} \quad d^2 = \frac{a^1[2m-1] - a^1[2m]}{\sqrt{2}} \quad (3.10)$$

$$a^3 = \frac{a^2[2m-1] + a^2[2m]}{\sqrt{2}} \quad d^3 = \frac{a^2[2m-1] - a^2[2m]}{\sqrt{2}} \quad (3.11)$$

$$a^4 = \frac{a^3[2m-1] + a^3[2m]}{\sqrt{2}} \quad d^4 = \frac{a^3[2m-1] - a^3[2m]}{\sqrt{2}} \quad (3.12)$$

para $m= 1, 2, 3, 4...N/2$, en donde N es la longitud de la secuencia discreta.

La forma general del promedio y la fluctuación en el término del enésimo término se define como

$$a^n = \frac{a^{n-1}[2n-1] + a^{n-1}[2n]}{\sqrt{2}} \quad d^n = \frac{d^{n-1}[2n-1] + d^{n-1}[2n]}{\sqrt{2}} \quad (3.13)$$

para $n = 1, 2, 3, 4 \dots N/2$

3.3 Transformada ondeleta Daubechies

La más simple de las transformadas ondeletas es la transformada discreta ondeleta Daubechies 4, denominada Daub4, que en esencia se define igual a la transformada Haar. Si la señal f tiene un número par de valores n entonces la transformada Daub4 en el nivel 1 esta mapeada como

$$f = (a^1 : d^1) \quad (3.14)$$

a^1 = señal de tendencia

d^1 = subseñal de fluctuación

cada valor a_m de la tendencia es igual al producto escalar

En la transformada ondelda discreta, se emplean los escalamientos V_N y las ondeletas W_N los cuales se definen a través de las siguientes expresiones

$$v_1^1 = (\alpha_1, \alpha_2, \alpha_3, \alpha_4, 0, 0, \dots, 0) \quad w_1^1 = (\beta_1, \beta_2, \beta_3, \beta_4, 0, 0, \dots, 0) \quad (3.15)$$

$$v_2^1 = (0, 0, \alpha_1, \alpha_2, \alpha_3, \alpha_4, 0, 0, \dots, 0) \quad w_2^1 = (0, 0, \beta_1, \beta_2, \beta_3, \beta_4, 0, 0, \dots, 0) \quad (3.16)$$

$$v_3^1 = (0, 0, 0, 0, \alpha_1, \alpha_2, \alpha_3, \alpha_4, 0, \dots, 0) \quad w_3^1 = (0, 0, 0, 0, \beta_1, \beta_2, \beta_3, \beta_4, 0, \dots, 0) \quad (3.17)$$

$$\vdots \quad \vdots$$

$$v_{\frac{N}{2}-1}^1 = (0, 0, \dots, \alpha_1, \alpha_2, \alpha_3, \alpha_4) \quad w_{\frac{N}{2}-1}^1 = (\beta_1, \beta_2, \beta_3, \beta_4, 0, 0, \dots, 0) \quad (3.18)$$

$$v_{\frac{N}{2}}^1 = (\alpha_3, \alpha_4, 0, 0, \dots, 0, \alpha_1, \alpha_2) \quad w_{\frac{N}{2}}^1 = (\beta_3, \beta_4, 0, 0, \dots, 0, \beta_1, \beta_2) \quad (3.19)$$

Los coeficientes de escalamiento se definen a través de las ecuaciones

$$\alpha_1 = \frac{1 + \sqrt{3}}{4\sqrt{2}} \quad (3.20)$$

$$\alpha_2 = \frac{3 + \sqrt{3}}{4\sqrt{2}} \quad (3.21)$$

$$\alpha_3 = \frac{3 - \sqrt{3}}{4\sqrt{2}} \quad (3.22)$$

$$\alpha_4 = \frac{1 - \sqrt{3}}{4\sqrt{2}} \quad (3.23)$$

Los coeficientes de cada ondeleta se definen a través de las siguientes expresiones

$$\beta_1 = \frac{1 - \sqrt{3}}{4\sqrt{2}} \quad (3.24)$$

$$\beta_2 = \frac{\sqrt{3} - 3}{4\sqrt{2}} \quad (3.25)$$

$$\beta_3 = \frac{3 + \sqrt{3}}{4\sqrt{2}} \quad (3.26)$$

$$\beta_4 = \frac{-1 - \sqrt{3}}{4\sqrt{2}} \quad (3.27)$$

Para la implementación de la transformada ondeleta discreta Daub 4, se definen las siguientes expresiones

$$\begin{aligned} a^1 &= \alpha_1 f[m] + \alpha_2 f[m-1] + \alpha_3 f[m-2] + \alpha_4 f[m-3] \\ d^1 &= \beta_1 f[m] + \beta_2 f[m-1] + \beta_3 f[m-2] + \beta_4 f[m-3] \end{aligned} \quad (3.28)$$

$$\begin{aligned} a^2 &= \alpha_1 a^1[m] + \alpha_2 a^1[m-1] + \alpha_3 a^1[m-2] + \alpha_4 a^1[m-3] \\ d^2 &= \beta_1 d^1[m] + \beta_2 d^1[m-1] + \beta_3 d^1[m-2] + \beta_4 d^1[m-3] \end{aligned} \quad (3.29)$$

$$\begin{aligned} a^3 &= \alpha_1 a^2[m] + \alpha_2 a^2[m-1] + \alpha_3 a^2[m-2] + \alpha_4 a^2[m-3] \\ d^3 &= \beta_1 d^2[m] + \beta_2 d^2[m-1] + \beta_3 d^2[m-2] + \beta_4 d^2[m-3] \end{aligned} \quad (3.30)$$

$$\begin{aligned} a^4 &= \alpha_1 a^3[m] + \alpha_2 a^3[m-1] + \alpha_3 a^3[m-2] + \alpha_4 a^3[m-3] \\ d^4 &= \beta_1 d^3[m] + \beta_2 d^3[m-1] + \beta_3 d^3[m-2] + \beta_4 d^3[m-3] \end{aligned} \quad (3.31)$$

$$\begin{aligned} a^n &= \alpha_1 a^{n-1}[m] + \alpha_2 a^{n-1}[m-1] + \alpha_3 a^{n-1}[m-2] + \alpha_4 a^{n-1}[m-3] \\ d^n &= \beta_1 d^{n-1}[m] + \beta_2 d^{n-1}[m-1] + \beta_3 d^{n-1}[m-2] + \beta_4 d^{n-1}[m-3] \end{aligned} \quad (3.32)$$

La energía almacenada en las componentes a^n y d^n de la transformada ondeleta, considera las bandas de frecuencia de los diferentes niveles en que se descompone la señal. Para lo cual se tiene la ecuación [63]

$$E_j = \sum_{k=1}^n |D_{jk}(n)|^2 \quad (3.33)$$

de tal forma que j es el nivel de la descomposición, y d_k es la magnitud de la subseñal fluctuación o detalle.

También se puede obtener el valor eficaz de los coeficientes a^n y d^n de la transformada wavelet, para los diferentes niveles en que se descompone la señal. La ecuación que define el valor eficaz ó rms es [65]

$$A_{rmsj} = \sqrt{\frac{1}{N} \sum_{k=1}^n |A_{jk}(n)|^2} \quad (3.34)$$

donde j es el nivel de la descomposición, N el número de muestras de la señal y A_k la magnitud de las componentes de la subseñal promedio o tendencia.

Para el monitoreo y diagnóstico de fallas en máquinas eléctricas se considera el uso de índices de diagnóstico, a través del procesamiento de las variables que se monitorean en la máquina. Cuando se emplean las transformadas ondeletas, se reporta el uso de un índice de diagnóstico basado en la relación entre la energía de las fluctuaciones a los diferentes niveles considerando la falla y la energía de las fluctuaciones a los diferentes niveles sin falla. La siguiente ecuación describe el índice de falla [64]

$$\alpha = \log_{10} \left(\frac{E_F}{E_H} \right) \quad (3.35)$$

La energía del índice de diagnóstico se expresa normalizada.

Para el cálculo de las transformadas ondeletas se requiere que las señales trifásicas se integren en una sola señal para ser procesada en los diferentes niveles. Debido a lo anterior se realizó la integración de las señales trifásicas a través del módulo del vector de Park como se indica en las siguientes expresiones [66]

$$f_d = \sqrt{\frac{2}{3}} f_a - \frac{1}{\sqrt{6}} f_b - \frac{1}{\sqrt{6}} f_c \quad (3.36)$$

$$f_q = \frac{1}{\sqrt{2}} f_b - \frac{1}{\sqrt{2}} f_c \quad (3.37)$$

$$|f| = |f_d + jf_q| = \sqrt{f_d^2 + f_q^2} \quad (3.38)$$

También se obtuvo el módulo de las tres señales trifásicas a través de la expresión

$$|f| = \sqrt{f_a^2 + f_b^2 + f_c^2} \quad (3.39)$$

3.4 Análisis multiresolución

Existen algunos algoritmos para modificar la resolución de la señal "f(n)", que se denomina análisis multiresolución. La teoría permite mostrar que la convolución con los varios niveles de las ondeletas es equivalente a filtrar la señal "f(n)" con familias de funciones de transferencia correspondientes a varias escalas de frecuencia, como la mostrada en la Figura 3.1. La descomposición se hace de forma recursiva con una serie de filtros pasa-bajos "h" y pasa-altos "g" como se indica en la Figura 3.1. El bloque $\downarrow 2$, indica tomar una muestra cada dos periodos de muestreo.




Figura 3.1. Descomposición de la función f(n) con un banco de filtros.

Al filtrar la señal de manera recursiva cada nivel o etapa de filtraje, se genera el coeficiente de aproximación o tendencia a^j de baja frecuencia y el detalle d^j de alta frecuencia, en una descomposición diádica entre los coeficientes de aproximación y los de detalle. En general, los detalles representan los coeficientes de las ondeletas a una cierta escala y al analizarlos se tiene una idea de la energía de la señal en una banda definida de frecuencias.

El algoritmo de Mallat [60] muestra que cada señal de la ondeleta está asociada con cierta banda de frecuencia. Si f_s es la frecuencia de muestreo para capturar la señal $f(n)$, entonces los detalles d^j contienen información de la subseñal con frecuencias que incluyen el intervalo

$$[(2^{-(j+1)} * f_s), (2^{-j} * f_s)] \text{ Hz} \quad (3.40)$$

Las aproximaciones contienen información de la subseñal en el intervalo de

$$[0, (2^{-(j+1)} * f_s)] \text{ Hz} \quad (3.41)$$

donde j es el nivel de la ondeleta

La descomposición del número de niveles de la ondeleta a las diferentes bandas de frecuencia se define por la siguiente expresión [63]

$$n = \left\lceil \frac{\log \left(\frac{f_s}{f_{señal}} \right)}{\log (2)} \right\rceil \quad (3.42)$$

donde

f_s es la frecuencia a la cual se muestrea la señal

$f_{señal}$ es la frecuencia de la señal original

n debe ser un número entero

3.5 Análisis de las transformadas ondeletas Haar y Daubechies 4 aplicado al diagnóstico de fallas.

En esta sección se desarrolla una serie de simulaciones para analizar el comportamiento de las transformadas ondeletas Haar y Daubechies 4, como una de las herramientas de diagnóstico para la detección de fallas eléctricas en el devanado del estator del GSIP.

Como primera etapa se usó la teoría básica de las transformadas ondeletas, su tratamiento y descomposición usando una señal monofásica no senoidal. En la siguiente etapa se buscó emular las formas sinusoidales trifásicas que produce el GSIP considerando el desbalance en las amplitudes por la presencia del cortocircuito en el estator y asociarlo con el procesamiento de la energía y valor eficaz de las subseñales de las tendencias y las fluctuaciones.

Dentro de las señales artificiales empleadas para comprobar el cambio de las subseñales con los coeficientes de tendencia y aproximación de las dos transformadas ondeletas, se emplea una señal sinusoidal distorsionada con amplitud unitaria en dos ciclos, como se indica en la Figura 3.2.






Figura 3.2. Señal sinusoidal distorsionada.




(a) Haar nivel 1




(b) Daubechies 4 nivel 1

Figura 3.3. Coeficientes de las tendencias del nivel 1 de la señal de prueba.




(a) Haar nivel 2




(b) Daubechies 4 nivel 2


Figura 3.4. Coeficientes de las tendencias del nivel 2 de la señal de prueba.




(a) Haar nivel 3.



(b) Daubechies 4 nivel 3.

Figura 3.5. Coeficientes de las tendencias del nivel 3 de la señal de prueba.

(a) Haar nivel 4.



(b) Daubechies 4 nivel 4.

Figura 3.6. Coeficientes de las tendencias del nivel 4 de la señal de prueba.

En las Figuras 3.3 a 3.6 se realizó la simulación de los diferentes niveles de descomposición de las transformadas ondeltas para visualizar la compresión de la señal en las diferentes bandas de frecuencia. Adicionalmente se analizó el comportamiento del valor eficaz en las componentes de las tendencias de las dos transformadas, y se verificó el cambio que experimentan entre un nivel y otro, así como gráficamente la modificación de las fluctuaciones con el cambio del nivel. En la Tabla 3.1 se indican los cálculos del valor eficaz de los coeficientes de las tendencias de acuerdo con el análisis multiresolución de ambas transformadas. Como la señal se comprime en cada banda de frecuencia, es susceptible de que el valor eficaz se modifique.

Tabla 3.1. Valor eficaz de los coeficientes de tendencia.

Haar	RMS	Daubechies	RMS
Nivel 1	1.0610	Nivel 1	1.0685
Nivel 2	1.4894	Nivel 2	1.5136
Nivel 3	2.0669	Nivel 3	2.1244
Nivel 4	2.6821	Nivel 4	2.8738

En la Tabla 3.1 se puede verificar que no existe diferencia significativa entre los valores eficaces de ambas transformadas.

En la siguiente etapa, se utilizaron señales trifásicas senoidales y no senoidales con amplitudes unitarias. El propósito fue una aproximación a las formas de onda de voltaje y corriente que se obtienen en el GSIP bajo prueba. En la Tabla 3.2 se indican los valores a través de los cuales se diseñaron en Matlab las señales trifásicas en un ciclo, tanto para las formas senoidales como no senoidales.

Tabla 3.2. Valores de las señales sinusoidales simuladas.

Amplitudes (p.u.)	F_{señal} (Hz)	F_{muestreo} (Hz)	N (muestras)	Armónico 5th (p.u.)
1.0	60	9600	160	0.1

Las formas de onda de las señales trifásicas se muestran en las Figuras 3.7 y 3.8. Las formas no senoidales contienen un quinto armónico con una amplitud del 10 % de la amplitud de la fundamental, con el propósito de que no se produzca una modificación muy significativa en las señales de prueba de la simulación. De esta forma se pueda comparar el efecto de esta distorsión al momento de ser procesadas por las transformadas ondeletas en su energía y valor eficaz contra la señal senoidal sin distorsión.




Figura 3.7. Señales trifásicas sinusoidales.




Figura 3.8. Señales trifásicas no sinusoidales.

La ecuación (3.38) se emplea para transformar las señales trifásicas mediante el módulo del vector de Park. En la Figura 3.9 se muestran las señales trifásicas no sinusoidales mapeadas en el módulo del vector de Park y se comparan con la señal obtenida en la Figura 3.10 mediante la ecuación (3.39), que emplea el módulo del cuadrado de las tres señales trifásicas. Los resultados de ambas transformaciones son iguales como se indican en las Figuras 3.9 y 3.10.




Figura 3.9. Módulo del vector instantáneo de Park de las funciones trifásicas.




Figura 3.10. Módulo del cuadrado de las funciones trifásicas.

Para realizar las pruebas de simulación con las señales trifásicas senoidales y senoidales distorsionadas, se seleccionaron tres escenarios de desbalance en las amplitudes de las funciones. Las modificaciones de estas amplitudes buscan relacionarse con las fallas más incipientes en las formas de onda de la corriente del generador bajo prueba. En la Tabla 3.3 se indican las combinaciones de los desbalances. Las modificaciones de las amplitudes se asociaron con el número 0 sin desbalance, 1 y 2 con la amplitud de una fase modificada y 3 con dos amplitudes de las fases modificadas.

Tabla 3.3. Desbalance de las magnitudes pico unitarias de las señales trifásicas.

Modificación de las amplitudes	Magnitud pico de la fase_a (p.u.)	Magnitud pico de la fase_b (p.u.)	Magnitud pico de la fase_c (p.u.)
0	1	1	1
1	1	1	1.05
2	0.9	1	1
3	0.9	1	1.05

Una vez definidas las formas de onda de las Figuras 3.7 y 3.8 con los diferentes desbalances, se procedió a obtener la transformada Haar por medio de la expresión (3.13) y la transformada Daubechies 4 por medio de las ecuaciones (3.32) para las tendencias y fluctuaciones considerando las constantes de esta transformada por medio de las ecuaciones (3.20) a la (3.27). Se tomó como referencia el proceso desarrollado en [60], para el análisis multiresolución de ambas transformadas ondeletas. Los niveles de ambas transformadas se obtuvieron considerando los datos que se indican en la ecuación (3.42).

En la transformada ondeleta, se subdividen las componentes de frecuencia de la señal procesada en cada uno de los niveles de descomposición, utilizando el algoritmo de Mallat, lo que muestra que cada señal de la ondeleta está asociada a

una banda de frecuencia. Partiendo de las funciones de prueba con una frecuencia de muestreo de 9.6 kHz, para cumplir el criterio de Nyquist, la frecuencia de la señal es de 4.8 kHz.

En la primera etapa se descompone la señal en dos partes, semejantes a un filtro pasa bajas y uno pasa altas, obteniéndose dos versiones diferentes de la señal original: una parte corresponde a la señal de tendencia o detalle, con un rango de frecuencias de 0 a 2.4 kHz, y otra a la señal de fluctuación o aproximación, con un rango de frecuencias de 2.4 a 4.8 kHz.

Posteriormente, se repite el proceso para la transformación tomando la componente de tendencia del nivel 1, de la cual se derivan los términos de tendencia y fluctuación del nivel 2, cada parte de los intervalos de frecuencia es de 0 a 1.2 kHz y de 1.2 a 2.4 kHz. El proceso se repite para el resto de los niveles como se muestra en la Figura 3.11.




