



EDUCACIÓN

SECRETARÍA DE EDUCACIÓN PÚBLICA



TECNOLÓGICO
NACIONAL DE MÉXICO

Tecnológico Nacional de México

Centro Nacional de Investigación
y Desarrollo Tecnológico

Tesis de Doctorado

Algoritmos de procesamiento de señales basados en
el cálculo fraccionario y su aplicación en la
detección, clasificación, cuantificación de disturbios
eléctricos y análisis de la calidad de la energía.

presentada por

M.C. Héctor Martín Cortés Campos

como requisito para la obtención del grado de

**Doctor en Ciencias en Ingeniería
Electrónica**

Director de tesis

Dr. José Francisco Gómez Aguilar

Codirector de tesis

Dr. Carlos Jesús Zúñiga Aguilar

Cuernavaca, Morelos, México. Junio de 2024.

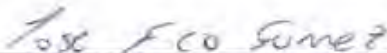
	ACEPTACIÓN DE IMPRESIÓN DEL DOCUMENTO DE TESIS DOCTORAL	Código: CENIDET-AC-006-D20
		Revisión: 0
	Referencia a la Norma ISO 9001:2008 7.1, 7.2.1, 7.5.1, 7.6, 8.1, 8.2.4	Página 1 de 1

Cuernavaca, Mor., a 28 de mayo de 2024

Dr. Carlos Manuel Astorga Zaragoza
Subdirector Académico
Presente
At'n: Dr. Víctor Manuel Alvarado Martínez
Presidente del Claustro Doctoral
del Departamento De Ing. Electrónica

Los abajo firmantes, miembros del Comité Tutorial del estudiante Héctor Martín Cortés Campos manifiestan que después de haber revisado el documento de tesis titulado "ALGORITMOS DE PROCESAMIENTO DE SEÑALES BASADOS EN CÁLCULO FRACCIONARIO Y SU APLICACIÓN EN LA DETECCIÓN, CLASIFICACIÓN, CUANTIFICACIÓN DE DISTURBIOS ELÉCTRICOS Y EN EL ANÁLISIS DE LA CALIDAD DE LA ENERGÍA ", realizado bajo la dirección del Dr. José Francisco Gómez Aguilar y la codirección del Dr. Carlos Jesús Zúñiga Aguilar, el trabajo se ACEPTA para proceder a su impresión.

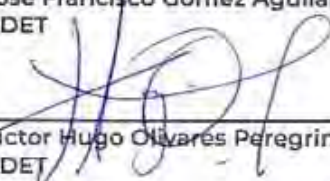
ATENTAMENTE




 Dr. José Francisco Gómez Aguilar
 CENIDET




 Dr. Carlos Jesús Zúñiga Aguilar
 Panzura Data Services



 Dr. Víctor Hugo Olivares Peregrino
 CENIDET



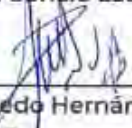
 Dr. Manuel Adam Medina
 CENIDET



 Dr. Ricardo Fabricio Escobar Jiménez
 CENIDET



 Dr. Jarniel García Morales
 CENIDET



 Dr. José Alfredo Hernández Pérez
 UAEM-CIICAp

cc.p/ M.T. Maria Elena Gómez Torres / Jefa del Departamento de Servicios Escolares.
 cc.p/ Dr. Jarniel García Morales / Jefe del Departamento de Ingeniería Electrónica.
 cc.p/ Expediente

Cuernavaca, Mor.,
No. De Oficio:
Asunto:

11/junio/2024
SAC/188/2024
Autorización de impresión de tesis


HÉCTOR MARTÍN CORTÉS CAMPOS
CANDIDATO AL GRADO DE DOCTOR EN CIENCIAS
EN INGENIERÍA ELECTRÓNICA
PRESENTE

Por este conducto, tengo el agrado de comunicarle que el Comité Tutorial asignado a su trabajo de tesis titulado **“ALGORITMOS DE PROCESAMIENTO DE SEÑALES BASADOS EN CÁLCULO FRACCIONARIO Y SU APLICACIÓN EN LA DETECCIÓN, CLASIFICACIÓN, CUANTIFICACIÓN DE DISTURBIOS ELÉCTRICOS Y EN EL ANÁLISIS DE LA CALIDAD DE LA ENERGÍA”**, ha informado a esta Subdirección Académica, que están de acuerdo con el trabajo presentado. Por lo anterior, se le autoriza a que proceda con la impresión definitiva de su trabajo de tesis.

Esperando que el logro del mismo sea acorde con sus aspiraciones profesionales, reciba un cordial saludo.

ATENTAMENTE

Excelencia en Educación Tecnológica
"Conocimiento y tecnología al servicio de México"



CARLOS MANUEL ASTORGA ZARAGOZA
SUBDIRECTOR ACADÉMICO

C. c. p. Departamento de Ingeniería Electrónica
Departamento de Servicios Escolares

CMAZ/lmz

Quiero dedicar esta tesis a mis amados padres Martha y Antonio . . .

Agradecimientos

A Dios por darme la oportunidad de vivir cada uno de estos instantes en mi vida.

A mis padres Martha Leticia Campos y José Antonio Cortes, por todo el amor que han brindado en la vida y por su apoyo continuo.

Al Dr. José Francisco Gómez Aguilar por el tiempo, apoyo, paciencia y conocimiento. Por darme la oportunidad de pertenecer a su grupo de trabajo y aprender herramientas y temas interesantes que me permiten crecer de manera profesional.

Al Dr. Carlos Jesús Zúñiga Aguilar por su apoyo, tiempo, paciencia y consejos que me ayudaron a desarrollarme tanto en mi proceso de posgrado y como persona, muchas gracias.

A mis revisores: Dr. Víctor Hugo Olivares, Dr. Manuel Adam Medina, Dr. Ricardo Fabricio Escobar y Dr. Jarniel García Morales, por su tiempo, comentarios y correcciones lo cuales me han permitido mejorar y enriquecer este trabajo de investigación.

A mis compañeros, Diana, Oyuki, Avelino, Cesar, Felipe, Alberto, Christian, Laura, Karime e Izac esas personas con las que he compartido grandes momentos a lo largo de mi proceso de maestría y doctorado.

A Dinora, Ana, Rocío, Omar y Yasmin, amigos que a lo largo de este proceso me han ayudado y alentado a seguir adelante.

A mis profesores del CENIDET los cuales me brindaron sus enseñanzas y conocimiento para desarrollarme y crecer en el ámbito de la investigación.

Al Centro Nacional de Investigación y Desarrollo Tecnológico (CENIDET) por permitirme crecer en esta institución durante todas las etapas de mi educación de posgrado.

Al Consejo Nacional de Humanidades, Ciencias y Tecnologías (CONAHCYT) por el apoyo económico otorgado mediante la beca doctoral y al tecnológico Nacional de México (TecNM) por facilitar las instalaciones y equipo que permitieron este el desarrollo de este trabajo para la obtención del grado.

Resumen

Desde su invención, las máquinas eléctricas se han convertido en herramientas cruciales para una amplia variedad de aplicaciones y siguen siendo de gran importancia hasta el día de hoy. Las máquinas eléctricas son componentes centrales en la generación, transmisión y distribución de energía eléctrica; por lo tanto, asegurar su correcto estado de funcionamiento es vital para garantizar un rendimiento adecuado.

Las metodologías de detección y diagnóstico de fallas pueden utilizarse para monitorear el estado de las máquinas eléctricas. Estos problemas pueden abordarse con técnicas de clasificación basadas en características de la señal, en las cuales se entrena un modelo de clasificación para encontrar patrones y diferencias entre el comportamiento normal y anormal de una máquina. Idealmente, el modelo entrenado debería ser capaz de etiquetar nuevas señales para el diagnóstico.

Las transformadas integrales se utilizan a menudo para la extracción de características en muchas señales; sin embargo, en algunos casos, las características obtenidas pueden no ser suficientes para distinguir correctamente algunas clases debido a su similitud. Las transformadas integrales de orden fraccionario permiten una representación diferente de la señal que puede utilizarse para obtener más información en comparación con su contraparte de orden entero. Por ejemplo, mientras que la transformada de Fourier permite la descomposición de una señal en componentes de funciones seno, la transformada de Fourier de orden fraccionario generaliza el núcleo de la transformación, descomponiendo la señal en funciones seno de frecuencia variable, lo que permite mostrar más información de la señal analizada.

Este trabajo trata sobre el diagnóstico de fallas en sistemas eléctricos empleando una metodología de reconocimiento de patrones, la cual es equivalente a resolver problemas de clasificación. Se proponen tres algoritmos de procesamiento de señales para la extracción de características: el primero utiliza la transformada de Fourier fraccionario, el segundo realiza una modificación de la matriz de transformación de Fourier clásico con la función de Mittag-Leffler,

y el tercero realiza una descomposición wavelet y, para cada nivel de descomposición, se calcula la energía relativa wavelet en el dominio de Fourier fraccionario.

Se analizaron fallas de cortocircuito en un transformador y un motor de inducción, así como fallas en sistemas fotovoltaicos, disturbios eléctricos y problemas de calidad de energía. Se probaron los distintos algoritmos propuestos y se compararon los desempeños obtenidos por cada conjunto de características para cada sistema, mostrando qué algoritmo ofrece las mejores características para cada uno de los sistemas.

Abstract

Since their invention, electrical machines have become indispensable tools for a multitude of applications, and their importance persists to this day. Electrical machines serve as central components in the generation, transmission, and distribution of electrical power. It is therefore of the utmost importance to ensure that these machines are functioning at their optimal level in order to guarantee adequate performance.

Fault detection and diagnosis methodologies can be employed to monitor the condition of electrical machines. These issues can be addressed through the use of classification techniques based on signal features. In this approach, a classification model is trained to identify patterns and differences between normal and abnormal behavior of a machine. It is desirable that the trained model be capable of labeling new signals for diagnosis.

Integral transforms are frequently employed for feature extraction in a multitude of signals. However, in certain instances, the extracted features may not be sufficiently discriminative to distinguish between classes due to their inherent similarity. Fractional-order integral transforms permit a distinct representation of the signal that can be utilized to obtain more information than its integer-order counterpart. For instance, while the Fourier transform permits the decomposition of a signal into components of sine functions, the fractional-order Fourier transform generalizes the kernel of the transform, decomposing the signal into sine functions of varying frequency, thereby enabling the display of a greater quantity of information about the analyzed signal.

This thesis addresses the issue of fault diagnosis in electrical systems through the lens of pattern recognition methodology, which is analogous to the process of classification. Three signal processing algorithms are proposed for feature extraction. The first algorithm employs the fractional Fourier transform, the second modifies the classical Fourier transform matrix with the Mittag-Leffler function, and the third performs a wavelet decomposition. For each level of decomposition, the relative wavelet energy in the fractional Fourier domain is calculated.

The present study analyzed a number of electrical faults, including those in transformers and induction motors, as well as those in photovoltaic systems, electrical disturbances, and power quality problems. The efficacy of the various proposed algorithms was evaluated through a series of tests, during which the performance of each set of features was assessed for each system. This analysis enabled the identification of the algorithm that offers the most optimal features for each system.

Contenido

Lista de figuras	XIII
Lista de tablas	XVII
Nomenclatura	XIX
1. Introducción	1
1.1. Antecedentes	1
1.2. Estado del arte	3
1.2.1. Diagnóstico de fallas en transformadores	3
1.2.2. Diagnóstico de fallas en motores	4
1.2.3. Diagnóstico de fallas en sistema fotovoltaico	5
1.2.4. Clasificación de disturbios eléctricos en la calidad de la energía	6
1.3. Planteamiento del problema	7
1.4. Hipótesis	8
1.5. Justificación	8
1.6. Objetivos	9
1.6.1. Objetivos específicos	9
1.7. Metas	9
1.8. Estructura del documento	9
2. Fundamentos teóricos	11
2.1. Sistemas eléctricos	11
2.1.1. Máquinas eléctricas	12
2.1.2. Fallas en máquinas eléctricas	15
2.1.3. Sistema fotovoltaico	17

2.1.4. Disturbios eléctricos	18
2.2. Cálculo fraccionario	18
2.3. Transformadas integrales	22
2.3.1. Transformadas clásicas	23
2.3.2. Transformadas Fraccionarias	25
2.4. Algoritmos de diagnóstico de fallas	26
2.5. Clasificación	28
2.5.1. Clasificadores	29
2.6. Algoritmos de optimización	35
2.6.1. Algoritmo de enjambre de partículas (PSO)	35
3. Diseño de algoritmos para el diagnóstico	37
3.1. Metodología general de diagnóstico de fallas	37
3.2. Transformada de Fourier fraccionaria	38
3.3. Transformada de Fourier con kernel de Mittag-Leffler	39
3.4. Descomposición wavelet con transformada de Fourier	41
3.5. Etapa de clasificación	43
3.6. Optimización del orden de α	45
4. Casos de estudio	47
4.1. Diagnóstico de fallas de cortocircuito en transformador	47
4.1.1. Detección y diagnóstico de fallas mediante clasificación jerárquica	56
4.2. Diagnóstico de fallas de cortocircuito en motor de inducción	57
4.3. Diagnóstico de fallas en sistema fotovoltaico	67
4.4. Clasificación de disturbios eléctricos	75
5. Conclusiones y trabajos futuros	83
5.1. Conclusiones	83
5.1.1. Casos de Estudio	83
5.1.2. Aportación	84
5.1.3. Conclusión General	85
5.2. Trabajos futuros	86
Bibliografía	87
Apéndice A. Productos obtenidos	95

Apéndice B. Análisis de la varianza (ANOVA)	97
Apéndice C. Algoritmo Adam para el Entrenamiento de una RNA	99

Lista de figuras

2.1.	Secciones de una máquina eléctrica rotativa.	13
2.2.	Circuito equivalente de un motor de inducción monofásico.	13
2.3.	Circuito equivalente de un generador monofásico.	14
2.4.	Diseño de transformador monofásico.	15
2.5.	Comportamiento de la función de Mittag-Leffler $\beta = 1$ y α variable.	20
2.6.	Funciones wavelet madre comunes.	25
2.7.	Modelo generalizado de diagnóstico mediante el reconocimiento de patrones.	27
2.8.	Clasificador de árbol de decisiones.	29
2.9.	Distribución de características en un clasificador de árbol de decisiones.	30
2.10.	Diagrama de clasificador bosque aleatorio.	30
2.11.	Neurona artificial.	32
2.12.	Matriz de confusión general.	32
3.1.	Metodología para detección y diagnóstico de fallas empleando algoritmos de procesamiento de señales de orden fraccionario.	37
3.2.	Composición de kernel de transformada de Fourier fraccionaria orden $\alpha = 1$	38
3.3.	Composición de kernel de transformada de Fourier fraccionaria orden $\alpha = 0,5$	39
3.4.	Composición de kernel de transformada de Fourier Mittag-Leffler.	41
3.5.	Valores de \mathbf{W}_N^{ML} en $N = 1$	42
3.6.	Valores de \mathbf{W}_N^{ML} en $N = 2$	42
3.7.	Árbol de descomposición wavelet de 3 niveles.	42
3.8.	Arquitectura de la RNA.	44
3.9.	Diagrama de optimización de los órdenes de los operadores.	45
3.10.	Diagrama de implementación de los ordenes óptimos para la extracción de características.	46

4.1. Diagrama de metodología para el diagnóstico de fallas en transformador. . . .	49
4.2. Comparación de corriente del transformador sin carga.	49
4.3. Comparación de corriente del transformador con carga lineal	49
4.4. Comparación de corriente del transformador con una carga mixta.	50
4.5. Comparación de corriente del transformador con carga no lineal	50
4.6. Características extraídas con la transformada de Fourier fraccionaria.	51
4.7. Entrenamiento de la RNA con las características FRFT.	51
4.8. Características extraídas con algoritmo FTML.	52
4.9. Entrenamiento de la RNA con las características FTML.	52
4.10. Características extraídas con descomposición wavelet-FRFT.	53
4.11. Entrenamiento de la RNA con las características descomposición wavelet y FRFT. 53	
4.12. Matriz de confusión de clasificación con características del transformador con algoritmo FRFT	54
4.13. Matriz de confusión de clasificación con características del transformador con algoritmo FTML	54
4.14. Matriz de confusión de clasificación con características del transformador con algoritmo FTML	55
4.15. Matriz de confusión de clasificación con características del transformador con algoritmo WDFRFT	55
4.16. Metodología de clasificación jerárquica.	56
4.17. Señales de corriente y voltaje de motor de inducción.	59
4.18. Voltaje inducido por el flujo de fuga - Saludable.	60
4.19. Voltaje inducido por el flujo de fuga - Falla 1, 2 y 3.	60
4.20. Voltaje inducido por el flujo de fuga - Falla 4, 5 y 6.	61
4.21. Metodología para diagnóstico de fallas IM.	61
4.22. Características del IM extraídas con el algoritmo FRFT.	63
4.23. Curva de entrenamiento con características FRFT.	63
4.24. Características del IM extraídas con el algoritmo FTML.	64
4.25. Curva de entrenamiento con características FTML.	64
4.26. Características del IM extraídas con el algoritmo WD_{FRFT}	64
4.27. Curva de entrenamiento con características WD_{FRFT}	64
4.28. Matriz de confusión de clasificación con características del motor de inducción con algoritmo FRFT	65

4.29. Matriz de confusión de clasificación con características del motor de inducción con algoritmo FTML	66
4.30. Matriz de confusión de clasificación con características del motor de inducción con algoritmo WDFRFT	66
4.31. Comparación de la corriente del arreglo fotovoltaico bajo distintas condiciones de falla.	69
4.32. Segunda comparación de la señal de corriente del arreglo fotovoltaico bajo distintas condiciones de falla.	69
4.33. Metodología para diagnóstico de fallas sistema fotovoltaico.	70
4.34. PV - Características extraídas con FRFT.	70
4.35. PV - curva de entrenamiento del clasificador con FRFT.	70
4.36. PV - Características extraídas con FTML.	71
4.37. PV - curva de entrenamiento del clasificador con FTML.	71
4.38. PV - Características extraídas con WD_{FRFT}	72
4.39. PV - curva de entrenamiento del clasificador con WD_{FRFT}	72
4.40. Matriz de confusión de la clasificación de características FRFT sobre el sistema fotovoltaico.	73
4.41. Matriz de confusión de la clasificación de características FTML sobre el sistema fotovoltaico.	73
4.42. Matriz de confusión de la clasificación de características WDFRFT sobre el sistema fotovoltaico.	74
4.43. Metodología extracción de características de disturbios eléctricos.	75
4.44. Disturbios eléctricos generados con combinaciones de 2, 3 y 4 disturbios eléctricos básicos.	77
4.45. PQD - Características extraídas usando el algoritmo FRFT 1.	78
4.46. PQD - Características extraídas usando el algoritmo FRFT 2.	78
4.47. PQD - Características extraídas usando el algoritmo FTML 1.	79
4.48. PQD - Características extraídas usando el algoritmo FTML 2.	79
4.49. PQD - Características extraídas usando el algoritmo WDFRFT 1.	79
4.50. PQD - Características extraídas usando el algoritmo WDFRFT 2.	79
4.51. Matriz de confusión de la clasificación de disturbios eléctricos con características FRFT	80
4.52. Entrenamiento del clasificador para disturbios eléctricos con características FRFT	81

Lista de tablas

2.1. Fallas comunes en los motores de inducción [1].	16
2.2. Comparativa de los distintos métodos de detección de fallas en transformadores [2].	17
2.3. Tipo de fallas y componentes afectados en los sistemas PV [3].	17
2.4. Categorías de disturbios en la calidad de la energía [4].	18
4.1. Clases de fallas de en transformador.	48
4.2. Hiperparámetros de la RNA para la clasificación de fallas en el transformador.	52
4.3. Comparativa de los resultados de clasificación utilizando un clasificador neuronal.	53
4.4. Comparación en la detección y diagnóstico	57
4.5. Características del motor	58
4.6. Clases de fallas con cargas mecánicas.	62
4.7. Hiperparámetros de la RNA para la clasificación de fallas en motor de inducción.	62
4.8. Resultados de la clasificación de fallas en el motor de Inducción.	65
4.9. Fallas en sistema fotovoltaico.	67
4.10. Señales de la base de datos.	68
4.11. Hiperparámetros de la RNA para la clasificación de fallas en sistema fotovoltaico.	71
4.12. Resultados de la clasificación de fallas en el sistema fotovoltaico.	72
4.13. Ecuaciones de los disturbios eléctricos basicos [5].	76
4.14. Parámetros para la simulación de disturbios eléctricos [6–8].	76
4.15. Hiperparámetros de la RNA para la clasificación de disturbios eléctricos (PQD).	77
4.16. Resultados de la clasificación disturbios eléctricos.	80

Nomenclatura

- α Orden del operador.
- \bar{E}_j Energía media de los niveles de descomposición wavelet en el dominio de Fourier fraccionario.
- $\Gamma(\cdot)$ Función Gamma.
- \hat{u}_k eigen vectores de las funciones de Hermite.
- $\lambda(\cdot)$ Función de escalamiento wavelet.
- \mathbf{IF}_{fr} Conjunto de características de la corriente de análisis de falla en Fourier fraccionario.
- \mathbf{IF}_{FTML} Conjunto de características de la corriente de análisis de falla en Fourier-Mittag-Leffler.
- \mathbf{IF}_{wfrft} Conjunto de características de la corriente de análisis de falla en Fourier fraccionario - wavelet.
- $\mathbf{I}pv_{fr}$ Conjunto de características de la corriente del sistema fotovoltaico en Fourier fraccionario.
- $\mathbf{I}pv_{FTML}$ Conjunto de características de la corriente del sistema fotovoltaico en Fourier-Mittag-Leffler.
- $\mathbf{I}pv_{wfrft}$ Conjunto de características de la corriente del sistema fotovoltaico en Fourier fraccionario - wavelet.
- $\mathbf{Q}, \mathbf{V}, \mathbf{U}$ Matrices de pesos sinápticos.
- \mathbf{VLK}_{fr} Conjunto de características del voltaje de flujo de fuga en Fourier fraccionario.
- \mathbf{VLK}_{FTML} Conjunto de características del voltaje de flujo de fuga en Fourier-Mittag-Leffler.

Nomenclatura

- \mathbf{VLK}_{wfrft} Conjunto de características del voltaje de flujo de fuga en Fourier fraccionario - wavelet.
- \mathbf{VPQ}_{fr} Conjunto de características del voltaje de disturbios en Fourier fraccionario.
- \mathbf{VPQ}_{FTML} Conjunto de características del voltaje de disturbios en Fourier-Mittag-Leffler.
- \mathbf{VPQ}_{wfrft} Conjunto de características del voltaje de disturbios en Fourier fraccionario - wavelet.
- \mathbf{W}_{ML}^{α} Kernel de transformación de la transformada discreta de Fourier modificada Mittag-Leffler.
- \mathbf{W} Kernel de transformación de la transformada discreta de Fourier en forma matricial.
- \mathbf{X}_{fr} Señal en dominio de Fourier fraccionario.
- \mathbf{X}_{FTML} Matriz de características extraídas con algoritmo Fourier-Mittag-Leffler.
- \mathbf{X}_{wfrft} Conjunto de características extraídas con el algoritmo wavelet-Fourier fraccionario.
- μ_0 Permeabilidad en vacío.
- μ_r Permeabilidad del material del núcleo del transformador.
- ω Frecuencia angular.
- ω_n Pesos sinápticos.
- ϕ Ángulo de transformación.
- $\Phi_{\alpha}(\cdot)$ Función wavelet madre en dominio de Fourier fraccionario.
- $\Psi(\cdot)$ Función wavelet madre.
- ρ Umbrales.
- θ Ángulo.
- Φ Flujo magnético.
- φ Función de activación.

- ${}^Q D_b^m$ Operador de derivada fraccionaria.
- a Relación de transformación.
- A_c Área transversal del núcleo del transformador.
- A_n Nivel de descomposición wavelet correspondiente a baja frecuencia.
- C_{ERWT_i} Energía relativa wavelet de cada nivel de descomposición.
- C_{WT_i} Nivel de descomposición wavelet en dominio de Fourier fraccionario.
- D_n Nivel de descomposición wavelet correspondiente a alta frecuencia.
- $e^{-i\omega t}$ Kernel de transformación de transformada de Fourier.
- $e^{\frac{-i2\pi kn}{N}}$ Kernel de transformación de transformada de Fourier discreta.
- E_A Voltaje inducido al rotor.
- E_j Energía de cada nivel de descomposición en dominio de Fourier fraccionario.
- E_T Energía total wavelet en dominio de Fourier fraccionario.
- $E_{\alpha,\beta}(\cdot)$ Función Mittag-Leffler.
- $F(\cdot)$ Operador de transformada.
- $F^{-1}(\cdot)$ Operador de transformada inversa.
- $F^\alpha(\cdot)$ Operador de transformada de Fourier de orden fraccionario.
- $g()$ Función ventana.
- i_1, i_p Corriente en el devanado primario.
- i_2, i_s Corriente en el devanado secundario.
- I_A Corriente de fase.
- I_F Corriente de fuente.
- i_F Corriente para análisis de falla en transformador.

Nomenclatura

i_{OP}	Corriente de operación del transformador.
i_{pv}	Corriente del arreglo fotovoltaico.
jX_s	Reactancia del inductor correspondiente al rotor.
$K(t,s)$	Kernel de transformación.
$K_\alpha(\cdot)$	Kernel de transformación de transformada de Fourier fraccionario.
L_F	Inductancia correspondiente al estator.
N	Número de muestras.
N_1	Número de vueltas en el devanado primario.
N_2	Número de vueltas en el devanado secundario.
P_{sal}	Potencia activa.
Q_{sal}	Potencia reactiva.
R_A	Resistencia correspondiente al estator.
R_F	Resistencia ajustable en estator.
R_t	Reluctancia.
t	Tiempo.
T_e	Par electromagnético.
V_1, V_p	Voltaje en el devanado primario.
V_2, V_s	Voltaje en el devanado secundario.
V_Φ	Voltaje de fase.
V_F	Voltaje de fuente.
V_{LK}	Voltaje inducido por el flujo de fuga en motor de inducción.
$W_f(\cdot)$	Operador de transformada wavelet.
$W_x^\alpha(\cdot)$	Operador de transformada wavelet de orden fraccionario.

Lista de acrónimos

CNN	(Convolutional Neural Network) Red neuronal convolucional
DGA	(Dissolved Gas Analysis) Análisis de gas disuelto
DT	(Decision Tree) Árbol de decisiones
FC	(Fractional Calculus) Cálculo fraccionario
FRA	(Frequency Response Analysis) Analisis de respuesta en frecuencia
FRFT	(Fractional Fourier Transform) Transformada de fourier fraccionario
FTML	Transformada de Fourier modificada Mittag-Leffler
GA	(Genetic Algorithms) Algoritmo genético
HC	(Hierarchical Classification) Clasificación jerárquica
HPMU	(Harmonic Phasor Measurement Unit) Unidades de medida fasorial armónicas
HT	(Hilbert Transform) Transformada Hilbert
HTHD	(High Frequency Harmonic Distortion) Distorsion armonica de alta frecuencia
IGWO	(Improved Grey Wolf Optimization) Optimización mejorada del lobo gris
IM	(Induction Motor) Motor de inducción
ITSC	(Inter Turn Short Circuit) Corto circuito entre vueltas
LDA	(Linear Discriminant Analysis) Análisis lineal discriminante
ML	(Machine Learning) Aprendizaje automático
MLSC	(Machine Learning based Stacking Clasifier) Clasificador de apilamiento basado en aprendizaje automático
PG	(Phase to Ground) Fase a tierra
PQD	(Power Quality Disturbance) Disturbio de calidad de la energía
PSD	(Power Spectral Density)Densidad de potencia espectral
PSO	(Particle Swarm Optimization) Optimización por enjambre de partículas
PV	(Photovoltaic System) Sistema fotovoltaico
RMS	(Root Mean Square) Valor cuadrático medio
RNA	Red Neuronal artificial

SC	(Short Circuit) Corto circuito
ST	(Stockwell Transform) Transformada Stockwell
STFT	(Short Time Fourier Transform) Transformada corta de Fourier
SVM	(Support Vector Machines) Maquina de vectores de soporte
THD	(Total Harmonic Distortion) Distorsión armónica total
TFO	Transformador
VDM	(Variational Mode Decomposition) Descomposición de modos variacional
WD	(Wavelet Decomposition) Descomposicion wavelet
WDFRFT	Algoritmo de descomposición wavelet en conjunto con la transformada de Fourier fraccionaria
WT	(Wavelet Transform) Transformada wavelet

Capítulo 1

Introducción

Los sistemas eléctricos tienen gran importancia en la actualidad, esto se debe a que están presentes en la generación, transmisión y distribución de energía eléctrica, por lo que es indispensable el monitoreo de su condición para asegurar su correcto funcionamiento.

