



Universidad Autónoma de Querétaro
Facultad de Ingeniería
Doctorado en Mecatrónica

Modelo basado en vibraciones para el diagnóstico de transformadores ante deformaciones estructurales con condiciones armónicas y desbalance en fuente de alimentación.

Tesis

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

Presenta:

M.I.E. José Roberto Huerta Rosales

Dirigido por:

Dr. Martín Valtierra Rodríguez

Dr. David Granados Lieberman

San Juan del Río, Querétaro, marzo 2023.



Dirección General de Bibliotecas y Servicios Digitales
de Información



Modelo basado en vibraciones para el diagnóstico de transformadores ante deformaciones estructurales con condiciones armónicas y desbalance en fuente de alimentación.

por

José Roberto Huerta Rosales

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

Clave RI: IGDCC-284000



Universidad Autónoma de Querétaro

Facultad de Ingeniería

Doctorado en Mecatrónica

Modelo basado en vibraciones para el diagnóstico de transformadores ante deformaciones estructurales con condiciones armónicas y desbalance en fuente de alimentación.

TESIS

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

Presenta:

M.I.E. José Roberto Huerta Rosales

Dirigido por:

Dr. Martín Valtierra Rodríguez

Dr. David Granados Lieberman

SINODALES

Dr. Martín Valtierra Rodríguez
Presidente

Dr. David Granados Lieberman
Secretario

Dr. Maximiliano Bueno López
Vocal

Dr. Juan Primo Benítez Rangel
Suplente 1

Dr. Luis Morales Velázquez
Suplente 2

Firma

Firma

Firma

Firma

Firma

Centro Universitario
Querétaro, Qro.
México
Marzo 2023

Resumen

El transformador es uno de los elementos más caros e importantes en una red eléctrica. Su adecuado funcionamiento es muy importante en la transmisión y distribución de la energía eléctrica, ya que durante su servicio opera bajo distintas condiciones eléctricas, las cuales pueden generar fallas y causar cortes en el suministro eléctrico, lo que generaría pérdidas económicas a nivel industrial, comercial y en casos catastróficos hasta pérdidas humanas. Algunas de las fallas más comunes son la deformación estructural debido a daños en el devanados y núcleo. En México las fallas en los devanados son de alrededor del 53% y en el núcleo de 2%. Las fallas en los devanados son causadas principalmente por corto circuito, mientras que en el núcleo por el aflojamiento de los pernos de sujeción de este. Aunado a esto, la presencia de desbalance y contenido armónico en la red eléctrica podría acrecentar estos problemas, ya que las vibraciones que se generan en el núcleo y devanados son proporcionales al voltaje y corriente que alimenta al transformador. En este trabajo se realizan distintos casos de estudio donde se analizan las señales de vibración generadas en el núcleo y devanados, buscando detectar y clasificar la falla por corto circuito, la cual es la principal falla que genera deformación en los devanados. Además, se realiza un modelo basado en las frecuencias de las vibraciones, con las que se busca obtener señales de vibración prescindiendo de un transformador el cual presente las distintas condiciones ya mencionadas. Se exploran técnicas en el dominio del tiempo y de la frecuencia para extraer características que describan el comportamiento del transformador para realizar la clasificación de manera automática, también se exploran distintos algoritmos inteligentes como la lógica difusa, máquinas de soporte vectorial y redes neuronales artificiales. Este último algoritmo también es utilizado para construir el modelo no paramétrico del transformador. Buscando desarrollar dispositivos inteligentes, una de las metodologías se implementó en una FPGA para lograr realizar un monitoreo en línea de un transformador de una manera más económica que las opciones comerciales actuales.

Palabras claves: Transformador, falla de corto circuito, redes neuronales, máquinas de soporte vectorial, índices estadísticos.

Summary

The transformer is one of the most expensive and important elements in an electrical network. Its proper performance is very important for the transmission and distribution of electrical energy, since during its service it operates under different electrical conditions, which can generate failures and cause cuts in the electrical supply, which would generate economic losses at an industrial and commercial level, as well as, in catastrophic cases, even human losses. Some of the most common failures are structural deformations in windings and core. In Mexico, winding failures are around 53% and 2% in the core. The failures in the windings are mainly caused by a short-circuit turns, while in the core by the loosening of the fixing bolts of the core. In addition to this, the presence of unbalanced and harmonic content in the electrical network could increase these problems since the vibrations generated in the core and windings are proportional to the voltage and current that supply the transformer. In this work, different case studies are carried out where the vibration signals generated in the core and windings are analyzed, looking for detecting and classifying the failure due to short-circuit turns, which is the main fault that generates deformation in the windings. Also, a model based on the vibration frequencies is developed in order to reproduce the vibration signals without a transformer that presents the different conditions previously mentioned. Techniques in the time and frequency domain are explored to extract characteristics that describe the behavior of the transformer. In order to carry out the classification automatically, different intelligent algorithms such as fuzzy logic, support vector machines and artificial neural networks are explored. This last algorithm is also used to build the non-parametric model of the transformer. For developing intelligent devices, one of the methodologies was implemented in an FPGA to achieve online monitoring of a transformer in a more economical way than current commercial options.