Figura 3.11. Bandas de frecuencia de los coeficientes de la ondeleta Haar y Daubechies 4.

El valor eficaz de los coeficientes de tendencia se calculó empleando la expresión (3.34) en cada uno de los niveles de ambas transformadas. La diferencia del valor eficaz entre las condiciones sin y con modificación de amplitud (de acuerdo con la Tabla 3.3) se indica en las Tablas 3.4 y 3.5 para la transformada Haar y las Tablas 3.6 y 3.7 para la transformada Daubechies 4.

La diferencia de la amplitud de los coeficientes se ha empleado como método de diagnóstico en algunos trabajos [67]. Sin embargo, esta diferencia está condicionada a la operación en estado estacionario de la máquina. Se requiere identificar la banda de frecuencia de la transformada asociada con la modulación de las bandas laterales del espectro en frecuencia de la señal monitoreada.

Tabla 3.4. Valores rms de las tendencias de la transformada Haar de las senoidales.

Nivel	<i>Fase c con valor pico de 1.05 (p.u.)</i>	<i>Fase a con valor pico de 0.9 (p.u.)</i>	<i>Fase a con valor pico de 0.9 y Fase c con valor pico de 1.05 (p.u.)</i>
1	-0.0586	0.0568	0.0272
2	-0.0830	0.0803	0.0384
3	-0.1173	0.1135	0.0544
4	-0.1647	0.1607	0.0771
5	-0.2357	0.2386	0.1200
6	-0.2410	0.3047	0.1835

Tabla 3.5. Valores rms de las tendencias de la transformada Haar senoidales distorsionadas.

Nivel	<i>Fase c con valor pico de 1.05 (p.u.)</i>	<i>Fase a con valor pico de 0.9 (p.u.)</i>	<i>Fase a con valor pico de 0.9 y Fase c con valor pico de 1.05 (p.u.)</i>
1	-0.0290	0.0564	0.0270
2	-0.0410	0.0799	0.0382
3	-0.0580	0.1130	0.0541
4	-0.0820	0.1604	0.0772
5	-0.1167	0.2379	0.1196
6	-0.1191	0.3039	0.1836

Tabla 3.6. Valores rms de las tendencias de la transformada Daub 4 de las senoidales.



Nivel	<i>Fase c con valor pico de 1.05 (p.u.)</i>	<i>Fase a con valor pico de 0.9 (p.u.)</i>	<i>Fase a con valor pico de 0.9 y Fase c con valor pico de 1.05 (p.u.)</i>
1	-0.0288	0.0580	0.0280
2	-0.0410	0.0820	0.0410
3	-0.0560	0.1190	0.0620
4	-0.0750	0.1770	0.1000
5	-0.0930	0.2630	0.1690
6	-0.1423	0.2830	0.1400

Se utilizó la ecuación (3.33) para el cálculo de la energía de las fluctuaciones en cada nivel de descomposición en ambas transformadas. Posteriormente se empleó la ecuación (3.35) para la normalización de la energía de los coeficientes de detalle en condiciones con modificación y sin modificación de la amplitud. A partir de esta información se construyeron las Figuras 3.12 y 3.13 para la transformada Haar y las Figuras 3.14 y 3.15 para la transformada Daubechies 4.

Tabla 3.7. Valores rms de las tendencias de la transformada Daub 4 de las senoidales distorsionadas.

Nivel	<i>Fase c con valor pico de 1.05 (p.u.)</i>	<i>Fase a con valor pico de 0.9 (p.u.)</i>	<i>Fase a con valor pico de 0.9 y Fase c con valor pico de 1.05 (p.u.)</i>
1	-0.0290	0.0570	-0.2790
2	-0.0400	0.0820	-0.3920
3	-0.0560	0.1190	-0.5430
4	-0.0750	0.1770	-0.7240
5	-0.0930	0.2680	-0.8780
6	-0.1420	0.2780	-1.2900

En este análisis se buscó tener una comparativa del índice de falla entre las dos formas de señales sinusoidales y las dos transformadas ondeletas. Este índice de falla ha sido empleado para el diagnóstico de fallas del motor de inducción bajo condiciones de estado permanente y dinámico [64].

**Figura 3.12.** Índice de falla de la ondeleta Haar con señales sinusoidales.**Figura 3.13.** Índice de falla de la ondeleta Haar con señales no sinusoidales.

En las Figuras 3.14 y 3.15 de las señales senoidales de ambas transformadas, se puede observar un cambio en la energía normalizada del índice de falla entre el caso sin modificación de la amplitud y con un incremento en 0.5 de la amplitud de la fase C. Lo anterior sugiere una sensibilidad de este parámetro para la posible detección de una falla incipiente en las formas de onda de corriente del generador bajo prueba.

En las Figuras 3.16 y 3.17 el cambio en el índice de falla es menor entre la condición sin modificación y la condición modificada, debido al efecto de la distorsión de las señales trifásicas que incluye el quinto armónico. Sin embargo, la evolución del índice de falla con la aplicación de ambas transformadas sugiere la posibilidad de indicar la existencia de una falla en el generador bajo prueba.




Figura 3.14. Índice de falla de la ondeleta Daub 4 con señales sinusoidales.




Figura 3.15. Índice de falla de la ondeleta Daub 4 con señales no sinusoidales.




Figura 3.16. Energía de los coeficientes de las aproximaciones Haar a diferentes frecuencias y amplitudes.




Figura 3.17. Energía de los coeficientes de las aproximaciones Daubechies 4 a diferentes frecuencias y amplitudes.

Como última etapa de los estudios de simulación se presentan los resultados que se muestran en las gráficas de las Figuras 3.18 y 3.19, para ambas transformadas. En las gráficas se incluye la energía de los coeficientes de aproximaciones a diferentes frecuencias contra los cambios en el valor pico de las señales trifásicas. Se buscó observar el comportamiento de la energía de estos coeficientes en los diferentes intervalos de frecuencia de 30 Hz a 120 Hz de las señales trifásicas.

En las Figuras 3.18 y 3.19 de la transformada Haar y la transformada Daubichies 4, las gráficas de las frecuencias de 120 a 60 Hz no presentan una variación significativa, se separa la gráfica en 30 Hz. En cambio, con la transformada Daubichies 4 la secuencia de cambio de la energía es más significativa con la distorsión de la señal y con la modificación de las amplitudes de las señales trifásicas. Este comportamiento habría que validarlo con señales reales del generador bajo prueba. El cálculo de la energía de los coeficientes de las aproximaciones y el índice de falla

representan una opción de diagnóstico de fallas para el generador síncrono de imanes permanentes bajo prueba.




Figura 3.18. Energía de los coeficientes de las aproximaciones Haar a diferentes frecuencias y amplitudes.




Figura 3.19. Energía de los coeficientes de las aproximaciones Daubechies 4 a diferentes frecuencias y amplitudes.

Capítulo 4

Métodos de aprendizaje automático

4.1 Métodos de aprendizaje automático aplicados al diagnóstico de fallas del GSIP operando en turbina eólica.

Los métodos de aprendizaje automático han sido ampliamente usados en el diagnóstico de fallas mecánicas, eléctricas y la combinación de las fallas anteriores en los diferentes tipos de máquinas eléctricas. El aprendizaje automático puede clasificar y localizar las fallas presentes en los componentes de la máquina eléctrica en tiempo real. El grado de complejidad de los algoritmos de aprendizaje es determinado por el nivel de asertividad en el diagnóstico de la máquina eléctrica [6].

El aprendizaje automático forma parte de los sistemas de reconocimiento de patrones; típicamente, se conforman en tres partes: el sensor o transductor, el extractor de características y el clasificador. El transductor mide las entradas de las señales a monitorear y las convierte en datos para que sean procesados. El extractor de características obtiene información relevante de los datos de entrada. El clasificador usa la información para asignar a los datos de entrada a un número finito de categorías y se pueda diagnosticar la falla en la máquina [13].

En el monitoreo de máquinas eléctricas se han implementado sistemas de reconocimiento de patrones y el diseño de clasificadores para el diagnóstico de diversas fallas a través del aprendizaje automático. Estos métodos hacen uso de plantillas o patrones para distinguir la operación aceptable o inaceptable de la máquina y determinar la existencia de alguna falla. Las plantillas pueden ser determinadas por especificaciones en el desempeño de la máquina, por observaciones basadas en la operación con falla, por conocimiento experto o por cualquier análisis o simulación de un modelo del sistema. Una vez entrenado el sistema, es posible que reconozca y clasifique las fallas en la máquina. Sin embargo, una de las desventajas que presenta el reconocimiento de patrones es la dependencia de una gran cantidad de datos para el proceso de entrenamiento y diagnóstico de la falla [5].

En [68] se utilizan las herramientas del módulo del vector de Park y los árboles de decisión para clasificar fallas mixtas de barras rotas y excentricidad en el entrehierro de un motor de inducción. En [69] se emplea análisis termográfico y los árboles de decisión para clasificar las fallas en rodamientos en un motor de inducción. En [44] se presenta una base de datos con mediciones de vibración mecánica para la

detección de fallas en rodamientos. En el extractor de características, los datos se procesan mediante el aprendizaje basado en transferencia de información y, como clasificador, se emplea el uso de bosques aleatorios. El modelo propuesto se adapta a diferentes condiciones de operación de un motor de inducción. En [45] se emplea el control estadístico de proceso y varios algoritmos de aprendizaje automático para el diagnóstico de fallas en turbinas eólicas, a través de mediciones de varios sensores recopiladas durante tres años en 31 turbinas eólicas localizadas en Taiwán.

En [70] se emplea la transformación de Park de las señales de corriente y se realiza la extracción de la amplitud del segundo armónico de corriente por medio del algoritmo de la transformada de Fourier que se compara con un método de extracción armónica basado en la red neuronal Adaline, para detectar la degradación del aislamiento en el devanado del estator de una máquina síncrona de imanes permanentes. En [39] se describe la detección de las fallas entre vueltas del devanado del estator de un motor síncrono de imanes permanentes a través del análisis biespectral, para la clasificación de las fallas se empleó una red neuronal convolucional. En [71] se obtienen las características de las señales de corriente y flujo por medio de la transformada ondeleta discreta. Se emplean seis clasificadores con sus respectivos subgrupos como parte de la técnica de aprendizaje automático para valorar la exactitud de las variables de flujo y corriente que diagnostican la falla en un motor de inducción trifásico. En [72], se diagnostican fallas en rodamientos externos a través de la señal de corriente de un motor síncrono utilizando una red neuronal convolucional y el proceso de fusión de la información. En [73] se diagnostican fallas en rodamientos en un generador síncrono de imanes permanentes en régimen de velocidad variable, a través de señales de vibración y corrientes. Por medio del procesamiento de las señales en dos etapas se extraen las características que son clasificadas con una red neuronal de retropropagación. En [27] se presenta la detección de la excentricidad de un motor síncrono de imanes permanentes internos. A través de la medición del flujo magnético disperso radial abierto del motor se diagnostica la excentricidad estática, dinámica y combinada. Por medio de una red neuronal de retropropagación se clasifican los diferentes tipos de excentricidad. En [40] se analiza un motor de inducción con desalineación en su carga, por medio de las frecuencias características de las señales de corriente, vibraciones mecánicas y flujo, se detecta la falla. Como algoritmo clasificador se emplea un perceptrón multicapa.

Uno de los puntos importantes en la clasificación es la existencia de características representativas para casos sanos y casos con fallos, las cuales son extraídas mediante la adquisición de información experimental. Esta información permite generar modelos de clasificación que representan las condiciones para clasificar o aislar las fallas en las máquinas eléctricas. Típicamente se extraen las características de señales de voltaje, corriente, flujo, velocidad, entre otras, para ser procesadas en el extractor

y posteriormente clasificadas en el algoritmo de aprendizaje supervisado. El nivel de complejidad en la tarea de extracción o clasificación depende del propósito que se busque realizar en el monitoreo y diagnóstico [74].

Los métodos de clasificación se agrupan en función de la forma en que se manipulan los patrones para obtener las condiciones de separabilidad en [8]:

- Cajas negras, las cuales consideran un conocimiento implícito de las características, tal es el caso cuando se usa como clasificador un modelo de redes neuronales artificiales.
- Cajas blancas, las cuales suponen un conocimiento explícito de las características, como es el caso de un sistema experto basado en reglas probabilísticas o árboles de decisión.

Los algoritmos de clasificación binaria que se han empleado en el diagnóstico de fallas del GSIP son:

- Perceptrón
- Regresión logística
- Perceptrón multicapa
- Árboles de decisiones
- Bosques Aleatorios

4.2 El perceptrón y la regresión logística

El perceptrón es un clasificador binario que forma parte del aprendizaje automático del tipo supervisado. Es la unidad base de las redes neuronales; se forma por una sola neurona con pesos y un umbral ajustable. Se puede definir una función de decisión $\phi(z)$ que toma una combinación lineal de las entradas "x" y sus correspondientes pesos "w", donde "z" es denominada la función de entrada

$$z = w_1x_1 + w_2x_2 + w_3x_3 + w_4x_4 + \cdots w_nx_n \quad (4.1)$$

Simplificando la función z, se tiene la siguiente expresión

$$z = \sum_{j=0}^m x_j w_j = w^T x \quad (4.2)$$

Si la entrada es mayor que el umbral θ se predice una clase o etiqueta 1 y si es menor que el umbral se predice una clase o etiqueta -1.

$$\phi(z) = \begin{cases} 1 & \text{si } z \geq \theta \\ -1 & \text{si } z < \theta \end{cases} \quad (4.3)$$

En el aprendizaje automático, el umbral negativo o peso suele denominarse unidad de sesgo.

El proceso de aprendizaje del perceptrón involucra los siguientes pasos:

- inicializar los pesos en cero o en valores aleatorios
- para cada etapa de entrenamiento , evaluar el valor de la salida y actualizar los pesos de acuerdo con la ecuación $w_j = w_j + \Delta w_j$
- el valor de actualización de los pesos es $\Delta w_j = \beta[y(i) - y'(i)]x(i)_j$
donde β es el intervalo de aprendizaje
 $y(i)$ es el valor n-ésimo de entrenamiento
 $y'(i)$ es el valor n-ésimo de predicción

Los pesos se actualizan simultáneamente, lo que implica que los valores de la predicción no se recalculan antes de la predicción. Un conjunto de datos puede ser actualizado de acuerdo con la siguiente secuencia [74]

$$\Delta w_0 = \beta[y(i) - y'(i)] \quad (4.4)$$

$$\Delta w_1 = \beta[y(i) - y'(i)]x(i)_1 \quad (4.5)$$

$$\Delta w_2 = \beta[y(i) - y'(i)]x(i)_2 \quad (4.6)$$

$$\Delta w_n = \beta[y(i) - y'(i)]x(i)_n \quad (4.7)$$

En la Figura 4.1 se muestra un diagrama de los elementos básicos del perceptrón. En la Figura 4.1, las entradas se multiplican por los pesos y se suman en la función "z", junto con el sesgo, el cual puede ser representado por el valor del peso w_0 . El error retroalimenta la salida para el ajuste de los pesos.




Figura 4.1. Diagrama básico de un perceptrón.

La regresión logística es un clasificador binario. La regresión logística utiliza métodos probabilísticos en su operación. Si a la ecuación (4.2), su función de activación se emplea una función probabilística sigmoide se tiene las siguientes ecuaciones

$$z = \sum_{j=0}^m x_j w_j = w^T x \quad (4.8)$$

$$\varphi(z) = \frac{1}{1 + e^{-z}} \quad (4.9)$$

En la Figura 4.2 se muestra la curva sigmoide, donde se puede observar que la función de activación tiende a 1 si "z" adquiere un valor infinito. De igual forma, "z" adquiere el valor de 0 cuando adquiere un valor infinito negativo, por lo cual actúa como la función de activación del perceptrón.




Figura 4.2 Curva sigmoide.

La diferencia de la función sigmoide radica en el valor de la pendiente que permite una clasificación probabilística binaria para las clases o datos de entrada que tienen que ser procesados.

En la Figura 4.3 se muestra un diagrama a bloques de la regresión logística; el error permite el ajuste de los pesos y el sesgo para su entrenamiento. A través del error cuadrático de la diferencia de su función de activación y su salida, que permita una mejor predicción [74].




Figura 4.3. Diagrama básico de un perceptrón con regresión logística.

4.3 Perceptrón multicapa

El perceptrón multicapa es una red que consiste en una conexión compleja entre todas las capas que la conforman, desde las entradas hasta la salida. La red está conformada por varias capas ocultas que permiten que realice el proceso de aprendizaje a través de la extracción progresiva de las características principales de las entradas.

La propagación hacia adelante involucra que los datos de entrada se multipliquen por los pesos y la suma de sus respectivos sesgos, como se indica en la siguiente expresión

$$\begin{bmatrix} W_{11} & W_{13} & W_{15} & W_{nn} \\ W_{12} & W_{14} & W_{16} & W_{nm} \end{bmatrix} \begin{bmatrix} X_1 \\ X_2 \\ X_3 \\ X_n \end{bmatrix} + \begin{bmatrix} S_{11} \\ S_{12} \end{bmatrix} = \begin{bmatrix} Z_1 \\ Z_2 \end{bmatrix} \quad (4.10)$$

simplificando las sumatorias

$$z_1 = \sum_{j=1}^n x_j w_j = w^T x \quad (4.11)$$

$$z_2 = \sum_{j=1}^m x_j w_j = w^T x \quad (4.12)$$

donde las funciones de activación de cada una de las sumatorias son

$$\varphi(z_1) = \frac{1}{1 + e^{-z_1}} \quad (4.13)$$

$$\varphi(z_2) = \frac{1}{1 + e^{-z_2}} \quad (4.14)$$

Las salidas de las neuronas se convierten a su vez en las entradas de la siguiente neurona

$$[W_{21} \quad W_{22} \quad \dots \quad W_{np}] \begin{bmatrix} \varphi(z_1) \\ \varphi(z_2) \\ \dots \\ \varphi(z_p) \end{bmatrix} + [s_{21}] = [z_3] \quad (4.15)$$

$$z_3 = \sum_{j=1}^p \varphi(z_j) w_j = w^T \varphi \quad (4.16)$$

La función de activación de la neurona representa las salidas de la red de acuerdo con

$$\varphi(z_3) = \frac{1}{1 + e^{-z_3}} \quad (4.17)$$

La propagación hacia atrás se realiza para el ajuste de los pesos de la capa de salida a la capa de entrada. Para lo anterior se calcula el error cuadrático entre el valor de la salida y el valor de la salida estimada, como se indica en la expresión

$$Err = \frac{1}{2} (y - y_{sal})^2 \quad (4.18)$$

En la Figura 4.4 se muestran los bloques del perceptrón multicapa, la información se propaga de izquierda a derecha, el error se propaga de derecha a izquierda y se requiere de un método que reduzca el error a través del uso de la derivada y el gradiente descendiente de la función que involucra el error cuadrático de la ecuación (4.18) [74].