Dentro de los métodos para el monitoreo podemos encontrar la detección y diagnóstico de fallas, una de las técnicas utilizadas es clasificación de características que describen el comportamiento tanto saludable como anormal del sistema, el objetivo de esta clasificación es aprender patrones de datos etiquetados y crear un modelo capaz de predecir estas etiquetas de datos nunca antes vistos. Las características juegan un papel importante en la precisión de la clasificación, por lo que es importante realizar una extracción de características adecuada. Una de las técnicas utilizadas es el procesamiento de señales en particular con el uso de las transformadas integrales, estas ofrecen representaciones en distintas distribuciones que brindan información útil para analizar la señales.

1.1. Antecedentes

En el **Centro nacional de investigación y desarrollo tecnológico** se han realizado trabajos de investigación acerca de cálculo fraccionario y procesamiento de señales, que son de interés para para este tema de tesis.

Ramos en 2019 [9] titulado Análisis de ruido electroquímico empleando diferentes métodos de evaluación, en donde lleva a cabo análisis experimentales de una aleación de aluminio expuesta a diferentes soluciones químicas, dentro de los análisis realizados presenta presenta

Introducción

3 casos en los cuales aplica transformadas integrales, en el primero utiliza la transformada de Fourier en conjunto con el método de máxima entropía, a partir de las cuales calcula la potencia de densidad espectral (PSD) de la cual emplea los valores de la pendiente para determinar el tipo de corrosión; en el segundo análisis aplica la transformada wavelet (WT) donde realiza una descomposición en diferentes niveles los cuales corresponden a una determinada banda de frecuencia, para determinar los tipos de corrosión extrae la energía relativa wavelet a cada uno de los niveles de descomposición y les da una representación de cristales; en otro de los análisis presentados aplica la transformada Stockwell (ST) obteniendo espectrogramas tiempo frecuencia de la señal de corriente y determinar los tipos de corrosión.

Arellano en 2020 [10] presenta un trabajo titulado Análisis de ruido electroquímico en una aleación de aluminio expuesta a la mezcla gasolina - etanol, en el cual realiza un estudio de la corrosión en una aleación de aluminio expuesta a diferentes mezclas de gasolina y etanol a diferentes porcentajes, se analizan señales de ruido electroquímico mediante la transformada synchrosqueezind y la energía de Shanon para determinar las velocidades y tipos de corrosión en el material.

Zúñiga en 2020 [11] presenta un trabajo de tesis titulado: Identificación de sistemas mediante el uso de redes neuronales de orden fraccionarios, donde aplica redes neuronales artificiales para la solución de ecuaciones diferenciales de orden variable, además de proponer un algoritmo de aprendizaje con base en el cálculo fraccionario. Presenta distintos sistemas a los cuales se les aplico los algoritmos de identificación como el sistema de predicción de glucosa mediante una red neuronal fraccionaria.

Solís en 2020 [12] realizó un trabajo de tesis titulado cálculo fraccionario aplicado en procesamiento de imágenes y señales, en esta tesis Solís emplea el cálculo fraccionario para desarrollar observadores espectral de tipo Kalman fraccionario, este tipo de observadores en su versión clásica parte de la serie de Fourier, la versión fraccionaria generaliza los operadores derivativos en el observador y en la ecuación diferencial de Riccati con la definición de Riemann-Liouville. Coronel en 2018 [13] realiza un trabajo de tesis titulado Modelado y Control de Sistemas Dinámicos Usando Cálculo Fraccionario, en esta aborda el modelado de sistemas de péndulo doble, péndulo triple y robot SCARA, utilizando las formulaciones Euler-Lagrange y Hamilton, en los cuales empleó definiciones de derivadas fraccionarias.

1.2. Estado del arte

1.2.1. Diagnóstico de fallas en transformadores

Mejia-Barron [14, 15] en sus trabajos presenta metodologías para el diagnóstico de fallas de un transformador monofásico, estas fallas son de cortocircuito entre vueltas del devanado, en la primer metodología presenta una metodología donde modela la corriente del transformador, el modelo consta de una parte estacionaria y otra transitoria, la parte transitoria tiene como base la suma de funciones gaussianas, por otro lado la parte estacionaria se modela con series de Fourier, a partir de este modelo calcula la distorsión armónica total (THD), la densidad espectral y la relación de la señal con el segundo armónico, este último se utiliza ya que su magnitud cambia dependiendo de la gravedad de la falla.

Algunas metodologías utilizan transformadas integrales, esta técnica de procesamiento de señales proporciona diferentes representaciones de la señal en otros dominios, lo cual es útil para extraer información en el diagnóstico de fallas. Guillen et al. [16] presenta una metodología para el diagnóstico de fallas ITSC en la cual aplica la transformada wavelet a la corriente de energización; los coeficientes estimados mediante la descomposición wavelet son empleados para calcular la densidad de potencia espectral (PSD), estos valores son utilizados para obtener la condición de falla. Simões et al. [17] presenta un esquema de protección de fallas basado en el análisis diferencial, esta metodología utiliza la transformada wavelet en la señal de corriente y a partir de estas calcula la energía diferencial, la condición del sistema es determinada mediante una clasificación de los coeficientes diferenciales de energía. Granados et al. [18] propone una metodología de diagnóstico de fallas en donde utiliza señales de corriente, para la estimación de la corriente de falla se realiza una diferencia de las señales basada en las protecciones diferenciales y calcula las unidades de medida fasoriales armónicas (HPMU), la condición de falla es determinado por un clasificador basado en lógica difusa.

Métodos de análisis de ITSC en transformadores utilizando señales distintas a corriente y voltaje han sido reportados en la literatura, algunos de estos métodos usan señales de vibraciones mecánicas [19], mediciones para DGA [20, 21], análisis de respuesta a la frecuencia (FRA) y procesamiento de imágenes [22], este último forma imágenes a partir de los datos obtenidos del FRA que son clasificadas por una red neuronal convolucional (CNN).

1.2.2. Diagnóstico de fallas en motores

Una de las fallas de interés en los IMs son las de cortocircuito (SC) en el estator. En la literatura existen diversos métodos para la detección y diagnóstico de fallas SC, Jean et al. [23] presentan una metodología con base en la clasificación de características estadísticas, las características se obtienen calculando el valor máximo, valor RMS, desviación estándar y factores de cresta a diferentes conjuntos de señales, consideran cuatro condiciones de falla en un clasificador de tipo red neuronal artificial (RNA). Sing et al. [24] aplica la transformada Stockwell para la extracción de características que son aplicadas al diagnóstico de fallas SC y fase a tierra (PG), la metodología clasifica las características con un clasificador SVM. El trabajo presentado por Devi et al. [25] usa la transformada wavelet en señales de un IM trifásico para obtener los coeficientes wavelet de las señales.

Algunos trabajos combinan el uso de las transformadas integrales con métodos estadísticos como el presentado por Guerreiro et al. [26], en la metodología propuesta utiliza el análisis multiresolución obtenido por la WT para calcular características estadísticas, estas son utilizadas en distintos clasificadores para diagnosticar 6 condiciones de fallas SC. Almounajjed et al. [27] usa un análisis multiresolución al cual le aplica la norma L2, la descomposición obtenida es utilizada como característica de error. Otros métodos emplean reconocimiento de patrones en las señales de corriente en distintas fase de los IMs, la cuales se clasifican mediante técnicas de aprendizaje automático (ML), estos son reportados en [28, 29]. Yagami et al. [30] presenta una técnica de detección de fallas SC basada en la clasificación de la magnitud y fase de las corrientes, el clasificador empleado en este trabajo es de tipo SVM. Rebouças et al. [31] realiza una comparativa de métodos para el diagnóstico de fallas SC, presenta 3 distintos conjuntos de características 2 de tipo estadístico y uno usando transformadas integrales, estos conjuntos de datos se utilizan en 3 clasificadores diferentes ANN, SVM y Bayesiano.

Trabajos en los cuales se aborda el cálculo fraccionario dentro de la metodología para el diagnóstico de fallas en IM han sido reportados, Murcia et al. [32] propone una metodología empleando el cálculo fraccionario (FC) para la detección de fallas de barras rotas, el método consiste en la aplicación de derivadas fraccionarias a las ventanas utilizadas en la transformada corta de Fourier (STFT), para realizar un análisis del espectrograma obtenido. Li et al. [33] presenta una metodología para el diagnóstico de fallas en rodamientos, proponiendo un método donde se aplica la transformada de Fourier fraccionaria (FRFT) en conjunto a la descomposición de modos variacional (VMD), el cual es aplicado a señales de vibraciones mecánicas para la detección de la falla.

1.2.3. Diagnóstico de fallas en sistema fotovoltaico

Liu et al. [34] presenta una metodología para el diagnóstico de fallas en sistemas fotovoltaicos (PV), donde emplea el análisis de sensibilidad de corriente y voltaje para diagnosticar SC y fallas de fisuras. emplea un clasificador de apilamiento basado en aprendizaje automático (MLSC) el cual calcula extrae probabilísticos de 3 clasificadores distintos a partir de los datos de corriente y voltaje, los arreglos probabilísticos se usan en un modelo de regresión logística para obtener la predicción de la falla. En el trabajo presentado por Eskarandi et al. [35] utiliza una clasificación jerárquica (HC) para la detección y clasificación de fallas, La metodología HC utiliza 1 clasificador para la detección de la falla y 3 para determinar el estado de la falla.

Existen métodos reportados que utilizan las transformadas integrales para el diagnóstico de fallas, Alrifayy et al. [36] aplica la WT a señales de voltaje para su descomposición a partir de los cuales calcula la energía y entropía de los coeficientes de descomposición, estos valores son usados como características en combinación de otro conjunto obtenido aplicando un auto encoder a la señal. Kurukuru et al. [37] presenta un conjunto de características con la WT aplicada a señales de corriente y voltaje de un sistema fotovoltaico, partiendo de los coeficientes wavelet calcula la energía, entropía, distorsión armónica total, potencia de densidad espectral, relación señal ruido y valores estadísticos.

Aziz et al. [38] presenta una metodología en la que aplica la WT a señales de radiación, temperatura, voltaje, corriente y potencia, a partir de la WT genera imágenes de espectrogramas obtenidos y son clasificados por una red neuronal convolucional(convolucional neural network-CNN). Haque et al.[39] aplica la WT a curvas de voltaje y corriente para obtener un análisis tiempo frecuencia, después aplica un análisis de componentes principales (PCA) obteniendo el conjunto de características y finalmente realiza una clasificación con ANN.

Otras metodologías proponen el uso de imágenes termográficas en combinación con algoritmos de ML para el diagnóstico de fallas en sistemas PV, en los trabajos presentados en [40, 41] utilizan las imágenes para alimentar una CNN y clasificar las fallas en sistemas PV. Bharath et al. [42] propone la extracción de características con gray-level cooccurrence matrix, este algoritmo permite extraer información de texturas en imágenes, en conjunto se utiliza la transformada Hough para un proceso de segmentación del arreglo fotovoltaico, y detectar los defectos en el sistema PV. Por otra parte algunas metodologías proponen el uso de algoritmos genéticos tal es el caso de los trabajos presentados en [43, 44], o características como la entropía de muestra [45].

1.2.4. Clasificación de disturbios eléctricos en la calidad de la energía

Diversas metodologías emplea el procesamiento de señales para la extracción de características, en el trabajo de Zhao et al. [46] emplea el método de descomposición de modo variacional (VMD) para la extracción de características. Otros trabajos aplican técnicas de ML en la extracción de características estos se reportan en [47–49, 4]. Diversos trabajos han sido reportados con metodologías para la detección y clasificación de PQD, Khokhar et al. [5] presenta una metodología para la clasificación de 16 PQDs, aplica la WT para la descomposición de señales de voltaje y corriente, la etapa de clasificación es llevada a cabo por una red neuronal probabilística. Thirumala et al. [50] presenta una metodología empleando la tunable-Q WT este método permite ajustar el factor de cresta dentro del parámetro de alta frecuencia, lo cual puede mejorar la descomposición de la señal, las características extraídas son valor RMS, Distorsión armónica de alta frecuencia (HTHD), valores máximos y mínimos de HTHD; la clasificación se lleva cabo mediante SMV multiclase doble.

En los trabajos presentados en [51, 8, 52] utilizan la ST para la extracción de características con un análisis multiresolución, aplican diferentes métodos de ML como optimización mejorada del lobo gris (IGWO) y árbol de decisiones (DT). Jamali et al. [53] propone una metodología empleando diferentes transformadas integrales como WT, ST, transformada de Fourier, STFT, transformada Hilbert (HT) y transformada tiempo- tiempo para la extracción de características, la selección adecuada de estas para la etapa de clasificación se lleva a cabo mediante GA; compara distintos clasificadores de tipo RNA, SVM, DT, bayesiano y análisis lineal discriminante (LDA).

Dentro de trabajos que abordan las transformadas integrales fraccionarias se han reportado trabajos como el presentado por Sing et al. [54], la metodología que propone consiste en extraer características estadísticas de la señal en el dominio de Fourier fraccionario, esta se obtiene a partir de aplicar la FRFT de orden $\alpha = 0,9$ a la señal en dominio temporal; esta metodología obtiene mejores desempeños en señales contaminadas por ruido en comparación con la ST. Samanta et al. [55] utiliza una metodología similar y realiza una comparativa con diferentes ordenes de α obteniendo resultados satisfactorios en señales bajo diferentes condiciones de ruido. Gao et al. [56] presenta un trabajo en el cual aplica la FRFT para extracción de características en una metodología de detección de fallas de series de arco, esta falla afecta la calidad de la energía y esta ligada a fallas de fase en IMs.

1.3. Planteamiento del problema

Las señales adquiridas de un sistema pueden verse influenciadas y contaminadas por distorsiones o ruido, originados por influencias externas, sistemas de medición deficientes o fenómenos en el material. El objetivo del procesamiento de señales es mejorar las señales o sus representaciones y obtener la mayor información posible de ellas. Para esto, se emplean técnicas en dominios temporal, frecuencial o el dominio de Fourier fraccionario. La elección correcta de la técnica a utilizar dependerá del tipo de señal que se procese y la información que se desee obtener.

En los sistemas eléctricos, el procesamiento de señales se utiliza para obtener información y analizar sus elementos. Uno de los elementos principales es el transformador, para el cual es necesario el monitoreo de sus condiciones de trabajo. En este proceso, se emplea el procesamiento de señales para identificar comportamientos anormales o fallas. Existen diversos algoritmos que se utilizan para este propósito; sin embargo, algunas condiciones complejas, como las fallas de cortocircuito puntuales en las vueltas de los devanados, fallas con condiciones de carga en armónicos, discriminación de fallas y corriente inrush, presentan desafíos significativos.

En el caso de las máquinas eléctricas rotativas, el reto radica en la naturaleza de las señales, que en algunos casos incluyen señales de vibraciones mecánicas o voltajes de flujo de fuga. Estas señales suelen ser más complejas, con frecuencias variantes en el tiempo, por lo cual es necesario contar con algoritmos que permitan la descomposición de la señal o representaciones en tiempo-frecuencia.

Algunos sistemas eléctricos están compuestos por varios elementos susceptibles a fallar o presentar comportamientos anormales, como es el caso de los sistemas fotovoltaicos. Estos sistemas pueden tener una multitud de elementos integrados, y en algunos casos, las señales disponibles para análisis son pocas, lo que demanda mejores algoritmos para la descripción del estado del sistema.

Uno de los principales problemas dentro de los sistemas eléctricos es la calidad de la energía, la cual puede verse comprometida por diversas causas, tales como la presencia de cargas no lineales, fallas en los dispositivos conectados y problemas en las fuentes de generación de energía, entre otros. Estos fenómenos deforman la forma de onda del voltaje o la corriente en la red eléctrica, lo que puede resultar en un consumo ineficiente de energía y un comportamiento anormal en los dispositivos que dependen de dicha energía.

Los fenómenos que distorsionan la forma de onda son conocidos como disturbios eléctricos. Con el avance y la creciente integración de fuentes de energía renovable, el uso de dispositivos

Introducción

electrónicos y la ocurrencia de fallas en máquinas eléctricas, estos disturbios se han vuelto cada vez más complejos. La combinación de estos factores hace que la detección y clasificación de los disturbios eléctricos sea un desafío creciente, dificultando su mitigación efectiva.

La detección y diagnóstico de fallas en sistemas eléctricos, así como la clasificación de disturbios eléctricos en sistemas eléctricos modernos, es una necesidad urgente. La creciente complejidad y variabilidad de los disturbios en la red eléctrica demandan métodos avanzados y precisos que puedan adaptarse a estas dinámicas cambiantes. La implementación de enfoques innovadores es esencial para garantizar la calidad de la energía suministrada a los consumidores, asegurando así la eficiencia, fiabilidad y seguridad de la infraestructura eléctrica. En este contexto, es crucial desarrollar técnicas que no solo detecten y diagnostiquen fallas de manera efectiva, sino que también clasifiquen con precisión los distintos tipos de disturbios eléctricos, permitiendo una respuesta rápida y adecuada a los problemas que puedan surgir en la red.

1.4. Hipótesis

Es posible mejorar el análisis de señales en sistemas eléctricos y disturbios en la calidad de la energía, con algoritmos de procesamiento de señales basados en cálculo fraccionario, aprovechando las propiedades para describir comportamientos de memoria, filtrado, descomposición de señales y mejora en las representaciones en dominios fraccionarios.

1.5. Justificación

Una de las aportaciones principales de este trabajo es el desarrollo de algoritmos de procesamiento de señales con el objetivo de ser aplicado en el análisis de señales en máquinas eléctricas y la calidad de la energía. El cálculo fraccionario mejora la descripción del comportamiento de los sistemas, de acuerdo con la revisión del estado del arte y los algoritmos desarrollados con base al cálculo fraccionario proporcionan una mejor información descriptiva de las señales analizadas, lo que permite un mayor desempeño en la detección de fallas y disturbios eléctricos.

Otras de las aportaciones y considerablemente importante en este trabajo de investigación es el desarrollo de la implementación en hardware y software de los algoritmos diseñados, esto implica la construcción de un módulo de prueba y adquisición de señales de máquinas eléctricas y sistemas eléctricos para el análisis de la señal, este aporte es considerable ya que existen pocos trabajos en los cuales se implemente en hardware algoritmos de procesamiento basados en cálculo fraccionario.

1.6. Objetivos

Desarrollar algoritmos de procesamiento de señales con base a operadores fraccionarios con la finalidad de aplicarse en el análisis de señales de máquinas eléctricas y disturbios eléctricos en la calidad de la energía.

1.6.1. Objetivos específicos

- Analizar el procesamiento de señales basados en transformadas integrales.
- Estudiar las técnicas de clasificación de características y fallas para máquinas eléctricas.
- Definir algoritmos de procesamiento de señales con base en cálculo fraccionario para la extracción de características de señales.
- Usar las técnicas de clasificación en conjunto con los algoritmos definidos de procesamiento de señales.

1.7. Metas

- Desarrollo de funciones basadas en cálculo fraccionario asociadas con el kernel o ventanas de transformadas integrales: FT y WT.
- Diseño de clasificadores que permitan la identificación automática de perturbaciones eléctricas: Bayesianos, ANN y SVM
- Desarrollo de algoritmos para la cuantificación de las magnitudes de perturbaciones y fallas eléctricas.
- Aplicación de los algoritmos diseñados en el análisis de señales en máquinas eléctricas y calidad de la energía.
- Implementación de los algoritmos desarrollados en software (simulación)

1.8. Estructura del documento

El documento de Tesis presentado estructurado de la siguiente forma:

Introducción

- **Capítulo 1:** Se presenta la introducción en donde se realiza una revisión de antecedentes y estado del arte relacionado a los temas de interés, se plantea la problemática, hipótesis, justificación, objetivos y metas de éste trabajo de investigación.
- **Capítulo 2:** Se exponen las bases teóricas acerca de los sistemas eléctricos, conceptos y definiciones del cálculo fraccionario, transformadas integrales, diagnóstico de fallas y aprendizaje automático.
- **Capítulo 3:** Se realiza la propuesta y diseño de los algoritmos de procesamiento de señales en base a transformadas integrales de orden fraccionario, las cuales son utilizadas para la extracción de características.
- **Capítulo 4:** Se presentan cuatro casos de estudio tres casos de diagnóstico de fallas y un caso de clasificación de disturbio eléctricos en los cuales fueron aplicados los algoritmos y metodología propuestos.
- **Capítulo 5:** Se presentan los resultados obtenidos de los casos de estudio, la conclusión general del trabajo de investigación y se plantean trabajos futuros derivados de esta investigación.

Capítulo 2

Fundamentos teóricos

En este capítulo se presenta conocimiento teórico acerca de sistemas eléctricos, cálculo fraccionario, transformadas integrales y algoritmos para el diagnóstico de sistemas.

2.1. Sistemas eléctricos

Los sistemas eléctricos son conjuntos elementos eléctricos y electrónicos que trabajan juntos para generar, transmitir, distribuir y utilizar energía eléctrica. Estos sistemas son fundamentales para el funcionamiento de casi todos los aspectos de la vida moderna, desde el alumbrado y la calefacción hasta la operación de dispositivos electrónicos y maquinaria industrial. Dentro de la etapa de generación podemos encontrar las plantas de generadoras las cuales producen la energía eléctrica a partir de otra, uno de los componentes clave en las plantas son los dispositivos que convierten otros tipos de energía en energía eléctrica como pueden ser los generadores o paneles solares; en la etapa de transmisión esta compuesta por redes eléctricas donde algunos de sus componentes fundamentales son las líneas de transmisión y subestaciones, estas últimas se encargan de llevar a niveles adecuados los niveles de tensión eléctrica para su transmisión y distribución. La etapa de distribución esta compuesta por líneas de transmisión y transformadores los cuales en ambas etapas se encargan de adecuar los niveles de tensión, a diferencia de la etapa de transmisión los niveles se deben adecuar para que los usuarios finales puedan conectarse a la red y puedan hacer uso de la energía eléctrica. Finalmente la etapa de consumo o utilización es la etapa en la cual se usa la energía eléctrica tanto para aplicaciones domesticas o industriales.

Fundamentos teóricos

Las máquinas eléctricas son fundamentales debido a varias razones clave que abarcan su aplicación práctica y su impacto en el desarrollo tecnológico y económico:

- **Conversión de Energía:** Los generadores convierten energía mecánica en eléctrica, crucial para el suministro de electricidad, mientras que los motores eléctricos transforman energía eléctrica en mecánica, permitiendo el funcionamiento de diversos dispositivos y sistemas.
- **Eficiencia Energética:** Las máquinas eléctricas, especialmente los motores, suelen ser más eficientes que los motores de combustión interna, reduciendo el consumo de energía y las emisiones contaminantes.
- **Automatización y Control:** Son esenciales en la automatización industrial, mejorando la precisión, velocidad y consistencia en la producción, lo que incrementa la productividad y la calidad de los productos.
- **Versatilidad y Adaptabilidad:** Existen en diversos tipos y tamaños, permitiendo su uso en una amplia gama de aplicaciones industriales y tecnológicas.
- **Desarrollo Tecnológico:** Su estudio y mejora han impulsado avances en ingeniería eléctrica y electrónica, facilitando innovaciones en materiales, diseño y control.
- **Impacto Económico:** La producción y mantenimiento de máquinas eléctricas generan empleo y fomentan la economía, además de ser fundamentales en la transición hacia energías renovables.

2.1.1. Máquinas eléctricas

Máquinas eléctricas rotativas

Las máquinas eléctricas rotativas se pueden definir como dispositivos que convierten la energía eléctrica en mecánica como es el caso de los motores de inducción o viceversa en el caso de los generadores.

El motor eléctrico y el generador están compuestos por un estator el cual es la parte fija de la máquina que contiene el bobinado de campo en los motores y el bobinado de armadura en los generadores. El rotor es la parte móvil de la máquina que gira dentro del estator. En motores, es donde se induce la fuerza que produce el movimiento rotativo; en generadores, es la parte que se mueve para inducir una corriente eléctrica, En la Figura 2.1 se muestra estas partes de las máquinas eléctricas rotativas.




Figura 2.1 Secciones de una máquina eléctrica rotativa.




Figura 2.2 Circuito equivalente de un motor de inducción monofásico.

La Figura 2.2 muestra el circuito equivalente de un motor de inducción eléctrico, las Ec. (2.1) y Ec.(2.2) describen el comportamiento del voltaje y corriente del motor. La Ec.(2.3) describe el comportamiento del par electromagnético del motor eléctrico

$$V_\phi = E_A + jX_s I_A + R_A I_A, \quad (2.1)$$

$$E_A = V_\phi - jX_s I_A - R_A I_A, \quad (2.2)$$

$$T_e = J \left(\frac{2}{P} \right) \frac{d\omega}{dt} + T_L, \quad (2.3)$$




Figura 2.3 Circuito equivalente de un generador monofásico.

en un generador se aplica un par mecánico al rotor y mediante la inducción de un campo magnético en el estator se produce un voltaje, la Ec. (2.4) describe ese comportamiento del voltaje producido.

$$V_{\phi} = E_A - jX_s I_A - R_A I_A. \quad (2.4)$$

Máquinas eléctricas estáticas

El transformador es una máquina eléctrica de tipo estática, su funcionamiento principal consiste en reducir o aumentar los niveles de voltaje sin variar su frecuencia, esto se consigue a través del principio de inducción electromagnética. El diseño básico de un transformador consiste en dos devanados de alambre magneto enrollados en un núcleo de material ferromagnético como se muestra en la Figura 2.4 en donde V_1 y V_2 son los voltajes en el devanado primario y secundario respectivamente, N_1 y N_2 son el número de vueltas en cada devanado, la Ec.(2.5) describe la relación de transformación de un transformador ideal, Ec.(2.6) describe la potencia activa y la Ec.(2.7) describen la potencia reactiva del transformador.

$$a = \frac{N_1}{N_2} = \frac{V_1}{V_2} = \frac{i_2}{i_1}, \quad (2.5)$$

$$P_{sal} = V_1 i_1 \cos(\theta), \quad (2.6)$$

$$Q_{sal} = V_1 i_1 \sin(\theta). \quad (2.7)$$




Figura 2.4 Diseño de transformador monofásico.