Keywords: Transformer, short-circuited turn fault, neural networks, support vector machines, statistical features.

Dedicatoria

A quien me vio iniciar este proyecto y lamentablemente no me vio culminarlo, a mi madre, por su apoyo incondicional y siempre dejarme ser, hasta la inmensidad para ti.

Agradecimientos

Agradezco completamente a mi familia por estar siempre a pesar de lo difícil que uno puede llegar a ser cuando la vida se complica, pero gracias a su compañía la vida se hace más fácil. Mi madre que me dio las herramientas (si no las tenía las buscaba) para enfrentar el camino que eligiera, a mi hermana que con su fortaleza y tenacidad me ha dado un gran ejemplo para seguir adelante sin bajar la cara, a mis sobrinos por darme esa alegría infantil y por darme la responsabilidad de ser un buen ejemplo para ir por la vida. A mi padre que muy a su modo me dio algunas lecciones para ser o no ser.

A mis asesores por la confianza y el apoyo durante esta etapa, por sus consejos y guía para mi desarrollo profesional.

Por la paciencia, por el conocimiento, por el amor a la enseñanza, por querer hacerme una un mejor profesionista y mucho mejor persona, gracias a mis profesores.

A mis compañeros que a pesar de la difícil situación de la pandemia conectamos en la amistad, algo tarde, pero hicieron más pasajero y ameno la etapa final del doctorado.

A todas las personas que han coincidido en este andar por la vida, que con lo poco o mucho, lo pleno y lo desafortunado, por lo real y lo virtual, han dejado aprendizaje en este ser, gracias por completar este viaje y sobre todo por recordarme que hay que ser feliz.

No podía faltar ese ser de luz que no me dejó cuando más solo me sentía, que con sus ojitos me daba ilusión, que con el sonido de sus patitas al caminar traía música a mis oídos, su energía para no dejarme caer, a mi canija Nymeria, mi fiel compañera.

Agradecimiento Institucional

Se agradece Consejo Nacional de Ciencia y Tecnología (CONACyT) por otorgarme la beca **734987** con la cual se pudo realizar esta investigación y además para realizar el doctorado en la Universidad Autónoma de Querétaro.



Índice

| | |
|------------------------------------------------------------------------------------|-----|
| Resumen..... | I |
| Summary..... | II |
| Dedicatoria..... | III |
| Agradecimientos | IV |
| Agradecimientos institucionales..... | V |
| Índice | VI |
| Índice de Tablas | IX |
| Índice de Figuras..... | X |
| Capítulo 1. Introducción | 1 |
| 1.1 Antecedentes de análisis de señales de vibración..... | 3 |
| 1.1.1 Análisis basado en señales..... | 4 |
| 1.1.2 Análisis basado en modelos..... | 6 |
| 1.1.3 Análisis basado en aprendizaje..... | 7 |
| 1.2 Descripción del problema..... | 9 |
| 1.3 Justificación..... | 10 |
| 1.4 Hipótesis y objetivos..... | 12 |
| 1.4.1 Hipótesis..... | 12 |
| 1.4.2 Objetivo general..... | 12 |
| 1.4.3 Objetivos particulares | 12 |
| 1.5 Planteamiento general..... | 12 |
| Capítulo 2. Fundamentación teórica..... | 14 |
| 2.1 El transformador..... | 14 |
| 2.2 Transformador trifásico..... | 17 |
| 2.3 Fallas y vibraciones generadas en el núcleo y devanados del transformador..... | 18 |
| 2.3.1 Vibraciones | 18 |
| 2.3.2. Vibraciones generadas en el núcleo del transformador..... | 19 |
| 2.3.3. Vibraciones generadas en los devanados del transformador..... | 20 |
| 2.4 Desbalance de tensiones en sistemas trifásicos..... | 20 |
| 2.5 Armónicos en sistemas eléctricos..... | 22 |
| 2.6 Características o indicadores de falla..... | 24 |
| 2.6.1 Indicadores estadísticos en el dominio del tiempo..... | 25 |