Figura 4.4. Diagrama de un perceptrón multicapa.

4.4 Árboles de decisiones y bosques aleatorios

Los árboles de decisión son un modelo de aprendizaje automático que permite operar como clasificadores con esquema abierto, en donde a través de los nodos y las ramas se va realizando una serie de decisiones que permiten generar la clasificación binaria. En la Figura 4.5 se muestra un esquema general del árbol de decisiones con tres capas y varias hojas. La distribución de los árboles se basa en una serie de decisiones relacionadas con una característica que permite ser valoradas a través de las acciones que llevan a resolverlas. De acuerdo con la complejidad de la clasificación, se produce el número de capas en el árbol.

Usando el algoritmo de decisión se inicia en la raíz del árbol y se dividen los datos en las características que resulten en la mayor ganancia de información (IG). Un proceso iterativo puede ser repetido en cada nodo interno hasta que las hojas sean puras. Esto significa que todos los datos de entrenamiento en cada nodo pertenecen a la misma clase, lo que puede generar un árbol muy profundo con muchos nodos, generando un sobreajuste en la clasificación. En la práctica esto no sucede ya que de origen se debe limitar los niveles del árbol.




Figura 4.5. Diagrama de un árbol de decisiones.

El árbol de decisión emplea una función objetivo que optimiza el algoritmo de aprendizaje a través de la ganancia de información en cada nodo. La expresión de la ganancia de información se describe por la siguiente ecuación

$$IG(D_p, f) = I(D_p) - \sum_{j=1}^m \frac{N_j}{N_p} I(D_j) \quad (4.19)$$

f es la característica de desempeño de la división en el nodo

D_p, D_j son el conjunto de datos del n -ésimo nodo padre e hijo

I es la medición de la impureza

N_p número de ejemplos de entrenamiento del nodo padre

N_j número de ejemplos de entrenamiento del nodo hijo

Un criterio de división es la entropía, la cual se define como la cantidad de información requerida en un promedio para describir la variable aleatoria. Su expresión se define como

$$E_p = - \sum_{x \in X} P(x) \log_2 P(x) \quad (4.20)$$

donde $P(x)$ es la probabilidad de que el evento "x" ocurra, y X es un conjunto de posibles eventos.

Los tres niveles de impureza o criterios de división que utilizan los árboles de decisiones son los siguientes: Gini, entropía y error de clasificación [74].

En general, los árboles de decisiones son algoritmos relativamente sencillos que pueden producir un buen desempeño con un conjunto de datos no muy extensos, pueden ser entrenados con datos faltantes, ya que cada nodo depende de una sola característica. No se requiere escalar los datos antes del entrenamiento y la prueba como lo requieren las redes neuronales. Sin embargo, son muy propensos al sobreajuste, debido a la partición en los nodos y la profundidad del árbol. En general son sensibles a la variación de los datos de entrada.

En un árbol de decisiones, los parámetros son los coeficientes numéricos que se obtienen automáticamente con el algoritmo de entrenamiento. Los hiperparámetros son los coeficientes numéricos o las variables que debemos definir por elección o por curvas de aprendizaje antes de entrenar el árbol. En la Figura 4.6 se muestra la diferencia entre parámetros e hiperparámetros en un árbol. Todos los modelos de aprendizaje automático están sujetos a un sobreajuste, debido a la variabilidad o complejidad de los datos con los que se entrenan y validan. El ajuste o afinación de hiperparámetros busca encontrar el conjunto de valores del algoritmo que genere un menor valor de sobreajuste.

El sobreajuste en un modelo se presenta cuando al haber sido entrenado por medio de unos datos y probado con datos diferentes, su validación indica valores muy distantes o dispares entre los resultados de las métricas de entrenamiento y las métricas de prueba. Entre mayor convergencia tenga el modelo en sus métricas de entrenamiento y prueba, menor posibilidad tendrá de presentar un sobreajuste del modelo.




Figura 4.6. Diferencia entre parámetros e hiperparámetros.

Los bosques aleatorios son un algoritmo de clasificación basado en un conjunto de árboles de decisión. Cada árbol se genera de forma independiente mediante un muestreo de un vector aleatorio y de un vector de entrada.

El algoritmo de los bosques aleatorios utiliza el aprendizaje por ensamble, el cual consiste en crear un modelo con muy buen desempeño a partir de la combinación de múltiples modelos débiles. Cada modelo dentro de los bosques aleatorios emplea el muestreo aleatorio con reemplazo (bootstrapping), donde cada dato del conjunto tiene la misma probabilidad de ser seleccionado como parte de la muestra en más de una ocasión. En la Figura 4.7 se muestra un diagrama esquemático del bosque aleatorio formado por varios árboles de decisiones [74].

El conjunto de datos provenientes del extractor de características se divide entre los "n" árboles de decisiones de forma aleatoria, considerando el muestreo aleatorio con reemplazo (bootstrapping). Los árboles de decisión pueden construirse con estructuras diferentes en cada nodo, lo que genera resultados de clasificación con distintos valores de la función objetivo. Puede ser el caso de que cada árbol asigna (aggregating) un voto a la clase con mayor prevalencia para el propósito de la clasificación del vector de entrada. En general, el resultado de la elección por voto de la mayoría de los árboles o el promedio de los resultados de cada árbol representa el resultado final de la clasificación [75]. El esquema de entrenamiento del bosque aleatorio utiliza la técnica bagging que emplea el muestreo por reemplazo y la agregación de las predicciones de cada uno de los modelos del bosque aleatorio como se describe en la expresión

$$\text{Bagging} = \text{Bootstrapping} + \text{Aggregating} \quad (4.21)$$




Figura 4.7. Diagrama de un bosque aleatorio.

Usando el algoritmo de decisión se inicia en la raíz de cada árbol y se dividen los datos en las características que resulten en la mayor ganancia de información (IG). Un proceso iterativo puede ser repetido en cada nodo interno hasta que las hojas sean puras. Los algoritmos de los bosques aleatorios pueden sintetizarse en cuatro pasos:

- Suministrar una muestra aleatoria de tamaño "n" (elegir aleatoriamente "n" valores del conjunto de datos de entrenamiento con reemplazo)
- Construir un árbol de decisión con la muestra de tamaño "n". En cada nodo se seleccionan las características sin remplazamiento. Dividir los nodos considerando las características que satisfagan la función objetivo, para las instancias maximizar la ganancia de información.
- Repetir los pasos 1 y 2 "k" veces
- Agregar la predicción por cada árbol para asignar la etiqueta de las clases de acuerdo con el voto por mayoría.

Los bosques aleatorios, cuando emplean el voto de mayor prevalencia, construyen un clasificador cuyo objetivo es balancear las salidas de cada uno de los árboles de decisión. El algoritmo del bosque aleatorio permite unir diferentes árboles de decisión con diferentes pesos que permitan integrar una salida menos sensible a la variación de los datos; en la ecuación se indica la función objetivo

$$y = \max \arg \sum_{j=1}^m w_j X_A[C_j(x) = i] \quad (4.22)$$

donde

y es la función objetivo

w_j son los pesos asociados con el clasificador C_j

X_A es la función característica la cual retorna un 1 si la predicción de la clase del C_{jth} clasificador coincide con i

La versión modificada para predecir las etiquetas de las clases por el voto de mayoría se indica por la siguiente ecuación

$$y = \max \arg \sum_{j=1}^m w_j p_{ij} \quad (4.23)$$

donde p_{ij} es la probabilidad de predecir el j_{th} clasificador para la clase i .

Los bosques aleatorios debido a la técnica de "bagging" permiten que el modelo procese un mayor número de características de los datos de entrada, presente menor sobreajuste, sea más robusto a la variación de los datos y en general presente un mejor desempeño respecto a los árboles de decisión.

4.5 Métodos de ajuste en los algoritmos del aprendizaje automático

Durante el proceso de entrenamiento y prueba del modelo del clasificador, es posible que se presente un sobreajuste, debido a la variabilidad o complejidad de los datos con los que se entrenan y validan. El sobreajuste en un modelo se presenta cuando al haber sido entrenado por medio de unos datos y probado con datos diferentes, su validación indica valores muy distantes o dispares entre los resultados de las métricas de entrenamiento y las métricas de prueba. Entre mayor convergencia tenga el modelo en sus métricas de entrenamiento y prueba, menor posibilidad tendrá de presentar un sobreajuste del modelo.

Para reducir el sobreajuste en el modelo del clasificador se emplea un proceso de optimización en los algoritmos de aprendizaje, lo que implica mejorar el desempeño en las tareas de clasificación. Durante el entrenamiento y la prueba cada modelo debe ejecutar un proceso de optimización de acuerdo con los resultados en el proceso de validación; los ajustes permiten obtener un modelo predictivo que realice con la mayor certeza la tarea de clasificación. Los métodos de optimización dependen del tipo de algoritmo empleado en el modelo. Algunos métodos de optimización son: validación cruzada, curvas de aprendizaje, búsqueda exhaustiva de hiperparámetros, búsqueda aleatoria de hiperparámetros, métodos específicos del algoritmo. Cabe señalar que se puede combinar más de un método para su

optimización; sin embargo, el modelo comprometerá su tiempo de procesamiento en el algoritmo empleado.

4.5.1 Entrenamiento de los algoritmos de los clasificadores binarios

Los pasos para el entrenamiento de los algoritmos de aprendizaje supervisado son los siguientes:

- *Adquisición de datos.* El sistema de adquisición de datos representa el contacto entre la máquina eléctrica y los algoritmos de clasificación. En esta etapa se preprocesa, a partir de los datos de voltajes o corrientes, la información asociada al conjunto de parámetros en condiciones nominales y de falla que requiere el clasificador.
- *Seleccionar las características o datos de entrada y recopilar las etiquetas o datos de entrenamiento.* La etapa de extracción de características consiste en determinar el conjunto mínimo de parámetros obtenidos a partir de los datos que caracterizan una misma falla y que arrojan valores muy distintos cuando se tiene otra condición de falla, o la condición normal. Esta tarea requiere visualizar y extraer información contenida en las señales o datos que se manejan. Una mala selección afecta los resultados del clasificador.
- *Elegir un método de entrenamiento.* La etapa de entrenamiento del clasificador consiste en ajustar las condiciones del tipo de clasificador seleccionado a partir de los patrones disponibles del proceso. Se utilizan el método de entubamiento de datos y validación cruzada como estrategias para mejorar la etapa de entrenamiento.
- *Elegir un clasificador y un algoritmo de optimización.* De acuerdo a la complejidad de los datos obtenidos del extractor de características, se elige el clasificador para realizar la tarea del diagnóstico de fallas. Asociado con cada clasificador va relacionado con su optimizador, que le permite generar el mejor desempeño y evitar el sobreajuste cuando existan cambios de los datos de prueba una vez que ha sido entrenado.
- *Evaluar el desempeño del modelo.* La evaluación permite determinar qué tan complejo debe hacerse el clasificador; se emplean diversas métricas para validar su desempeño. Es recomendable empezar con algoritmos simples de clasificación e ir avanzando hacia algoritmos mucho más complejos.
- *Ajustar el algoritmo con el optimizador.* Una vez que se ha elegido el clasificador, se ha entrenado y validado, en base a los resultados de las métricas para los valores de entrenamiento y prueba, se pueden realizar ajustes en los clasificadores por medio del proceso de optimización que haya elegido. El propósito final es que el algoritmo quede lo mejor entrenado y preparado para evitar el sobreajuste.

4.5.2 Validación cruzada

En los procesos de entrenamiento y validación de los algoritmos de aprendizaje, se emplean conjuntos de datos los cuales tienen diferentes proporciones en su distribución. En la Figura 4.8 se indica un diagrama de la validación convencional del algoritmo de aprendizaje. En la etapa de preparación de los datos para el aprendizaje del algoritmo, el conjunto de datos se divide en entrenamiento y prueba en una proporción que podría ser 70 % y 30 % u 80 % y 20 % respectivamente. Esta división depende de la extensión y complejidad del conjunto de datos que recibe el algoritmo de aprendizaje; en la Figura 4.8 se muestra la partición del conjunto de datos de entrenamiento y prueba. Los datos de entrenamiento tienen el propósito de que el algoritmo reciba información que le permita clasificar o predecir la función objetivo o predictora ante nuevos datos. Los datos de prueba tienen el propósito de comprobar que el algoritmo ha realizado el aprendizaje supervisado y ante la medición de algunas métricas se pueda validar el desempeño de este.




Figura 4.8. Distribución del conjunto de datos con validación convencional.

Si el conjunto de datos ahora se subdivide en: datos de entrenamiento, datos de validación y datos de prueba como se indica en la Figura 4.9, permite al algoritmo de aprendizaje, cuando está siendo entrenado, realizar un ajuste de los hiperparámetros del algoritmo para elegir los valores óptimos que mejoren su proceso de aprendizaje.




Figura 4.9 Distribución del conjunto de datos con validación cruzada con reserva.

En la validación cruzada se dividen los datos de entrenamiento en diferentes conjuntos de datos, los cuales son usados para el entrenamiento del modelo y un conjunto para la evaluación del desempeño del modelo. El procedimiento se repite "n" veces para obtener "n" modelos con sus respectivos rendimientos. Típicamente se usa la validación cruzada para poder ajustar el modelo, ya que, con el método convencional, el modelo puede llegar a una subestimación o sobrestimación de su capacidad para clasificar o predecir valores.

A un modelo con la validación cruzada se le proporcionan más ejemplos de entrenamiento al algoritmo de aprendizaje, lo que da como resultado un modelo más preciso y robusto. En la Figura 4.10 se muestra la división del conjunto de datos en distintos subconjuntos o pliegues. Se reserva un subconjunto de los datos para probar el desempeño del algoritmo. No existe un número preciso de subdivisiones en la validación cruzada; depende en gran medida de la complejidad y la extensión de los datos que reciba el modelo; en [74] se cita una referencia que recomienda un promedio de 10 subconjuntos o pliegues. Cabe señalar que, cuanto más subconjuntos de datos se generen, el modelo incrementará el tiempo de procesamiento del algoritmo utilizado.




Figura 4.10. Distribución del conjunto de datos con validación cruzada.

4.5.3 Optimización de los algoritmos de los clasificadores binarios

El proceso de optimización en los algoritmos de aprendizaje implica mejorar el desempeño en las tareas de clasificación. Durante el entrenamiento y la prueba cada modelo debe ejecutar un proceso de optimización de acuerdo con los resultados en el proceso de validación, los ajustes permiten obtener un modelo predictivo que realice con la mayor certeza la tarea de clasificación. Los métodos de optimización

dependen del tipo de algoritmo empleado en el modelo; pueden ser cajas negras o cajas blancas donde el ajuste de uno o más de sus parámetros permita mejorar el desempeño del modelo. Sin embargo, independientemente de la complejidad del algoritmo de aprendizaje supervisado, las siguientes estrategias de forma conjunta o parcial contribuyen a la optimización del modelo:

- Validación cruzada
- Curvas de aprendizaje o validación con datos
- Búsqueda exhaustiva de hiperparámetros
- Búsqueda aleatoria de hiperparámetros
- Métodos de optimización de cada algoritmo

La validación cruzada, junto con la búsqueda exhaustiva o aleatoria de los hiperparámetros, permite contribuir a la optimización del algoritmo. Se indican a continuación las etapas de la selección y utilización de los hiperparámetros:

- Definir posibles valores de hiperparámetros
- Definir todas las posibles combinaciones de hiperparámetros
- Por cada combinación entrenar y validar el modelo con los datos de entrenamiento
- Escoger el mejor modelo, una vez validado con el mejor desempeño en sus métricas

4.6 Métricas de medición en el aprendizaje automático

En los clasificadores, las métricas permiten validar el desempeño del modelo. Se realiza una comparativa entre los datos de entrenamiento y de prueba que se utilizaron en el modelo del clasificador. En este trabajo se emplearon las métricas o índices de desempeño que validan al clasificador ante los escenarios de falla establecidos en los datos de las corrientes del GSIP. Algunas métricas que se emplean para la validación de los algoritmos de clasificación binaria se describen a continuación.

La matriz cuadrada de confusión es un indicador, el cual permite visualizar los errores individuales y relativos del clasificador. Se puede decir que dicha matriz, como el sistema, confunde escenarios de falla con respecto a N datos conocidos y permite evaluar funciones probabilísticas de cada escenario de falla. En la Figura 4.11 se indica la gráfica del arreglo de la matriz de confusión [8]. La matriz incluye verdaderos positivos y falsos positivos, que son aquellos datos que se asocian con los aciertos de la clasificación. Los falsos positivos y falsos negativos se asocian con los desaciertos de la clasificación.

		Predicción	
		Simétrico	Falla
Clase Real	Simétrico	Verdadero Positivo	Falso Negativo
	Falla	Falso Positivo	Verdadero Negativo

Figura 4.11. Matriz de confusión.

La curva característica de operación recibida, ROC (Receiver Operating Characteristic), es un índice gráfico que describe las clasificaciones correctas con respecto a las falsas alarmas. Para problemas de clasificación el umbral de decisiones es binario, es decir, si la falla se clasifica correctamente, se le asigna 1, de otro modo se asigna un 0. Se grafican entre las relaciones de la sensibilidad y la especificidad. La sensibilidad o probabilidad de clasificación se define como una relación de la expresión

$$Sens = \frac{VP}{VP + FN} \quad (4.24)$$

donde VP son los verdaderos positivos y FN son los falsos negativos que emite el clasificador binario.

La especificidad o probabilidad de falsas alarmas se define como una relación de la expresión

$$Espec = \frac{FP}{FP + VN} \quad (4.25)$$

donde FP son los falsos positivos y VN son los verdaderos negativos que emite el clasificador binario. En la Figura 4.12 se muestra la curva ROC, dado que mientras mayor es el área bajo la curva, mejor es el desempeño del clasificador. La curva ROC semejante a la línea recta de 45° denota un clasificador muy ineficiente [8].