La reluctancia es la propiedad de resistencia al flujo magnético que tiene un material, esta propiedad se presenta en los transformadores y se define en la Ec.(2.8) en donde l es la longitud media a través del núcleo del transformador, μ_r es la permeabilidad del material del núcleo, μ_0 es la permeabilidad en vacío y A_c es el área de la sección transversal del núcleo.

$$R_t = \frac{l}{\mu_r \cdot \mu_0 \cdot A_c}, \quad (2.8)$$

El flujo magnético que tiene un transformador se define en la Ec. (2.9) donde se relaciona la reluctancia, las vueltas de los devanados y las corrientes.

$$\phi = \frac{N_1 \cdot i_1 + N_2 \cdot i_2}{R_t}. \quad (2.9)$$

2.1.2. Fallas en máquinas eléctricas

Debido a la importancia de las máquinas eléctricas y su uso en la industria, tanto los motores de inducción como los transformadores son parte esencial por lo que es necesario su continuo monitoreo y diagnóstico de fallas, para asegurar un correcto funcionamiento de los dispositivos.

Fallas en Motores

Dentro máquinas eléctricas rotativas podemos encontrar motores y generadores, los motores de inducción (IMs) son parte fundamental en la industria ya que son utilizados para la generación de energía mecánica que puede ser aplicada en diversos sectores, por lo cual es primordial el monitoreo de su condición para detectar y diagnosticar fallas. De acuerdo a la literatura el 37% de la fallas de cortocircuito (SC) están relacionadas al aislamiento. Los IMs al ser parte un

Fundamentos teóricos

dispositivo de gran utilidad se ve sometido a grandes cargas de trabajo por largo tiempo, lo cual genera estrés térmico que degrada el tiempo de vida del aislamiento en los devanados del rotor o estator [1, 57]; La Tabla 2.1 muestra las fallas comunes en los motores de inducción, el elemento afectado y el tipo de falla.

Tabla 2.1 Fallas comunes en los motores de inducción [1].

Tipo	Elemento	Falla
Eléctrica	Estator	-Vuelta a vuelta -Devanado a vuelta -Fase a fase -Fase a tierra
Eléctrica	Rotor	-Barras rotas -Anillos rotos
Eléctrica	Fuente de alimentación	-Desbalance de fases -Fase sola
Mecánica	Rodamientos	-Anillos de rodamiento externo e interno. -Elementos del rodamiento. -Jaula/ tren.
Mecánica	Rotor	-Rotor desbalanceado -Rotor curvado -Desalineación

Fallas en transformadores

Los transformadores son máquinas eléctricas estáticas esenciales utilizadas para la transmisión de energía eléctrica en las etapas de distribución y transmisión. Varios factores deterioran la salud del transformador, provocando fallos internos y externos; cerca del 80% de los daños sufridos por el aparato se deben a fallas internas. Las fallas internas pueden causar un comportamiento anormal de algún elemento de la máquina, lo que provoca la degradación del aislamiento del devanado, la contaminación del aceite de refrigeración, el aumento de la temperatura o daños en el núcleo [58]. Los cambiadores de tomas en carga y los devanados presentan el mayor índice de fallas en los transformadores con un porcentaje de entre el 30 y el 40 según diferentes autores [59, 60]. En el caso de un devanado la falla se representa como un cortocircuito entre espiras (ITSC), dando lugar a diversos escenarios que pueden causar funcionamiento anormal del aparato y, en el caso extremo, la destrucción del transformador. La Tabla 2.2 muestra varios enfoques para la detección de fallos en transformadores descritos en la referencia [2].

Tabla 2.2 Comparativa de los distintos métodos de detección de fallas en transformadores [2].

Método	Desventajas
Monitoreo de corriente con un dispositivo externo.	Discriminación imprecisa entre fallas externas e internas.
Análisis de gas disuelto (DGA).	No aplicable a transformadores de tipo seco.
Análisis de respuesta en frecuencia (FRA).	-Resultados complejos. -Falta de estandarización en los resultados.
Análisis de las señales de corriente y voltaje.	Altos costos de implementación y complejidad.

2.1.3. Sistema fotovoltaico

Fallas en sistema fotovoltaico

Dentro de los sistemas eléctricos una parte fundamental son las fuentes de energía eléctrica, existen diversos métodos para la generación de energía eléctrica una de las tecnologías que ha avanzado rápidamente es la producción de energía de fuentes renovables. Debido a sus ventajas y facilidad de implementación, los sistemas PV han ganado popularidad dentro de las fuentes de generación de energía renovable [3]. Los sistemas PV generan aproximadamente un terawatt de la energía eléctrica global [61]. Debido a la importancia que han adquirido estos sistemas, es esencial el desarrollo de metodologías para el diagnóstico de fallas en sistemas fotovoltaicos. En la Tabla 2.3 se muestra algunas de las fallas comunes en los sistemas PV y los componentes afectados.

Tabla 2.3 Tipo de fallas y componentes afectados en los sistemas PV [3].

Tipo de falla	Componente afectado
Punto caliente	Celdas / modulo
Fallas en diodos	Diodo puente o diodo de bloqueo
Falla en caja de conexiones	Caja de conexiones
fallas en Modulo PV y arreglo PV	Modulo PV
Falla de tierra	Arreglo PV o Cadena PV
Falla de arco	Arreglo PV
Falla de linea a linea	Arreglo PV

2.1.4. Disturbios eléctricos

Los eventos de fallas en máquinas eléctricas como en sistemas de generación de energía, tienen impactos directos en la red eléctrica, ya que pueden deformar la forma de onda de corriente y voltaje del sistema [62, 63]. Estos eventos tienen un impacto en la calidad de la energía (PQ). Bollen et al.[64] define la calidad de la energía como: "**Calidad de la energía es la combinación de calidad de voltaje y corriente; la calidad de corriente y voltaje se refiere a las desviaciones de los valores de voltaje o corriente reales respecto a sus valores ideales.**". En la Tabla 2.4 se muestran los distintos disturbios eléctricos y su categoría.

Tabla 2.4 Categorías de disturbios en la calidad de la energía [4].

Categoría	PQD
Transitorio	- Impulso, - Oscilatorio
Tiempo de variación corto	- Interrupción , - Sag, - Swell
Tiempo de variación largo	- Interrupción sostenida, - Bajo voltaje - Alto voltaje
Voltaje desbalanceado	Voltaje desbalanceado
Distorsión de la forma de onda	- DC desplazado, - Armónicos, - Inter armónicos - Notching, - Ruido
Fluctuación de voltaje	Fluctuación de voltaje
Variación de frecuencia	Variación de frecuencia

2.2. Cálculo fraccionario

El cálculo fraccionario es una rama de las matemáticas que estudia los operadores derivativos e integrales de orden arbitrario, es decir el orden del operador puede tomar valores no enteros, complejos e incluso se puede ser una función, los operadores se representan con la siguiente notación:

$${}^Q D_b^m f(t), \tag{2.10}$$

donde Q corresponde al sentido de la derivada, m es el orden de la derivada, a y b son los límites de integración en la integral de la derivada.

Funciones especiales

En el cálculo fraccionario además de generalizar los operadores derivativos e integrales existen funciones generalizadoras que son útiles para el análisis matemático como las funciones Gamma y Mittag-Leffler.

■ **Función Gamma**

La función gamma permite generalizar los números factoriales, la necesidad de esta función se debe a que en las definiciones de la derivadas fraccionarias se emplean factoriales de orden no entero, la definición de esta función esta dada como:

$$\Gamma(x) = \int_0^{\infty} e^{-t} t^{x-1} dt, \tag{2.11}$$

una de las propiedades útiles para el manejo de los factoriales es:

$$\Gamma(x + 1) = x\Gamma(x) = x!, \tag{2.12}$$

■ **Función de Mittag-Leffler**

La función de Mittag-Leffler es una función biparamétrica que depende de los valores de α y β , es útil debido a que nos permite generalizar exponenciales y funciones trigonométricas, se define en la Ec.(2.13).

$$E_{\alpha}(z) = \sum_{k=0}^{\infty} \frac{z^k}{\Gamma(\alpha k + \beta)}, \tag{2.13}$$

el valor de α nos permite la generalización de las funciones en algunos casos se pueden crear comportamientos de pseudo exponenciales cuando su valor es muy cercano a uno, algunos casos particulares de la función de Mittag-Leffler son:

■ **Función error**

$$E_{\frac{1}{2}}(z) = e^{(z^2)} \operatorname{erfc}(-z) \tag{2.14}$$

■ **Función exponencial**

$$E_1(z) = e^{(z)} \tag{2.15}$$

■ **Función coseno**

$$E_2(-z^2) = \cos(z) \tag{2.16}$$

Fundamentos teóricos

- Función coseno hiperbólico

$$E_2(z^2) = \cosh(z) \quad (2.17)$$

En la Figura 2.5 se muestra el comportamiento de la función con ordenes de α cercanos a 1 y $\beta = 1$ el comportamiento de la función es pseudo exponencial y conforme se acerca al $\alpha = 1$ se asemeja a la función exponencial.

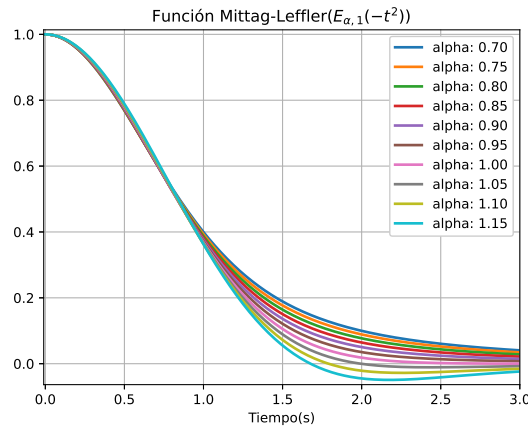


Figura 2.5 Comportamiento de la función de Mittag-Leffler $\beta = 1$ y α variable.

Derivadas

- **Derivada Riemann-Liouville**

Existen diversas definiciones en el cálculo fraccionario de derivadas fraccionarias, una de las más conocida es la definición de Riemann-Liouville (**R-L**) la cual se define como:

$${}^R_L D_t^\alpha f(t) = \frac{1}{\Gamma(n-m)} \frac{d^n}{dt^n} \int_0^t (t-\tau)^{n-m-1} f(\tau) d\tau, \alpha \in [n-1, n], \quad (2.18)$$

esta derivada realiza una convolución entre la función $f(\tau)$ y un kernel de potencia $(t-\tau)^{n-m-1}$ el cual permite describir la memoria de los sistemas físicos.

- **Derivada Grünwald-Letnikov**

La versión discreta de esta derivada es la definición de Grünwald-Letnikov(**G-L**) esta definición es de utilidad en las aplicaciones de sistemas discretos y se define como:

$${}^{GL}D^\alpha f(t) = \lim_{h \rightarrow 0} \frac{1}{h^\alpha} \sum_{m=0}^{\frac{t-\alpha}{h}} (-1)^m \frac{\Gamma(a+1)}{m! \Gamma(\alpha - m + 1)} f(t - mh), \quad (2.19)$$

■ Derivada Caputo

La definición en sentido de Caputo fue propuesta por Michele Caputo y es definida como:

$${}_0^C D_t^\alpha f(t) = \frac{1}{\Gamma(n-m)} \int_0^t \frac{d^n}{dt^n} (t-\tau)^{n-m-1} f(\tau) d\tau, \alpha \in [n-1, n] \quad (2.20)$$

la principal diferencia con la definición de Riemann-Liouville en la Ec.(2.18) es el operador derivativo, ya que en la definición de Caputo este se encuentra dentro de la integral, debido a esto las condiciones iniciales para resolver una ecuación diferencial utilizando esta derivada son enteras, mientras que al utilizar (**R-L**) se requieren condiciones iniciales fraccionarias en las cuales es difícil encontrar su significado físico.

■ Derivada Caputo-Fabrizio

En los últimos años han surgido nuevas definiciones de derivadas fraccionarias con es el caso de la derivada de Caputo-Fabrizio (**C-F**) definida en [65] se emplea un kernel exponencial:

$${}_b^{CF} D_t^\alpha f(t) = \frac{M(\alpha)}{1-\alpha} \int_b^t f'(\tau) \exp \left[-\alpha \frac{t-\tau}{1-\alpha} \right] d\tau, \quad (2.21)$$

donde $M(\alpha)$ es la función de normalización cumpliendo con $M(0) = M(1) = 1$, el kernel de esta derivada evita la singularidad cuando $t = \tau$ y cuando $f(\tau)$ es una constante su derivada es 0.

■ Derivada Atangana-Baleanu

La definición de la derivada Atangana-Baleanu [66] utiliza la función de Mittag-Leffler como kernel el cual ofrece no localidad, esto permite describir comportamientos con periodos de tiempo extensos:

$${}_b^{ABC} D_t^\alpha f(t) = \frac{B(\alpha)}{1-\alpha} \int_b^t f'(\tau) E_\alpha \left[-\alpha \frac{(t-\tau)^\alpha}{1-\alpha} \right] d\tau, \quad (2.22)$$

al igual que en la defunción de Caputo-Fabrizio la función $B(\alpha)$ es la función de normalización y la derivada cuando $f(t)$ es una constante es 0.

▪ Derivada Atangana-Gomez

Esta definida en [67], esta derivada utiliza un kernel de distribución normal y existe con dos sentidos, en sentido de Riemann-Liouville y Liouville-Caputo.

$${}_{b}^{AGAC}D_t^\alpha f(t) = \frac{AG(\alpha)}{n-\alpha} \int_b^t f^n(y) \exp\left[-\frac{\alpha}{n-\alpha}(t-y)^2\right] dy, \quad (2.23)$$

$${}_{b}^{AGAR}D_t^\alpha f(t) = \frac{AG(\alpha)}{n-\alpha} \frac{d^n}{dt^n} \int_b^t f(y) \exp\left[-\frac{\alpha}{n-\alpha}(t-y)^2\right] dy, \quad (2.24)$$

donde $AG(\alpha)$ es la función de normalización, la diferencia entre las definiciones es el operador derivativo ya que en la Ec.(2.23) esta dentro de la integral y en Ec.(2.24) esta fuera, esta defunción puede ser utilizada para modelos de problemas estadísticos, algunas aplicaciones presentadas son el sistema presa-depredador y el modelo Black-Scholes utilizado en matemáticas financieras.

2.3. Transformadas integrales

Las transformadas integrales son operadores que relacionan una función de un determinado conjunto respecto a un parámetro por medio de la integración como se muestra en la Ec.(2.25)

$$F(s) = \int_{a1}^{a2} f(t)K(t,s)dt, \quad (2.25)$$

en donde $f(t)$ es la función a transformar, $K(t,s)$ es el kernel de transformación, $a1$ y $a2$ son los limites de la integral y $F(s)$ es la función transformada.

A lo largo del tiempo se ha definido una variedad de transformadas integrales, el estudio y aplicación de estos operadores es bastante extenso y existen definiciones tanto clásicas es decir de orden entero, como de orden fraccionario.

2.3.1. Transformadas clásicas

Transformada de Fourier (FT)

La transformada de Fourier es una de las más útiles y estudiadas, este operador surgió debido a la restricción que tenían las series de Fourier para representar funciones en intervalos no finitos, esta transformada se define como:

$$F(\omega) = \int_{-\infty}^{\infty} f(t)e^{-i\omega t} dt, \quad (2.26)$$

en esta transformación el kernel es $e^{-i\omega t}$ el cual permite mapear la función $f(t)$ en dominio temporal a dominio frecuencial, las transformadas tienen una función de kernel asociada inversa permitiendo realizar la transformación viceversa del dominio. La transformada de Fourier inversa se define como:

$$F^{-1}(\omega) = \int_{-\infty}^{\infty} F(\omega)e^{i\omega t} d\omega, \quad (2.27)$$

la aplicación de esta transformada requiere una versión discreta para ser implementada, debido a los sistemas digitales que existen en ingeniería, la definición discreta se define como:

$$X[k] = \sum_{n=0}^{N-1} x[n]e^{-\frac{i2\pi kn}{N}}, \quad (2.28)$$

y su transformada inversa

$$x[n] = \frac{1}{N} \sum_{k=0}^{N-1} X[k]e^{\frac{i2\pi kn}{N}}, \quad (2.29)$$

en donde N representa el número total de datos, el índice k se utiliza para los datos discretizados en dominio frecuencial y el índice n para los datos en dominio temporal.

Transformada corta de Fourier (STFT)

La transformada de Fourier es útil en diversas aplicaciones como el procesamiento y análisis de señales, sin embargo, sus resultados son satisfactorios únicamente en señales periódicas, para casos en los cuales se tienen señales con frecuencias variante en el tiempo (señales no estacionarias) no sucede lo mismo, esto se debe a que a pesar de que sus funciones base son de duración infinita en tiempo, son locales en frecuencia, lo cual nos detecta la presencia de la frecuencia pero no brinda información de su evolución en el tiempo, para este tipo de casos se

Fundamentos teóricos

utiliza la transformada corta de Fourier la cual se define como:

$$S_f(\omega, \tau) = \int f(t)g(t - \tau)e^{-i\omega t} dt, \quad (2.30)$$

donde $g(t)$ es una ventana móvil la cual se desplazará a lo largo del tiempo de la señal, esto permite obtener información acerca de las frecuencias y su evolución en el tiempo, la ventana comúnmente utilizada es de tipo Gaussiana y se define como:

$$g(t) = \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{(t-\mu)^2}{2\sigma}}, \quad (2.31)$$

existen diversos tipos de ventana que ofrecen mejoras dependiendo la aplicación o tipo de señal, como la ventana Hann, Hamming o Blackman estas mejoran la resolución del espectrograma que se obtiene de la señal.

Transformada Wavelet (WT)

La transformada corta permite analizar señales no estacionarias, sin embargo, tiene algunas limitaciones, una de ellas se debe al ancho de la ventana fija, esto provoca no poder identificar cambios de comportamiento que se encuentre dentro de la misma amplitud de la ventana. La herramienta utilizada para resolver este problema es la transformada Wavelet, esta transformada permite realizar análisis multiresolución con ventanas dilatadas de esta manera se utilizan ventanas angostas para mayores rangos de frecuencia y ventanas angostas para rangos menores, la transformada Wavelet se define como:

$$W_f(s, \tau) = \int f(t)\psi_{s,\tau}(t)dt, \quad (2.32)$$

en donde $\psi(t)$ es la función wavelet madre y se define como:

$$\psi_{s,\tau}(t) = \frac{1}{\sqrt{s}} \psi \left[\frac{t - \tau}{s} \right], \quad (2.33)$$

donde τ es el factor de desplazamiento de la ventana y s el factor de escalado, en la Figura 2.6 se muestran algunas de las funciones wavelets comúnmente empleadas para la descomposicion, como son la Daubechies, Symlets o Coiflet.

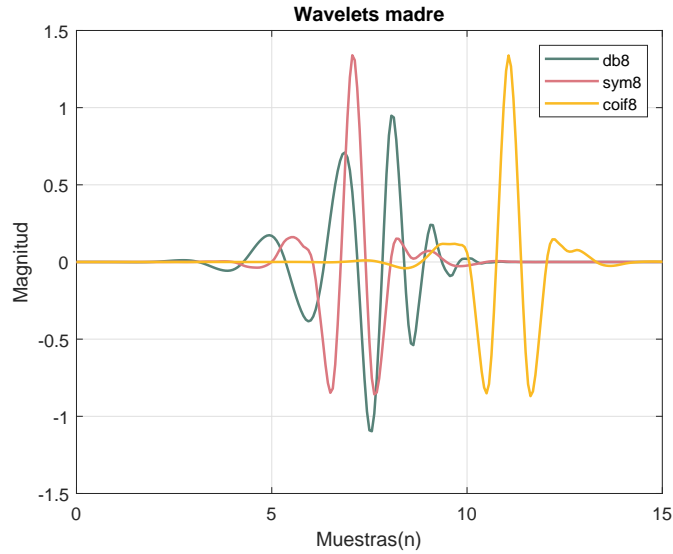


Figura 2.6 Funciones wavelet madre comunes.

2.3.2. Transformadas Fraccionarias

Transformada de Fourier fraccionaria (FRFT)

En las últimas décadas han surgido nuevas definiciones de transformadas integrales como la transformada fraccionaria de Fourier definida por Víctor Namias en 1980 [68] y tratada matemáticamente por Mcbride en [69], se define como:

$$F^\alpha[f(t)] = \int_{-\infty}^{\infty} f(t)K_\alpha(t, u)dt, \quad (2.34)$$

en el cual α representa el orden de la transformada y $K_\alpha(t, u)$ es el kernel de transformación el cual se define como:

$$K_\alpha(t, u) = K_\phi \exp(i\pi(u^2 \cot \phi - 2ut \csc \phi + t^2 \cot \phi)), \quad (2.35)$$

donde $\phi = \frac{\alpha\pi}{2}$ y K_ϕ se define como:

$$K_\phi = \exp \left[\frac{-i\pi(\text{sign}(\phi)) - \frac{\phi}{2}}{\sqrt{|\sin \phi|}} \right], \quad (2.36)$$

Fundamentos teóricos

esta transformada nos permite obtener representaciones de señales en el dominio de Fourier fraccionario, además que se puede obtener el caso clásico al utilizar un orden de transformación unitario.

Transformada Wavelet fraccionaria (FRWT)

La transformada wavelet fraccionaria fue presentada por Mendlovic [70] en donde utilizaba la transformada de Fourier fraccionaria para obtener el espectro en el dominio de Fourier fraccionario y sobre el se aplica la transformada wavelet, recientemente Dai en [71] presenta una nueva definición de la transformada wavelet fraccionaria, definida como:

$$W_x^\alpha(a, b) = \sqrt{\frac{2\pi a}{1 + i \cot \alpha}} \int_{-\infty}^{\infty} e^{-\frac{i}{2} a^2 u^2 \cot \alpha} X_\alpha(u) \Phi_\alpha(au) K_{-\alpha}(u, b) du, \quad (2.37)$$

la diferencia principal de esta definición y la transformada clásica es la función wavelet madre, en este caso se define como wavelet madre fraccionaria que depende del orden de α , $\Phi_\alpha(au)$ y $X_\alpha(u)$ equivalen a la Wavelet madre y la señal en el dominio de Fourier fraccionario, la principal contribución de esta transformada es la obtención de información local de la señal que permite realizar análisis multiresolución en el dominio de Fourier fraccionario para señales transitorias y no estacionarias.

2.4. Algoritmos de diagnóstico de fallas

El diagnóstico y detección de fallas tiene un rol importante dentro de la operación y mantenimiento de los sistemas, esto se debe a que pueden ser afectados por diversos factores imprevisibles e inevitables y las fallas se pueden presentar en cualquier momento. Los métodos de diagnóstico de fallas se dividen en tres categorías: método basado en modelos analíticos, método basado en el conocimiento del sistema y el método basado en el procesamiento de señales [72].

El método basado en modelos analíticos se puede dividir en 3 subcategorías: estimación de estado, estimación de parámetros y espacio equivalente; estos métodos requieren de un modelo matemático preciso del sistema a diagnosticar, lo cual se refleja en una alta precisión en el diagnóstico, sin embargo, puede resultar poco viable en sistemas en los cuales obtener un modelo matemático preciso es complejo.

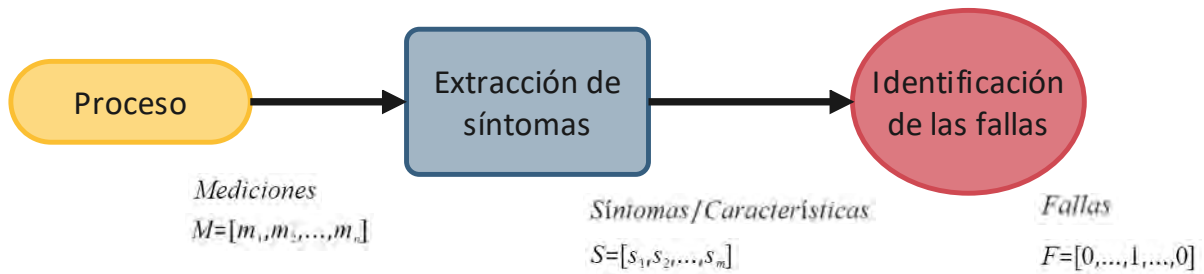


Figura 2.7 Modelo generalizado de diagnóstico mediante el reconocimiento de patrones.

El método de diagnóstico basado en el conocimiento del sistema no requiere modelos matemáticos precisos del sistema, es un método que se centra en el procesamiento de la información del sistema y utiliza el conocimiento profundo del funcionamiento del sistema, comúnmente se emplean algoritmos de aprendizaje automático, este método es utilizado para sistemas no lineales. Los métodos que se incluyen en esta categoría son: método basado en sistemas expertos, método basado en redes neuronales, método de árbol de fallas y algunas otras técnicas de aprendizaje automático.

El método de diagnóstico basado en señales es útil cuando no se puede establecer un modelo matemático preciso, este método emplea el procesamiento de las señales generadas por el sistema mediante técnicas como las transformadas integrales, análisis espectral y análisis de componentes principales, de los cuales se extraen características que describen comportamientos del sistema como: amplitud, varianza, frecuencias para el diagnóstico de fallas. Este método comúnmente se combina con el método basado en el conocimiento.

De acuerdo con Korbicz et al. 2012 [73] una descripción paramétrica de un sistema incluye solo una parte de todos los parámetros de estado existentes, una mejor descripción se puede obtener con la relación de los valores de un conjunto de magnitudes físicas o señales y el estado en el que se encuentra el sistema. A partir del enfoque de señales se pueden emplear métodos de reconocimiento de patrones para asociar los patrones que tiene una señal o un conjunto de magnitudes con un determinado estado del sistema como se muestra en la Figura 2.7

Emplear el enfoque de reconocimiento de patrones para el diseño de métodos de diagnóstico de fallas presenta diversas ventajas. Este enfoque se basa en datos numéricos obtenidos a partir de mediciones u observaciones de magnitudes del sistema. El reconocimiento de patrones abarca los problemas de detección, representación y reconocimiento de los estados de un conjunto de valores que describen un sistema.

Aplicar métodos con un enfoque de reconocimiento de patrones equivale a resolver problemas de clasificación. Esto permite identificar y diferenciar entre distintos estados o condiciones

del sistema, facilitando un diagnóstico más preciso y eficiente de fallas. Por lo tanto, el reconocimiento de patrones no solo mejora la detección y clasificación de fallas, sino que también contribuye a la representación efectiva de los datos y la comprensión de los estados del sistema, ofreciendo una herramienta poderosa para el mantenimiento y la gestión de sistemas eléctricos.

2.5. Clasificación

Herrera et al. 2016 [74] menciona que los clasificadores tienen como objetivo aprender patrones etiquetados, crear un modelo capaz de predecir la etiqueta(clase) de datos futuros, nunca antes vistos. Aggarwa et al. 2015 [75] plantea el problema de clasificación como: *Dado un conjunto de puntos de datos de entrenamiento junto con las etiquetas de entrenamiento asociadas, determine la etiqueta de clase para una instancia de prueba sin etiquetar.* Comúnmente los algoritmos de clasificación tienen dos etapas:

- Entrenamiento: consiste en construir un modelo a partir de los datos de entrenamiento.
- Prueba: se utiliza el modelo construido para asignar una etiqueta, a datos no conocidos sin etiquetar.

La clasificación se puede enfocar en 3 categorías:

- *Centrado en la técnica:* aquí encontramos técnicas como árbol de decisiones, métodos basados en reglas, métodos SVM, redes neuronales, métodos del vecino más cercano y métodos probabilísticos.
- *Centrado en el tipo de datos:* se centra en el diseño de la técnica en base al tipo de dato, estos pueden ser datos que incluyan texto, multimedia, series de tiempo, secuencias discretas entre otros.
- *Variaciones en el análisis de clasificación:* en esta categoría se centra en escenarios de clasificación más complejos, como el aprendizaje de clases poco comunes, aprendizaje por transferencia o aprendizaje semi-supervisado.