| | |
|----------------------------------------------------------------------------------------------------------------------|-----------|
| 2.6.2 <i>Indicador de contraste</i> | 25 |
| 2.7 Reducción de características. | 28 |
| 2.7.1 <i>Selección de características</i> | 28 |
| 2.7.2 <i>Extracción de características</i> | 28 |
| 2.8 Técnicas avanzadas de procesamiento de señales. | 30 |
| 2.8.1 <i>Descomposición de modos no lineales.</i> | 30 |
| 2.8.2 <i>Transformada Hilbert</i> | 33 |
| 2.8.3 <i>Filtro de promedio móvil</i> | 33 |
| 2.9 Algoritmos de aprendizaje de automático. | 34 |
| 2.9.1 <i>Redes neuronales artificiales.</i> | 34 |
| 2.9.2 <i>Lógica Difusa.</i> | 36 |
| 2.9.3 <i>Máquinas de soporte vectorial.</i> | 37 |
| 2.10 Modelado de Sistemas | 39 |
| 2.10.1 <i>Métodos de obtención de modelos.</i> | 40 |
| 2.10.2 <i>identificación de sistemas.</i> | 40 |
| Capítulo 3. Metodología. | 44 |
| 3.1 Descripción general de la metodología. | 44 |
| 3.2 Casos de estudio. | 47 |
| 3.2.1. <i>Caso de estudio 1: Metodología de diagnóstico en el dominio del tiempo.</i> | 47 |
| 3.2.2. <i>Caso de estudio 2: Metodología de diagnóstico con transformación de dominio.</i> ... | 51 |
| 3.2.3. <i>Caso de estudio 3: Modelo basado en vibraciones.</i> | 52 |
| 3.2.4. <i>Caso de estudio 4: Metodología de diagnóstico temprano en el dominio del tiempo.</i> | 56 |
| Capítulo 4. Resultados. | 60 |
| 4.1 Caso de estudio 1: Análisis de la metodología de diagnóstico en el dominio del tiempo. | 60 |
| 4.2 Caso de estudio 2: Análisis de la metodología de diagnóstico con transformación de dominio. | 68 |
| 4.3 Caso de estudio 3: Análisis del modelo basado en vibraciones. | 73 |
| 4.4 Caso de estudio 4: Análisis de la metodología de diagnóstico temprano en el dominio del tiempo. | 84 |
| Capítulo 5. Conclusiones. | 90 |
| 5.1 Prospectivas. | 91 |

| | |
|-------------------------------------------------------|------------|
| Referencias..... | 93 |
| Anexos..... | 104 |
| Anexo A: Artículo indizado (caso de estudio 1) | |
| Anexo B: Artículo indizado (caso de estudio 2) | |
| Anexo C: Artículo indizado (caso de estudio 4) | |
| Anexo D: Artículo de congreso internacional | |

Índice de tablas

| | |
|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Tabla 1. Características estadísticas en el dominio del tiempo..... | 26 |
| Tabla 2. Funciones de activación..... | 35 |
| Tabla 3. Valores de entrada para la red neuronal..... | 56 |
| Tabla 4. Porcentajes de precisión de la SVM y ANN con diferentes valores de umbral de acuerdo con lo que se muestra en la Figura 31..... | 63 |
| Tabla 5. Matriz de confusión de la clasificación SCTs usando validación cruzada k-fold cuando k=3.... | 65 |
| Tabla 6. Tiempo y erro relativo de cada núcleo de procesamiento..... | 67 |
| Tabla 7. Recursos de la FPGA utilizados | 67 |
| Tabla 8. Media (x) y desviación estándar (σ) para los valores RMS..... | 71 |
| Tabla 9. Reglas para el Sistema de lógica difusa propuesto..... | 72 |
| Tabla 10. Matriz de confusión..... | 72 |
| Tabla 11. Errores del modelo en diferentes condiciones de SCT, cargas y 0% de desbalance, valores estimados vs. valores reales..... | 78 |
| Tabla 12. Errores del modelo en diferentes condiciones de SCT, cargas y 2.5% de desbalance, valores estimados vs. valores reales..... | 79 |
| Tabla 13. Errores del modelo en diferentes condiciones de SCT, cargas y 5% de desbalance, valores estimados vs. valores reales..... | 80 |
| Tabla 14. Errores del modelo en diferentes condiciones de SCT, cargas y 7.5% de desbalance, valores estimados vs. valores reales..... | 81 |
| Tabla 15. Errores del modelo en diferentes condiciones de SCT, cargas y 10% de desbalance, valores estimados vs. valores reales..... | 82 |
| Tabla 16. Errores del modelo en diferentes condiciones de desbalance, cargas y 0 SCT, valores estimados vs. valores reales..... | 83 |
| Tabla 17. Errores del modelo en diferentes condiciones de desbalance, cargas y 5 SCT, valores estimados vs. valores reales..... | 83 |
| Tabla 18. Errores del modelo en diferentes condiciones de desbalance, cargas y 10 SCT, valores estimados vs. valores reales..... | 84 |
| Tabla 19. Media (μ) y desviación estándar (σ) de los valores de contraste en diferentes combinaciones de carga y diferentes condiciones de falla SCT..... | 85 |
| Tabla 20. Media (μ) y desviación estándar (σ) para las diferentes distribuciones de contraste de las diferentes condiciones de falla..... | 87 |
| Tabla 21. Promedio del porcentaje de precisión para los clasificadores ANN y SVM considerando las diferentes estimaciones del contraste..... | 88 |
| Tabla 22. Matriz de confusión para la clasificación de SCTs..... | 89 |