Otras métricas que se utilizan para la validación de los modelos de aprendizaje automático son las que se describen a continuación

$$Accuracy = \frac{Predicciones\ correctas}{Total\ de\ predicciones} \quad (4.26)$$

$$Precisión = \frac{Verdaderos\ positivos}{Verdaderos\ positivos + Falsos\ positivos} \quad (4.27)$$

$$Recall = \frac{Verdaderos\ positivos}{Verdaderos\ positivos + Falsos\ negativos} \quad (4.28)$$

$$F1\ Score = \frac{2}{\frac{1}{Precisión} + \frac{1}{Recall}} \quad (4.29)$$




Figura 4.12. Funciones de probabilidad y la relación con la curva ROC.

Cada una de las métricas permite proporcionar información complementaria sobre los resultados que se obtienen del clasificador para valorar su desempeño.

Capítulo 5

Resultados

5.1. Formulación de los datos del extractor de características

En esta sección se utilizan los datos de las señales de las corrientes adquiridas del GSIP de 400 W como parte del banco de pruebas reportado en el apéndice B [76], con una carga resistiva, una velocidad fija de 200 rpm y cambios de velocidad entre 200 y 400 rpm. Con la etapa de adquisición de las señales de las corrientes en el banco de pruebas, se procesan a través del extractor de características que emplea las transformadas ondeletas Haar y Daubichies 4, y posteriormente ingresan a los diferentes modelos del clasificador binario en Python. En la Figura 5.1 se muestran los bloques básicos del proceso de diagnóstico de fallas del GSIP de 400 W.




Figura 5.1. Diagrama de bloques del proceso de clasificación de fallas del GSIP.

Los voltajes y corrientes del GSIP cambian su amplitud y frecuencia en función de la velocidad del motor primario que lo impulsa. En las Figuras 5.2(a) y 5.3(a) se muestran las señales trifásicas de las corrientes del GSIP a 200 rpm con una falla de cortocircuito (c.c.) de 1 vuelta y de 7 vueltas en la fase A. La reducción en la amplitud en la fase es debida a la presencia de la falla, lo que produce el desbalance en las corrientes del GSIP. En las Figuras 5.2(b) y 5.3(b) se muestra el módulo del vector de las corrientes al cuadrado de las tres señales trifásicas. Ambas señales de corrientes fueron calculadas por la ecuación (3.39) y graficadas en Python.




Figura 5.2. Corrientes del GSIP de 400 W, considerando una falla de 1 vuelta en c.c.




Figura 5.3. Corrientes del GSIP de 400 W, considerando una falla de 7 vueltas en c.c.

El proceso de adquisición consistió en el muestreo de las corrientes trifásicas conformado por 60 registros de 960 muestras con una frecuencia de muestreo de 1 kHz para los siguientes escenarios de falla en el estator que se indican en la Tabla A6 del GSIP de 400 W:

1. Sin vueltas en c.c.
2. 1 vuelta en c.c. de la fase a
3. 2 vueltas en c.c. de la fase a
4. 7 vueltas en c.c. de la fase a
5. 7 vueltas en c.c. de la fase a y 2 vueltas en c.c. de la fase b

Para cada uno de los escenarios anteriores, los registros fueron adquiridos de forma consecutiva. De las corrientes trifásicas adquiridas, se obtiene el módulo de las corrientes para que se procese con el algoritmo de la ondeleta y se generen 14 subseñales de las tendencias y fluctuaciones.

Las bandas de frecuencia fueron determinadas por la frecuencia de la señal y la frecuencia de muestreo como se indica en la ecuación (3.42). En la Tabla 5.1 se

indican las bandas de frecuencia para las subseñales de las tendencias y fluctuaciones de la ondeleta. Todos los componentes de frecuencia de interés en las señales de las corrientes se encuentran por debajo de la frecuencia de Nyquist (500 Hz). Se obtuvieron siete niveles del análisis multiresolución de la ondeleta, debido a que el GSIP opera en una frecuencia entre 20 y 40 Hz. Para los casos de falla en c.c. en el estator del GSIP, las componentes de frecuencia se generan al doble de la frecuencia fundamental de las corrientes de línea.

Tabla 5.1. Bandas de frecuencia de las tendencias y fluctuaciones.

Nivel	Tendencias	Banda de frecuencia (Hz)	Fluctuación	Banda de frecuencia (Hz)
1	A1	0-250	D1	250-500
2	A2	0-125	D2	125-250
3	A3	0-62.5	D3	62.5-125
4	A4	0-31.25	D4	31.25-62.5
5	A5	0-15.62	D5	15.62-31.25
6	A6	0-7.81	D6	7.81-15.62
7	A7	0-3.90	D7	3.90-7.81

Tabla 5.2. Valores eficaces de los coeficientes de la ondeleta Haar sin falla a 200 rpm.

Características	Simétrico	y
A1	4.4315	0
A2	6.2659	0
A3	8.8905	0
A4	12.5246	0
A5	17.6937	0
A6	25.0143	0
A7	35.3678	0
D1	0.0265	0
D2	0.0779	0
D3	0.1838	0
D4	0.3619	0
D5	0.8991	0
D6	0.6806	0
D7	0.5564	0

Los valores eficaces o rms, de las subseñales de las tendencias y fluctuaciones fueron calculados con la ecuación (3.34), para generar los valores del extractor de características. El valor de N fue de 483 para las subseñales *a1* y *d1*, 245 para las subseñales *a2* y *d2*, 126 para las subseñales *a3* y *d3*, 66 para las subseñales *a4* y *d4*, 36 para las subseñales *a5* y *d5*, 21 para las subseñales *a6* y *d6* y 14 para las subseñales

$a7$ y $d7$. Las Tablas 5.2, 5.3 y 5.4 muestran los valores eficaces de las subseñales sin falla de c.c. de las dos ondeletas Haar y Daub4.

Tabla 5.3. Valores eficaces de los coeficientes de la ondeleta Daub 4 sin falla a 200 rpm.

Características	Simétrico	y
A1	4.4315	0
A2	6.2659	0
A3	8.8905	0
A4	12.5246	0
A5	17.6937	0
A6	25.0143	0
A7	35.3678	0
D1	0.0265	0
D2	0.0779	0
D3	0.1838	0
D4	0.3619	0
D5	0.8991	0
D6	0.6806	0
D7	0.5564	0

Tabla 5.4. Valores eficaces de los coeficientes de la ondeleta Daub 4 sin falla a 400 rpm.

Características	Simétrico	y
A1	6.8460	0
A2	9.6810	0
A3	13.6913	0
A4	19.3577	0
A5	27.2337	0
A6	38.5448	0
A7	54.5620	0
D1	0.0817	0
D2	0.1761	0
D3	0.2369	0
D4	0.6374	0
D5	0.4543	0
D6	0.2462	0
D7	0.4348	0

En las Tablas 5.5, 5.6 y 5.7 se muestran los valores eficaces de las subseñales con las diferentes fallas de c.c. de las dos ondeletas Haar y Daub4 a dos velocidades del GSIP.

Tabla 5.5. Valores eficaces de los coeficientes de la ondeleta Haar con fallas a 200 rpm.

Características	1 v fase A	2 vs fase A	4 vs fase A	7 vs fase A	7 vs-fase A 2 vs-fase B	y
A1	4.4222	4.4447	4.4561	4.4492	4.5741	1
A2	6.2536	6.2861	6.3011	6.2899	6.4688	1
A3	8.8423	8.8905	8.9868	8.8886	9.1483	1
A4	12.5068	12.5603	12.5772	12.5840	12.9644	1
A5	17.7456	17.7456	17.7456	17.7456	17.7456	1
A6	25.2483	25.2483	25.2483	25.2483	25.2483	1
A7	35.9641	35.9639	35.9641	35.9641	35.9641	1
D1	0.0270	0.0276	0.0299	0.0311	0.0301	1
D2	0.0829	0.0826	0.0874	0.0873	0.0962	1
D3	0.1829	0.1836	0.1807	0.1865	0.1891	1
D4	0.3615	0.3482	0.3505	0.3810	0.4031	1
D5	0.8857	0.8854	0.8857	0.8857	0.8857	1
D6	0.6843	0.6899	0.6843	0.6843	0.6843	1
D7	0.4794	0.4794	0.4794	0.4794	0.4794	1

Tabla 5.6. Valores eficaces de los coeficientes de la ondeleta Daub 4 con fallas a 200 rpm.

Características	1 v fase A	2 vs fase A	4 vs fase A	7 vs fase A	7 vs-fase A 2 vs-fase B	y
A1	4.4222	4.4447	4.4561	4.4492	4.5741	1
A2	6.2536	6.2861	6.3011	6.2899	6.4688	1
A3	8.8423	8.8905	8.9868	8.8886	9.1483	1
A4	12.5068	12.5603	12.5772	12.5840	12.9644	1
A5	17.7456	17.7456	17.7456	17.7456	17.7456	1
A6	25.2483	25.2483	25.2483	25.2483	25.2483	1
A7	35.9641	35.9639	35.9641	35.9641	35.9641	1
D1	35.9641	35.9639	35.9641	35.9641	35.9641	1
D2	0.0270	0.0276	0.0299	0.0311	0.0301	1
D3	0.0829	0.0826	0.0874	0.0873	0.0962	1
D4	0.1829	0.1836	0.1807	0.1865	0.1891	1
D5	0.3615	0.3482	0.3505	0.3810	0.4031	1
D6	0.8857	0.8854	0.8857	0.8857	0.8857	1
D7	0.6843	0.6899	0.6843	0.6843	0.6843	1

Los datos de las instancias de las Tablas 5.2 a 5.7 fueron etiquetados con 0 y 1, lo que indica condiciones de no falla y falla respectivamente. Se formó un arreglo con estas tablas de 120 renglones (instancias) y 15 columnas (14 características y una etiqueta) para cada uno de los escenarios de falla del estator como entrada al clasificador.

Tabla 5.7. Valores eficaces de los coeficientes de la ondeleta Daub 4 con fallas a 400 rpm.

Características	1 v fase A	2 vs fase A	4 vs fase A	7 vs fase A	7 vs-fase A 2 vs-fase B	y
A1	68382	68382	6.8465	6.8465	6.9251	1
A2	96691	96691	9.6805	9.6805	9.7922	1
A3	13.6721	13.6721	13.6872	13.6872	13.8471	1
A4	19.3298	19.3298	19.3461	19.3461	19.5756	1
A5	27.6283	27.6283	27.6283	27.6283	27.6283	1
A6	39.1413	39.1413	39.1413	39.1413	39.1413	1
A7	55.4757	55.4757	55.4757	55.4757	55.4757	1
D1	0.0847	0.0847	0.0816	0.0816	0.0821	1
D2	0.1828	0.1828	0.1788	0.1788	0.1844	1
D3	0.2538	0.2538	0.2408	0.2408	0.2557	1
D4	0.5818	0.5818	0.6145	0.6145	0.6437	1
D5	0.4366	0.4366	0.4366	0.4366	0.4366	1
D6	0.2177	0.2177	0.2177	0.2177	0.2177	1
D7	0.3396	0.3396	0.3396	0.3396	0.3396	1

El propósito de la clasificación es detectar la presencia de la falla bajo diferentes escenarios de vueltas en c.c. del estator del GSIP y operando a una velocidad fija y una velocidad variable. Múltiples modelos binarios fueron entrenados de forma independiente para cada escenario de falla. Las fallas son progresivas, inician con unas cuantas vueltas en c.c. de una fase, hasta la combinación de más vueltas en c.c. de dos fases.

Los algoritmos de clasificación empleados en los modelos son los siguientes:

- Regresión logística
- Perceptrón
- Perceptrón multicapa
- Árbol de decisión
- Bosques aleatorios

Para el entrenamiento, validación y prueba de los modelos binarios se utilizó una computadora con las siguientes especificaciones: CPU con Intel Core i7-1065G7 @ 1.30 GHz con 8 GB de RAM. Se empleó Python 3.11.8 con las siguientes librerías: NumPy 1.26.4, Scikit-learn 1.2.2, Matplotlib 3.8.0, Pandas 2.1.4 y Plotly 5.19.0.

En el proceso de preparación de los datos de ingreso al clasificador, se realiza una separación en datos de entrenamiento y en datos de prueba. Para los resultados de la mayoría de los datos de ingreso a los clasificadores, se realizaron en una división de 70 % de entrenamiento y 30 % de prueba. Antes de ingresar los datos al modelo se efectúa un tratamiento de la información, es decir, un ajuste a través de las librerías de Python. Este proceso permite que no existan desviaciones muy grandes

entre los valores mínimos y máximos dentro del conjunto de datos y no dificulte al algoritmo el proceso de aprendizaje.

Para reducir el sobreajuste en la validación y prueba de los modelos de clasificación binaria, se empleó la validación cruzada y la técnica de búsqueda exhaustiva de hiperparámetros en cuatro de los algoritmos utilizados, y el muestreo con reemplazo además del voto mayoritario en el algoritmo restante. Estas técnicas fueron descritas en las secciones 4.4 y 4.5 para la optimización de los modelos. Las métricas utilizadas para la validación de los modelos de clasificación binaria, fueron las que se describen en la sección 4.6.

5.2 Análisis de desempeño de los modelos del clasificador binario.

En esta sección se presentan los resultados de las pruebas de validación de los cinco algoritmos de aprendizaje de las librerías de Scikit-learn empleados en Python. Se utiliza de forma independiente la validación cruzada de los datos, las curvas de aprendizaje con algunas constantes de los algoritmos y el impacto de la cantidad de datos de entrenamiento en la validación. En las Figuras 5.4 y 5.5 se muestran las gráficas del accuracy o exactitud $\pm$ desviación estándar de los datos de entrenamiento y los datos de validación. Se aplicó la validación cruzada con valores de partición de 10 y 20 subconjuntos o pliegues en dos de los algoritmos, la regresión logística y el perceptrón multicapa.

En las gráficas de las Figuras 5.4 y 5.5 se muestra que a través de la valoración de la exactitud de los datos de entrenamiento y prueba, se encuentra el número de pliegues más adecuado que reduzca el sobreajuste del modelo. Entre mayor sea el proceso de subdivisión, mayor será el tiempo de entrenamiento que emplea el modelo de clasificación. Se obtiene una buena convergencia entre la validación de los datos de entrenamiento y validación cuando el número de subconjuntos es menor a 10, como se indica en las Figuras 5.5(a) y 5.5(b).




Figura 5.4. Estimación de la exactitud $\pm$ desviación con 20 pliegues.




Figura 5.5. Estimación de la exactitud $\pm$ desviación con 10 pliegues.

Empleando los algoritmos de la regresión logística y el perceptrón multicapa en el modelo, se analizó la medición de los datos de entrenamiento y prueba, sin validación cruzada y con validación cruzada utilizando 5 subconjuntos. Los datos que ingresan a los clasificadores corresponden a los valores eficaces de las subseñales de la transformada ondeleta. Los parámetros empleados en el algoritmo de la regresión logística fueron los siguientes: tolerancia de 0.0001, $C = 1.0$, algoritmo de optimización "lbfgs", número máximo de iteraciones 100. Los parámetros empleados en el perceptrón multicapa fueron los siguientes: número de capas 100, algoritmo de optimización "adams", $\alpha = 0.0001$, tolerancia de 0.0001, número máximo de iteraciones 100.

Tabla 5.8. Ajuste de la exactitud del modelo con el algoritmo de la regresión logística.

Vueltas en c.c.	Sin validación cruzada (k=0)		Con validación cruzada (k=5)	
	Datos entrenamiento	Datos de validación	Datos de entrenamiento (promedio)	Datos de validación (promedio)
1-fase A	0.9047	0.8333	0.8767	0.8833
2- fase A	0.9047	0.8333	0.8767	0.8833
4-fase A	0.8809	0.8888	0.8933	0.8333
7- fase A	0.9047	0.8333	0.8767	0.8833
7-fase A/ 2-fase B	0.9761	0.9444	0.9667	0.9500

En las Tablas 5.8 y 5.9 se muestran los resultados del desempeño de los dos algoritmos. Los resultados de la regresión logística se mantienen muy próximos, independientemente de la validación cruzada. En cambio, en los resultados del perceptrón multicapa hay cambios con y sin validación cruzada. El sobreajuste es

más evidente en un algoritmo como el perceptrón, por la estructura de su algoritmo y la forma en que procesa los datos a clasificar.

Tabla 5.9. Ajuste de la exactitud del modelo con el algoritmo del perceptrón multicapa.

Vueltas en c.c.	Sin validación cruzada (k=0)		Con validación cruzada (k=5)	
	Datos entrenamiento	Datos de validación	Datos de entrenamiento (promedio)	Datos de validación (promedio)
1-fase A	0.8750	0.8333	0.8334	0.7400
2- fase A	0.8750	1.0000	0.8759	0.9000
4-fase A	0.8750	1.0000	0.8759	0.9000
7- fase A	0.8541	1.0000	0.8296	0.8000
7-fase A/ 2-fase B	0.9583	1.0000	0.9500	0.9333

Para identificar la proporción más adecuada de los datos de entrenamiento en el modelo que permita reducir el sobreajuste, se utilizó la exactitud como una métrica de análisis de las gráficas de las Figuras 5.6 y 5.7. Estas curvas de validación indican que el sobreajuste es más evidente a menor número de datos que se ingresan al modelo. A medida que se incrementan los datos, se reduce el sobreajuste.




Figura 5.6. Ajuste de los datos en la regresión logística y el perceptrón multicapa.

Se analizaron algunas constantes que forman parte de los hiperparámetros de los algoritmos de clasificación, como se muestra en las Figuras 5.8 y 5.9. Con estas curvas de aprendizaje se ajustan los valores que contribuyan al proceso de optimización del clasificador. El número de neuronas o capas en una red neuronal, el número de hojas o niveles en un árbol de decisión y el número de árboles o estimadores en un bosque aleatorio son algunos de los parámetros para mejorar el desempeño.




Figura 5.7. Ajuste de los datos de un árbol de decisión y del bosque aleatorio.

Una vez analizada la curva, se eligen las constantes que generen el menor sobreajuste, para ser utilizadas con el modelo que será entrenado y validado.