A continuación se describirán algunos de los clasificadores más comunes.

2.5.1. Clasificadores

Árbol de decisiones

De manera general la técnica de árbol de decisiones divide de forma recursiva los datos de entrenamiento y maximiza la discriminación entre las diferentes clases en cada nodo la cual corresponde cuando se maximiza el sesgo entre las clases, para medir el sesgo se utiliza el índice gini o la entropía definidos como

$$G(N) = 1 - \sum_{i=1}^k P_i^2, \quad (2.38)$$

$$E(N) = - \sum_{i=1}^k P_i \cdot \log(P_i), \quad (2.39)$$

la estructura para realizar la clasificación mediante la técnica de árbol de decisiones se muestra en la Figura 2.8, la distribución de los datos al emplear la técnica de árbol de decisiones se muestra en la Figura 2.9




Figura 2.8 Clasificador de árbol de decisiones.

Random forest

Esta técnica está formada por grupos de modelos de árbol de decisiones, donde cada árbol da una clasificación (vota por una clase), el resultado de la técnica es la clase con mayoría de votación, en la Figura 2.10 se muestra el esquema general de la técnica




Figura 2.9 Distribución de características en un clasificador de árbol de decisiones.

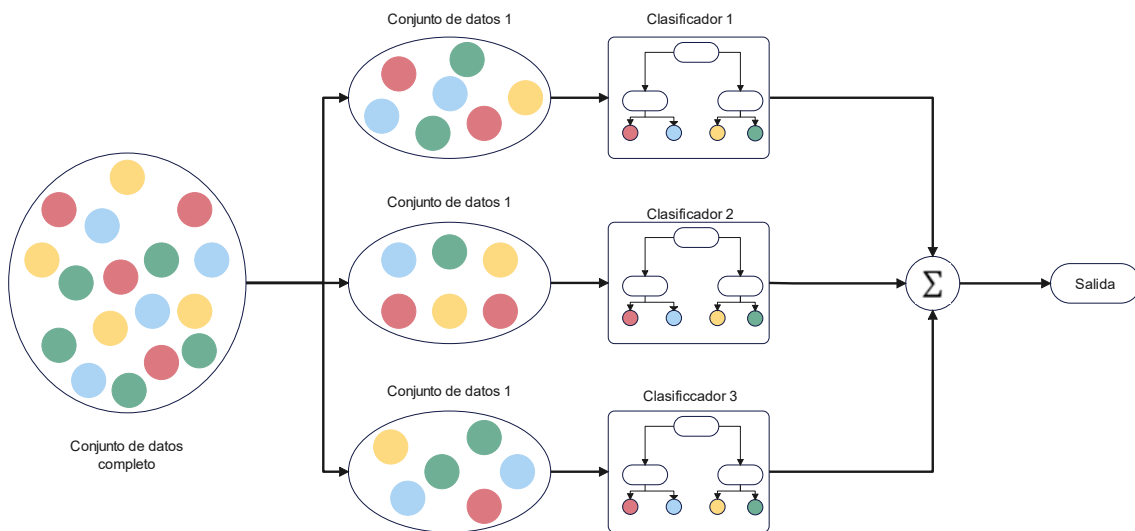


Figura 2.10 Diagrama de clasificador bosque aleatorio.

Support vector machines

Esta técnica consiste en utilizar condiciones lineales para separar la clases, generalmente es usada en clasificaciones binarias, tiene como base el uso de kernels de transformación para obtener la información de similitud entre los datos, algunos funciones que se utilizan como kernel son: función de base radial (2.40), polinomial (2.41) y tangente hiperbólica (2.42).

$$K(\bar{X}_i, \bar{X}_j) = e^{-\|\bar{X}_i - \bar{X}_j\|^2 / 2\sigma^2}, \quad (2.40)$$

$$K(\bar{X}_i, \bar{X}_j) = (\bar{X}_i \cdot \bar{X}_j + 1)^h, \quad (2.41)$$

$$K(\bar{X}_i, \bar{X}_j) = \tanh(k\bar{X}_i \cdot \bar{X}_j - \delta), \quad (2.42)$$

donde \bar{X}_i son los valores de \mathbb{X} y \bar{X}_j son los valores de \mathbb{X}^T .

Redes neuronales

Las redes neuronales artificiales intentan simular al cerebro humano, la unidad de cálculo en una red neuronal es la neurona y esta puede emplearse en diferentes tipos de arquitecturas, en la Figura 2.11 se muestra la arquitectura de tipo perceptrón que se define en la Ec.(2.43)

$$y = \varphi \left(\sum_{n=1}^N \omega_n x_n + \rho \right), \quad (2.43)$$

$$\mathbf{V} = \Phi^+ \mathbf{Y}, \quad (2.44)$$

donde x_n representa el vector de entradas de la RNA, ω_n y ρ son pesos sinápticos y umbrales, respectivamente, definidos aleatoriamente con el fin de extender el co-dominio de las funciones de activación (φ) de la primera capa. La Ec.(2.44) representa el entrenamiento de los pesos sinápticos \mathbf{V} de la capa de salida donde Φ^+ es la matriz pseudoinversa de la dinámica generada por $\varphi(\omega\mathbf{X} + \rho)$ y \mathbf{Y} es un vector definido por las etiquetas o clases.

Métricas de clasificación

Las métricas para clasificación son medidas utilizadas para evaluar el rendimiento de un modelo de clasificación en tareas de aprendizaje automático (Machine learning). Estas métricas

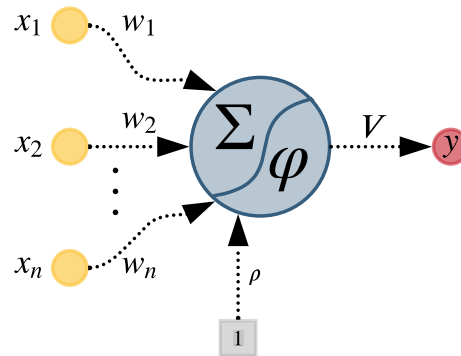


Figura 2.11 Neurona artificial.

ayudan a determinar cuán bien el modelo predice las etiquetas correctas para nuevas muestras de datos.

		Valores Reales	
		Positivo	Negativo
Valores Predichos	Positivo	TP	FP
	Negativo	FN	TN

Figura 2.12 Matriz de confusión general.

La matriz de confusión es una tabla que muestra las verdaderas etiquetas frente a las predicciones del modelo. Contiene valores para verdaderos positivos (TP), verdaderos negativos (TN), falsos positivos (FP) y falsos negativos (FN), como se muestra en la Figura 2.12. A

partir de la matriz de confusión se derivan distintas métricas de clasificación que se muestran a continuación:

Exactitud (Accuracy): La exactitud es la proporción de predicciones correctas (tanto verdaderos positivos como verdaderos negativos) sobre el total de predicciones. Es una métrica global que indica el porcentaje de predicciones correctas. Es útil cuando las clases están balanceadas, pero puede ser engañosa en casos de clases desequilibradas.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}. \quad (2.45)$$

Exhaustividad (Recall): La exhaustividad, también conocida como sensibilidad o tasa de verdaderos positivos, mide la proporción de verdaderos positivos entre todas las muestras que realmente son positivas, es útil cuando el costo de un falso negativo es alto.

$$Recall = \frac{TP}{TP + FN}. \quad (2.46)$$

Precisión (Precision): La precisión mide la proporción de verdaderos positivos entre todas las muestras clasificadas como positiva, es especialmente útil en situaciones donde el costo de un falso positivo es alto.

$$Precision = \frac{TP}{TP + FP}. \quad (2.47)$$

Especificidad (Specificity): La especificidad, o tasa de verdaderos negativos, mide la proporción de verdaderos negativos entre todas las muestras que realmente son negativas, es útil en casos donde es importante identificar correctamente las instancias negativas.

$$Specificity = \frac{TN}{TN + FP}. \quad (2.48)$$

Los valores de las métricas anteriormente mencionadas, se pueden presentar en el rango de cero a uno, o en un formato porcentual de 0 a 100, el valor objetivo de esta métrica es 1 y en el caso del formato porcentual es el 100%.

Funciones de pérdida (Loss function)

Las funciones de pérdida (loss functions) son fundamentales en el entrenamiento de modelos de machine learning, especialmente en tareas de clasificación. Estas funciones cuantifican el error entre las predicciones del modelo y las etiquetas reales, guiando el proceso de optimización

Fundamentos teóricos

para minimizar dicho error, los valores de estas metricas comunmente se encuentran entre cero y uno donde el objetivo es llegar al valor más bajo, algunas de estas se describen a continuación:

Error Absoluto Medio (Mean Absolute Error - MAE)

La métrica MAE comúnmente utilizada en problemas de regresión para evaluar la precisión de un modelo predictivo. Su uso en clasificación es adaptado para ciertos contextos específicos, en particular, puede ser útil en situaciones donde las clases pueden ser ordenadas o tener una relación ordinal (por ejemplo, en clasificación ordinal o en problemas de etiquetado de niveles), la métrica del MAE para un problema de clasificación se puede definir como:

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i|, \quad (2.49)$$

donde y_i es la etiqueta real de la muestra o característica i y \hat{y}_i es la etiqueta que predice el clasificador.

Pérdida de entropía cruzada binaria (Binary Cross entropy loss - BCE)

La pérdida de entropía cruzada mide la discrepancia entre la distribución de probabilidad predicha y la distribución de probabilidad real, se emplea comúnmente en problemas de clasificación binaria y multiclase, se define en la Ec.(2.50)

$$BCE = -\frac{1}{N} \sum_{i=1}^N [y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)], \quad (2.50)$$

donde y representa las etiquetas reales de los datos, si las etiquetas son binarias su valor es 0 o 1, \hat{y} es la probabilidad de clase estimada su valor se encuentra entre 0 y 1. En redes neuronales se utiliza empleando una función de activación sigmoide en la capa de salida de la RNA, la función sigmoide tiene un rango de (0, 1) lo cual asegura que las predicciones de la red se puedan comparar directamente con las etiquetas binarias de los datos.

Pérdida de entropía cruzada categórica (Categorical Cross-Entropy Loss - CCE) La función de pérdida de entropía cruzada categórica se emplea para clasificaciones multiclase, al igual que la función BCE mide la diferencia entre las probabilidades de la etiquetas reales y la predichas por el clasificador, esta se define en la Ec. (2.51)

$$CCE = -\frac{1}{N} \sum_{i=1}^N \sum_{c=1}^C y_{ic} \log(\hat{y}_{ic}), \quad (2.51)$$

donde y_{ic} es el valor correspondiente a la clase c para la i -ésima muestra o característica, \hat{y}_{ic} es la probabilidad estimada por el clasificador para la clase c de la muestra o característica i .

2.6. Algoritmos de optimización

Los algoritmos de optimización son métodos y procedimientos diseñados para encontrar la mejor solución posible (óptimo) en un espacio de soluciones factibles, generalmente minimizando o maximizando una función objetivo. Estos algoritmos son fundamentales en diversas áreas, incluyendo la ciencia, la ingeniería, la economía y el aprendizaje automático

2.6.1. Algoritmo de enjambre de partículas (PSO)

La optimización por enjambre de partículas es un algoritmo biológicamente inspirado [76] donde tienen como base la inteligencia de enjambre, el algoritmo consiste en la búsqueda de una solución en un espacio de soluciones, análogamente con la naturaleza se cree que una bandada de aves que suelen moverse en grupo pueden beneficiarse de todos los demás miembros del grupo. El término optimización hace referencia al procedimiento de encontrar el mejor elemento dentro de un conjunto de opciones posibles con base a serie de criterios definidos por el usuario.

En términos matemáticos el procedimiento se alcanza definiendo el objetivo en términos de una función parametrizada, por lo tanto la optimización se resume en la búsqueda de los valores de los parámetros.

Algoritmo 1 Algoritmo PSO

```
1: Inicializar población
2: for  $t = 1$  do
3:   for  $i = 1$  do
4:     if  $f(x_{i,d}(t)) < f(p_i(t))$  then  $p_i(t)$ 
5:        $f(p_g(t)) = \min_i(f(p_i(t)))$ 
6:     end
7:     for  $d = 1$  do
8:        $v_{i,d}(t+1) = wv_{i,d}(t) + c_1r_1(p_i - x_{i,d}(t)) + c_2r_2(p_g - x_{i,d}(t))$ 
9:        $x_{i,d}(t+1) = x_{i,d}(t) + v_{i,d}(t+1)$ 
10:      if  $v_{i,d}(t+1) > v_{max}$  then  $v_{i,d}(t+1) = v_{max}$ 
11:      else if  $v_{i,d}(t+1) < v_{min}$  then  $v_{i,d}(t+1) = v_{min}$ 
12:      end
13:      if  $x_{i,d}(t+1) > x_{max}$  then  $x_{i,d}(t+1) = x_{max}$ 
14:      else if  $x_{i,d}(t+1) < x_{min}$  then  $x_{i,d}(t+1) = x_{min}$ 
15:      end
16:    end
17:  end
18: end
```

▷ Generación máxima
▷ Tamaño de la población
▷ Dimensión

Capítulo 3

Diseño de algoritmos para el diagnóstico

3.1. Metodología general de diagnóstico de fallas

La metodología utilizada para el diagnóstico de los sistemas consta de 3 etapas como se muestra en la Figura 3.1, la primera etapa consiste en la medición de las señales del sistema o simulación del sistema y la recopilación de los datos. La segunda etapa consiste en la extracción de características para lo cual se utilizan las transformadas integrales de orden generalizado. Finalmente, la última etapa consiste en la clasificación de las características, en esta etapa se obtiene la condición del sistema.

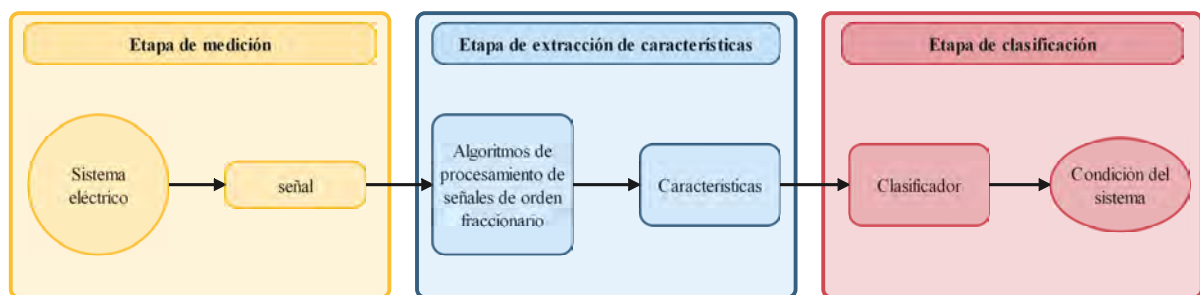


Figura 3.1 Metodología para detección y diagnóstico de fallas empleando algoritmos de procesamiento de señales de orden fraccionario.

A continuación se muestran los algoritmos de procesamiento de señales empleando transformadas integrales de orden generalizado.

3.2. Transformada de Fourier fraccionaria

En este algoritmo se aplica la transformada de Fourier fraccionaria con un orden α a una señal $x[n]$

$$\mathbf{X}_{\text{fr}}[n, m_\alpha] = F^\alpha \mathbf{x}, \quad (3.1)$$

donde F^α es la matriz de transformación dada por la Ec. (3.2)

$$F^\alpha = \begin{cases} \sum_{k=0}^{N-1} e^{-jk\alpha} \hat{u}_k \hat{u}_k^T, & N = 4m + 1 \\ \left\{ \sum_{k=0}^{N-2} e^{-jk\alpha} \hat{u}_k \hat{u}_k^T \right\} + e^{-jN\alpha} \hat{u}_N \hat{u}_N^T, & N = 4m \end{cases}, \quad (3.2)$$

donde \hat{u}_k representa los eigenvectores normalizados de las funciones discretas de Hermite de orden k .

La transformada de Fourier fraccionaria permite obtener distintas distribuciones de energía de la señal dependiendo del orden de α , la transformada de Fourier clásica es un caso particular de la transformada de Fourier fraccionaria cuando el orden es 1.

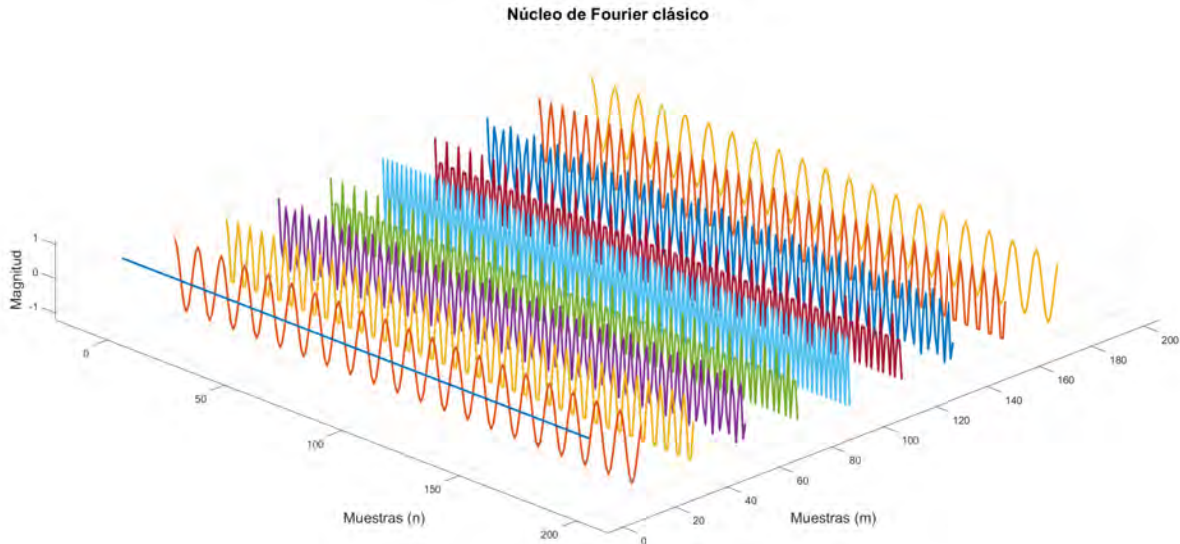


Figura 3.2 Composición de kernel de transformada de Fourier fraccionaria orden $\alpha = 1$.

La composición del núcleo de la transformada con orden 1 (Fourier clásico) está compuesto de funciones sinusoidales como se muestra en la Figura 3.2, esto permite obtener una distribución de energía en el dominio frecuencial. Las composiciones del núcleo de la transformada con órdenes distintos de 1 está compuesto por funciones con frecuencia variante en el tiempo

3.3 Transformada de Fourier con kernel de Mittag-Leffler

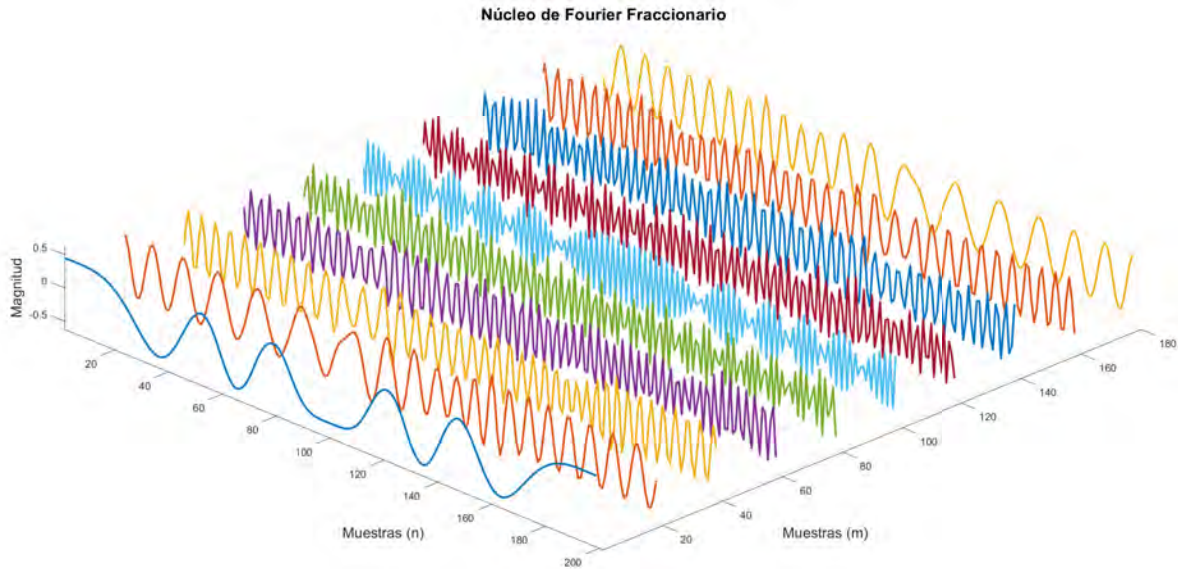


Figura 3.3 Composición de kernel de transformada de Fourier fraccionaria orden $\alpha = 0,5$.

como se muestra en la Figura 3.3, esto permite obtener información de señales con frecuencia variantes en el tiempo o contaminadas por ruido.

Las características extraídas al aplicar la transformada de Fourier fraccionaria son utilizadas para clasificación en una red neuronal artificial la cual tiene la arquitectura mostrada en la Figura 3.8

$$\mathbf{Y} = \varphi_3[\mathbf{Q}(\varphi_2[\mathbf{V}(\varphi_1[\mathbf{U}\mathbf{X}_{fr} + \rho]) + \rho)] + \rho], \quad (3.3)$$

en donde \mathbf{Y} es la salida de la RNA; \mathbf{Q} , \mathbf{V} y \mathbf{U} corresponden a las matrices de los pesos sinápticos de cada una de las capas; ρ es la sinapsis; φ_1 , φ_2 y φ_3 son las funciones de activación y \mathbf{X}_{fr} es el conjunto de características extraídas.

3.3. Transformada de Fourier con kernel de Mittag-Leffler

En el segundo algoritmo de extracción de características se propone una modificación del núcleo de la transformada, la transformada discreta de Fourier se define como:

$$\mathbf{X}[k] = \sum_{n=0}^{N-1} \mathbf{x}[n] e^{\frac{-i2\pi kn}{N}}. \quad (3.4)$$

Diseño de algoritmos para el diagnóstico

donde N representa el número total de datos en la señal, $\mathbf{x}[n]$ es la señal a transformar, la función anterior también expresada como matriz de transformación como:

$$\mathbf{X} = \mathbf{W}\mathbf{x}, \quad (3.5)$$

donde \mathbf{X} es la señal transformada, \mathbf{x} es la señal a transformar y \mathbf{W} es la matriz de transformación definida como:

$$\mathbf{W} = \frac{1}{\sqrt{N}} \begin{bmatrix} 1 & 1 & 1 & 1 & \dots & 1 \\ 1 & \omega & \omega^2 & \omega^3 & \dots & \omega^{(N-1)} \\ 1 & \omega^2 & \omega^4 & \omega^6 & \dots & \omega^{2(N-1)} \\ 1 & \omega^3 & \omega^6 & \omega^9 & \dots & \omega^{3(N-1)} \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & \omega^{(N-1)} & \omega^{2(N-1)} & \omega^{3(N-1)} & \dots & \omega^{(N-1)(N-1)} \end{bmatrix}, \quad (3.6)$$

donde $\omega = e^{-2\pi i/N}$. El algoritmo que se propone emplea la función de Mittag-Leffler para sustituir la función exponencial, esta función de dos parámetros nos permite obtener el caso particular del exponencial y ajustando los valores de los parámetros obtener comportamientos pseudo exponenciales, por lo tanto al utilizar esta función podemos obtener diferentes distribuciones de energía en una señal transformada, reescribiendo ω con la función de Mittag-Leffler de un solo parámetro se tiene

$$\omega_{ML} = E_{\alpha} \left(-i \frac{2\pi}{N} \right), \quad (3.7)$$

por lo tanto, la Ec.(3.6) se define como:

$$\mathbf{W}_{ML}^{\alpha} = \frac{1}{\sqrt{N}} \begin{bmatrix} 1 & 1 & 1 & 1 & \dots & 1 \\ 1 & \omega_{ML} & \omega_{ML}^2 & \omega_{ML}^3 & \dots & \omega_{ML}^{(N-1)} \\ 1 & \omega_{ML}^2 & \omega_{ML}^4 & \omega_{ML}^6 & \dots & \omega_{ML}^{2(N-1)} \\ 1 & \omega_{ML}^3 & \omega_{ML}^6 & \omega_{ML}^9 & \dots & \omega_{ML}^{3(N-1)} \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & \omega_{ML}^{(N-1)} & \omega_{ML}^{2(N-1)} & \omega_{ML}^{3(N-1)} & \dots & \omega_{ML}^{(N-1)(N-1)} \end{bmatrix}, \quad (3.8)$$

la composición de esta matriz de transformación se muestra en la Figura 3.4, las funciones que componen el núcleo tienen una variación de frecuencia y amplitud dependiendo del orden, en la Figura 3.5 se muestra la comparación de las componentes del núcleo con distintos órdenes.

3.4 Descomposición wavelet con transformada de Fourier

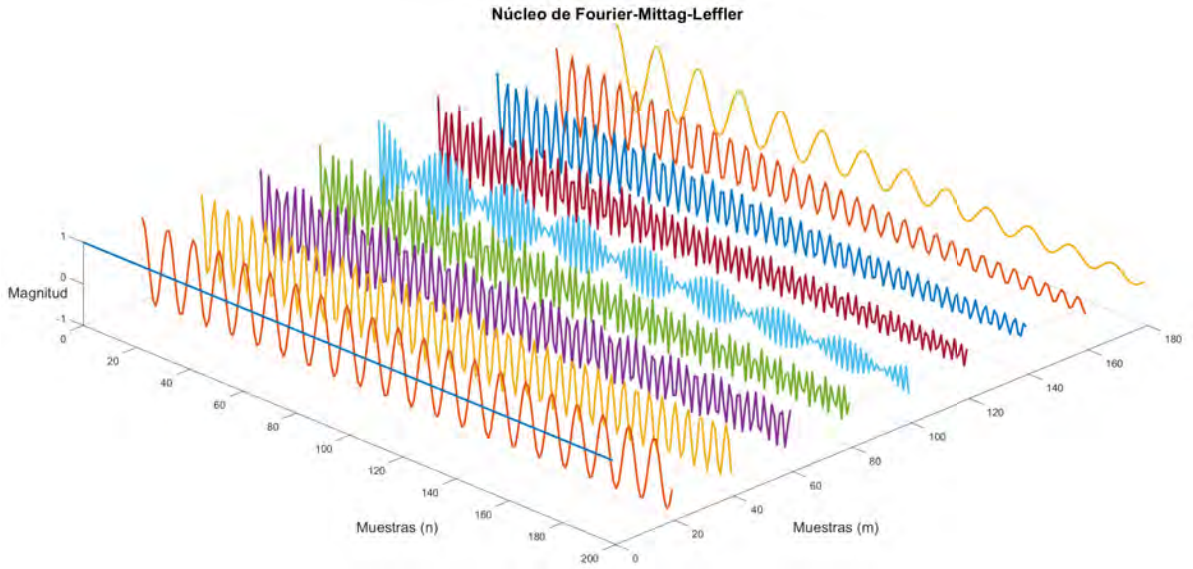


Figura 3.4 Composición de kernel de transformada de Fourier Mittag-Leffler.

por lo tanto el conjunto de características de este algoritmo se define como la multiplicación de la matriz modificada Ec.(3.8) por la señal \mathbf{x} como se muestra en la Ec. (3.9) .

$$\mathbf{X}_{\text{FTML}} = \mathbf{W}_{\text{ML}}^{\alpha} \mathbf{x} \quad (3.9)$$

3.4. Descomposición wavelet con transformada de Fourier

El siguiente algoritmo tiene como base el uso de la descomposición wavelet en conjunto con la transformada de Fourier fraccionario, la descomposición wavelet consiste en la convolución de una señal con distintas ventanas de tipo wavelet, esto genera diferentes sub bandas en el plano frecuencial, a dichas sub-bandas se les puede considerar niveles de energía de una señal. Las funciones de las ventanas wavelet se definen como:

$$\psi_{a,b} = \frac{w\left(\frac{x-b}{a}\right)}{\sqrt{|a|}}; (a,b) \in R, a \neq 0, \quad (3.10)$$

donde el parámetro a permite ajustar la dilatación y contracción de la función, las familias más conocidas de wavelets son: Daubechies, Haar, Coiflets, Symlets, morlet, etc.