Índice de Figuras

| | |
|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Figura 1. Patrón de fallo de los transformadores (M. Wang et al., 2002)..... | 3 |
| Figura 2. Fallas en transformadores en México (Álvarez, 2017)..... | 11 |
| Figura 3. Diagrama del planteamiento general del proyecto..... | 13 |
| Figura 4. Esquema básico de un transformador (Harper, 2005) | 15 |
| Figura 5. Tipos de transformadores (Chapman, 2000): (a) Transformador tipo núcleo y (b) transformador tipo acorazado..... | 15 |
| Figura 6. Transformador ideal (Chapman, 2000). | 16 |
| Figura 7. Construcción de los transformadores trifásicos: (a) Banco trifásico realizado con tres transformadores monofásicos y (b) Transformador trifásico realizado en un núcleo de tres columnas (Chapman, 2000). | 18 |
| Figura 8. Conexión en Y – Δ (Chapman, 2000). | 18 |
| Figura 9. Magnetostricción en el acero (García et al., 2005) | 20 |
| Figura 10. Ternas fasoriales, desbalanceadas (arriba) y simétricas (abajo) (ECAMEC, 2009). | 21 |
| Figura 11. Formad de onda: (a) sin armónicos y (b) con armónicos. | 23 |
| Figura 12. Arquitectura de una ANN. (a) ANN multicapa con capas de entrada, ocultas y de salida; y (b) Una neurona..... | 35 |
| Figura 13. Arquitectura de la SVM. | 38 |
| Figura 14. Esquema de las SVMs en paralelo. | 39 |
| Figura 15. Diagrama de bloque de un sistema (López, 2008). | 40 |
| Figura 16. Diagrama metodológico..... | 45 |
| Figura 17. Diagrama de bloques de la metodología del segundo caso de estudio. | 48 |
| Figura 18. Diagrama de bloques para (a)metodología de la etapa de diseño; (b)metodología para etapa de diseño..... | 49 |
| Figura 19. Configuración del experimento del caso del segundo caso de estudio. | 50 |
| Figura 20. Señales de vibración adquiridas en tres direcciones, (a)condición sana y (b)daño de 35 SCTs. | 51 |
| Figura 21. Diagrama de bloques de la metodología propuesta. | 52 |
| Figura 22. Montaje del experimento. | 53 |
| Figura 23. Señales de vibración adquiridas del eje x del acelerómetro triaxial. | 53 |
| Figura 24. Metodología para el desarrollo de un modelo basado en vibraciones. | 53 |
| Figura 25. Diagrama eléctrico de la alimentación, interconexión del transformador trifásico. | 54 |
| Figura 26. Metodología para la obtención del modelo no paramétrico basado en redes neuronales artificiales. | 55 |
| Figura 27. Modelo no paramétrico basado en redes neuronales artificiales, entradas y salida. | 55 |
| Figura 28. Diagrama de flujo de la metodología propuesta en el caso de estudio 3. | 57 |
| Figura 29. Configuración del experimento..... | 58 |
| Figura 30. Señales adquiridas del transformador: señales VA para (a) 0 SCTs, (b)1 SCTs y (c)2 SCTs. . | 59 |
| Figura 31. Características estimadas normalizadas en la condiciones sana y de 35 SCTs de falla: (a) Media, valor máximo, RMS, SMR y varianza para 0 SCTs; (b) Media, valor máximo, RMS, SMR y varianza para 35 SCTs; (c) desviación estándar (Std), factor forma (RMS) (SRMS), factor forma (SRM) (SSRM), fator cresta (CF) y factor latitud para 0 SCT; (d) desviación estándar (Std), factor forma (RMS) (SRMS), factor forma (SRM) (SSRM), fator cresta (CF) y factor latitud para 35 SCT; (e) factor impulso | |