Figura 5.8. Curvas de aprendizaje para la regresión logística y el perceptrón multicapa.




Figura 5.9. Curvas de aprendizaje para el árbol de decisión y los bosques aleatorios.

Empleando el método de la búsqueda exhaustiva con hiperparámetros, se analizaron los resultados de la exactitud con los datos de entrenamiento y con los datos de prueba a una velocidad de 200 rpm para los tres algoritmos, ya que el bosque aleatorio no emplea esta técnica. De acuerdo con la Tabla 5.10, existe un sobreajuste en el modelo que utiliza el algoritmo de la regresión logística sin ajuste de hiperparámetros, lo que reduce el valor de las métricas cuando se valida el modelo con los datos de prueba. En la Tabla 5.11 el sobreajuste se reduce para el perceptrón multicapa cuando se utiliza el ajuste de hiperparámetros.

Tabla 5.10. Exactitud del modelo con ajuste de hiperparámetros en la regresión logística.

Vueltas en c.c.	Sin ajuste de hiperparámetros (k= 5)		Con ajuste de hiperparámetros (k= 5)	
	Datos entrenamiento	Datos de validación	Datos de entrenamiento	Datos de validación
1-fase A	0.8541	0.8333	0.5833	0.5000
2- fase A	0.9791	0.9166	0.7291	0.6666
4-fase A	0.8750	0.9166	0.7291	0.8333
7- fase A	0.8541	0.9166	0.7708	0.5833
7-fase A/ 2-fase B	0.9583	1.0000	0.8125	0.9166

Tabla 5.11. Exactitud del modelo con ajuste de hiperparámetros en el perceptrón.

Vueltas en c.c.	Sin ajuste de hiperparámetros (k= 5)		Con ajuste de hiperparámetros (k= 5)	
	Datos entrenamiento	Datos de validación	Datos de entrenamiento	Datos de validación
1-fase A	0.9375	0.8333	0.8541	0.8333
2- fase A	0.9583	0.9166	1.0000	0.9166
4-fase A	0.9166	0.9166	0.8125	0.9166
7- fase A	0.9583	0.9166	0.8125	0.9166
7-fase A/ 2-fase B	0.9583	1.0000	0.8958	1.0000

En la Tabla 5.12 se muestra el efecto de la variación de los datos en el árbol de decisiones con un sobreajuste menor que la regresión logística. En la comparación de los algoritmos de clasificación, el perceptrón multicapa es el que presenta el mejor desempeño ante las variaciones de los datos de entrada y validación en el modelo de clasificación.

Tabla 5.12. Exactitud del modelo con ajuste de hiperparámetros en el árbol de decisiones.

Vueltas en c.c.	Sin ajuste de hiperparámetros (k= 5)		Con ajuste de hiperparámetros (k= 5)	
	Datos entrenamiento	Datos de validación	Datos de entrenamiento	Datos de validación
1-fase A	1.0000	0.7500	0.9375	0.6666
2- fase A	1.0000	0.4166	1.0000	0.9166
4-fase A	1.0000	0.8333	1.0000	0.9166
7- fase A	1.0000	0.8333	0.9583	0.8333
7-fase A/ 2-fase B	1.0000	0.5000	0.9583	1.0000

5.3. Modelo del clasificador binario con el algoritmo de la regresión logística y el algoritmo del perceptrón.

En esta sección se valida el desempeño del modelo del clasificador binario a través de los algoritmos de la regresión logística y el perceptrón. Se utilizaron las cinco combinaciones de las vueltas en c.c. del estator como escenarios de falla, y las señales de las corrientes se procesaron a una velocidad fija de 200 rpm y una velocidad variable de 200 rpm- 400 rpm - 200 rpm - 400 rpm del GSIP.

En el modelo, se empleó la validación cruzada con 5 subconjuntos de los datos de entrada. Se utilizó la búsqueda exhaustiva de hiperparámetros para la regresión logística, considerando: la tolerancia, el número máximo de iteraciones y la constante alpha. Para el perceptrón se ajustó por el mismo método: la tolerancia, el número máximo de iteraciones y el solver.

La métrica de la exactitud establece la relación de los verdaderos positivos respecto al total de las predicciones; el valor unitario representa el mejor desempeño del clasificador. En las Figuras 5.10, 5.11 y 5.12, para ambos algoritmos utilizados se realiza una validación con proporciones de los datos de prueba en: 10 %, 20 % y 30 %, con las cinco fallas del estator y una velocidad de 200 rpm del GSIP.

Se puede observar en las figuras que el desempeño de ambos algoritmos es regular ante la falla de 1 vuelta, mientras que para las restantes fallas el desempeño de ambos algoritmos es el mejor. Se alcanza a notar una ligera mejora en la exactitud de la regresión logística respecto al perceptrón cuando se considera la falla de 1 vuelta y 10 % de datos de prueba; esto se debe a la función de activación que emplean ambos algoritmos. Los resultados anteriores permiten definir el algoritmo del clasificador, ya que no sólo debe contar con una estructura relativamente simple para su implementación, sino que debe ser capaz de lograr el mejor desempeño en todas las combinaciones posibles de fallas a diagnosticar en el GSIP.




Figura 5.10. Exactitud con 10% de datos de prueba a 200 rpm.




Figura 5.11. Exactitud con 20% de datos de prueba a 200 rpm.




Figura 5.12. Exactitud con 30% de datos de prueba a 200 rpm.

En la Figura 5.13 se valida el modelo del clasificador con ambos algoritmos, empleando 10% de datos de prueba y una velocidad variable de 200 rpm–400 rpm–200 rpm–400 rpm del GSIP. En las dos gráficas de la exactitud de la Figura 5.13 se reduce significativamente su valor, respecto a las gráficas de la exactitud que consideran la velocidad fija de 200 rpm. Al ser algoritmos relativamente simples, su

desempeño ante cambios en los datos no permite garantizar una correcta clasificación de las fallas en c.c. del estator del GSIP. En la Figura 5.14 en las gráficas de la exactitud, se modifica la proporción de los datos de prueba en 10 %, 20 % y 30 % con velocidad variable del GSIP. El desempeño del modelo es deficiente para el perceptrón y regular para la regresión logística.




Figura 5.13. Exactitud con 10% de datos de prueba y velocidad variable.




Figura 5.14. Exactitud con cambios en los datos de prueba y velocidad variable.

Las curvas ROC, las cuales representan la sensibilidad en función de los falsos positivos para los diferentes escenarios de la falla en el estator en el GSIP. De la Figura 5.15 a la Figura 5.19 se muestra la comparativa de las curvas ROC del perceptrón y la regresión logística, con velocidad variable en el GSIP. De acuerdo con la Figura 5.15(a) y la Figura 5.15(b), la respuesta del clasificador binario en ambos algoritmos es regular; se presentan algunos falsos positivos, lo que reduce los verdaderos positivos. Para que en las curvas ROC se muestre un buen desempeño del clasificador, la probabilidad de clasificación debe alcanzar el valor unitario, es decir, en el cálculo de la sensibilidad no existen falsos negativos y en la especificidad no existen falsos positivos. En la Figura 5.16(a) y la Figura 5.16(b) las curvas ROC de los dos modelos igualmente tienen una probabilidad de clasificación regular.




Figura 5.15. Curvas ROC considerando una falla de 1 vuelta en la fase A.




Figura 5.16. Curvas ROC considerando una falla de 2 vueltas en la fase A.

En la Figura 5.17(a) el desempeño del modelo se encuentra al límite del umbral de la curva ROC, por lo que no podrá realizar la clasificación correcta. En la Figura 5.17(b), el desempeño del modelo es regular. En las Figuras 5.18(a) y 5.18(b) el desempeño del modelo con ambos algoritmos mejora respecto a las curvas ROC con las fallas incipientes de 1 a 2 vueltas, pero no alcanza la clasificación unitaria.




Figura 5.17. Curvas ROC considerando una falla de 4 vueltas en la fase A.




Figura 5.18. Curvas ROC considerando una falla de 7 vueltas en la fase A.

En las Figuras 5.19(a) y 5.19(b), las curvas ROC de ambos modelos se encuentran por encima de la línea del umbral con una probabilidad de clasificación unitaria, lo que indica que el clasificador tiene un buen desempeño.




Figura 5.19. Curvas ROC con una falla de 7 vueltas en la fase A y 2 vueltas en la fase B.

Tabla 5.13. Matriz de confusión del perceptrón a 200 rpm.

Vueltas-c.c.	VP	VN	FP	FN
1-fase A	8	16	3	9
2-fase A	15	19	0	2
4-fase A	16	14	5	1
7-fase A	17	19	0	0
7-fase A y 2-fase B	17	19	0	0

La matriz de confusión separa las posibles combinaciones de los aciertos o desaciertos estimados por el modelo de clasificación binaria. En la Tabla 5.13 se presentan los resultados con los datos de prueba al 30 % y velocidad de 200 rpm para el perceptrón y en la Tabla 5.14 para la regresión logística. Estas tablas son

complementarias a las gráficas de la Figura 5.12, donde aparece una proporción importante de falsos positivos (FP) y falsos negativos (FN) para el algoritmo del perceptrón. A partir de 2 vueltas el número de verdaderos positivos (VP) y verdaderos negativos (VN) es mayor, lo que representa un buen desempeño del clasificador.

Tabla 5.14. Matriz de confusión de la regresión logística a 200 rpm.

Vueltas-c.c.	VP	VN	FP	FN
1-fase A	14	15	4	3
2-fase A	17	19	0	0
4-fase A	17	17	2	0
7-fase A	17	19	0	0
7-fase A y 2-fase B	17	19	0	0

En las Tablas 5.15 y 5.16 se calcularon las métricas (indicadas en la sección 4.6) para validar el modelo de clasificación binaria, con el algoritmo del perceptrón y todas las condiciones de falla del estator del GSIP. Existe una variación en los resultados de las métricas debido al cambio en la velocidad del GSIP de un valor fijo a variable. Es un algoritmo con un bajo desempeño en la clasificación, ya que su estructura relativamente simple no le permite generar predicciones confiables ante la modificación de los datos de entrada.

Tabla 5.15. Métricas del perceptrón a 200 rpm.

Vueltas-c.c.	Accuracy	Precision	Recall	F1
1-fase A	0.67	0.73	0.47	0.57
2-fase A	0.94	1.00	0.88	0.94
4-fase A	0.83	0.76	0.94	0.84
7-fase A	1.00	1.00	1.00	1.00
7-fase A y 2-fase B	1.00	1.00	1.00	1.00

Tabla 5.16. Métricas del perceptrón a velocidad variable.

Vueltas-c.c.	Accuracy	Precision	Recall	F1
1-fase A	0.68	0.62	0.94	0.74
2-fase A	0.75	0.72	0.76	0.74
4-fase A	0.50	0.47	0.47	0.47
7-fase A	0.81	0.71	0.8	0.83
7-fase A y 2-fase B	0.89	0.9	0.89	0.95

En las Tablas 5.17 y 5.18 se calcularon las métricas para validar el modelo de clasificación binaria con el algoritmo de la regresión logística. Los resultados de las

métricas presentan variación por el cambio de la velocidad en el GSIP, esto significa que es un algoritmo con un desempeño regular a bajo para el modelo, debido a que en las predicciones se pueden producir falsos positivos o falsos negativos.

Tabla 5.17. Métricas de la regresión logística a 200 rpm.

Vueltas-c.c.	Accuracy	Precision	Recall	F1
1-fase A	0.81	0.78	0.82	0.80
2-fase A	1.00	1.00	1.00	1.00
4-fase A	0.94	0.89	1.00	0.94
7-fase A	1.00	1.00	1.00	1.00
7-fase A y 2-fase B	1.00	1.00	1.00	1.00

Tabla 5.18. Métricas de la regresión logística a velocidad variable.

Vueltas-c.c.	Accuracy	Precision	Recall	F1
1-fase A	0.83	0.87	0.76	0.81
2-fase A	0.86	0.80	0.94	0.86
4-fase A	0.78	0.74	0.82	0.78
7-fase A	0.89	0.81	0.9	0.89
7-fase A y 2-fase B	1.00	1.00	1.00	1.00

Debido a que los modelos reciben los datos sin falla y con falla de las subseñales de la transformada ondelata, como se indican en la Tabla 5.2 a la Tabla 5.7, no todos los coeficientes de las tendencias y fluctuaciones presentan una variación significativa de su valor eficaz entre ambas condiciones. En general, los coeficientes aumentan su valor eficaz a medida que aumenta la asimetría de las fallas. Una falla de varias vueltas tendrá una diferencia más significativa que una falla de pocas vueltas en sus valores eficaces de los coeficientes. Esta condición tiene impacto en el procesamiento que realiza el clasificador al considerar fallas incipientes.

5.4. Modelo del clasificador binario con el algoritmo perceptrón multicapa

En esta sección se analiza el desempeño del modelo del clasificador binario, cuando se emplea un algoritmo con el perceptrón multicapa con la estructura indicada en la Figura 4.4. Este algoritmo por su complejidad debería mejorar la predicción del modelo, sobre todo con los datos asociados a las fallas incipientes. Se utilizaron las cinco combinaciones de las vueltas en c.c. del estator como escenarios de falla, y las señales de las corrientes se procesaron a una velocidad fija de 200 rpm y una velocidad variable de 200 rpm - 400 rpm - 200 rpm - 400 rpm del GSIP.

En el modelo, se empleó la validación cruzada con 5 subconjuntos de los datos de entrada. Se utilizó la búsqueda exhaustiva de hiperparámetros para el perceptrón

multicapa, considerando: el solver, el número de capas ocultas, la tolerancia, el número máximo de iteraciones.

En las Figuras 5.20 y 5.21 se muestran las gráficas de la exactitud del modelo de clasificación binaria con el perceptrón multicapa; el sobreajuste del modelo se reduce respecto al modelo que utiliza el perceptrón de una capa como lo indican las Figuras 5.10 (a), 5.11 (a) y 5.12 (a) considerando la velocidad de 200 rpm.




Figura 5.20. Exactitud del perceptrón multicapa a 200 rpm.




Figura 5.21. Exactitud del perceptrón multicapa con 30% de datos de prueba a 200 rpm.

En la Figura 5.22 se muestra la gráfica de la exactitud con 10 % de los datos de prueba y velocidad variable en el GSIP, se puede observar que el sobreajuste en el modelo del clasificador es relativamente bajo, con los diferentes escenarios de fallas de c.c. del estator. En la Figura 5.23 se muestran las gráficas de barras de la exactitud con los diferentes porcentajes de datos de prueba y velocidad variable de la exactitud. La exactitud se reduce en menor proporción que en las gráficas del perceptrón de la Figura 5.14 (a), debido a la estructura de las capas en la red neuronal. El valor más bajo en la exactitud se presenta con el escenario de falla de 4 vueltas en c.c., en donde los datos generan un mayor error en la predicción del

modelo con el algoritmo del perceptrón multicapa, de acuerdo con la ecuación (4.18).




Figura 5.22. Exactitud del perceptrón con 10% de datos de prueba y velocidad variable.




Figura 5.23. Exactitud del perceptrón multicapa con cambios en los datos de prueba y velocidad variable.

Las curvas ROC se emplean para validar qué porcentaje de los datos en el modelo ha sido capaz de identificar correctamente el algoritmo del perceptrón multicapa, como se muestran en las Figuras 5.24 a 5.27. En estas figuras se consideran un 30 % de los datos de prueba y la velocidad variable del GSIP.

En las Figuras 5.24(a), 5.24(b) y 5.25(a), las curvas ROC se encuentran por arriba de la línea del umbral, lo que representa que el modelo producirá en mayor medida verdaderos positivos, pero con la presencia de algunos falsos positivos. A diferencia del perceptrón en las Figuras 5.15(a) y 5.16(a), donde su desempeño es regular y en la Figura 5.17(a) su desempeño es bajo, el modelo con el perceptrón multicapa, su desempeño es bueno. La esquina de la curva en la Figura 5.25 (a) se desplaza hacia la línea del umbral reduciendo los verdaderos positivos y acorde con la reducción de la gráfica de barras de la exactitud de la Figura 5.23 para el escenario de falla de 4 vueltas en c.c. del estator del GSIP.




Figura 5.24. Curvas ROC del perceptrón multicapa con 1 y 2 vueltas en c.c.




Figura 5.25. Curvas ROC del perceptrón multicapa con 4 y 7 vueltas en c.c.




Figura 5.26. Curvas ROC del perceptrón multicapa con 7 vueltas en c.c. de la fase A y 2 vueltas en c.c. de la fase B.

En las Figuras 5.25 y 5.26, las curvas ROC producen el total de verdaderos positivos, lo que significa que el modelo del clasificador tiene un buen desempeño con los datos de entrada. En general, el perceptron multicapa muestra un mejor desempeño en todas las combinaciones de las fallas de c.c. Es un algoritmo más complejo que permite una predicción más acertada.

La Tabla 5.19 muestra los resultados de la matriz de confusión para el perceptrón multicapa a 200 rpm y 30 % de los datos de prueba. Para cada uno de los escenarios de falla en c.c. se observa un valor reducido de falsos positivos y negativos, lo que representa un buen desempeño del modelo de clasificación binaria.

Los resultados en las métricas de las Tablas 5.20 y 5.21 del perceptrón multicapa a velocidad fija, velocidad variable y 30 % de los datos de prueba, no cambian significativamente sus valores, lo que representa un buen desempeño en el modelo del clasificador binario. Los valores de la exactitud y el F1 se mantienen en la misma proporción en la Tabla 5.20; esto significa que los falsos positivos y los falsos negativos se encuentran en valores bajos. En la Tabla 5.21 para el escenario de la falla de 4 vueltas en c.c. las métricas presentan los valores más bajos acorde con lo que se describe en la Figura 5.23.

Tabla 5.19. Matriz de confusión del perceptrón multicapa a 200 rpm.

Vueltas-c.c.	VP	VN	FP	FN
1-fase A	14	18	1	3
2-fase A	17	19	0	0
4-fase A	17	17	2	0
7-fase A	17	17	2	0
7-fase A y 2-fase B	17	19	0	0

Tabla 5.20. Métricas del perceptrón multicapa a 200 rpm.