En la descomposición se utiliza la wavelet madre en una función de escalamiento definida como:




Figura 3.5 Valores de W_N^{ML} en $N = 1$.




Figura 3.6 Valores de W_N^{ML} en $N = 2$.

$$\lambda(t) = \sum_{k=-1}^{N-2} (-1)^k \cdot c_{k+1} \psi(2t+k), \quad (3.11)$$

donde c_k son los coeficientes wavelet los cuales pueden ser considerados como filtros, los cuales al ser acomodados en dos patrones distintos uno funciona como filtro pasa baja y otro pasa alta, en la Figura 3.7 se muestra la descomposición de 3 niveles




Figura 3.7 Árbol de descomposición wavelet de 3 niveles.

donde $x[n]$ es la señal a descomponer, $h_{1,2,3,\dots,i}$ son los filtro pasa alta, $l_{1,2,3,\dots,j}$, $D_{1,2,3}$ y A_3 niveles de descomposición. El algoritmo consiste en realizar una descomposición de la señal mediante wavelets, se aplican 5 niveles de descomposición donde cada una de estas componentes, tiene una longitud diferente a la señal y por lo tanto una banda de frecuencias

que depende del nivel de descomposición, a cada uno de los niveles de descomposición se les aplica la transformada fraccionaria de Fourier como se muestra en la ecuación 3.12

$$C_{WT_i} = F^\alpha [D_i], \quad (3.12)$$

donde F^α es matriz de transformacion de Fourier fraccionario que se puede calcular en la Ec.(3.1) y D_i es el i-esimo nivel de descomposición wavelet. Para el cálculo de la energía relativa wavelet en dominio de Fourier fraccionario la energía relativa wavelet que se define como:

$$E_j = \sum_{i=1}^{N_j} |C_{WT_j}|^2, \quad (3.13)$$

$$\bar{E}_j = \frac{1}{N_j} \sum_{i=1}^{N_j} |C_{WT_j}|^2, \quad (3.14)$$

$$E_T = \sum_{j=1}^N \bar{E}_j, \quad (3.15)$$

$$C_{ERWT_j} = \frac{\bar{E}_j}{E_T}, \quad (3.16)$$

En donde la Ec.(3.14) define la energía en cada nivel de descomposición, la Ec.(3.15) representa la media de energía y finalmente la Ec.(3.16) define la energía relativa en cada nivel de descomposición.

El conjunto de características que se utiliza a partir de este algoritmo de extracción es el siguiente

$$\mathbf{X}_{wfft} = [\mathbf{x}, \mathbf{C}_{WT1}, \mathbf{C}_{WT2}, \mathbf{C}_{WT3}, \mathbf{C}_{WT4}, \mathbf{C}_{WT5}, \mathbf{C}_{WTA1}, \mathbf{C}_{ERWT}], \quad (3.17)$$

a estas características se les aplicó la desviación de las medias para mejorar el desempeño en la clasificación.

3.5. Etapa de clasificación

El monitoreo de las condiciones del sistema es llevada a cabo por un sistema de clasificación de los conjuntos de características mostrado en las secciones anteriores, para llevar a cabo la clasificación de las condiciones del sistema es necesario conocer las características de este y

Diseño de algoritmos para el diagnóstico

tener un registro de datos históricos de sus condiciones. El clasificador utilizado en las etapa de clasificación es una red neuronal multicapa con múltiples salidas, los datos de entrada al clasificador son las características que se obtuvieron a partir de los algoritmos de extracción de características fraccionarios. Los hiper parámetros de la RNA, son el número de neuronas, el número de capas ocultas, el número de neuronas de salida y las funciones de activación. Los número de neuronas en la capa de salida depende del número de clases que se están clasificando, en la Figura 3.8 se muestra la arquitectura de la RNA utilizada.

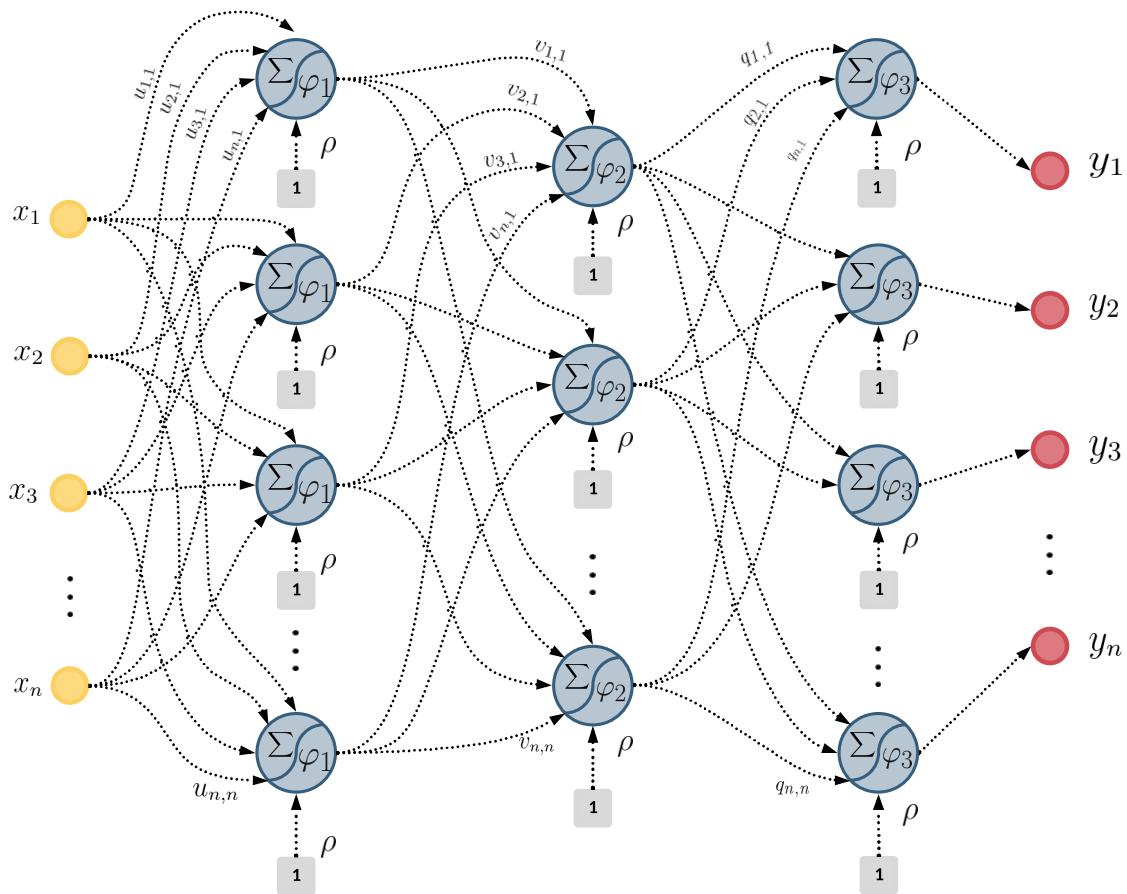


Figura 3.8 Arquitectura de la RNA.

3.6. Optimización del orden de α

La optimización del orden de α para cada cada algoritmo de extracción de características se realiza mediante el algoritmo de enjambre de partículas (PSO), la metodología de aplicación de este algoritmo se muestra en la Figura 3.9, donde el parámetro que se introduce en el algoritmo a optimizar es el orden de transformación utilizado para la extracción de características, como métrica utilizada para generar el error

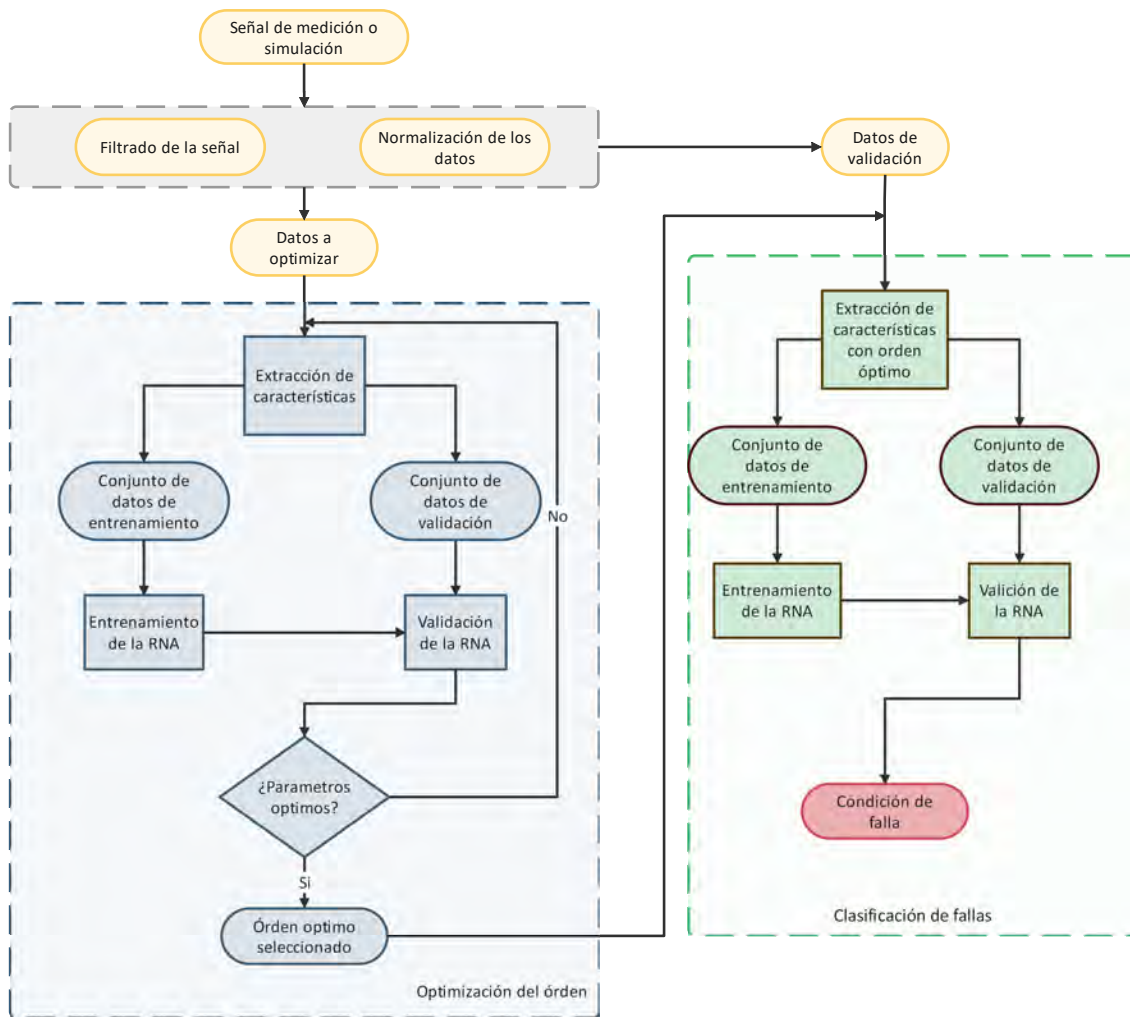


Figura 3.9 Diagrama de optimización de los órdenes de los operadores.

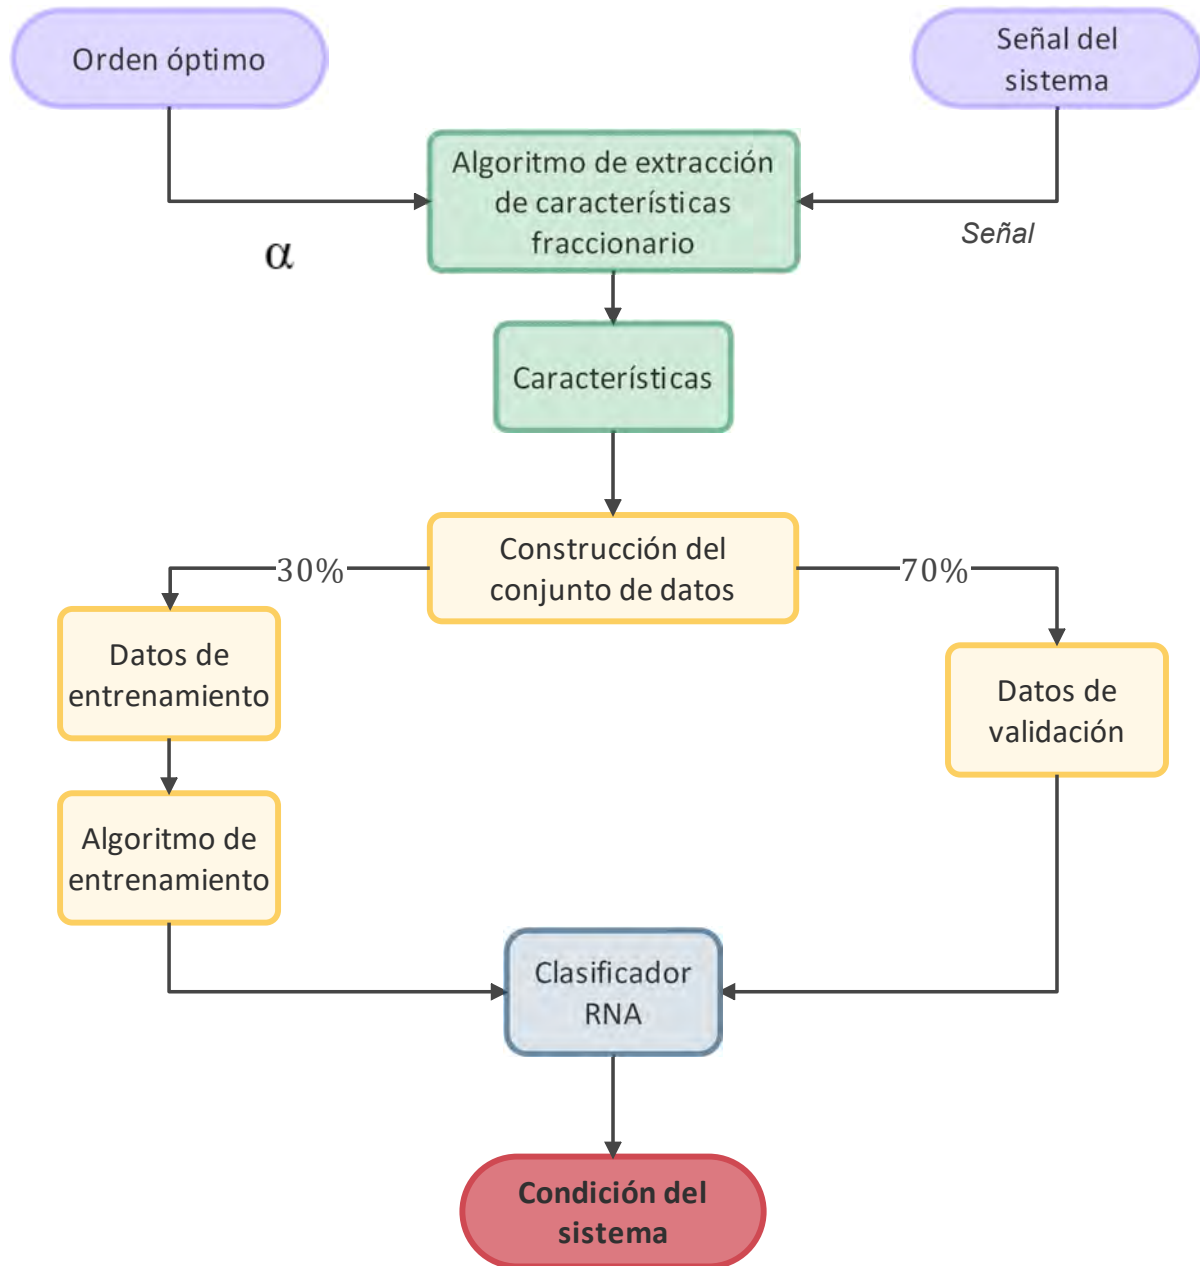


Figura 3.10 Diagrama de implementación de los órdenes óptimos para la extracción de características.

Capítulo 4

Casos de estudio

Una señal puede tener distintas representaciones, las más comunes son: dominio temporal, frecuencial, Fourier fraccionario, Tiempo-frecuencia, entre otras. Cada representación ofrece distinta información útil, como las componentes frecuenciales de una señal, la evolución de la frecuencia a lo largo del tiempo, la fase de la señal, entre otras características. Una herramienta útil para obtener estas representaciones es el uso de las transformadas integrales.

Con el objetivo de mejorar las representaciones de las señales en los sistemas eléctricos para el diagnóstico de fallas y en el análisis de la calidad de la energía, se propone una metodología con base en el cálculo fraccionario, específicamente en la rama de las transformadas integrales de orden fraccionario.

4.1. Diagnóstico de fallas de cortocircuito en transformador

Los transformadores son dispositivos esenciales en una red eléctrica ya que se pueden encontrar desde la etapa de generación, transmisión y distribución. Debido a esta importancia es necesario el monitoreo de su condición. Diversos factores pueden ser causar condiciones de operación anormales o fallas en el transformador. Una de las fallas mas comunes en el transformador es la falla de cortocircuito entre vueltas de los devanados, la causada de esta falla es asociada a altos niveles de voltaje o corriente causando una degradación en el aislamiento de los conductores.

En el primer caso de estudio se realiza el diagnóstico de fallas de cortocircuito en un transformador monofásico de 1.5 kVA, la descripción detallada de la etapa de experimentación y adquisición de datos se presenta en [77], el conjunto de datos obtenidos de esta compuestos

Casos de estudio

por señales de corriente y voltaje en los devanados, las condiciones del transformador que fueron consideradoras se listan en la Tabla 4.1, en esta tabla se listan 24 condiciones de estado del transformador las cuales son la combinación de 5 condiciones de cortocircuito y una condición saludable, en cada una de estas se consideran 4 condiciones de carga, la combinación de esto da como resultado un total de 24 condiciones del estado del transformador.

Tabla 4.1 Clases de fallas de en transformador.

Clase	Vuelta en cortocircuito	Carga	Clase	Vuelta en cortocircuito	Carga
1	0	Sin Carga	13	15	Sin Carga
2	0	Lineal	14	15	Lineal
3	0	Lineal y no lineal	15	15	Lineal y no lineal
4	0	No Lineal	16	15	No Lineal
5	5	Sin Carga	17	20	Sin Carga
6	5	Lineal	18	20	Lineal
7	5	Lineal y no lineal	19	20	Lineal y no lineal
8	5	No Lineal	20	20	No Lineal
9	10	Sin Carga	21	25	Sin Carga
10	10	Lineal	22	25	Lineal
11	10	Lineal y no lineal	23	25	Lineal y no lineal
12	10	No Lineal	24	25	No Lineal

La metodología empleada para éste caso de estudio se muestra en el diagrama de la Figura 4.1, esta compuesta por 3 etapas, la primera etapa es la etapa de medición en la cual se obtienen las señales que proporcionaran la información acerca del sistema, la segunda etapa es donde se realiza la extracción de características esto se lleva a cabo aplicando los algoritmos basados en transformadas integrales de orden fraccionario. Finalmente la tercera etapa es la de clasificación en esta etapa se emplean una red neuronal para la estimación de las clases a partir de las características obtenidas en la segunda etapa, para obtener la condición de falla o condición del sistema.

En la Figura 4.2 se muestra las señales de la corriente en el devanado primario con los diferentes niveles de falla y sin carga en el devanado secundario, la Figura 4.3 muestra las señales con carga lineal, la Figura 4.4 con carga combinada lineal y no lineal y finalmente en la Figura 4.5 se muestra la comparativa de la señales con carga no lineal.

4.1 Diagnóstico de fallas de cortocircuito en transformador

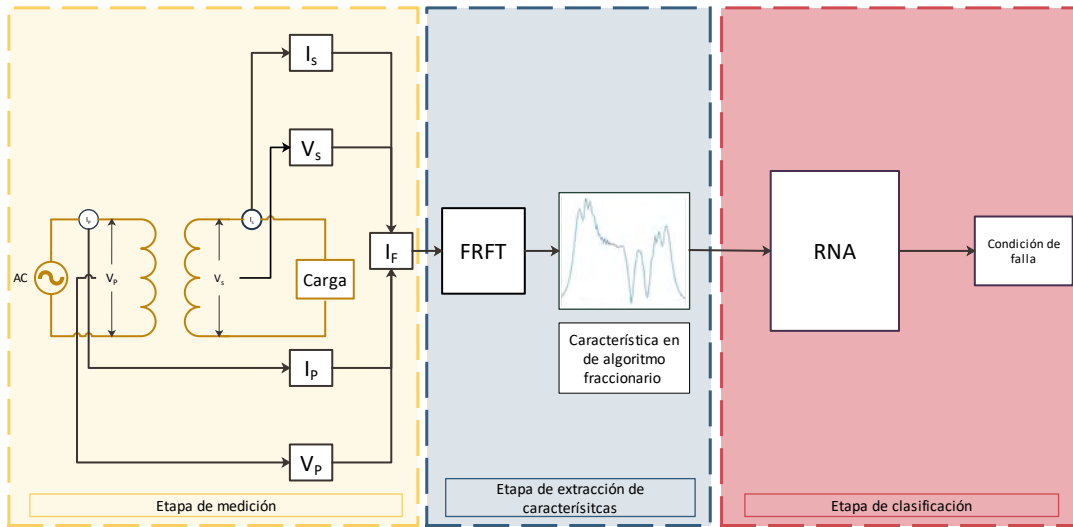


Figura 4.1 Diagrama de metodología para el diagnóstico de fallas en transformador.

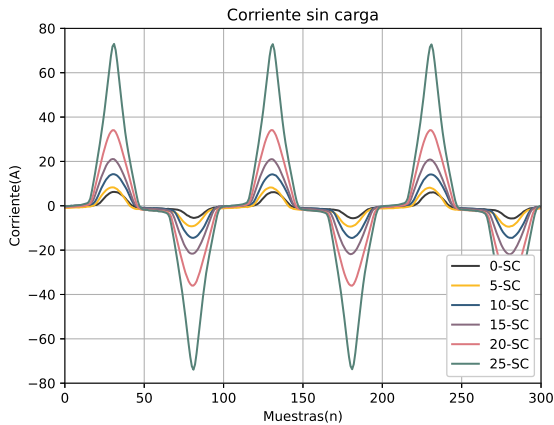


Figura 4.2 Comparación de corriente del transformador sin carga.




Figura 4.3 Comparación de corriente del transformador con carga lineal

En la etapa de medición, la señales de voltaje y corriente tanto del devanado primario y secundario fueron usadas para calcular la corriente i_F , la cual tiene como base el principio de las protecciones diferenciales usando la relación de transformación calculada con base a la ecuaciones de un transformador ideal.

$$i_p = \frac{i_s}{a}, \quad (4.1)$$

Casos de estudio




Figura 4.4 Comparación de corriente del transformador con una carga mixta.

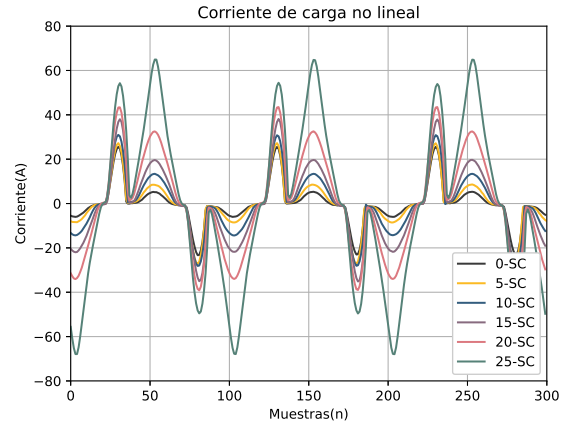


Figura 4.5 Comparación de corriente del transformador con carga no lineal

Donde i_p es la corriente del devanado primario, i_s es la corriente del devanado secundario y $a = \frac{V_s}{V_p}$ es la relación de transformación, esta se calcula a partir del voltaje del devanado primario V_p y devanado secundario V_s . La diferencia entre las dos corrientes de la Ec. 4.1 es cero en el caso de un transformador, sin embargo, en el caso de un transformador real esto no se cumple y se debe a las corrientes de magnetización, pérdidas en el núcleo del transformador y por corrientes de falla, estos puntos se pueden incluir en la corriente de operación definida en la Ec. 4.2

$$i_{OP} = i_p - \frac{i_s}{a}. \quad (4.2)$$

Los fenómenos de no linealidades y pérdidas en el núcleo se presentan en la rama de magnetización del transformador, los valores de corriente correspondiente a estos fenómenos se encuentran entre el 2% y 3% de la corriente de la carga total, por lo tanto, se puede considerar analizar la corriente de operación para el diagnóstico de fallas de cortocircuito en los devanados como se presenta en la Ec. 4.3.

$$i_F = i_{OP}. \quad (4.3)$$

La corriente i_F se utiliza para la extracción de las características, el primero conjunto se extrae al aplicar el algoritmo **FRFT** del Capítulo 3, aplicando la Ec. (3.1), el conjunto de características se define por la Ec. (4.4), el conjunto de características esta compuesto por 4800

4.1 Diagnóstico de fallas de cortocircuito en transformador

tiras de datos de una longitud de 100 muestras, para cada condición de fallas corresponde a 200 tiras de datos por clase.

$$\mathbf{IF}_{fr} = \mathbf{F}^\alpha \mathbf{i}_F. \quad (4.4)$$

En la Figura 4.6 se muestra la comparativa de las características de la Ec. (4.4) en las 6 primeras condiciones de falla bajo las 4 condiciones de fallas. En la Figura 4.7 se muestran las métricas de entrenamiento del clasificador de tipo RNA descritas en la Sec.(2.5.1)




Figura 4.6 Características extraídas con la transformada de Fourier fraccionaria.

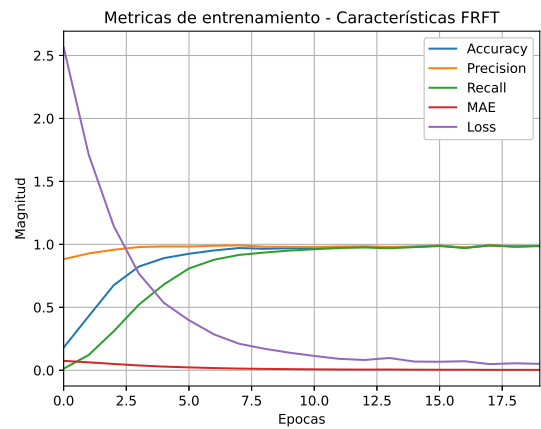


Figura 4.7 Entrenamiento de la RNA con las características FRFT.