| | |
|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| (IF), oblicuidad (Skw), factor de oblicuidad (SkF), curtosis (Kur) y factor curtosis (KF) para 0 SCTs; (f) factor impulso (IF), oblicuidad (Skw), factor de oblicuidad (SkF), curtosis (Kur) y factor curtosis (KF) para 35 SCTs; (g) 5to momento normalizado (5m), 6to momento normalizado (6m), entropía de Sahnnon (SE) y energía de entropía logarítmica (LEE) para 0 SCTs; (h) 5to momento normalizado (5m), 6to momento normalizado (6m), entropía de Sahnnon (SE) y energía de entropía logarítmica (LEE) para 35 SCTs. | 61 |
| Figura 32. Histograma de las mejores características. | 62 |
| Figura 33. Comparación de desempeño entre (a) transformación PCA y (b) transformación LDA. | 63 |
| Figura 34. Clasificación de la SVM: (a) usando un conjunto de 7 características; (b) proyección de las regiones de decisión y su entrenamiento cuando se utiliza un 5-fold; (c) proyección de las regiones de decisión y su entrenamiento cuando k=4 y (d) proyección de las regiones de decisión y su entrenamiento cuando k = 3. | 65 |
| Figura 35. Arquitectura principal del procesador basado en FPGA. | 66 |
| Figura 36.(a) Señales de vibración, (b) modo no lineal 1 (NM1), (c) modo no lineal 2 (NM2), (d) modo no lineal 3 (NM3), (e) modo no lineal 4 (NM4) y (f) residuos. | 69 |
| Figura 37. Valor cuadrático medio (RMS) de los diferentes NMs. | 70 |
| Figura 38. Valores RMS de todas las condiciones SCTs: (a) NM4 del eje x y (b) NM1 del eje y. | 70 |
| Figura 39. Funciones de membresía para (a) entradas y (b) salidas. | 72 |
| Figura 40. Señal de vibraciones en estado estable de la fase del transformador que emula SCTs. | 73 |
| Figura 41. a) Amplitudes de los armónicos y b) fases de los armónicos. | 74 |
| Figura 42. Desempeños de las distintas estructuras de las ANN (a) Amplitud de ANN con una capa oculta, (b) Amplitud de ANN con dos capas ocultas, (c) Amplitud de ANN con tres capas ocultas, (d) Fase de ANN con una capa oculta, (e) Fase de ANN con dos capas ocultas y (f) Fase de ANN con tres capas ocultas. | 75 |
| Figura 43. Estimaciones para la entrada en condiciones nominales, sin carga y sin espiras en corto circuito de (a) amplitudes y (b) fases. | 76 |
| Figura 44. Amplitudes y fases estimadas para una entrada de interpolación de 7.5% de desbalance, con contenido armónico y cinco espiras en corto circuito. | 76 |
| Figura 45. Ejemplo de señales: (a) señal VA y (b) su normalización en escala de grises. | 85 |
| Figura 46. Media (μ) del contraste para diferentes cargas: (a) Contraste de Unser con d=15 y (b) contraste de Tamura. | 86 |
| Figura 47. Distribución de los datos de los valores de contraste para las señales VA con diferentes condiciones de fallas SCT: (a) contraste de Unser y (b) contraste de Tamura. | 86 |
| Figura 48. Agrupaciones del contraste de Unser para diferente valores d: (a) d = 5, (b) d = 10, (c) d = 15, (d) d = 20, (e) d = 25, (f) d = 30, (g) d = 35 y (h) d = 40. | 88 |