Vueltas-c.c.	Accuracy	Precision	Recall	F1
1-fase A	0.89	0.93	0.82	0.87
2-fase A	1.00	1.00	1.00	1.00
4-fase A	0.94	0.89	1.00	0.94
7-fase A	0.94	0.89	1.00	0.94
7-fase A y 2-fase B	1.00	1.00	1.00	1.00

Tabla 5.21. Métricas del perceptrón multicapa a velocidad variable.

Vueltas-c.c.	Accuracy	Precision	Recall	F1
1-fase A	0.86	0.88	0.82	0.85
2-fase A	0.83	0.76	0.94	0.84
4-fase A	0.78	0.80	0.71	0.75
7-fase A	0.90	1.00	1.00	0.90
7-fase A y 2-fase B	1.00	0.90	0.95	0.96

5.5. Modelo del clasificador binario con los algoritmos de un árbol de decisiones y los bosques aleatorios.

Para validar el desempeño del modelo del clasificador binario, con los algoritmos de los árboles de decisión y bosques aleatorios se emplearon las mismas métricas de las secciones 5.3 y 5.4. Se utilizaron las cinco combinaciones de las vueltas en c.c. del estator como escenarios de falla, y las señales de las corrientes se procesaron a una velocidad fija de 200 rpm, una velocidad variable de 200 rpm -400 rpm y una velocidad variable de 200 rpm- 400 rpm - 200 rpm - 400 rpm del GSIP.

En el modelo, se empleó la validación cruzada con 5 subconjuntos de los datos de entrada para el algoritmo de los árboles de decisiones y el muestreo por reemplazo y la agregación de predicciones en el algoritmo de los bosques aleatorios. Se utilizó la búsqueda exhaustiva de hiperparámetros para los árboles de decisiones considerando los parámetros: criterio de división, máxima profundidad, máximo número de nodos, mínima división de muestras. Para el bosque aleatorio los siguientes parámetros : número de estimadores, máxima profundidad del árbol, parámetros o características de cada árbol.

Para reducir el sobreajuste en el modelo de clasificación binaria que emplea el árbol de decisiones, se probaron técnicas de optimización como la poda de árboles y la búsqueda aleatoria de hiperparámetros, sin embargo, los mejores resultados en las métricas del modelo se obtuvieron con la técnica de la búsqueda exhaustiva de hiperparámetros junto con la validación cruzada. En las gráficas de la exactitud de la Figura 5.27, los datos de prueba son del 30 % con una velocidad variable en el GSIP. Se observa en el modelo que el desempeño del algoritmo de los bosques aleatorios es más robusto ante la variación de la velocidad que el algoritmo del árbol de decisiones, lo que implica que hay menor sobreajuste y, por lo tanto, se producen mejores predicciones.




Figura 5.27. Exactitud del árbol y de los bosques con cambios de velocidad.




Figura 5.28. Exactitud del árbol y de los bosques a 200 rpm.

En la figura 5.28(a) se muestra el desempeño del modelo con el algoritmo del árbol de decisión, considerando los cambios en la proporción de datos de prueba de 10 %, 20 % y 30 % y una velocidad del GSIP de 200 rpm. El mejor desempeño del modelo corresponde a la proporción del 10 %, lo anterior debido a que, en el método de validación cruzada, entre mayor sea el conjunto de datos para la formación de los subconjuntos de entrenamiento, mayor será el desempeño del modelo en los datos de prueba. En la Figura 5.28(b) se muestra el desempeño del modelo con el algoritmo del bosque aleatorio en donde se puede observar que el mejor desempeño que tiene el modelo le corresponde cuando se tiene la proporción del 10 % de los datos de prueba, lo que significa mayor proporción en la cantidad de datos de entrenamiento. Esto permite que el muestreo aleatorio con reemplazo (bootstrapping) en cada uno de los árboles que forman el bosque produzca un mejor entrenamiento y una mejor validación del modelo.

En la Figura 5.29(a) se muestra el desempeño del modelo con el algoritmo del árbol de decisión, con un cambio en la velocidad del GSIP de 200 a 400 rpm. El modelo reduce su desempeño debido a la modificación en los coeficientes de las tendencias y fluctuaciones con el cambio de la velocidad. El sobreajuste en el modelo es relativamente bajo con el ajuste de hiperparámetros y validación cruzada para el algoritmo del árbol de decisión. En la Figura 5.29(b) se muestra el desempeño del modelo con el algoritmo del bosque aleatorio, en donde al comparar la Figura 5.28 (b) y la Figura 5.29 (b) se indica la robustez que presenta el modelo frente a los cambios de velocidad. En las gráficas de la Figura 5.30 se muestra el desempeño del modelo con cambios de velocidad; la exactitud se reduce en menor proporción que en las gráficas del perceptrón multicapa de la Figura 5.23. Ambos algoritmos permiten al modelo de clasificación mejores predicciones ante las fallas de c.c.




Figura 5.29. Exactitud del árbol y de los bosques con cambios de 200 a 400 rpm.





Figura 5.30. Exactitud del árbol y de los bosques con velocidad variable.

Las curvas ROC de las Figuras 5.31 a 5.35 indican qué porcentaje de los datos de prueba el modelo identifica correctamente la falla. Las curvas se construyeron considerando un 30 % de los datos de prueba y cambios en la velocidad del GSIP.


En las curvas ROC de las Figuras 5.31(a) y 5.31(b) el modelo entrenado con los dos algoritmos se encuentra por encima de la línea del umbral, pero no alcanza a reflejar el valor máximo de los verdaderos positivos; su desempeño es regular. En las curvas ROC de las Figuras 5.32(a) y 5.32(b), el modelo presenta un mejor desempeño en la clasificación. En las curvas ROC de las Figuras 5.33(a) y 5.33(b), el modelo tiene un desempeño regular en la clasificación, debido al procesamiento de los datos de entrada y la sensibilidad de ambos algoritmos. En las curvas ROC de las Figuras 5.34 y 5.35, el modelo tiene un mejor desempeño en la clasificación para ambos algoritmos, algunos falsos positivos y falsos negativos aparecen en la predicción por el cambio en los datos de entrada debido a la velocidad variable.



(a) Árbol de decisiones

(b) Bosques aleatorios


Figura 5.31. Curvas ROC con una falla de 1 vuelta en la fase A.



(a) Árbol de decisiones

(b) Bosques aleatorios

Figura 5.32. Curvas ROC con una falla de 2 vueltas en la fase A.



(a) Árbol de decisiones

(b) Bosques aleatorios

Figura 5.33. Curvas ROC con una falla de 4 vueltas en la fase A.




Figura 5.34. Curvas ROC con una falla de 7 vueltas en la fase A.




Figura 5.35. Curvas ROC con las fallas de 7 vts. en la fase A y 2 vts. en la fase B.

Tabla 5.22. Métricas del árbol de decisiones a 200 rpm.

Vueltas-c.c.	Accuracy	Precision	Recall	F1
1-fase A	1.00	1.00	1.00	1.00
2-fase A	0.94	0.89	1.00	0.94
4-fase A	0.86	0.88	0.82	0.85
7-fase A	0.97	0.94	1.00	0.97
7-fase A y 2-fase B	0.94	1.00	0.88	0.94

Tabla 5.23. Métricas del árbol de decisiones a velocidad variable.

Vueltas-c.c.	Accuracy	Precision	Recall	F1
1-fase A	1.00	1.00	1.00	1.00
2-fase A	0.97	0.94	1.00	1.00
4-fase A	0.86	0.80	0.94	0.86
7-fase A	0.94	0.94	0.94	0.94
7-fase A y 2-fase B	0.89	0.81	1.00	0.89

En la Tabla 5.22 se muestran los resultados de las métricas del modelo con el árbol de decisión. Estos resultados se obtuvieron con el 30 % de los datos de prueba y velocidad de 200 rpm en el GSIP. Las métricas Precision y Recall permiten identificar la proporción de falsos positivos y falsos negativos que genera el modelo, y el F1 Score indica el equilibrio entre ambas métricas. En la Tabla 5.23 se muestran los resultados de las métricas del modelo con el árbol de decisión a velocidad variable. La diferencia entre los resultados de las Tablas 5.22 y 5.23 de las diferentes métricas indica un buen desempeño del modelo del clasificador.

En las Tablas 5.24 y 5.25 se muestran los resultados de las métricas para el modelo que emplea el bosque aleatorio, con 30 % de datos de prueba. A pesar de que en la Tabla 5.24 la velocidad es fija y en la Tabla 5.25 la velocidad es variable, el desempeño del modelo para todos los escenarios de falla del estator, las métricas son de valor casi unitario para la mayoría, lo que indica el mejor desempeño en la clasificación. El uso de la técnica de bagging en el modelo de los bosques aleatorios, permite ofrecer robustez, independiente del número de datos que se procesan y el cambio de velocidad en los datos de entrada del clasificador.

Tabla 5.24. Métricas de los bosques aleatorios a 200 rpm.

Vueltas-c.c.	Accuracy	Precision	Recall	F1
1-fase A	1.00	1.00	1.00	1.00
2-fase A	1.00	1.00	1.00	1.00
4-fase A	0.89	0.88	0.88	0.88
7-fase A	1.00	1.00	1.00	1.00
7-fase A y 2-fase B	0.94	1.00	0.88	0.94

Tabla 5.25. Métricas de los bosques aleatorios a velocidad variable.

Vueltas-c.c.	Accuracy	Precision	Recall	F1
1-fase A	1.00	1.00	1.00	1.00
2-fase A	0.97	1.00	0.94	0.97
4-fase A	0.81	0.81	0.76	0.79
7-fase A	0.97	0.94	1.00	0.97
7-fase A y 2-fase B	1.00	1.00	1.00	1.00

5.6. Comparación del desempeño en los modelos del clasificador binario

En esta sección se muestra el desempeño del modelo del clasificador binario a través de los resultados de las Tablas 5.26 y 5.27. En las tablas se compara el promedio de la exactitud de los datos de prueba y el tiempo de entrenamiento y de prueba para cada uno de los algoritmos que utilizó el modelo. A velocidad fija, los tres primeros algoritmos de la Tabla 5.26 presentan un buen desempeño; a velocidad variable, sólo dos de los algoritmos de la Tabla 5.27 mantienen el mismo desempeño.

Los algoritmos de la regresión logística y el perceptrón de una sola capa presentan el desempeño más bajo del modelo, debido a su estructura relativamente simple. La utilización de estos algoritmos en este trabajo fue para comparar y valorar el desempeño del modelo, con algoritmos de los más simples a los más complejos.

El modelo del perceptrón multicapa, no mantiene el mismo desempeño considerando los datos a velocidad fija y variable, a pesar de que en su entrenamiento se utilizó la validación cruzada y la búsqueda exhaustiva de hiperparámetros, el error en las predicciones tiende a ser mayor con cambios de la velocidad del GSIP, se debe considerar un esquema más complejo en el manejo de las redes neuronales o un método alternativo de optimización que mejore su desempeño. Su tiempo de entrenamiento y prueba es el más elevado de los cinco algoritmos utilizados en el modelo del clasificador binario.

En los modelos del árbol de decisión y bosques aleatorios se presenta el mejor desempeño de los cinco algoritmos; los tiempos de entrenamiento y prueba son menores que los de las redes neuronales, además de que son algoritmos relativamente más robustos a la variación de datos.

Tabla 5.26. Desempeño del modelo del clasificador binario a 200 rpm.

Algoritmo	Clases	Accuracy (%)	Tiempo (s)
Bosques aleatorios	2	97.2	0.197
Árbol de decisión	2	94.2	3.102
Perceptrón multicapa	2	94.6	12.583
Regresión logística	2	76.2	0.581
Perceptrón	2	58.0	4.590

Tabla 5.27. Desempeño del modelo del clasificador binario a velocidad variable.

Algoritmo	Clases	Accuracy (%)	Tiempo (s)
Bosques aleatorios	2	96.1	0.287
Árbol de decisión	2	92.3	4.220
Perceptrón multicapa	2	76.0	13.495
Regresión logística	2	60.0	0.786
Perceptrón	2	55.4	5.231

Capítulo 6

Conclusiones y trabajos futuros

6.1 Conclusiones

En la búsqueda de un diagnóstico confiable y con una estructura relativamente simple, se desarrolla una técnica no invasiva en un GSIP de 400 W que utiliza modelos con base en la transformada ondeleta Haar y Daubechies 4 como extractores de características y métodos de aprendizaje automático como clasificador binario, para la detección de fallas de cortocircuito en algunas vueltas del estator del GSIP. La implementación de la transformada Haar o Daubechies 4 en las bandas de frecuencia asociadas a la falla presenta una variación en el valor eficaz de sus coeficientes al considerar la condición sin falla y con la falla de vueltas en c.c. del estator. El resultado anterior contribuye de manera significativa al proceso de clasificación binaria. El modelo del clasificador binario emplea los algoritmos de la regresión logística, el perceptrón de una sola capa, el perceptrón multicapa, el árbol de decisiones y los bosques aleatorios. Con un análisis de la estructura menos compleja a más compleja de los algoritmos de clasificación binaria, se validaron los resultados del modelo con los datos provenientes del extractor de características conformado por el valor eficaz de las componentes de las tendencias y fluctuaciones de la transformada ondeleta. Se utilizaron los datos con dos velocidades del GSIP de 400 W, una velocidad fija y una velocidad variable. La falla entre vueltas de c.c. se utilizó de forma progresiva en el modelo de clasificación binaria. Se utilizó la validación cruzada, el manejo de la búsqueda exhaustiva de hiperparámetros, el aprendizaje por ensamble y el voto mayoritario en los modelos de clasificación binaria. Se emplearon principalmente las métricas de la exactitud, las curvas ROC y la matriz de confusión para validar el desempeño de los modelos.

El desempeño del modelo con los algoritmos de la regresión logística y el perceptrón es de regular a bajo. A pesar de que puede detectar fallas incipientes de pocas vueltas con velocidad fija, su estructura relativamente simple no le permite la robustez que demanda el diagnóstico del GSIP. El desempeño del modelo con el algoritmo del perceptrón multicapa se observó un buen desempeño ante la falla más incipiente del GSIP y con velocidad fija. En la comparativa durante la validación, frente a la regresión logística y el perceptrón, el modelo supera en sensibilidad el diagnóstico ante las diferentes fallas en el GSIP. El desempeño del modelo con velocidad variable es regular, pese a las técnicas de optimización utilizadas en la red neuronal. Fue el algoritmo con mayor tiempo empleado en el entrenamiento y prueba de los cinco utilizados en el modelo de clasificación binaria.

Los árboles de decisión procesan el conjunto de datos utilizando un criterio de selección en cada nodo, a partir de las características que ingresan al modelo. En un primer modelo con el árbol de decisión se utilizaron el índice de Gini y la entropía como criterios de selección; la validación del modelo mediante la métrica de exactitud fue similar para ambos criterios y en los diferentes conjuntos de datos. A pesar de que el algoritmo del árbol de decisión permite procesar un conjunto de datos no tan extenso, los resultados muestran que, al validar el modelo con cambios en el conjunto de datos debido a las fallas, se observa un sobreajuste. Para reducir el sobreajuste del modelo, se utilizó en el árbol de decisión la validación cruzada, con una partición de los datos en 5 subconjuntos. Adicionalmente, se utilizó el ajuste de los hiperparámetros mediante el método de búsqueda exhaustiva, en el que se emplearon dos criterios de selección: la profundidad del árbol y el número de hojas, así como los datos mínimos a cada nodo. El sobreajuste del modelo se redujo y el desempeño mejoró. Sin embargo, el modelo sigue siendo susceptible al cambio de la proporción de datos entre entrenamiento y prueba, así como a cambios en la velocidad del GSIP. Con respecto a los resultados de las métricas utilizadas en el modelo, indican un buen desempeño con la velocidad fija y una reducción en su desempeño con la velocidad variable. En una siguiente etapa se utilizó el método de aprendizaje por ensamble, donde a través de varios modelos que emplean el algoritmo del árbol de decisiones se unen para generar un modelo más grande denominado bosques aleatorios. A pesar de que cada modelo tiene como base el árbol de decisión, la conformación del bosque puede ser de árboles con diferentes tamaños y entrenados con porciones de datos diferentes. Los bosques aleatorios al utilizar la técnica de “bagging” mejoran la robustez del modelo. Las métricas indican un muy buen desempeño del modelo con este algoritmo tanto con la velocidad fija como con la velocidad variable. En general permiten al algoritmo no tener susceptibilidad al cambio del conjunto de datos, es más robusto y su implementación es relativamente simple comparada con una red neuronal. Se puede convertir en la combinación más adecuada del extractor de características y el clasificador binario para ser implementada en el modelo que permita el monitoreo y diagnóstico en línea del GSIP.

6.2 Trabajos futuros

Con base en el desarrollo en el proyecto de investigación se proponen las siguientes etapas para trabajos futuros:

- Modificar el número de datos a procesar en el extractor de características que impacten directamente en el clasificador y probar con otros algoritmos de aprendizaje automático.

- Implementar la transformada Hilbert-Huang o una transformada compleja como extractor de características, para evaluar el desempeño e impacto en los clasificadores binarios ya analizados.
- Adquirir las señales de corriente con diferentes perfiles de velocidad variables en el banco de pruebas del GSIP, que permitan valorar el desempeño del extractor de características y el clasificador binario en presencia de las fallas incipientes de vueltas en c.c. en el estator del GSIP.
- Implementar el aprendizaje por ensamble en el clasificador binario, que permita con una estructura simple de los algoritmos de aprendizaje la detección de las fallas incipientes de c.c. en el estator del GSIP.
- Implementar los algoritmos del extractor de características y el clasificador para realizar un diagnóstico del GSIP en tiempo real.
- Implementar la detección y discriminación de fallas mixtas, eléctricas-mecánicas en el GSIP.

6.3 Artículos publicados

Derivado del trabajo realizado a lo largo del programa de Doctorado en Ciencias de la Ingeniería en el TecNm Instituto Tecnológico de Aguascalientes, se han generado los siguientes productos de la investigación:

Artículos de congreso

- Álvarez-Salas, J.A., Villalobos-Pina, F. J., Gonzalez-Garcia, M., Álvarez-Salas, R., Morones-Alba, J.A., & Rodríguez-Cobos, A. "Desarrollo de un banco de pruebas para el diagnóstico de fallas en el estator de un generador síncrono de imanes permanentes". Semana Nacional de Ingeniería Electrónica (SENIE) 2023.
- Álvarez-Salas, J.A., Villalobos-Pina, F. J., Gonzalez-Garcia, M., Álvarez-Salas, R., Cardenas-Galindo V., "Stator fault diagnosis of a permanent magnet synchronous generator using a decision tree classifier
- ". Congreso Nacional de Control Automático (CNCA) 2024.