El segundo conjunto de características que se extrajeron a partir de i_F se obtuvo al aplicar el algoritmo **FTML** descrito en la Sec.(3.3) el cual consiste en la modificación de la matriz de transformación de Fourier clásico empleando la función de Mittag-Leffler el cual se define en la Ec. (3.9) donde el conjunto de características \mathbf{IF}_{FTML} se define en la Ec.(4.5).

$$\mathbf{IF}_{FTML} = \mathbf{W}_{FTML}^\alpha \mathbf{i}_F. \quad (4.5)$$

En la Figura 4.8 se muestra la comparación de las 6 primeras características extraídas con un orden de $\alpha = 2,9417$ el cual se obtuvo en la etapa de optimización con la RNA, en la Figura 4.9 se muestran las métricas de entrenamiento del clasificador con estas características.

El último conjunto de características que se extrajeron para el caso del transformador se realiza empleando el algoritmo **WDFRFT** el cual se describe en la Sec.(3.4) aplicando la Ec. (3.17) el conjunto de características se define como:

Casos de estudio




Figura 4.8 Características extraídas con algoritmo FTML.




Figura 4.9 Entrenamiento de la RNA con las características FTML.

Tabla 4.2 Hiperparámetros de la RNA para la clasificación de fallas en el transformador.

Parámetros	
Número de neuronas en la capa de entrada	128
Número de capas ocultas	2
Número de neuronas en la capa de salida	24
Función de activación de la capa de entrada y capas ocultas	ReLU
Función de activación de la capa de salida	Softmax
Épocas de entrenamiento	20

$$\mathbf{IF}_{wfrft} = [\mathbf{i}_F, \mathbf{Ci}_{WT1}, \mathbf{Ci}_{WT2}, \mathbf{Ci}_{WT3}, \mathbf{Ci}_{WT4}, \mathbf{Ci}_{WT5}, \mathbf{Ci}_{WTA1}, \mathbf{Ci}_{ERWT}], \quad (4.6)$$

donde las matrices \mathbf{Ci}_{WT} corresponde a las energías relativas wavelet de cada nivel de descomposición de la señal \mathbf{i}_F , la matriz \mathbf{Ci}_{WTA1} corresponde a la energía relativa de 5 nivel de descomposición en baja frecuencia y \mathbf{Ci}_{ERWT} corresponde a la energía relativa wavelet de toda la señal \mathbf{i}_F , en la Figura 4.10 se muestra la comparación de las características de las 6 primeras condiciones de falla extraídas con un orden de $\alpha = 3,8296$, en la Figura 4.11 se muestran las métricas obtenidas durante el entrenamiento del clasificador tipo RNA.

Los hiperparámetros y características de la RNA utilizada para la clasificación de los 3 conjuntos de características extraídos se muestra en la Tabla 4.2 se emplearon 2 capas ocultas

4.1 Diagnóstico de fallas de cortocircuito en transformador




Figura 4.10 Características extraídas con descomposición wavelet-FRFT.




Figura 4.11 Entrenamiento de la RNA con las características descomposición wavelet y FRFT.

con funciones ReLu y una capa de salida con un número de neuronas igual al número de clases, las cuales corresponden al número de condiciones de falla en el transformador.

Tabla 4.3 Comparativa de los resultados de clasificación utilizando un clasificador neuronal.

Métricas	FRFT	FTML	WDFRFT
Accuracy	100 %	99.67 %	99.25 %
Precision	100 %	99.75 %	99.25 %
Recall	100 %	99.67 %	99.25 %
MAE	0.0023	0.000644	0.0013
Loss	0.0305	0.008	0.0209
Orden (α)	3.8296	2.9417	3.8296
Longitud de las características	100	100	246

Los resultados obtenidos por la clasificación de cada uno de los conjuntos de características se muestra en la Tabla 4.3 en donde el mejor desempeño obtenido resulto con el conjunto de características extraídas con el algoritmo **FRFT**, sin embargo, cabe resaltar que los desempeños obtenido con los otros algoritmos son desempeños que tienen una variación menor al 1% respecto al mejor. En las Figuras (4.12, 4.14, 4.15) se muestran las matrices de confusión de las clasificaciones.

Casos de estudio




Figura 4.12 Matriz de confusión de clasificación con características del transformadoe con algoritmo FRFT.




Figura 4.13 Matriz de confusión de clasificación con características del transformador con algoritmo FTML.

4.1 Diagnóstico de fallas de cortocircuito en transformador




Figura 4.14 Matriz de confusión de clasificación con características del transformador con algoritmo FTML.




Figura 4.15 Matriz de confusión de clasificación con características del transformador con algoritmo WDFRFT.

4.1.1. Detección y diagnóstico de fallas mediante clasificación jerárquica

Se realizó una segunda metodología de clasificación con 2 clasificadores, un clasificador de máquina de vectores de soporte (SVM) y la RNA, con el objetivo de crear un modelo que detecte la condición falla y otro que determine la condición, en la Figura 4.16 se muestra el esquema de la metodología que se propone la cual esta compuesta por 4 etapas la etapa de medición, la etapa de extracción de características, una etapa de detección y finalmente la etapa de diagnóstico.

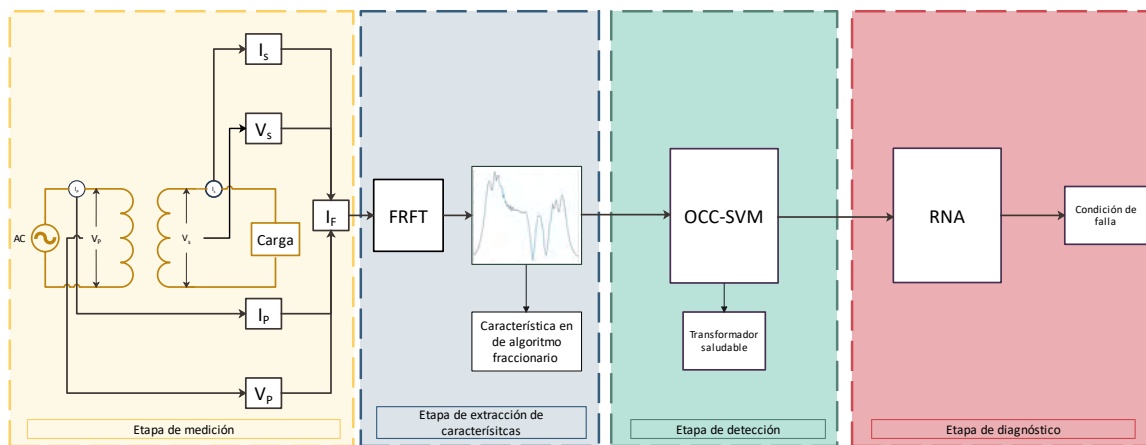


Figura 4.16 Metodología de clasificación jerárquica.

Las etapas de medición, extracción de características y diagnóstico se realiza de la misma forma que la metodología general, la etapa de detección tiene como base la clasificación de una sola clase (One class classification - OCC).

El clasificador OCC se centra en aprender las características del comportamiento normal del sistema. Cualquier desviación significativa de este comportamiento normal puede ser interpretada como una potencial falla. Esto es esencial en la detección de fallas, donde el objetivo es identificar anomalías respecto a un funcionamiento normal conocido.

Para la etapa de clasificación de una sola clase se empleo un clasificador de tipo SVM y modifíco el conjunto de datos de entrenamiento separando los datos con un estado saludable y otro con fallas se realizo el entrenamiento con solo el conjunto de datos con falla, esto se debe a que una de las restricciones del clasificador OCC es contar con un conjunto de datos des balanceado, por lo tanto la identificación de datos fuera de la clase con la que se entreno es considerado una condición saludable del transformador. Cuando la característica identificada pertenece a la clase es decir a una condición con falla, se procede a la clasificación multiclase donde se estimará la condición de falla a la que pertenece.

4.2 Diagnóstico de fallas de cortocircuito en motor de inducción

Tabla 4.4 Comparación en la detección y diagnóstico

	Orden	Exactitud	Tiempo	Pendiente (m)	Intercepto(b)
FRFT	3.82957	94.7292 %	2.956 s	1.027	-0.47613
FTML	2.94166	98.0263 %	2.084 s	1	-0.2002327

En la Tabla 4.4 se muestran los desempeños obtenidos en esta comparación, en la parte de la detección se utiliza un clasificador de una clase tipo svm, en la etapa de diagnóstico se utiliza una red neuronal artificial con 128 neuronas en la capa de entrada, 30 en la capa oculta y 23 en capa de salida.

4.2. Diagnóstico de fallas de cortocircuito en motor de inducción

Los motores de inducción son componentes esenciales en una amplia variedad de aplicaciones industriales debido a su robustez, eficiencia y bajo costo de mantenimiento. Sin embargo, como cualquier dispositivo electromecánico, estos motores están sujetos a fallas que pueden afectar su rendimiento y, en consecuencia, la productividad y seguridad de los procesos industriales donde se emplean. La identificación temprana y precisa de fallas en motores de inducción es, por tanto, crucial para garantizar la continua operación y minimizar los costos asociados a tiempos de inactividad y reparaciones.

Las fallas más comunes en estos motores incluyen desequilibrio eléctrico, fallas en los devanados del estator, desgaste en los rodamientos, excentricidad del rotor y problemas de aislamiento. Cada una de estas fallas puede manifestarse de manera diferente y tener múltiples causas subyacentes, lo que hace que el diagnóstico sea un desafío técnico significativo.

En el segundo caso de estudio se realiza el diagnóstico de fallas de cortocircuito en el estator de un motor de inducción. Los algoritmos propuestos en este trabajo se aplicaron a una base de datos de emulación de fallas de cortocircuito en el estator de un motor de inducción, la cual se reporta en [78]. En la Tabla 4.5 se muestran las características del motor de inducción en el cual fueron emuladas las fallas de cortocircuito.

De acuerdo a la información proporcionada en la base de datos, la adquisición de datos se realiza mediante una emulación de fallas de cortocircuito en el estator. Este estator fue

Tabla 4.5 Características del motor

Descripción	
Número de polos	4
Potencia	1 hp
Voltaje de alimentación	220 V
Corriente nominal	3 A

rebobinado para permitir el acceso a las vueltas de los devanados del estator, con el propósito de insertar cortocircuitos de diferentes magnitudes.

La emulación de la carga mecánica se lleva a cabo utilizando un segundo motor, el cual está conectado mecánicamente al rotor del motor modificado. Se emplean dos convertidores de frecuencia que permiten que ambos motores trabajen a distintas frecuencias, emulando así una carga mecánica.

Se simulan dos tipos de averías que corresponden a comportamientos de alta impedancia (HI) y baja impedancia (LI). Las fallas de alta impedancia (HI) representan una etapa inicial de la falla, que se presenta cuando el aislamiento de los devanados comienza a degradarse. Por otro lado, el comportamiento de baja impedancia (LI) representa un cortocircuito avanzado.

En la emulación de las fallas se consideran tres niveles de porcentaje de cortocircuito en el estator: 1.41 %, 4.81 % y 9.26 %. Considerando los dos comportamientos de averías y los tres niveles de porcentaje, se obtienen seis condiciones de falla y una condición saludable.

Cada condición de falla y la condición saludable se emuló con tres condiciones de carga mecánica, las cuales corresponden a 0%, 50% y 100% de carga mecánica. De esta manera, se obtienen 21 condiciones del motor, combinando las siete condiciones del motor con los tres tipos de carga mecánica, como se muestra en la Tabla 4.6.

Las señales proporcionadas en esta base de datos son las corrientes trifásicas del estator y el voltaje inducido por la fuga de flujo, como se muestra en la Figura 4.17.

De acuerdo con la naturaleza de las señales proporcionadas por el conjunto de datos, tanto el voltaje inducido por el flujo de fuga como la corriente pueden ser útiles para diagnosticar fallas en un motor de inducción. Sin embargo, su utilidad depende del tipo de falla que se esté analizando. Para este caso de fallas, se emplea el voltaje inducido por el flujo de fuga, ya que esta señal puede proporcionar información sobre la integridad del aislamiento de los devanados. Aunque la corriente suele ser un indicador directo para la detección de la falla de cortocircuito, debido a que este tipo de falla provoca un incremento en su magnitud, la emulación de estas

4.2 Diagnóstico de fallas de cortocircuito en motor de inducción




Figura 4.17 Señales de corriente y voltaje de motor de inducción.

fallas indica diferentes niveles de deterioro en el aislamiento de los devanados del estator, por lo cual resulta conveniente utilizar el voltaje inducido por el flujo de fuga.

En la Figura 4.18 se muestra la señal en una condición saludable sin carga. La Figura 4.19 y la Figura 4.20 muestran las señales con las diferentes condiciones de falla, la primera muestra los comportamientos de alta impedancia y la segunda con los de baja impedancia. Cabe resaltar que las señales son no estacionarias en comparación con las señales de corriente, lo que representa un desafío para los algoritmos de extracción de características.

En la Figura 4.21, se muestra la metodología general para el diagnóstico de falla, la cual consta de 3 etapas: la etapa de medición y la etapa de extracción de características. En la etapa de medición se realiza un preprocesamiento del conjunto de datos, en donde se verifican las señales y se construye un conjunto de datos lo más balanceado posible, ya que si el número de muestras de datos por clase se encuentra muy desbalanceado, afectará el entrenamiento del clasificador, lo cual disminuirá la exactitud con la que se puede diagnosticar la falla.

Para la etapa de clasificación, se utilizó una Red Neuronal Multicapa. La arquitectura empleada consta de 4 capas ocultas de 1024 neuronas cada una, y una capa de salida con un número de neuronas igual al número de clases las cuales se muestran en la Tabla 4.6. Las funciones de activación utilizadas en la red son la función ReLU para las capas ocultas y la

Casos de estudio




Figura 4.18 Voltaje inducido por el flujo de fuga - Saludable.




Figura 4.19 Voltaje inducido por el flujo de fuga - Falla 1, 2 y 3.

4.2 Diagnóstico de fallas de cortocircuito en motor de inducción




Figura 4.20 Voltaje inducido por el flujo de fuga - Falla 4, 5 y 6.

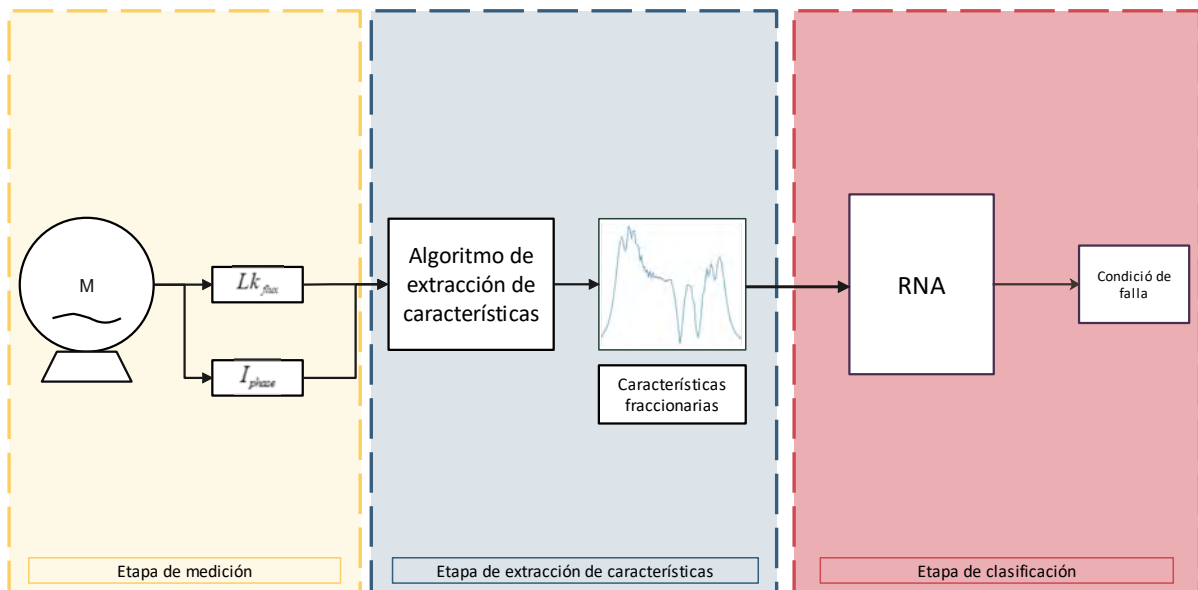


Figura 4.21 Metodología para diagnóstico de fallas IM.

Casos de estudio

función softmax para la capa de salida, los parámetros empleados en la RNA se muestran en la Tabla 4.7.

Tabla 4.6 Clases de fallas con cargas mecánicas.

Clase	Condición	Carga	Clase	Condición	Carga	Clase	Condición	Carga
0	Saludable	0%	7	HI 2	50%	14	LI 1	100%
1	Saludable	50%	8	HI 2	100%	15	LI 2	0%
2	Saludable	100%	9	HI 3	0%	16	LI 2	50%
3	HI 1	0%	10	HI 3	50%	17	LI 2	100%
4	HI 1	50%	11	HI 3	100%	18	LI 3	0%
5	HI 1	100%	12	LI 1	0%	19	LI 3	50%
6	HI 2	0%	13	LI 1	50%	20	LI 3	100%

Tabla 4.7 Hiperparámetros de la RNA para la clasificación de fallas en motor de inducción.

Parámetros	
Número de neuronas en la capa de entrada	1024
Número de capas ocultas	3
Número de neuronas en la capa de salida	21
Función de activación de la capa de entrada y capas ocultas	ReLU
Función de activación de la capa de salida	Softmax
Épocas de entrenamiento	30

En la etapa de extracción de características se emplean los algoritmos que se describen en el Capítulo 3, el primer conjunto de características aplica el algoritmo **FRFT** el cual se define en la Ec.(3.1), el conjunto de características se define en la Ec.(4.7), donde \mathbf{V}_{Lk} es el conjunto de datos compuesto por un total 12950 tiras de datos.

$$\mathbf{VLK}_{fr} = \mathbf{F}^{\alpha} \mathbf{V}_{Lk}. \quad (4.7)$$

En la Figura 4.22 se muestra la comparativa de las características bajo las 6 condiciones de falla y el estado saludable. El orden utilizado para este algoritmo es de $\alpha = -1,013$, el cual se obtuvo aplicando la optimización del orden de transformación, como se muestra en la

4.2 Diagnóstico de fallas de cortocircuito en motor de inducción




Figura 4.22 Características del IM extraídas con el algoritmo FRFT.




Figura 4.23 Curva de entrenamiento con características FRFT.

Figura 3.9. En la Figura 4.23 se muestran las métricas del entrenamiento del clasificador con las características extraídas.

El segundo conjunto de características que se extrajeron para el caso de diagnóstico de fallas en el motor se obtuvo al aplicar el algoritmo **FTML** descrito en la Sec. (3.3), donde se aplica la Ec. (3.9) en el conjunto de datos V_{Lk} y se define el conjunto de características como:

$$\mathbf{VLK}_{FTML} = \mathbf{W}_{FTML}^{\alpha} \mathbf{V}_{Lk}. \quad (4.8)$$

La Figura 4.24 muestra la comparación de la características extraídas con un orden de $\alpha = 3,64$ el cual se obtienen con el algoritmo de la Figura 3.9. En la Figura 4.25 se muestran las métricas del entrenamiento del clasificador.

El último conjunto de características que se extrajeron se realiza con el algoritmo WD_{FRFT} este se define en la Sec.(3.4) aplicando la Ec.(3.17) al conjunto de datos \mathbf{V}_{Ik} este conjunto de características para el diagnóstico de fallas de cortocircuito en el motor de inducción se define a continuación

$$\mathbf{VLK}_{Wfrft} = [\mathbf{V}_{Lk}, \mathbf{C}_{vWT1}, \mathbf{C}_{vWT2}, \mathbf{C}_{vWT3}, \mathbf{C}_{vWT4}, \mathbf{C}_{vWT5}, \mathbf{C}_{vWTA1}, \mathbf{C}_{vERWT}], \quad (4.9)$$

donde las matrices \mathbf{C}_{vWT} contienen los valores de energía relativa wavelet de cada nivel de descomposición de la señal V_{Lk} , la matriz \mathbf{C}_{vWTA1} contiene las características de la energía relativa correspondiente al quinto nivel de descomposición en baja frecuencia y la matriz

Casos de estudio

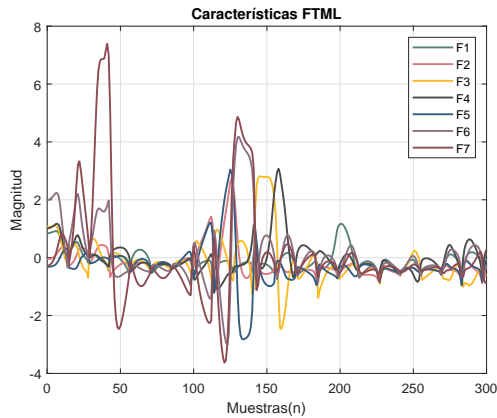


Figura 4.24 Características del IM extraídas con el algoritmo FTML.




Figura 4.25 Curva de entrenamiento con características FTML.




Figura 4.26 Características del IM extraídas con el algoritmo WD_{FRFT} .




Figura 4.27 Curva de entrenamiento con características WD_{FRFT} .

CV_{ERWT} es la energía relativa wavelet total de todos los niveles de descomposición. En la Figura 4.26 se muestra la comparación de las características correspondientes a la matriz CV_{WT4} de las primeras 7 condiciones de falla donde se aplicó un orden de $\alpha = -1,029$. La Figura 4.27 se muestran las métricas de entrenamiento obtenidas con el conjunto de características definidas en la Ec.(4.9) con 30 épocas de entrenamiento.

Los resultados obtenidos en las clasificaciones se muestran en la Tabla 4.8 donde los mejores desempeños se obtuvieron con el conjunto de características en donde se aplicó el algoritmo **WDFRFT** obteniendo una exactitud del 99.16% lo cual es alrededor de un 13% mayor al algoritmo **FRFT** y un 12% al **FTML**.

4.2 Diagnóstico de fallas de cortocircuito en motor de inducción

Tabla 4.8 Resultados de la clasificación de fallas en el motor de Inducción.

Métrica	FRFT	FTML	WDFRFT
Accuracy	86.60 %	87.4 %	99.16 %
Precision	86.81 %	87.74 %	99.17 %
Recall	86.38 %	87.28 %	99.17 %
MAE	0.0131	0.0124	0.00085
Loss	0.0409	0.0453	0.0043
Orden	-1.013	3.64	-1.029
Longitud de las características	1024	1024	1024

En las Figura 4.28 muestra la matriz de confusión que se obtuvo con la clasificación de las características **FRFT**, la Figura 4.29 muestra la matriz de confusión de la clasificación que se obtuvieron con la características del algoritmo **FTML** y la Figura 4.30 muestra la matriz de confusión con las características extraídas con el algoritmo **WDFRFT**.




Figura 4.28 Matriz de confusión de clasificación con características del motor de inducción con algoritmo **FRFT**.

Casos de estudio




Figura 4.29 Matriz de confusión de clasificación con características del motor de inducción con algoritmo FTML.




Figura 4.30 Matriz de confusión de clasificación con características del motor de inducción con algoritmo WDFRFT.

4.3. Diagnóstico de fallas en sistema fotovoltaico

Los sistemas fotovoltaicos (PV) han emergido como una de las fuentes de energía renovable más prometedoras y sostenibles, desempeñando un papel crucial en la transición hacia un futuro energético más limpio. Estos sistemas convierten la energía solar directamente en electricidad mediante el efecto fotovoltaico, proporcionando una solución viable y ecológica para la generación de energía. Sin embargo, como cualquier sistema tecnológico complejo, los sistemas fotovoltaicos no están exentos de fallas que pueden comprometer su eficiencia y fiabilidad.

El diagnóstico de fallas en sistemas fotovoltaicos es una actividad crítica para asegurar su funcionamiento óptimo y prolongar su vida útil. Las fallas en estos sistemas pueden originarse en diversos componentes, incluyendo los módulos fotovoltaicos, los inversores, el sistema de cableado y los dispositivos de almacenamiento de energía. Identificar y corregir estas fallas de manera oportuna no solo mejora el rendimiento y la eficiencia del sistema, sino que también reduce los costos de operación y mantenimiento a largo plazo.

En el tercer caso de estudio se realiza el diagnóstico de fallas en un sistema fotovoltaico, para lo cual se utiliza una base de datos descrita en los trabajos de [79] y [80]. La base de datos está compuesta por 16 archivos de datos, cada uno de los cuales corresponde a un escenario de falla diferente. Las fallas contempladas son en el arreglo fotovoltaico, el inversor, anomalías en la red, fallas en el sensor de retroalimentación y fallas en el controlador. En la Tabla 4.9 se da una descripción de cada falla .

Tabla 4.9 Fallas en sistema fotovoltaico.

Falla	Elemento	Descripción
F0	N/A	Sistema saludable
F1	Inversor	Falla completa en uno de los IGBTs
F2	Sensor de retroalimentación	Falla del 20 % en sensor de una fase
F3	Anomalía en la red	Voltaje intermitente (Sags)
F4	Arreglo fotovoltaico	Sombra parcial entre 10 y 20 %
F5	Arreglo fotovoltaico	circuito abierto en el arreglo fotovoltaico
F6	Controlador	-20 % de ganancia en el parámetro PI del controlador
F7	Controlador del convertidor	+20 % en la constante de tiempo en el parámetro PI

La base de datos está compuesta por 13 señales distintas, las cuales se muestran en la Tabla 4.10. De estas señales disponibles, se hicieron diferentes pruebas y se consideró utilizar la

Casos de estudio

corriente del arreglo fotovoltaico I_{pv} . En las Figs. 4.31 y 4.32 se muestra la comparación de las diferentes condiciones de falla del sistema, donde en la primera gráfica se muestra la condición saludable del sistema. Cabe resaltar que las señales en todas las condiciones son muy similares, con pequeños cambios en la magnitud, lo cual hace que el diagnóstico de fallas sea un reto.

Tabla 4.10 Señales de la base de datos.

Señal	Descripción	Señal	Descripción
I_{pv}	Corriente de arreglo PV	I_c	Corriente de fase c
V_{pv}	Voltaje de arreglo PV	V_a	Voltaje fase a
V_{dc}	Voltaje CD	V_b	Voltaje fase b
I_a	Corriente de fase a	V_c	Voltaje de fase c
I_b	Corriente de fase b	I_{abc}	Secuencia positiva de magnitudes de corriente
V_{abc}	Secuencia positiva de magnitudes de voltaje	I_f	Secuencia positiva de frecuencia en corriente
V_f	Secuencia positiva de frecuencia en voltaje		

Se aplica la metodología definida en el Capítulo 3, donde se aplican los distintos algoritmos propuestos para el diagnóstico de fallas. En la Figura 4.33 se muestra de forma general la metodología aplicada, la cual consta de tres etapas: Etapa de medición, Etapa de extracción de características y Etapa de clasificación. En la primera etapa se construye el conjunto de datos en bruto a partir de la señal I_{pv} . En la etapa de extracción de características se aplicarán los algoritmos propuestos para la creación de conjuntos de características y, finalmente, en la etapa de clasificación se realizará la estimación de la condición del sistema mediante la clasificación.

El primer conjunto de características se obtiene aplicando el algoritmo *FRTF* descrito por la Ec.(3.2) al conjunto de datos de corriente de sistema fotovoltaico, las características resultantes se definen en la Ec.(4.10), la Figura 4.34 muestra la comparación de las 7 condiciones de falla extraídas con el algoritmo **FRFT** con un orden de $\alpha = 0,99$, en la Figura 4.35 se muestran las métricas de entrenamiento, los parámetros utilizados para el clasificador de este caso de estudio se muestran en la Tabla 4.11.

$$\mathbf{I}_{pv_{fr}} = \mathbf{F}^{\alpha} \mathbf{I}_{pv}. \quad (4.10)$$

El segundo conjunto de características se obtiene aplicando el algoritmo de **FTML** descrito en la Sec.(2.5), donde se aplicara la Ec. (3.9) en el conjunto de corrientes del arreglo fotovoltaico

4.3 Diagnóstico de fallas en sistema fotovoltaico




Figura 4.31 Comparación de la corriente del arreglo fotovoltaico bajo distintas condiciones de falla.




Figura 4.32 Segunda comparación de la señal de corriente del arreglo fotovoltaico bajo distintas condiciones de falla.

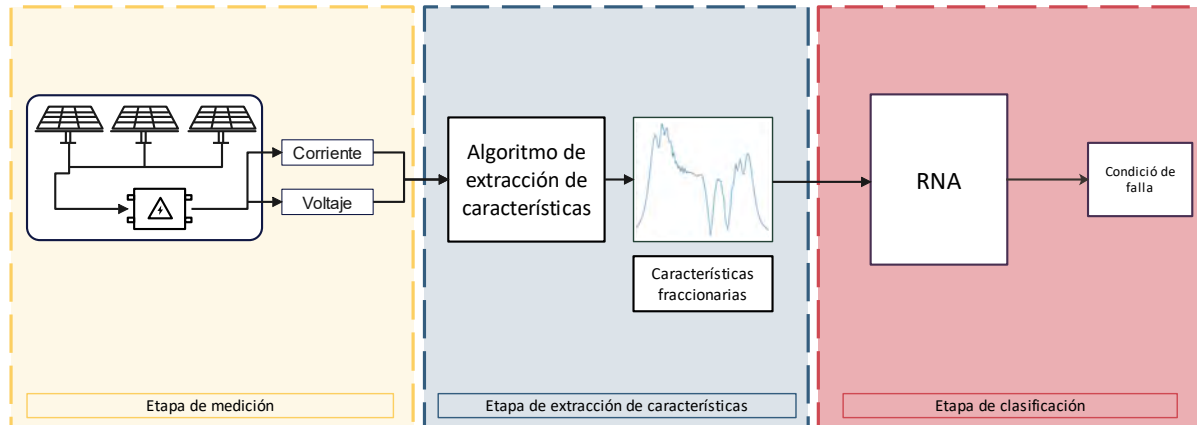


Figura 4.33 Metodología para diagnóstico de fallas sistema fotovoltaico.




Figura 4.34 PV - Características extraídas con FRFT.




Figura 4.35 PV - curva de entrenamiento del clasificador con FRFT.

como se define en la Ec. (4.11). La Figura 4.36 muestra la comparativa de las características extraídas con un orden de $\alpha = 2,64$ bajo las 7 condiciones de falla. En la Figura 4.37 se muestran las métricas de entrenamiento del clasificador con las características I_{pv}^{FTML} .

$$I_{pv}^{FTML} = W_{FTML}^{\alpha} I_{pv}. \quad (4.11)$$

En el tercer conjunto de características se aplica el algoritmo **WDFRFT** a el cual se define en la Sec. (3.4), se aplica la Ec.3.17 al conjunto de corrientes de arreglo fotovoltaico definiendo el conjunto de característica como se muestra en la Ec.(4.12).

4.3 Diagnóstico de fallas en sistema fotovoltaico

Tabla 4.11 Hiperparámetros de la RNA para la clasificación de fallas en sistema fotovoltaico.

Parámetros	
Número de neuronas en la capa de entrada	1024
Número de capas ocultas	4
Número de neuronas en la capa de salida	7
Función de activación de la capa de entrada y capas ocultas	ReLU
Función de activación de la capa de salida	Softmax
Épocas de entrenamiento	20




Figura 4.36 PV - Características extraídas con FTML.




Figura 4.37 PV - curva de entrenamiento del clasificador con FTML.

$$I_{pv_{Wfrft}} = [I_{pv}, C_{pvWT1}, C_{pvWT2}, C_{pvWT3}, C_{pvWT4}, C_{pvWT5}, C_{pvWTA1}, C_{pvERWT}]. \quad (4.12)$$

La Figura 4.38 muestra la comparativa de las características en las 7 condiciones de falla obtenidas con un orden de $\alpha = 0,82$, En la Figura 4.39 se muestran la métricas obtenidas del entrenamiento del clasificador con este conjunto de características.

Los resultados obtenidos con cada una de las características se muestran en la Tabla 4.12, en donde se observa que el mejor desempeño se obtiene con el algoritmo **FRFT** el cual tiene una exactitud del 99.98% aproximadamente más de el 2% mayor al algoritmo **FTML**, cabe mencionar que el algoritmo **WDFRFT** ofrece un conjunto de características también con un buen desempeño. Se adjuntan las matrices de confusión obtenidas con cada uno de los conjuntos

Casos de estudio




Figura 4.38 PV - Características extraídas con WD_{FRFT} .

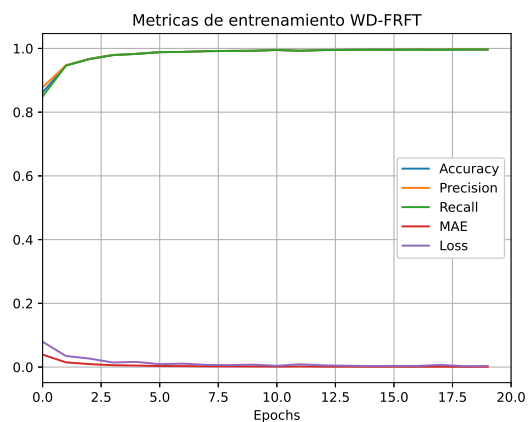


Figura 4.39 PV - curva de entrenamiento del clasificador con WD_{FRFT} .

Tabla 4.12 Resultados de la clasificación de fallas en el sistema fotovoltaico.

Métrica	FRFT	FTML	WDFRFT
Accuracy	99.98 %	97.18 %	99.496 %
Precision	99.99 %	97.22 %	99.50 %
Recall	96.98 %	97.14 %	99.50 %
MAE	0.000462	0.0074	0.0013
Loss	0.0001799	0.0291	0.0045
Orden	0.99	2.64	0.82
Longitud de las características	1024	1024	1024

de características, En la Figura 4.40 se muestra la de la clasificación con las características $I_{vp_{fr}}$, la Figura 4.41 muestra la matriz con las características $I_{vp_{FTML}}$ y finalmente la Figura 4.42 muestra los resultados obtenidos con las características $I_{pv_{Wfrft}}$.

4.3 Diagnóstico de fallas en sistema fotovoltaico




Figura 4.40 Matriz de confusión de la clasificación de características **FRFT** sobre el sistema fotovoltaico.




Figura 4.41 Matriz de confusión de la clasificación de características **FTML** sobre el sistema fotovoltaico.

Casos de estudio




Figura 4.42 Matriz de confusión de la clasificación de características **WDFRFT** sobre el sistema fotovoltaico.

4.4. Clasificación de disturbios eléctricos

La calidad de la energía eléctrica es un factor crucial para el funcionamiento eficiente y fiable de las máquinas eléctricas en diversas aplicaciones industriales, comerciales y residenciales. La energía eléctrica de alta calidad implica una tensión y frecuencia estables, con mínimas perturbaciones, armónicos y otros fenómenos que puedan afectar el rendimiento de los equipos conectados. Sin embargo, la calidad de la energía puede verse comprometida por diversas causas, lo que a su vez puede provocar fallas en las máquinas eléctricas o viceversa.

Los disturbios eléctricos y las fallas en sistemas eléctricos están estrechamente relacionados. Los disturbios eléctricos son eventos que alteran las condiciones normales de operación de un sistema eléctrico, mientras que las fallas son interrupciones o anomalías graves que pueden resultar de estos disturbios. Esto afecta la calidad de la energía al distorsionar la forma de onda de un sistema de red eléctrica. Estos disturbios pueden tener diversos orígenes, tales como variaciones en la carga, introducción de fuentes de energía renovable y activación de protecciones.

En el último caso de estudio, se propone una metodología para la extracción de características de disturbios eléctricos para su clasificación, como se muestra en la Figura 4.43, ya que es fundamental su monitoreo para disminuir sus efectos y preservar la fiabilidad de un sistema eléctrico.

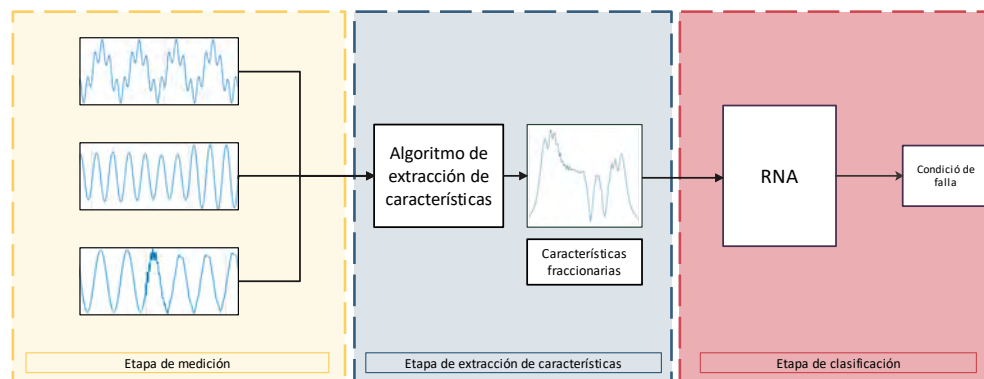


Figura 4.43 Metodología extracción de características de disturbios eléctricos.

Para este caso de estudio se generó un conjunto de datos donde se simularon diversos disturbios eléctricos de acuerdo a las normas de la IEC [6] e IEEE [7], las ecuaciones que definen el comportamiento de los disturbios eléctricos básicos se muestran en la tabla 4.13.

Se realizó una simulación de 28 disturbios eléctricos con valores de parámetros aleatorios dentro de los rangos de valores que establecen las normas de la IEEE e IEC los cuales se

Casos de estudio

Tabla 4.13 Ecuaciones de los disturbios eléctricos básicos [5].

Evento PQD	Ecuación
Señal	$v(t) = A \sin(\omega t + \phi)$
Interrupción	$v(t) = A(1 - \rho(u(t - t_1) - u(t - t_2))) \sin(\omega t)$
Sag	$v(t) = A(1 - \alpha(u(t - t_1) - u(t - t_2))) \sin(\omega t)$
Swell	$v(t) = A(1 - \beta(u(t - t_1) - u(t - t_2))) \sin(\omega t)$
Impulso	$v(t) = A[\sin(\omega t - \phi) - \psi(e^{-750(t-t_a)} - e^{-344(t-t_a)})(u(t - t_a) - u(t - t_b))]$
Transitorio	$v(t) = A[\sin(\omega t - \phi) + \beta e^{-(t-t_f)/\tau} \sin(\omega_n(t - t_f) - \xi)(u(t - t_a) - u(t - t_b))]$
Armónicos	$v(t) = A[\sin(\omega t + \phi) + \sum_{n=2}^7 a_n \sin(n\omega t - \xi_n)]$
Flicker	$v(t) = A[1 + \lambda \sin(\omega_f t) \sin(\omega t - \phi)]$
Notch	$v(t) = A[\sin(\omega t - \phi) - (\sin(\omega t - \phi)) \sum_{n=0}^N a_n \sin(n\omega t - \xi)]$

muestran en la Tabla 4.14, se consideraron parámetros con valores constantes como la frecuencia fundamental $f = 60Hz$, la frecuencia de muestreo de las señales $f_s = 2,5kHz$ y la amplitud de la señal $A = 110V$, esto para simular señales de una red eléctrica en la etapa de baja tensión.

Tabla 4.14 Parámetros para la simulación de disturbios eléctricos [6–8].

Parámetro	Valores
N_f Número de ciclos (Frecuencia)	30 : 100
α Porcentaje de distorsión (Sag)	10 % : 90 %
A Amplitud de la señal	0,1V : 440kV
β Porcentaje de distorsión (Swell)	10 % : 80 %
F_s Frecuencia de muestreo	200Hz : 30kHz
ρ Porcentaje de distorsión (Interrupción)	90 % : 100 %
t_1 Tiempo de inicio del disturbio	
ψ Porcentaje de distorsión (Impulso)	22 % : 111 %
t_2 Tiempo final de disturbio	
λ Porcentaje de distorsión (Flicker)	5 % : 10 %
ξ Fase	$-\pi : \pi$
f_f Frecuencia (Flicker)	8Hz : 25Hz
n Número de armónicos	3, 5, 7
f_n Frecuencia de oscilacion (Transitorio oscilatorio)	300Hz : 900Hz
a_n Porcentaje de distorsión (Armónicos)	5 % : 15 %
τ Tiempo de transitorio	8ms : 40ms
f Frecuencia fundamental	40Hz – 100Hz

4.4 Clasificación de disturbios eléctricos

En la Figura 4.44 se muestran las señales de los disturbios eléctricos simulados, cabe mencionar que se muestran combinaciones de disturbios eléctricos básicos, es común que estas combinaciones se presenten en las señales de la red debido a la combinación de cargas que puede tener conectada.

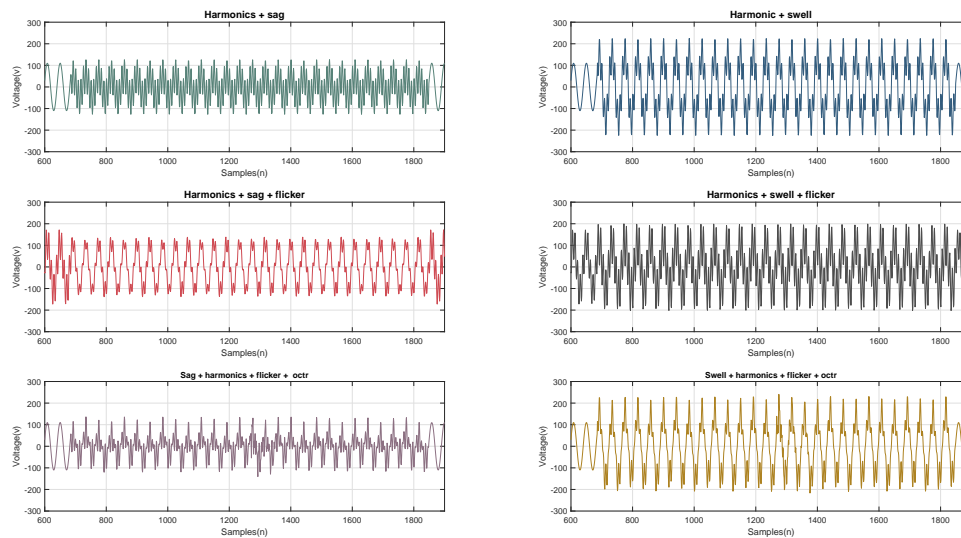


Figura 4.44 Disturbios eléctricos generados con combinaciones de 2, 3 y 4 disturbios eléctricos básicos.

Tabla 4.15 Hiperparámetros de la RNA para la clasificación de disturbios eléctricos (PQD).

Parámetros	
Número de neuronas en la capa de entrada	1024
Número de capas ocultas	4
Número de neuronas en la capa de salida	21
Función de activación de la capa de entrada y capas ocultas	ReLU
Función de activación de la capa de salida	Softmax
Épocas de entrenamiento	20

Para la etapa de extracción de características se utilizan las señales generadas con los algoritmos del Capítulo (3), el primer conjunto de características se obtienen al aplicar el algoritmo de la Ec.(3.1) sobre la señal de voltaje de los disturbios eléctricos V_{PQD} por lo tanto el conjunto de características se define en la Ec.(4.13) donde la matriz \mathbf{VPQ}_{fr} representa el conjunto de características en el dominio de Fourier fraccionario.

Casos de estudio

$$\mathbf{VPQ}_{fr} = \mathbf{F}^{\alpha} \mathbf{V}_{PQD}. \quad (4.13)$$

En las Figura 4.45 y Figura 4.46 se muestran la comparativa de las características en el dominio de Fourier fraccionario con un orden de $\alpha = -0,97$ tanto de una señal saludable como con PDQ de diferente nivel de combinación.

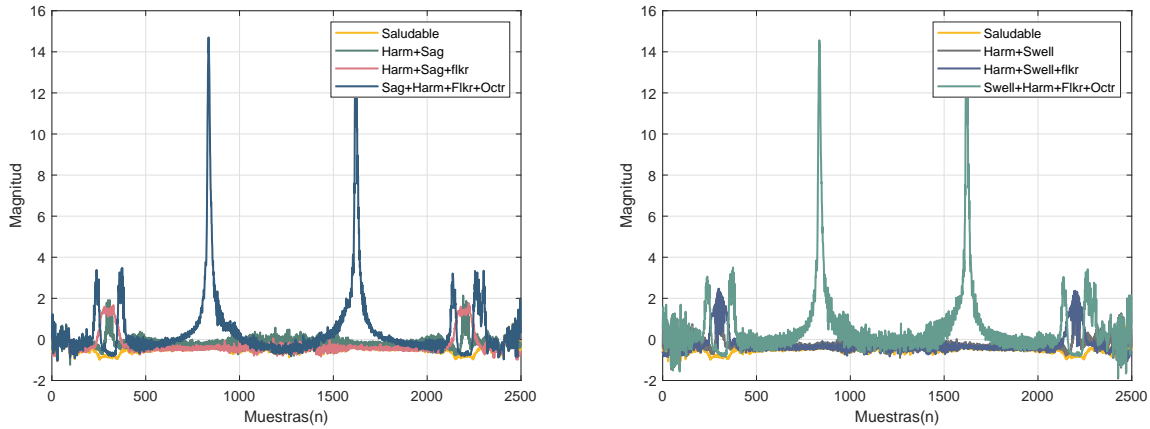


Figura 4.45 PQD - Características extraídas usando el algoritmo **FRFT 1**. **Figura 4.46** PQD - Características extraídas usando el algoritmo **FRFT 2**.

El segundo conjunto de características se obtiene aplicando el algoritmo con la **FTML** donde al conjunto de datos V_{PQD} se le aplica la Ec.(3.9) definiendo el segundo conjunto de características como se muestra en la Ec.(4.14) donde $\mathbf{W}_{FTML}^{\alpha}$ es la matriz de transformación de Fourier modificada con la función de Mittag Leffler del parámetro α .

$$\mathbf{VPQ}_{FTML} = \mathbf{W}_{FTML}^{\alpha} \mathbf{V}_{PQD}. \quad (4.14)$$

En las Figura 4.47 y Figura 4.48 se muestran la comparativa de las características donde el orden es $\alpha = 2,82$ tanto de una señal saludable como con PDQ de diferente nivel de combinación.

EL tercer conjunto de características se realiza al aplicar el algoritmo **WDFRFT** sobre el conjunto de datos de voltaje V_{PQD} al cual se le aplica la EC.(3.17) obteniendo el conjunto de características \mathbf{VPQ}_{Wfrft} definido en la Ec.(4.15) donde las matrices \mathbf{C}_{qWT} y \mathbf{C}_{qWTA} corresponden a la energía relativa Wavelet de cada nivel de descomposición y \mathbf{C}_{qERWT} corresponde a la energía relativa wavelet de todos lo niveles de descomposición

4.4 Clasificación de disturbios eléctricos





Figura 4.47 PQD - Características extraídas usando el algoritmo **FTML 1**. **Figura 4.48** PQD - Características extraídas usando el algoritmo **FTML 2**.

$$\mathbf{VPQ}_{W_{frft}} = [\mathbf{VPQD}, \mathbf{CqWT1}, \mathbf{CqWT2}, \mathbf{CqWT3}, \mathbf{CqWT4}, \mathbf{CqWT5}, \mathbf{CqWTA1}, \mathbf{CqERWT}]. \quad (4.15)$$

La Figura 4.49 y Figura 4.50 muestra el conjunto de características extraído con el algoritmo **WDFRFT** con un orden de $\alpha = -0,97$ comparando la señal saludable y diferentes niveles de combinaciones de disturbios eléctricos.


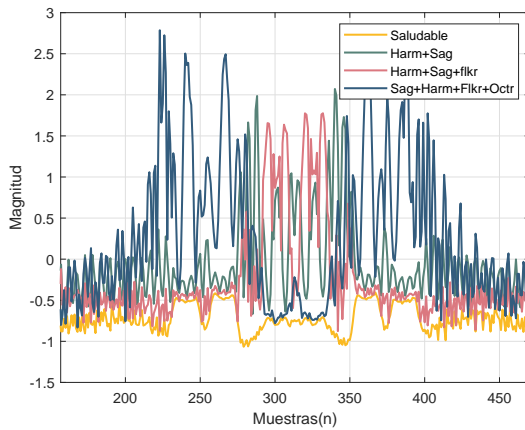


Figura 4.49 PQD - Características extraídas usando el algoritmo **WDFRFT 1**. **Figura 4.50** PQD - Características extraídas usando el algoritmo **WDFRFT 2**.

Casos de estudio

Tabla 4.16 Resultados de la clasificación disturbios eléctricos.

Métrica	FRFT	FTML	WDFRFT
Accuracy	94.95 %	90.23 %	87.11 %
Precision	94.98 %	90.49 %	88.51 %
Recall	94.93 %	89.93 %	81.03 %
MAE	0.0071	0.0096	0.0096
Loss	0.0164	0.0186	0.0314
Orden	-0.97	2.82	-0.97
Longitud de las características	1024	1024	1024

Los resultados obtenidos en la etapa de clasificación comparando cada conjunto de características se muestra en la Tabla 4.16 en donde se puede observar que los mejores desempeños obtenidos, los hiperparámetros utilizado para el clasificador de muestran en la Tabla 4.15, el algoritmo **FRFT** resulto con los mejores desempeños obteniendo una exactitud del 94.95 % en la Figura 4.52 se muestran las métricas obtenidas en el entrenamiento del clasificador, la Figura 4.51 muestra la matriz de confusión de la clasificación de los disturbios eléctricos.




Figura 4.51 Matriz de confusión de la clasificación de disturbios eléctricos con características **FRFT**.




Figura 4.52 Entrenamiento del clasificador para disturbios eléctricos con características FRFT.

Capítulo 5

Conclusiones y trabajos futuros

5.1. Conclusiones

En esta tesis se desarrollaron cuatro algoritmos diferentes para la extracción de características en sistemas eléctricos. Los algoritmos presentados se basan en el uso de transformadas integrales de orden fraccionario. El primer algoritmo aplica la transformada de Fourier de orden fraccionario en su versión discreta, utilizando una matriz de transformación para pasar las señales al dominio de Fourier fraccionario, el cual tendrá una distribución diferente para cada ángulo de transformación.

El segundo algoritmo consiste en la modificación de la matriz de transformación del kernel de la transformada de Fourier clásica. En este caso, se propone la sustitución de las funciones exponenciales dentro de la matriz de transformación por la función de Mittag-Leffler. Esta función, para valores cercanos a 1, puede tener comportamientos pseudo exponenciales, permitiendo variar las componentes de la matriz tanto en magnitud como en frecuencia.

El tercer algoritmo desarrollado consta de dos etapas. En la primera etapa se realiza una descomposición de la señal, permitiendo analizar las señales en diferentes bandas de frecuencia. La segunda etapa consiste en mover cada uno de esos niveles de descomposición al dominio de Fourier fraccionario, donde se calcula la energía relativa de cada nivel de descomposición y la energía global.

5.1.1. Casos de Estudio

Se presentaron cuatro casos de estudio donde se aplicaron los algoritmos para la extracción de características:

Conclusiones y trabajos futuros

1. Corto Circuito en un transformador monofásico: En este caso de estudio se realizó una clasificación de fallas de cortocircuito en un transformador monofásico. Los resultados de las métricas obtenidas son cercanos al 100 % en el caso de la clasificación con la RNA. En la clasificación jerárquica, la exactitud alcanza un valor de 98.02 % con las características FTML. Además, las características extraídas tienen un menor tiempo computacional para su cálculo, lo cual hace al algoritmo FTML la mejor opción para la clasificación jerárquica.
2. Diagnóstico de fallas en un motor de inducción: Se analizó la señal del voltaje inducido por el flujo de fuga. Esta señal representa un reto debido a la dinámica y la poca diferencia entre las señales sanas y con cierto nivel de falla. Los resultados de las clasificaciones se presentaron en la Tabla 4.8, donde el mejor algoritmo para este caso es el WDFRFT, con una exactitud del 99.16 %.
3. Fallas en un sistema fotovoltaico: Este caso de estudio presenta siete diferentes fallas en elementos del sistema fotovoltaico. Las señales obtenidas son muy similares entre las señales con falla y la señal saludable, lo cual representa un reto para la clasificación. Los resultados se muestran en la Tabla 4.12, donde tanto el algoritmo FRFT como el WDFRFT muestran desempeños favorables, cercanos al 100 % de exactitud.
4. Clasificación de disturbios eléctricos: Se realizó la simulación de 28 disturbios eléctricos con diferentes niveles de combinación. Las consideraciones de los parámetros utilizados para la simulación se basaron en las normas IEEE 1159 e IEC 61000, que definen los estándares para evaluar la gravedad y el impacto de los disturbios eléctricos. Los resultados obtenidos se muestran en la Tabla 4.16, donde el mejor algoritmo es el FRFT, con una exactitud alrededor del 94 % para 21 tipos de disturbios eléctricos, incluyendo combinaciones complejas de hasta cuatro PQDs básicos.

5.1.2. Aportación

El desarrollo de esta tesis presenta diversas contribuciones significativas tanto en el ámbito del análisis de señales de sistemas eléctricos como en el análisis de la calidad de la energía. En el caso de estudio del transformador y el motor de inducción, se destaca la eficiencia de los algoritmos desarrollados y la implementación de transformadas integrales de orden fraccionario para la clasificación de fallas. La disponibilidad de métodos eficientes y precisos para la detección y clasificación de fallas puede prevenir catástrofes, pérdidas monetarias y

daños materiales en sectores donde se utilizan estas máquinas eléctricas, además las fallas de corto circuito provocan deformaciones en las forma de onda de una red eléctrica lo cual se refleja en una disminución de la calidad de la energía.

En el diagnóstico de fallas en sistemas fotovoltaicos, la aportación principal radica en la aplicación de algoritmos basados en cálculo fraccionario en sistemas de generación de energías renovables. A través de la revisión de la literatura, se identificaron diversos métodos de diagnóstico de fallas, sin embargo, son muy pocos los que abordan el enfoque del cálculo fraccionario. En comparación, los algoritmos propuestos en este trabajo muestran un mayor desempeño y exactitud. El desarrollo de estos algoritmos mejora la eficiencia en el diagnóstico de fallas, lo que contribuye a la mejora de la calidad de la energía. Esto es especialmente relevante, ya que las fuentes de energía renovable, al emplear elementos de electrónica de potencia, generan comportamientos no lineales que deforman la forma de onda. Es fundamental distinguir entre el comportamiento nominal y el de falla para garantizar una buena calidad de la energía.

Respecto a los disturbios eléctricos, aunque existen métodos basados en el cálculo fraccionario, los trabajos reportados previamente consideran una menor cantidad de eventos de disturbios en comparación con este estudio, que abarca hasta 21 eventos distintos. Estos eventos describen fenómenos que pueden ocurrir en la red debido a cambios de carga, fallas en máquinas eléctricas e interrupciones o fluctuaciones en las fuentes de generación de energía. Tales eventos pueden provocar más fallas y pérdidas materiales o monetarias. Por lo tanto, el desarrollo de algoritmos que mejoran la eficiencia y precisión en la detección y clasificación de disturbios eléctricos complejos puede mitigar las consecuencias adversas de estos disturbios.