Artículos en revistas arbitradas

- Álvarez-Salas, J.A., Villalobos-Pina, F. J., Gonzalez-Garcia, M., Álvarez-Salas, R., Molina-Contreras, J.R., & Rodríguez-Cobos, A. "La regresión logística como clasificador en el diagnóstico de fallas eléctricas en un generador síncrono de imanes permanentes". Científica, vol. 29, núm. 1, pp. 01-18, enero-junio 2025, ISSN 2594-2921, DOI: 10.46842/ipn.cien.v29n1a04.

Artículos en revistas indexadas

- Alvarez-Salas, J.A.; Villalobos-Pina, F.J.; Gonzalez-Garcia, M.A.; Alvarez-Salas, R. Interturn Short-Circuit Fault Diagnosis in a Permanent Magnet Synchronous Generator Using Wavelets and Binary Classifiers. *Processes* 2026, 14, 377. <https://doi.org/10.3390/pr14020377>

Trabajos de divulgación científica

- Ponencia en la 4th Ph.D. Mexican Summer School on Power Electronics September 11, 2024 "Diagnóstico de Fallas Eléctricas en un Generador Síncrono de Imanes Permanentes".

Apéndice A

Modificación del estator en el GSIP de 600 y 400 W

A1. GSIP de 600 W.

El devanado de la fase A consta de 12 bobinas por fase. En cada fase, el proceso de rebobinado se realizó en tres secciones de cuatro bobinas, debido a la fabricación del molde de la bobina. En esta fase no se modificaron las bobinas. El devanado de la fase B consta de 12 bobinas por fase. En esta fase se incorporaron cuatro derivaciones en dos de las cuatro secciones que conforman la fase B. El devanado de la fase C consta de 12 bobinas por fase. En esta fase se incorporaron cuatro derivaciones en una de las cuatro secciones que conforman la fase C. En la Figura A1 se muestran las secciones que conforman cada una de las fases del estator.




Figura A1. Secciones de las fases del circuito del estator.

En la Figura A2 se muestra la sección de una fase, la cual se forma por cuatro bobinas con 63 vueltas por bobina. Esta configuración se realizó en tres secciones, debido a que el molde para su construcción es más práctico al quedar conformado por cuatro bobinas en serie como se indica en la Figura A3. Este molde toma en cuenta las dimensiones y el número de vueltas de las bobinas originales. Una vez construidas las secciones, se unen entre sí para formar las 12 bobinas por fase con un total de 756 vueltas en la fase.




Figura A2. Bobinas que conforman una sección de una fase.




Figura A3. Molde para la construcción de las bobinas.

Cada una de las bobinas se amarró con hilo para que en el montaje en su respectiva ranura no se muevan las vueltas que la conforman. En la Figura A4 se muestran las bobinas que incluyen las derivaciones con las terminales para simular las fallas de cortocircuito en parte de las vueltas de la bobina. Estas terminales se marcaron con la bobina y sección en la cual se realizó la derivación.




Figura A4. Bobinas construidas con derivaciones.

En la Tabla A1 se concentran las derivaciones que se generaron en cada una de las fases del devanado del estator. A la fase A no se le incluyeron derivaciones, en la

fase B se incluyeron 4 derivaciones o “taps” en dos de las secciones que conforman la fase y en la fase C sólo en la sección cercana a la estrella se incluyeron las derivaciones. En la Tabla A2 se incluye el porcentaje de vueltas por fase en el cual se obtuvieron las terminales de las derivaciones para simular la falla del cortocircuito.

Tabla A1. Distribución de las derivaciones en las fases del estator.

Fase A	Fase B	Fase C
Sin modificación de la fase	Derivación_1-S1 Derivación_2-S1 Derivación_3-S1 Derivación_4-S1 Derivación_1-S2 Derivación_2-S2 Derivación_3-S2 Derivación_4-S2	Derivación_1 Derivación_2 Derivación_3 Derivación_4

Tabla A2. Derivaciones en las fases del devanado del estator.

% de vueltas/fase	# de vueltas/fase
2	15
6	45
10	75
14	105

Una vez que se realizó la modificación de las bobinas con las derivaciones en cada una de las fases del GSIP de 600 W, se procede a la reconstrucción del estator. En la Figura A5 se muestra el núcleo en el cual se realiza el acomodo del papel aislante en cada una de las ranuras que alojan las bobinas del estator; este papel permite proteger a las bobinas del contacto eléctrico con el núcleo del estator.

En la Figura A6 se muestra el proceso de montaje de las bobinas en grupo que fueron construidas. Su acomodo debe cuidar de no dañar las bobinas al ingresar en las ranuras del núcleo del estator.

En la Figura A7 se muestra el montaje de las secciones con la conexión interna en cada una de las fases del devanado de la armadura. Estas conexiones le permiten la continuidad en las tres secciones que conforman la fase, como se indica en la Figura A2. En esta etapa se realiza el acomodo del papel aislante sobre la ranura que contiene las bobinas y se preparan las terminales de las fases y derivaciones para etiquetarlas y aislarlas. En la Figura A8 se muestra el etiquetado de estas terminales que pueden corresponder a una derivación o a una de las fases del estator. Las fases se conectan en estrella y se deriva un conductor para tener acceso al neutro, al cual en la configuración original de la máquina no se tenía acceso.



Figura A5. Acomodo el papel aislante en las ranuras del núcleo.




Figura A6. Montaje de las bobinas modificadas en el núcleo.



Figura A7. Montaje de las bobinas modificadas en el núcleo.



Figura A8. Estructura del devanado con sus derivaciones.

En la Figura A9 se muestra el amarre y acomodo de todo el devanado del estator. Las terminales tanto de las fases como de las derivaciones deben comprimirse, ya que en las tapas no deben ocupar espacio que impida el montaje del generador. En esta etapa una vez unido todo el devanado, pasa por un proceso de barnizado para mejorar el aislamiento de todo el estator y no generar vibraciones durante su operación. El estator de la Figura A9 queda listo para el montaje y prueba del GSIP de 600 W.



Figura A9. Estructura del devanado del estator después de la modificación.

En la Tabla A1 se indican las posibles combinaciones empleadas entre las derivaciones de la fase C en el GSIP de 600 W, para la medición de las resistencias. En la Tabla A3 se indica el cortocircuito entre la derivación y la conexión a neutro.

Tabla A3. Vueltas en c.c. entre la derivación y el neutro de la fase C.

#	Derivación	Vueltas
0	Sin derivación	0
1	#1-neutro	15
2	#2- neutro	45
3	#3-neutro	75
4	# 4-neutro	105

De acuerdo con la Tabla A4, la fase C cuenta con cuatro derivaciones que permiten hacer combinaciones de cortocircuitos (c.c.) entre el número de vueltas de la fase.

Tabla A4. Vueltas en c.c. entre las derivaciones de la fase C.

	Derivación	Vueltas
0	Sin derivación	0 vueltas
1	#1 - #2	30 vueltas
2	#1 - #3	60 vueltas
3	#1 - #4	90 vueltas

En la Figura A10 se muestra la conexión del c.c. entre derivaciones de la misma fase C. En esta conexión se reduce la resistencia por fase del estator del GSIP.




Figura A10. Conexión del c.c. en la fase C.

A2. GSIP de 400 W.

En la Tabla A5 se indica la estructura del estator del GSIP de 400 W. El GSIP ha sido empleado previamente en pruebas para la detección de fallas de c.c., ya que cuenta con derivaciones como se indica en la Figura A11. Dos fases han sido modificadas con derivaciones de 1 a 7 vueltas en c.c. de las fases del GSIP.

En la Tabla A6 se indican las derivaciones y el número de vueltas que tiene el GSIP. A partir de estas configuraciones se puede realizar una combinación en cada fase o entre fases para generar fallas de c.c. que modifiquen las señales de voltaje y corriente.

En las Tablas A7 y A8 de las fases A y B se indican las posibles combinaciones entre las derivaciones y el neutro y entre derivaciones de la misma fase. No todas las combinaciones son posibles de emular un c.c. entre vueltas, ya que eso depende de cómo los conductores compartan una ranura de una misma fase o entre fases

Tabla A5. Valores del estator del GSIP de 400 W.

Número de ranuras	Paso de la bobina (ranuras)	Número de bobinas/fase	Número de vueltas/bobina	Calibre de conductor	Tipo de devanado
36	4	12	18	19	ondulado/doble capa




Figura A11. Conexión del devanado de armadura con las derivaciones en las fases.

Tabla A6. Derivaciones en las fases del GSIP de 400 W.

Fase	Núm. de derivación	Núm. de vueltas	Fase	Núm. de derivación	Núm. de vueltas
A	1	1v	B	1	1v
	2	1v		2	1v
	3	4v		3	2v
	4	4v		4	2v
	5	7v		5	4v
	6	7v		6	4v

Tabla A7. Vueltas en c.c. entre la derivación y el neutro de las fases A y B.

Fase A			Fase B		
0	Sin derivación	0 vueltas	0	Sin derivación	0 vueltas
1	1v-neutro	1 vuelta	1	1v-neutro	1 vuelta
2	4v- neutro	4 vueltas	2	2v- neutro	2 vueltas
3	7v-neutro	7 vueltas	3	4v-neutro	4 vueltas

Tabla A8. Vueltas en c.c. entre las derivaciones de las fases A y B.

Fase A			Fase B		
0	Sin derivación	0 vueltas	0	Sin derivación	0 vueltas
1	1v-4v	3 vueltas	1	1v-2v	1 vuelta
2	1v- 7v	6 vueltas	2	2v-4v	2 vueltas
3	4v-7v	3 vueltas	3	2v-4v	2 vueltas

Apéndice B

Datos y banco de pruebas del GSIP

B1. Banco de pruebas del GSIP de 400 W

En la Figura B1 se muestra el diagrama a bloques de cada uno de los elementos del banco de pruebas para el GSIP que se reportó en [76]. Los elementos básicos para el funcionamiento del banco son los siguientes:

- Generador síncrono de imanes permanentes de 400 W, con derivaciones en c.c. en el circuito del estator.
- Motor de corriente directa de 1 kW con un convertidor cd-cd, cuya función equivale a una turbina que impulsa al GSIP de 400 W.
- Convertidor cd-cd (chopper) para el motor de corriente directa.
- Un sistema de control en base al dsPIC30F4011, que se comunica a la computadora personal por medio de USB.
- Sensores de corriente de efecto Hall, circuito acondicionador de señales y tarjeta de control que adquieren y acondicionan las señales de corriente.
- Computadora personal, para el control y procesamiento de las señales de corriente y del motor de corriente directa.
- Carga resistiva conectada a las terminales del estator del GSIP de 400 W.




Figura B1. Banco de pruebas del GSIP de 400 W.

En la Tabla B1 se indican los valores del proceso de adquisición de las señales de corriente del GSIP

de acuerdo con lo que se reporta en [76]. Considerando dos velocidades de operación de 200 y 400 rpm, se dispone de un conjunto de archivos en formato de texto con 960 adquisiciones de las tres señales de corriente del GSIP de 400 W. Se realizó la repetición de la adquisición 30 veces por cada uno de los escenarios de falla en c.c. y en condiciones de simetría.

Tabla B1. Valores utilizados en el proceso de adquisición de las señales de corriente.

Amplitudes (A)	F_{señal} (Hz)	F_{muestreo} (kHz)	N (muestras)
2	20/40	1	50

En la Figura B2 se muestra una imagen del banco de pruebas con algunas modificaciones como el acoplamiento del generador-motor, las conexiones de las derivaciones y el sistema de control del motor de cd.




Figura B2. Imagen del banco de pruebas del GSIP de 400 W.

Referencias

- [1] I. Boldea, "Electric generators and motors: An overview", *CES Trans. Electr. Mach. Syst.*, vol. 1, no. 1, pp. 3–14, 2020, doi: 10.23919/tems.2017.7911104.
- [2] J. Zhang, Z. Xu, J. Wang, J. Zhao, Z. Din, ja M. Cheng, "Detection and Discrimination of Incipient Stator Faults for Inverter-Fed Permanent Magnet Synchronous Machines", *IEEE Trans. Ind. Electron.*, vol. 68, no. 8, pp. 7505-7515, 2021, doi: 10.1109/TIE.2020.3009563.
- [3] S. H. Kia, H. Henao, ja G.-A. Capolino, "Efficient digital signal processing techniques for induction machines fault diagnosis", *2013 IEEE Workshop on Electrical Machines Design, Control and Diagnosis (WEMDCD)*, 2013, pp. 232-246. doi: 10.1109/WEMDCD.2013.6525183.
- [4] S. Choi *et al.*, "Fault diagnosis techniques for permanent magnet AC machine and drives-A review of current state of the art", *IEEE Trans. Transp. Electrification*, vol. 4, no. 2, pp. 444-463, 2018, doi: 10.1109/TTE.2018.2819627.
- [5] S. H. Kia, H. Henao, and G. A. Capolino, "Survey of real-time fault diagnosis techniques for electromechanical systems", *Proc. - 2017 IEEE Workshop on Electrical Machines Design, Control and Diagnosis, WEMDCD 2017*, pp. 290-297, 2017, doi: 10.1109/WEMDCD.2017.7947761.
- [6] H. A. Toliyat, S. Nandi, S. Choi, and H. Meshgin-Kepp. *Electric Machines Modeling, Condition Monitoring, and Fault Diagnosis*. USA: CRC Press, 2013. doi: 10.1201/b13008-1.
- [7] A. Stetco *et al.*, "Machine learning methods for wind turbine condition monitoring: A review", *Renewable Energy*, vol. 133, pp. 620-635, 2019, doi: 10.1016/j.renene.2018.10.047.
- [8] Hu, X.; Tang, T.; Tan, L.; Zhang, H. Fault Detection for Point Machines: A Review, Challenges, and Perspectives. *Actuators* 2023, 12, 391.
- [9] Z. Liu ja L. Zhang, "A review of failure modes, condition monitoring and fault diagnosis methods for large-scale wind turbine bearings", *Meas. J. Int. Meas. Confed.*, vol. 149, pp. 107002, 2020, doi: 10.1016/j.measurement.2019.107002.
- [10] H. Henao *et al.*, "Trends in fault diagnosis for electrical machines: A review of diagnostic techniques", *IEEE Ind. Electron. Mag.*, vol. 8, no. 2, pp. 31-42, 2014, doi: 10.1109/MIE.2013.2287651.
- [11] G. Helbing ja M. Ritter, "Deep Learning for fault detection in wind turbines", *Renew. Sustain-Energy Rev.*, vol. 98, no. September, pp. 189–198, 2018, doi: 10.1016/j.rser.2018.09.012.
- [12] W. Lee ja G. Choi, "A Comprehensive Review of Fault-Tolerant AC Machine Drive Topologies: Inverter, Control, and Electric Machine", *2021 IEEE 13th Int. Symp. Diagnostics Electr. Mach. Power Electron. Drives, SDEMPED 2021*, pp. 269-275, 2021, doi: 10.1109/SDEMPED51010.2021.9605560.

-
- [13] M.K.H. Toliyat, Hamid A., Nandi Subhasis, Choi Seungdeog, "Application of Pattern Recognition to Fault Diagnosis", *Electric Machines Modeling, Condition Monitoring and Fault Diagnosis*, C. Press, Toim USA: Taylor and Francis Group, 2015, pp. 185.
 - [14] K. Fischer, F. Besnard, and L. Bertling, "Reliability-centered maintenance for wind turbines based on statistical analysis and practical experience", *IEEE Trans. Energy Convers.*, vol. 27, no. 1, pp. 184-195, 2012, doi: 10.1109/TEC.2011.2176129.
 - [15] S. Karmakar, S. Chattopadhyay, M. Mitra, and S. Sengupta, "Induction Motor Fault Diagnosis Approach Through Current Signature Analysis", 1a Ed. India: Springer, 2016. doi: 10.1007/978-981-10-0624-1.
 - [16] W. R. Jensen, E. G. Strangas, and S. N. Foster, "A Method for Online Stator Insulation Prognosis for Inverter-Driven Machines", *IEEE Trans. Ind. Appl.*, vol. 54, no. 6, pp. 5897-5906, 2018, doi: 10.1109/TIA.2018.2854408.
 - [17] A. Mohammed ja S. Djurovic, "Electric Machine Bearing Health Monitoring and Ball Fault Detection by Simultaneous Thermo-Mechanical Fibre Optic Sensing", *IEEE Trans. Energy Convers.*, vol. 36, no. 1, pp. 71-80, 2021, doi: 10.1109/TEC.2020.3003793.
 - [18] Z. Mei, G. J. Li, Z. Q. Zhu, R. Clark, A. Thomas, and Z. Azar, "Scaling Effect On Inter-Turn Short-Circuit Fault of PM Machines for Wind Power Application", *IEEE Trans. Ind. Appl.*, vol. 59, no. 1, pp. 789-800, 2023, doi: 10.1109/TIA.2022.3211249.
 - [19] Z. T. Mei, G. J. Li, Z. Q. Zhu, R. Clark, A. Thomas, and Z. Azar, "Scaling Effect on Inter-Turn Short-Circuit of PM Machines for Wind Power Application", *2021 IEEE Int. Electr. Mach. Drives Conf. IEMDC 2021*, 2021, doi: 10.1109/IEMDC47953.2021.9449606.
 - [20] A. Mohammed ja S. Djurović, "FBG Thermal Sensing Ring Scheme for Stator Winding Condition Monitoring in PMSMs", *IEEE Trans. Transp. Electr.*, vol. 5, no. 4, pp. 1370-1382, 2019, doi: 10.1109/TTE.2019.2945523.
 - [21] S. K. Pradhan and R. K. Srivastava, "Analysis of PMSG under stator turn-to-turn fault using winding function theory", *2013 IEEE 1st Int. Conf. Cond. Assess. Tech. Electr. Syst. IEEE CATCON 2013 - Proc.*, pp. 116-121, 2013, doi: 10.1109/CATCON.2013.6737483.
 - [22] G. Forstner, A. Kugi, and W. Kemmetmuller, "A Magnetic Equivalent Circuit Based Modeling Framework for Electric Motors Applied to a PMSM with Winding Short Circuit", *IEEE Trans. Power Electron.*, vol. 35, no. 11, pp. 12285-12295, 2020, doi: 10.1109/TPEL.2020.2986042.
 - [23] W. El Sayed, A. Aboelhassan, A. Madi, A. Hebala, and M. Galea, "Comparative analysis between unscented and extended Kalman filters for PMSG inter-turn fault detection", *Proc. - 2021 IEEE Work. Electr. Mach. Des. Control Diagnosis*,