En resumen, las aportaciones de esta tesis se centran en la mejora de métodos de análisis y diagnóstico en sistemas eléctricos, destacando la eficiencia y precisión de los algoritmos desarrollados, así como su aplicación en la prevención de fallas y en la mejora de la calidad de la energía en diversos contextos.

5.1.3. Conclusión General

Los casos de estudio y los resultados obtenidos demuestran que los algoritmos desarrollados en esta tesis mejoran significativamente el desempeño en la clasificación para el diagnóstico de fallas y en el análisis de la calidad de la energía. En particular, el algoritmo que modifica el kernel con la función de Mittag-Leffler muestra una notable reducción en el tiempo de cómputo para la extracción de características, en comparación con otras transformadas integrales de

Conclusiones y trabajos futuros

orden fraccionario. Además, los algoritmos de extracción de características desarrollados, que combinan técnicas clásicas y de orden fraccionario, permiten un análisis estadístico detallado de las características y su desempeño.

Los algoritmos presentados en esta tesis ofrecen herramientas efectivas y precisas para el diagnóstico y análisis de sistemas eléctricos. Sin embargo, se identificaron algunas limitaciones, principalmente relacionadas con el mayor costo computacional debido a la complejidad de los métodos numéricos necesarios para el cálculo de las matrices de transformación. En el diagnóstico de fallas en máquinas y sistemas eléctricos, es viable realizando un entrenamiento fuera de línea para luego aplicar los algoritmos en línea. No obstante, en el análisis de la calidad de la energía, es necesario cumplir con lineamientos y normativas específicas para su monitoreo. Según la norma IEEE 1159-2019 [7], la resolución mínima requerida para las técnicas o equipos de monitoreo es de al menos un ciclo de la frecuencia de la red.

Para abordar estas limitaciones, se sugiere realizar modificaciones a los algoritmos y explorar métodos de discretización más eficientes, así como su implementación en software. Esto permitirá cumplir con los requisitos normativos y mejorar la aplicabilidad práctica de los algoritmos en el monitoreo continuo de la calidad de la energía y el diagnóstico de fallas en sistemas eléctricos. En resumen, las contribuciones de esta tesis proporcionan un avance significativo en la detección y clasificación de disturbios eléctricos, ofreciendo una base sólida para futuras investigaciones y aplicaciones en el campo de la calidad de la energía y el diagnóstico de fallas eléctricas.

5.2. Trabajos futuros

- Análisis de los métodos de discretización de las transformadas integrales para la mejora de los algoritmos propuestos.
- Desarrollar la modificación de la transformada de Fourier clásica aplicando la función de Mittag-Leffler de 2 parámetros.
- Ampliar la aplicación de los algoritmos a procesamiento de imágenes.
- Implementar transformadas integrales con ordenes complejos.
- Aplicar ordenes variables a los algoritmos propuestos.
- Extraer características en 2 dimensiones realizando espectrogramas con variación del ángulo de transformación.

Bibliografía

- [1] Purushottam Gangsar and Rajiv Tiwari. Signal based condition monitoring techniques for fault detection and diagnosis of induction motors: A state-of-the-art review. *Mechanical Systems and Signal Processing*, 144:106908, October 2020.
- [2] Hossein Ahmadi, Behrooz Vahidi, and Amin Foroughi Nematollahi. A simple method to detect internal and external short-circuit faults, classify and locate different internal faults in transformers. *Electrical Engineering*, 103(2):825–836, April 2021.
- [3] A. Mellit, G.M. Tina, and S.A. Kalogirou. Fault detection and diagnosis methods for photovoltaic systems: A review. *Renewable and Sustainable Energy Reviews*, 91:1–17, August 2018.
- [4] Poras Khetarpal and Madan Mohan Tripathi. A critical and comprehensive review on power quality disturbance detection and classification. *Sustainable Computing: Informatics and Systems*, 28:100417, December 2020.
- [5] Suhail Khokhar, Abdullah Asuhaimi Mohd Zin, Aslam Pervez Memon, and Ahmad Sawawi Mokhtar. A new optimal feature selection algorithm for classification of power quality disturbances using discrete wavelet transform and probabilistic neural network. *Measurement*, 95:246–259, January 2017.
- [6] International Electrotechnical Commission et al. Electromagnetic compatibility (emc)-part 4-30: Testing and measurement techniques-power quality measurement methods. *IEC 61000-4-30*, 2003.
- [7] IEEE Std 1159-2019, IEEE Recommended Practice for Monitoring Electric Power Quality. 2019.
- [8] Tie Zhong, Shuo Zhang, Guowei Cai, Yue Li, Baojun Yang, and Yun Chen. Power Quality Disturbance Recognition Based on Multiresolution S-Transform and Decision Tree. *IEEE Access*, 7:88380–88392, 2019.
- [9] Oscar Jaime Ramos-Negrón. *Análisis de ruido electroquímico empleando diferentes métodos de evaluación*. PhD thesis, CENIDET, 2019.
- [10] José Hugo Arellano-Peréz. *Análisis de Ruido Electroquímico en una Aleación de Aluminio Expuesta a la Mezcla Gasolina-Etanol*. PhD thesis, CENIDET, 2020.

Bibliografía

- [11] Carlos Jesús Zúñiga-Aguilar. *Identificación de Sistemas Mediante el Uso de Redes Neuronales de Orden Fraccionario*. PhD thesis, CENIDET, 2020.
- [12] Jesús Emmanuel Solís-Pérez. *Cálculo Fraccionario Aplicado en Procesamiento de Imágenes y Señales*. PhD thesis, CENIDET, 2020.
- [13] Antonio Coronel-Escamilla. *Modelado y Control de Sistemas Dinámicos Usando Cálculo Fraccionario*. PhD thesis, CENIDET, 2018.
- [14] Arturo Mejia-Barron, Martin Valtierra-Rodriguez, David Granados-Lieberman, Juan C. Olivares-Galvan, and Rafael Escarela-Perez. Experimental data-based transient-stationary current model for inter-turn fault diagnostics in a transformer. *Electric Power Systems Research*, 152:306–315, November 2017.
- [15] Arturo Mejia-Barron, Martin Valtierra-Rodriguez, David Granados-Lieberman, Juan C. Olivares-Galvan, and Rafael Escarela-Perez. The application of EMD-based methods for diagnosis of winding faults in a transformer using transient and steady state currents. *Measurement*, 117:371–379, March 2018.
- [16] D. Guillen, J.C. Olivares-Galvan, R. Escarela-Perez, D. Granados-Lieberman, and E. Barocio. Diagnosis of interturn faults of single-distribution transformers under controlled conditions during energization. *Measurement*, 141:24–36, July 2019.
- [17] Lucas D. Simões, Hagi J.D. Costa, Matheus N.O. Aires, Rodrigo P. Medeiros, Flavio B. Costa, and Arturo S. Bretas. A power transformer differential protection based on support vector machine and wavelet transform. *Electric Power Systems Research*, 197:107297, August 2021.
- [18] David Granados-Lieberman, Jose R. Razo-Hernandez, Vicente Venegas-Rebollar, Juan C. Olivares-Galvan, and Martin Valtierra-Rodriguez. Harmonic PMU and Fuzzy Logic for Online Detection of Short-Circuited Turns in Transformers. *Electric Power Systems Research*, 190:106862, January 2021.
- [19] Jose R. Huerta-Rosales, David Granados-Lieberman, Arturo Garcia-Perez, David Camarena-Martinez, Juan P. Amezcua-Sanchez, and Martin Valtierra-Rodriguez. Short-Circuited Turn Fault Diagnosis in Transformers by Using Vibration Signals, Statistical Time Features, and Support Vector Machines on FPGA. *Sensors*, 21(11):3598, May 2021.
- [20] Yuhan Wu, Xianbo Sun, Baofu Dai, Pengfei Yang, and Zhihao Wang. A transformer fault diagnosis method based on hybrid improved grey wolf optimization and least squares-support vector machine. *IET Generation, Transmission & Distribution*, 16(10):1950–1963, May 2022.
- [21] Guoshi Wang, Ying Liu, Xiaowen Chen, Qing Yan, Haibin Sui, Chao Ma, and Junfei Zhang. Power transformer fault diagnosis system based on Internet of Things. *EURASIP Journal on Wireless Communications and Networking*, 2021(1):21, December 2021.

-
- [22] Arash Moradzadeh, Hamed Moayyed, Behnam Mohammadi-Ivatloo, G. B. Gharehpetian, and A. Pedro Aguiar. Turn-to-Turn Short Circuit Fault Localization in Transformer Winding via Image Processing and Deep Learning Method. *IEEE Transactions on Industrial Informatics*, 18(7):4417–4426, July 2022.
- [23] Arturo Yosimar Jaen-Cuellar, David Alejandro Elvira-Ortiz, and Juan Jose Saucedo-Dorantes. Statistical Machine Learning Strategy and Data Fusion for Detecting Incipient ITSC Faults in IM. *Machines*, 11(7):720, July 2023.
- [24] Megha Singh and Abdul Gafoor Shaik. Incipient Fault Detection in Stator Windings of an Induction Motor Using Stockwell Transform and SVM. *IEEE Transactions on Instrumentation and Measurement*, 69(12):9496–9504, December 2020.
- [25] N. Rama Devi, D. V. S. S. Siva Sarma, and P. V. Ramana Rao. Diagnosis and classification of stator winding insulation faults on a three-phase induction motor using wavelet and MNN. *IEEE Transactions on Dielectrics and Electrical Insulation*, 23(5):2543–2555, October 2016.
- [26] Rebeca Guerreiro Carvalho Cunha, Elias Teodoro Da Silva, and Cláudio Marques De Sá Medeiros. Machine learning and multiresolution decomposition for embedded applications to detect short-circuit in induction motors. *Computers in Industry*, 129:103461, August 2021.
- [27] Abdelelah Almounajjed, Ashwin Kumar Sahoo, and Mani Kant Kumar. Diagnosis of stator fault severity in induction motor based on discrete wavelet analysis. *Measurement*, 182:109780, September 2021.
- [28] Gustavo Henrique Bazan, Paulo Rogerio Scalassara, Wagner Endo, Alessandro Goedtel, Rodrigo Henrique Cunha Palacios, and Wagner Fontes Godoy. Stator Short-Circuit Diagnosis in Induction Motors Using Mutual Information and Intelligent Systems. *IEEE Transactions on Industrial Electronics*, 66(4):3237–3246, April 2019.
- [29] Gustavo Henrique Bazan, Paulo Rogério Scalassara, Wagner Endo, Alessandro Goedtel, Wagner Fontes Godoy, and Rodrigo Henrique Cunha Palácios. Stator fault analysis of three-phase induction motors using information measures and artificial neural networks. *Electric Power Systems Research*, 143:347–356, February 2017.
- [30] Yusuke Yagami, Chika Araki, Yukio Mizuno, and Hisahide Nakamura. Turn-to-turn insulation failure diagnosis of stator winding of low voltage induction motor with the aid of support vector machine. *IEEE Transactions on Dielectrics and Electrical Insulation*, 22(6):3099–3106, December 2015.
- [31] Pedro Pedrosa Rebouças Filho, Navar M.M. Nascimento, Igor R. Sousa, Cláudio M.S. Medeiros, and Victor Hugo C. De Albuquerque. A reliable approach for detection of incipient faults of short-circuits in induction generators using machine learning. *Computers & Electrical Engineering*, 71:440–451, October 2018.

Bibliografía

- [32] Nathaly Murcia-Sepúlveda, Jorge M Cruz-Duarte, Ignacio Martin-Diaz, Arturo Garcia-Perez, J Juan Rosales-García, Juan Gabriel Avina-Cervantes, and Carlos Rodrigo Correa-Cely. Fractional calculus-based processing for feature extraction in harmonic-polluted fault monitoring systems. *Energies*, 12(19):3736, 2019.
- [33] Xin Li, Zengqiang Ma, De Kang, and Xiang Li. Fault diagnosis for rolling bearing based on VMD-FRFT. *Measurement*, 155:107554, April 2020.
- [34] Bo Liu, Kai Sun, Xiaoyu Wang, Jian Zhao, and Xiaochao Hou. Fault diagnosis of photovoltaic strings by using machine learning-based stacking classifier. *IET Renewable Power Generation*, page rpg2.12755, May 2023.
- [35] Aref Eskandari, Jafar Milimonfared, and Mohammadreza Aghaei. Fault Detection and Classification for Photovoltaic Systems Based on Hierarchical Classification and Machine Learning Technique. *IEEE Transactions on Industrial Electronics*, 68(12):12750–12759, December 2021.
- [36] Moath Alrifayey, Wei Hong Lim, Chun Kit Ang, Elango Natarajan, Mahmud Iwan Solihin, Mohd Rizon Mohamed Juhari, and Sew Sun Tiang. Hybrid Deep Learning Model for Fault Detection and Classification of Grid-Connected Photovoltaic System. *IEEE Access*, 10:13852–13869, 2022.
- [37] Varaha Satya Bharath Kurukuru, Frede Blaabjerg, Mohammed Ali Khan, and Ahteshamul Haque. A Novel Fault Classification Approach for Photovoltaic Systems. *Energies*, 13(2):308, January 2020.
- [38] Farkhanda Aziz, Azhar UI Haq, Shahzor Ahmad, Yousef Mahmoud, Marium Jalal, and Usman Ali. A Novel Convolutional Neural Network-Based Approach for Fault Classification in Photovoltaic Arrays. *IEEE Access*, 8:41889–41904, 2020.
- [39] Ahteshamul Haque, Kurukuru Varaha Satya Bharath, Mohammed Ali Khan, Irshad Khan, and Zainul Abdin Jaffery. Fault diagnosis of Photovoltaic Modules. *Energy Science & Engineering*, 7(3):622–644, June 2019.
- [40] Ricardo Henrique Fonseca Alves, Getúlio Antero De Deus Júnior, Enes Gonçalves Marra, and Rodrigo Pinto Lemos. Automatic fault classification in photovoltaic modules using Convolutional Neural Networks. *Renewable Energy*, 179:502–516, December 2021.
- [41] Naveen Venkatesh Sridharan and V Sugumaran. Convolutional Neural Network based Automatic Detection of Visible Faults in a Photovoltaic Module. *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects*, pages 1–16, March 2021.
- [42] V S Bharath. Kurukuru, Ahteshmaul Haque, and Mohammed Ali Khan. Fault Classification for Photovoltaic modules using Thermography and Image Processing. In *2019 IEEE Industry Applications Society Annual Meeting*, pages 1–6, Baltimore, MD, USA, September 2019. IEEE.

- [43] Amal Hichri, Mansour Hajji, Majdi Mansouri, Kamaleldin Abodayeh, Kais Bouzrara, Hazem Nounou, and Mohamed Nounou. Genetic-Algorithm-Based Neural Network for Fault Detection and Diagnosis: Application to Grid-Connected Photovoltaic Systems. *Sustainability*, 14(17):10518, August 2022.
- [44] Caixia Tao, Xu Wang, Fengyang Gao, and Min Wang. Fault diagnosis of photovoltaic array based on deep belief network optimized by genetic algorithm. *Chinese Journal of Electrical Engineering*, 6(3):106–114, September 2020.
- [45] Aria Khoshnami and Iman Sadeghkhan. Sample entropy-based fault detection for photovoltaic arrays. *IET Renewable Power Generation*, 12(16):1966–1976, December 2018.
- [46] Chen Zhao, Kaicheng Li, Yuanzheng Li, Lingyun Wang, Yi Luo, Xuebin Xu, Xiaojun Ding, and Qingxu Meng. Novel Method Based on Variational Mode Decomposition and a Random Discriminative Projection Extreme Learning Machine for Multiple Power Quality Disturbance Recognition. *IEEE Transactions on Industrial Informatics*, 15(5):2915–2926, May 2019.
- [47] Jidong Wang, Di Zhang, and Yue Zhou. Ensemble deep learning for automated classification of power quality disturbances signals. *Electric Power Systems Research*, 213:108695, December 2022.
- [48] Poras Khetarpal, Neelu Nagpal, Mohammed S. Al-Numay, Pierluigi Siano, Yogendra Arya, and Neelam Kassarwani. Power Quality Disturbances Detection and Classification Based on Deep Convolution Auto-Encoder Networks. *IEEE Access*, 11:46026–46038, 2023.
- [49] Jian Ma, Jun Zhang, Luxin Xiao, Kexu Chen, and Jianhua Wu. Classification of Power Quality Disturbances via Deep Learning. *IETE Technical Review*, 34(4):408–415, July 2017.
- [50] Karthik Thirumala, M. Siva Prasad, Trapti Jain, and Amod C. Umarikar. Tunable-Q Wavelet Transform and Dual Multiclass SVM for Online Automatic Detection of Power Quality Disturbances. *IEEE Transactions on Smart Grid*, 9(4):3018–3028, July 2018.
- [51] Tatireddy Ravi and K. Sathish Kumar. Detection and Classification of Power Quality Disturbances Using Stock Well Transform and Improved Grey Wolf Optimization-Based Kernel Extreme Learning Machine. *IEEE Access*, 11:61710–61727, 2023.
- [52] Om Prakash Mahela, Abdul Gafoor Shaik, Baseem Khan, Rajendra Mahla, and Hassan Haes Alhelou. Recognition of Complex Power Quality Disturbances Using S-Transform Based Ruled Decision Tree. *IEEE Access*, 8:173530–173547, 2020.
- [53] Sadegh Jamali, Ali Reza Farsa, and Navid Ghaffarzadeh. Identification of optimal features for fast and accurate classification of power quality disturbances. *Measurement*, 116:565–574, February 2018.

Bibliografía

- [54] Utkarsh Singh and Shyam Narain Singh. Application of fractional Fourier transform for classification of power quality disturbances. *IET Science, Measurement & Technology*, 11(1):67–76, January 2017.
- [55] Indu Sekhar Samanta, Pravat Kumar Rout, and Satyasis Mishra. An optimal extreme learning-based classification method for power quality events using fractional Fourier transform. *Neural Computing and Applications*, 33(10):4979–4995, May 2021.
- [56] Hongxin Gao, Zhiyong Wang, Aixia Tang, Congxin Han, Fengyi Guo, and Baifu Li. Research on series arc fault detection and phase selection feature extraction method. *IEEE Transactions on Instrumentation and Measurement*, 70:1–8, 2021.
- [57] Tomas Garcia-Calva, Daniel Morinigo-Sotelo, Vanessa Fernandez-Cavero, and Rene Romero-Troncoso. Early Detection of Faults in Induction Motors—A Review. *Energies*, 15(21):7855, October 2022.
- [58] Jawad Faiz and Reza Heydarabadi. Diagnosing power transformers faults. *Russian Electrical Engineering*, 85(12):785–793, December 2014.
- [59] Mohsen Mostafaei, Jawad Faiz, Prasad A. Venikar, and Makarand S. Ballal. Turn-to-turn fault monitoring methods in electrical power transformers-State of the art. *International Transactions on Electrical Energy Systems*, 28(12):e2644, December 2018.
- [60] Md Mominul Islam, Gareth Lee, and Sujeewa Nilendra Hettiwatte. A review of condition monitoring techniques and diagnostic tests for lifetime estimation of power transformers. *Electrical Engineering*, 100(2):581–605, June 2018.
- [61] Jäger-Waldau, Arnulf. Snapshot of photovoltaics - may 2023. *EPJ Photovolt.*, 14:23, 2023.
- [62] A. V. Valyanskii, I. I. Kartashev, and Yu. V. Sharov. The effect of power quality on power-transformer reliability. *Russian Electrical Engineering*, 85(3):138–144, March 2014.
- [63] Zuzana Krivohlava, Stanislav Chren, and Bruno Rossi. Failure and fault classification for smart grids. *Energy Informatics*, 5(1):33, October 2022.
- [64] Math H. J. Bollen and Irene Yu-Hua Gu. *Signal processing of power quality disturbances*. IEEE Press series on power engineering. Wiley-Interscience, Hoboken, NJ, 2006. OCLC: ocm71006034.
- [65] Michele Caputo and Mauro Fabrizio. A new definition of fractional derivative without singular kernel. *Progr. Fract. Differ. Appl*, 1(2):1–13, 2015.
- [66] Abdon Atangana and Dumitru Baleanu. New fractional derivatives with nonlocal and non-singular kernel: theory and application to heat transfer model. *arXiv preprint arXiv:1602.03408*, 2016.

-
- [67] Abdon Atangana and J. F. Gómez-Aguilar. A new derivative with normal distribution kernel: Theory, methods and applications. *Physica A: Statistical Mechanics and its Applications*, 476:1–14, 2017.
- [68] Victor Namias. The fractional order Fourier transform and its application to quantum mechanics. *IMA Journal of Applied Mathematics*, 25(3):241–265, 1980.
- [69] C McBride. On Namias ’ s Fractional Fourier Transforms. *IMA Journal of Applied Mathematics*, pages 159–175, 1987.
- [70] David Mendlovic, Zeev Zalevsky, David Mas, Javier García, and Carlos Ferreira. Fractional wavelet transform. *Applied optics*, 36(20):4801–4806, 1997.
- [71] A new fractional wavelet transform. *Communications in Nonlinear Science and Numerical Simulation*, 44:19–36, 2017.
- [72] Ziyun Wang, Yan Wang, and Zhicheng Ji. *Advances in fault detection and diagnosis using filtering analysis*. Springer, 2022.
- [73] Józef Korbicz, Jan M Koscielny, Zdzislaw Kowalczyk, and Wojciech Cholewa. *Fault diagnosis: models, artificial intelligence, applications*. Springer Science & Business Media, 2012.
- [74] Francisco Herrera, Francisco Charte, Antonio J Rivera, and María J Del Jesus. Multilabel classification. In *Multilabel Classification*, pages 17–31. Springer, 2016.
- [75] Charu C Aggarwa et al. *Data classification: Algorithms and applications*, 2015.
- [76] Federico Marini and Beata Walczak. Particle swarm optimization (pso). a tutorial. *Chemosometrics and Intelligent Laboratory Systems*, 149:153–165, 2015.
- [77] Hector Martin Cortes Campos et al. *Metodología para el diagnóstico de fallas en máquinas eléctricas empleando transformadas integrales de orden generalizado*. PhD thesis, 2020.
- [78] Rebeca Guerreiro Carvalho Cunha, Elias Teodoro da Silva Junior, and Cláudio Marques de Sá Medeiros. Inter-turn short-circuit in induction motor:, 2021.
- [79] Amar Guichi, Abdelaziz Talha, El Madjid Berkouk, Saad Mekhilef, and Samir Gassab. A new method for intermediate power point tracking for pv generator under partially shaded conditions in hybrid system. *Solar Energy*, 170:974–987, 2018.
- [80] Azzeddine Bakdi, Wahiba Bounoua, Saad Mekhilef, and Laith M Halabi. Nonparametric kullback-divergence-pca for intelligent mismatch detection and power quality monitoring in grid-connected rooftop pv. *Energy*, 189:116366, 2019.

Apéndice A

Productos obtenidos

APPLICATION OF FRACTIONAL-ORDER INTEGRAL TRANSFORMS IN THE DIAGNOSIS OF ELECTRICAL SYSTEM CONDITIONS

H. M. CORTÉS CAMPOS^{Ⓢ,*} J. F. GÓMEZ-AGUILAR^{Ⓢ,†,¶} C. J. ZÚÑIGA-AGUILAR,[‡]
L. F. AVALOS-RUIZ^{Ⓢ,*} and J. E. LAVÍN-DELGADO[Ⓢ]

**Centro Nacional de Investigación y Desarrollo Tecnológico (CENIDET)
Tecnológico Nacional de México
Interior Internado Palmira S/N, Col. Palmira
C. P. 62490, Cuernavaca, MR, Mexico*

*†Consejo Nacional de Humanidades, Ciencias y Tecnologías (CONAHCyT)
Centro Nacional de Investigación y Desarrollo Tecnológico (CENIDET)
Tecnológico Nacional de México, Interior Internado Palmira S/N
Col. Palmira, C. P. 62490, Cuernavaca, MR, Mexico*

*‡Panzura Data Services, Bhr. Puerta de Hierro 5153, Puerta de Hierro
45116 Zapopan, JA, Mexico*

*§Dirección de Ingeniería en Redes y Telecomunicaciones
Universidad Politécnica del Estado de Guerrero (UPEG)
Puente Campuzano, Carretera Federal Iguala-Taxco K. M. 105
Taxco de Alarcón, C. P. 40321, GE, Mexico
¶jose.ga@cenidet.tecnm.mx*

Received November 18, 2023

Accepted February 19, 2024

Published March 26, 2024

Abstract

This paper proposes a methodology for the diagnosis of electrical system conditions using fractional-order integral transforms for feature extraction. This work proposes three feature

¶Corresponding author.

Apéndice B

Análisis de la varianza (ANOVA)

El análisis de la varianza fue aplicado en cada conjunto de características mencionada en los avances, las principales ecuaciones para realizarla son:

$$v = \sum_{j,k} (x_{jk} - \bar{x})^2, \quad (\text{B.1})$$

$$v_w = \sum_{j,k} (x_{jk} - \bar{x}_j)^2, \quad (\text{B.2})$$

$$v_m = \sum_{j,k} n_j (\bar{x}_j - \bar{x})^2, \quad (\text{B.3})$$

en donde x_{jk} representa el valor de cada características, \bar{x}_j es la media de cada clase y \bar{x} es la media global de los datos. La ecuación (B.1) define la varianza entre la media global de los datos y cada dato, la ecuación (B.2) es la variación de cada dato respecto a la media de clase y por ultimo la ecuación (B.3) define la variación de la media de clase respecto a la media global. a partir de este análisis se gráfico la variación de la medias de las características con respecto a la media global, para mejorar las características se les aplico la desviación de la media global la cual se define como:

$$MAD = \frac{|x_i - \bar{X}|}{N} \quad (\text{B.4})$$

Donde x_i es el valor de la característica y \bar{X} es la media global del grupo y N es el numero total de las características. a continuación se muestran la gráfica de las variaciones de la media.

Apéndice C

Algoritmo Adam para el Entrenamiento de una RNA

Algoritmo 2 Algoritmo Adam

Entradas: α : tamaño de paso $\beta_1, \beta_2 \in [0, 1)$: tasas del decaimiento exponencial $f(\theta)$: Función objetivo estocástica con parámetros θ θ_0 : vector de parámetros iniciales**Inicialización:** $m_o \leftarrow 0$

▷ Inicialización del vector del primer momento

 $v_o \leftarrow 0$

▷ Inicialización del vector del segundo momento

 $t \leftarrow 0$

▷ Inicialización del tiempo de muestreo

while θ_0 : no converge **do** $t \leftarrow t + 1$ $g_t \leftarrow \nabla_{\theta} f_t(\theta_{t-1})$ ▷ Obtener gradientes respecto al objetivo estocástico en t $m_t \leftarrow \beta_1 \cdot m_{t-1} + (1 - \beta_1) \cdot g_t$

▷ Actualizar la estimación sesgada del primer momento

 $v_t \leftarrow \beta_2 \cdot v_{t-1} + (1 - \beta_2) \cdot g_t^2$

▷ Actualización sesgada de la estimación del segundo momento bruto

 $\hat{m}_t \leftarrow m_t / (1 - \beta_1^t)$

▷ Calcular la estimación del primer momento con corrección de sesgo

 $\hat{v}_t \leftarrow v_t / (1 - \beta_2^t)$

▷ Calcular la estimación del segundo momento con corrección de sesgo

 $\theta_t \leftarrow \theta_{t-1} - \alpha \cdot \hat{m}_t / (\sqrt{\hat{v}_t} + \epsilon)$

▷ Actualización de los parámetros

end**Retorna** θ_t ▷ Parametros resultantes