-
- WEMDCD 2021, pp. 243-248, 2021, doi: 10.1109/WEMDCD51469.2021.9425684.
- [24] W. Wafik, M. A. El-Geliel, and A. Lotfy, "PMSG fault diagnosis in marine application", *2016 20th Int. Conf. Syst. Theory, Control Comput. ICSTCC 2016 - Jt. Conf. SINTES 20, SACCS 16, SIMSIS 20 - Proc.*, pp. 626-631, 2016, doi: 10.1109/ICSTCC.2016.7790736.
- [25] H. Chen, J. He, X. Guan, N. A. O. Demerdash, A. M. El-Refaie, ja C. H. T. Lee, "High-Resistance Connection Diagnosis in Five-Phase PMSMs Based on the Method of Magnetic Field Pendulous Oscillation and Symmetrical Components", *IEEE Trans. Ind. Electron.*, vol. 69, no. 3, pp. 2288-2299, 2022, doi: 10.1109/TIE.2021.3065617.
- [26] M. Bouzid, I. Bahloul, and S. Khojet El Khil, "Reliable and Robust Inter-turn Short-Circuit Fault Detection in PMSG without confusion with Healthy Operating under Load Unbalance", *2021 IEEE 13th Int. Symp. Diagnostics Electr. Mach. Power Electron. Drives, SDEMPED 2021*, pp. 372-378, 2021, doi: 10.1109/SDEMPED51010.2021.9605551.
- [27] C. Ma, J. Li, N. Zhang, F. Bu, and Z. Yang, "Open-Circuit Radial Stray Magnetic Flux Density Based Noninvasive Diagnosis for Mixed Eccentricity Parameters of Interior Permanent Magnet Synchronous Motors in Electric Vehicles", *IEEE Trans. Ind. Electron.*, vol. 70, no. 2, pp. 1983-1992, 2023, doi: 10.1109/TIE.2022.3165250.
- [28] K. N. Gyftakis *et al.*, "Fast Determination of Transient Short-Circuit Current of PM Synchronous Machines Via Magnetostatic Flux Maps", *IEEE Trans. Ind. Electron.*, vol. 70, no. 3, pp. 5192-5202, 2023, doi: 10.1109/TIA.2022.3211249.
- [29] J. Yang, Y. Wang, W. Zhang, Z. Dai, Z. Zhang, and K. Xiangli, "Modeling and Fault Diagnosis of Multi-phase Winding Inter-turn Short Circuit for Five-phase PMSM based on Improved Particle Swarm Optimization", *2020 IEEE 9th Int. Power Electron. Motion Control Conf. IPEMC 2020 ECCE Asia*, pp. 1967-1972, 2020, doi: 10.1109/IPEMC-ECCEAsia48364.2020.9367859.
- [30] K. Ahsanullah, S. K. Panda, R. Shanmukha, and S. Nadarajan, "Inter-turns fault diagnosis for surface permanent magnet-based marine propulsion motors", *2016 IEEE 2nd Annu. South. Power Electron. Conf. SPEC 2016*, vol. 400, no. 1, pp. 1-6, 2016, doi: 10.1109/SPEC.2016.7846131.
- [31] I. H. Kao, W. J. Wang, Y. H. Lai, and J. W. Perng, "Analysis of Permanent Magnet Synchronous Motor Fault Diagnosis Based on Learning", *IEEE Trans. Instrum. Meas.*, vol. 68, no. 2, pp. 310-324, 2019, doi: 10.1109/TIM.2018.2847800.
- [32] A. Alloui, K. Laadjal, M. Sahraoui, and A. J. Marques Cardoso, "Online Interturn Short-Circuit Fault Diagnosis in Induction Motors Operating Under Unbalanced Supply Voltage and Load Variations, Using the STLSP Technique", *IEEE Trans. Ind. Electron.*, vol. 70, no. 3, pp. 3080-3089, 2023, doi:

- 10.1109/TIE.2022.3172751.
- [33] G. Zanuso, S. L. S. Kumar, and L. Peretti, "Interturn Fault Detection in Induction Machines Based on High-Frequency Injection", *IEEE Trans. Ind. Electron.*, vol. 70, no. 10, pp. 10639-10647, 2023, doi: 10.1109/TIE.2022.3217590.
 - [34] P. Chen, Y. Xie, ja S. Hu, "Electromagnetic Performance and Diagnosis of Induction Motors with Stator Interturn Fault", *IEEE Trans. Ind. Appl.*, vol. 57, no. 2, pp. 1354-1364, 2021, doi: 10.1109/TIA.2020.3043214.
 - [35] G. S. y M. M. R. Verde Cristina, "Monitoreo y Diagnóstico Automático de Fallas en Sistemas Dinámicos". UNAM, Cd. de México, pp. 248, 2011.
 - [36] W. Yang, P. J. Tavner, and M. Wipp. Inson, "Condition monitoring and fault diagnosis of a wind turbine with a synchronous generator using wavelet transforms", *IET Conf. Publ.*, no. 538 CP, pp. 6-10, 2008, doi: 10.1049/cp:20080473.
 - [37] S. Halder, S. Bhat, C. Bhaumik, and R. Rakshit, "Stator Inter- Turn Fault Diagnosis in Permanent Magnet Synchronous Motor", *Proc. 2020 IEEE 1st Int. Conf. Smart Technol. Power, Energy Control. STPEC 2020*, pp. 3-8, 2020, doi: 10.1109/STPEC49749.2020.9297677.
 - [38] J. Hang, J. Zhang, M. Xia, S. Ding, and W. Hua, "Interturn Fault Diagnosis for Model-Predictive-Controlled-PMSM Based on Cost Function and Wavelet Transform", *IEEE Trans. Power Electron.*, vol. 35, no. 6, pp. 6405-6418, 2020, doi: 10.1109/TPEL.2019.2953269.
 - [39] P. Pietrzak, M. Woppiewicz, and T. Orłowska-Kowalska, "PMSM Stator Winding Fault Detection and Classification Based on Bispectrum Analysis and Convolutional Neural Network", *IEEE Trans. Ind. Electron.*, vol. 70, no. 5, pp. 5192-5202, 2022, doi: 10.1109/TIE.2022.3189076.
 - [40] T. Goktas, M. Arkan, and V. Gurusamy, "A Comparative Study of Current, Vibration and Stray Magnetic Flux Based Detection for Parallel Misalignment Fault in Induction Motors", *2021 IEEE 13th Int. Symp. Diagnostics Electr. Mach. Power Electron. Drives, SDEMPED 2021*, no. c, pp. 11-16, 2021, doi: 10.1109/SDEMPED51010.2021.9605507.
 - [41] S. Kumar *et al.*, "A Comprehensive Review of Condition-Based Prognostic Maintenance (CBPM) for Induction Motor", *IEEE Access*, vol. 7, pp. 90690-90704, 2019, doi: 10.1109/ACCESS.2019.2926527.
 - [42] S. Zhang, O. Wallscheid, and M. Porrmann, "Machine Learning for the Control and Monitoring of Electric Machine Drives: Advances and Trends", *IEEE Open J. Ind. Appl.*, vol. 4, no. May, pp. 188-214, 2023, doi: 10.1109/OJIA.2023.3284717.
 - [43] P. Pietrzak and M. Woppiewicz, "Application of Support Vector Machine to stator winding fault detection and classification of permanent magnet synchronous motor", *Proc. - 2021 IEEE 19th Int. Power Electron. Motion Control*

-
- Conf. PEMC 2021*, pp. 880-887, 2021, doi: 10.1109/PEMC48073.2021.9432629.
- [44] D. Saha, M. E. Hoque, and M. E. H. Chowdhury, "Enhancing Bearing Fault Diagnosis Using Transfer Learning and Random Forest Classification: A Comparative Study on Variable Working Conditions", *IEEE Access*, vol. 12, no. November 2023, pp. 5986-6000, 2024, doi: 10.1109/ACCESS.2023.3347345.
 - [45] J. Y. Hsu, Y. F. Wang, K. C. Lin, M. Y. Chen, and J. H. Y. Hsu, "Wind turbine fault diagnosis and predictive maintenance through statistical process control and machine learning", *IEEE Access*, vol. 8, pp. 23427-23439, 2020, doi: 10.1109/ACCESS.2020.2968615.
 - [46] Nitish and A. K. Singh, "Condition Monitoring and Fault Diagnosis Techniques of Electric Machines", *2019 3rd International Conference on Recent Developments in Control, Automation & Power Engineering (RDCAPE)*, 2019, pp. 594-599. doi: 10.1109/RDCAPE47089.2019.8979045.
 - [47] S. K. S. and R. K. S. R. R. Kumar, "Thermal modelling of dual-stator five-phase permanent magnet synchronous generator", *IEEE Transp. Electr. Conf.*, 2017.
 - [48] J. P. Peter J. Tavner, *Condition Monitoring of Electrical Machines*, Second Edition. UK: John Wiley and Sons Inc., 1987.
 - [49] A. H. Bonnet, "Analysis of Winding Failures in Three-Phase Squirrel Cage Induction Motors", *IEEE Trans. Ind. Appl.*, vol. IA-14, no. 3, pp. 223-226, 1978.
 - [50] Z. Nie ja N. Schofield, "Condition monitoring of a permanent magnet synchronous generator for a wind turbine application", *IET Conf. Publ.*, vol. 2016, no. CP684, pp. 1-6, 2016, doi: 10.1049/cp.2016.0233.
 - [51] A. M. and S. T. Monia Ben Khader Bouzid, Gerard Champenois, "Efficient Simplified Physical Faulty Model of a Permanent Magnet Synchronous Generator Dedicated to the Stator Fault Diagnosis Part I: Faulty Model Conception", *IEEE Trans. Ind. Appl.*, vol. 53, no. 3, pp. 2752-2761, 2017.
 - [52] M. G.- Fernández-Cabanas y S.-S. J. Melero Manuel, Alonso-Orcajo Gonzalo, Cano-Rodriguez Jose Manuel, *Técnicas para el mantenimiento y diagnóstico de máquinas eléctricas rotativas*, Primera Ed. Barcelona: Marcombo-ABB, 1998.
 - [53] J. Parmar and P. R. Gandhi, "PMSG-Based Control Strategy for Interconnected Power System", *3rd Int. Conf. Work. Recent Adv. Innov. Eng. ICRAIE 2018*, vol. 2018, no. November, pp. 1-5, 2018, doi: 10.1109/ICRAIE.2018.8710416.
 - [54] A. Tobías-González, R. Peña-Gallardo, J. Morales-Saldaña, A. Medina-Ríos, and O. Anaya-Lara, "A state-space model and control of a full-range PMSG wind turbine for real-time simulations", *Electr. Eng.*, vol. 100, no. 4, pp. 2177-2191, 2018, doi: 10.1007/s00202-018-0691-y.
 - [55] H. Ben Mahdhi, H. Ben Azza, and M. Jemli, "Direct Power Control of a PMSG in Wind Power Conversion System under Faulty Rectifier Conditions", *19th Int. Conf. Sci. Tech. Autom. Control Comput. Eng. STA 2019*, pp. 394-398, 2019, doi: 10.1109/STA.2019.8717311.

-
- [56] K. Bunjongjit, "Matlab/Simulink Modeling of Stator Current Control of PMSG for Grid-Connected Systems", no. 3, pp. 3-6, 2014.
- [57] A. Gandhi, T. Corrigan, and L. Parsa, "Recent advances in modeling and online detection of stator interturn faults in electrical motors", *IEEE Trans. Ind. Electron.*, vol. 58, no. 5, pp. 1564-1575, 2011, doi: 10.1109/TIE.2010.2089937.
- [58] Y. Park, H. Choi, S. Bin Lee, and K. N. Gyftakis, "Search Coil-Based Detection of Nonadjacent Rotor Bar Damage in Squirrel Cage Induction Motors", *IEEE Trans. Ind. Appl.*, vol. 56, no. 5, pp. 4748-4757, 2020, doi: 10.1109/TIA.2020.3000461.
- [59] H. Chen, J. He, N. A. O. Demerdash, X. Guan, and C. H. T. Lee, "Diagnosis of Open-Phase Faults for a Five-Phase PMSM Fed by a Closed-Loop Vector-Controlled Drive Based on Magnetic Field Pendulous Oscillation Technique", *IEEE Trans. Ind. Electron.*, vol. 68, no. 7, pp. 5582-5593, 2021, doi: 10.1109/TIE.2020.3000109.
- [60] J. A. Ramirez-Nunez *et al.*, "Evaluation of the Detectability of Electromechanical Faults in Induction Motors Via Transient Analysis of the Stray Flux", *IEEE Trans. Ind. Appl.*, vol. 54, no. 5, pp. 4324-4332, 2018, doi: 10.1109/TIA.2018.2843371.
- [61] S. Tancock, E. Arabul, and N. Dahnoun, "A Review of New Time-To-Digital Conversion Techniques", *IEEE Trans. Instrum. Meas.*, vol. 68, no. 10, pp. 3406-3417, 2019, doi: 10.1109/TIM.2019.2936717.
- [62] M. Albader and H. A. Toliyat, "Wavelet-Based Demodulation: A Diagnostic Method for Reliable Rotor Fault Index", *2021 IEEE 13th Int. Symp. Diagnostics Electr. Mach. Power Electron. Drives, SDEMPED 2021*, vol. 3128, pp. 532-538, 2021, doi: 10.1109/SDEMPED51010.2021.9605526.
- [63] H. Cherif, A. Menacer, B. Bessam, and R. Kechida, "Stator inter-turns fault detection using discrete wavelet transform", *Proc. - SDEMPED 2015 IEEE 10th Int. Symp. Diagnostics Electr. Mach. Power Electron. Drives*, pp. 138-142, 2015, doi: 10.1109/DEMPED.2015.7303681.
- [64] M. Sintoni, A. Bellini, D. Forlivesi, and C. Bianchini, "Rotor fault detection of induction machines with optimal wavelet transform", *Proc. - 2021 IEEE Work. Electr. Mach. Des. Control Diagnosis, WEMDCD 2021*, pp. 283-288, 2021, doi: 10.1109/WEMDCD51469.2021.9425651.
- [65] J. S. Wapper, *A primer on wavelets and their scientific applications, second edition*. 2008.
- [66] A. Paz Parra, M. C. Amaya Enciso, J. Olaya Ochoa, and J. A. Palacios Penaranda, "Stator fault diagnosis on squirrel cage induction motors by ESA and EPVA", *2013 Power Electron. Power Qual. Appl. PEPQA 2013 - Proc.*, 2013, doi: 10.1109/PEPQA.2013.6614937.
- [67] J. A. Reyes-Malanche, F. J. Villalobos-Pina, E. Cabal-Yepez, R. Alvarez-Salas, and C. Rodriguez-Donate, "Open-Circuit Fault Diagnosis in Power Inverters through Currents Analysis in Time Domain", *IEEE Trans. Instrum. Meas.*, vol. 70,

-
- 2021, doi: 10.1109/TIM.2021.3082325.
- [68] J. Mao, F. Chen, B. Jiang, and L. Wang, "Composite fault diagnosis of rotor broken bar and air gap eccentricity based on park vector module and decision tree algorithm", *Proc. 2019 11th CAA Symp. Fault Detect. Supervision, Saf. Tech. Process. SAFEPROCESS 2019*, pp. 701-706, 2019, doi: 10.1109/SAFEPROCESS45799.2019.9213340.
 - [69] A. Choudhary, D. Goyal, and S. S. Letha, "Infrared Thermography-Based Fault Diagnosis of Induction Motor Bearings Using Machine Learning", *IEEE Sens. J.*, vol. 21, no. 2, pp. 1727-1734, 2021, doi: 10.1109/JSEN.2020.3015868.
 - [70] D. Wei, K. Liu, W. Hu, X. Peng, Y. Chen, and R. Ding, "Short-Time Adaline Based Fault Feature Extraction for Inter-Turn Short Circuit Diagnosis of PMSM via Residual Insulation Monitoring", *IEEE Trans. Ind. Electron.*, vol. 70, no. 3, pp. 3103-3114, 2023, doi: 10.1109/TIE.2022.3167164.
 - [71] M. B. Younas, N. Ullah, T. Goktas, M. Arkan, and V. Gurusamy, "The Performance Evaluation of Machine Learning based Techniques via Stator Current and Stray Flux for Broken Bar Fault in Induction Motors", *2021 IEEE 13th Int. Symp. Diagnostics Electr. Mach. Power Electron. Drives, SDEMPED 2021*, pp. 180-185, 2021, doi: 10.1109/SDEMPED51010.2021.9605516.
 - [72] D. T. Hoang ja H. J. Kang, "A Motor Current Signal-Based Bearing Fault Diagnosis Using Deep Learning and Information Fusion", *IEEE Trans. Instrum. Meas.*, vol. 69, no. 6, pp. 3325-3333, 2020, doi: 10.1109/TIM.2019.2933119.
 - [73] X. Wang, J. Guo, ja S. Lu, "A Two-Step Method for PMSG Bearing Fault Recognition under Varying Speed Condition", *Proc. 32nd Chinese Control Decis. Conf. CCDC 2020*, pp. 5102-5106, 2020, doi: 10.1109/CCDC49329.2020.9164543.
 - [74] S. and V. M. Raschka, *Python Machine Learning*, Third Edition. Birmingham, UK: Packt Birmingham-Mumbai, 2019.
 - [75] M. Aishwarya and R. M. Brisilla, "Design and Fault Diagnosis of Induction Motor Using ML-Based Algorithms for EV Application", *IEEE Access*, vol. 11, no. April, pp. 34186-34197, 2023, doi: 10.1109/ACCESS.2023.3263588.
 - [76] M.I. Raúl Arturo Ortiz Medina, "Diagnóstico de Fallas Eléctricas en el Estator de Máquinas Eléctricas de Aerogeneradores", ITA, 2021.