Capítulo 1. Introducción

El uso de energía eléctrica se ha convertido de vital importancia en la vida cotidiana tanto en el sector social, comercial e industrial. En estos sectores, la diversidad de máquinas y dispositivos que hacen uso de esta energía es variada, además que, dependiendo del tipo de carga su demanda de energía es diferente. Para entregar la cantidad de energía y potencia a los usuarios es necesario el uso de transformadores eléctricos, estos se encargan de adecuar los niveles de voltaje y a su vez disminuyen las pérdidas en las líneas de transmisión y distribución (Aljibes L, 2015). Las redes de transmisión y distribución son bastante complejas, en ellas el transformador juega un rol de vital importancia (Zheng et al., 2015) y es uno de los más caros en la red eléctrica (Hong, Huang, & Zhou, 2015). Cabe mencionar que hay miles de ellos en un sistema eléctrico y está sujeto a distintas condiciones climáticas, mecánicas y eléctricas durante su vida de servicio; las cuales degradan y afectan negativamente su vida útil. Esto conlleva a la aparición de fallas que pueden causar cortes en el suministro de energía, lo que causa pérdidas económicas y en otros casos podría estallar o incendiarse lo que resulta en accidentes catastróficos (Bagheri et al., 2012). Reemplazar transformadores tiene costos elevados, por lo que es deseable desarrollar técnicas que permitan realizar el monitoreo y diagnóstico de fallas tanto severas como de forma incipiente o temprana.

Como se mencionó, los transformadores no están exentos de tener fallas en su funcionamiento, las cuales se pueden categorizar en eléctricas, mecánicas o térmicas (M. Wang et al., 2002). Las causas de estas pueden ser internas o externas. Dentro de las fallas externas se encuentran la sobrecarga, causada por una elevada demanda eléctrica, sobretensiones, generadas por descargas atmosféricas y variaciones de frecuencias en el sistema, las cuales se derivan de la conmutación de grandes cargas o la entrada de generadores, entre otras. Por el otro lado, algunas de las causas de fallas internas son por defectos de fabricación, deterioro del aislamiento de los devanados, sobrecalentamiento, aflojamiento de los devanados y del núcleo, descargas parciales, entre otras. Hay que tomar en cuenta que muchas de estas fallas permiten al transformador seguir operando, sin embargo, el riesgo de falla catastrófica o que cause paros en el suministro de la energía eléctrica se incrementa en el futuro cercano (Borucki, 2012). El patrón de falla que se

encuentra en los transformadores sigue una curva parecida a la de una tina de baño como se muestra en la Figura 1. La primera sección (I) se conoce como la etapa de mortalidad temprana, debido a que las causas de fallo son por defectos de fabricación o malas instalaciones. La segunda sección (II) es donde la tasa de fallo es constante, es decir que el porcentaje de fallo es de entre el 1 y 2% y principalmente debido a la humedad, contaminación, descompresión de los embobinados entre otras causas. Finalmente, en la tercera etapa (III), las fallas son principalmente por el envejecimiento del transformador, donde las principales causas de falla son por las derivaciones de carga, los embobinados, envejecimiento de los aislantes y contaminación (M. Wang et al., 2002). Si se realiza un monitoreo y mantenimiento al transformador durante la etapa (II) se puede prolongar su vida de servicio, por lo que estudiar las causas de fallo en esta etapa es relevante para la vida de un transformador. En un estudio realizado por el consejo internacional de grandes redes eléctricas (CIGRÉ) (M. Wang et al., 2002) se muestra que el 53% de las fallas son de origen mecánico, donde alrededor del 30 al 50% son fallas por deformación de los devanados y un 5% por deformación en el núcleo. Se observa un alto porcentaje de fallas en los devanados, esto se debe a que estos son los componentes internos más vulnerables del transformador (Hu et al., 2019; Islam et al., 2018).

Algunas de las fallas más estudiadas son las derivadas de la interacción de las fuerzas electrodinámicas en el embobinado y el núcleo, lo cual puede desencadenar fallas más severas. Por ejemplo, una falla de deformación del núcleo (aflojamiento de la prensa, separación entre las láminas del núcleo, etc.), modifica el comportamiento de las fuerzas dentro del transformador, haciendo que la deformación del núcleo aumente y por consiguiente nuevamente las fuerzas se modifican, generando un efecto de bola de nieve y colapsando el dispositivo. Evidentemente, la eficiencia y degradación de la vida útil del transformador se ven drásticamente afectadas. También, es importante mencionar que las variaciones asociadas a las deformaciones estructurales incrementan las vibraciones, que a su vez generan una fatiga mecánica en los aislantes causando desgastes entre las bobinas y cortos circuitos (SCTs del inglés *Short-Circuited Turns*). Así mismo, al aumentar la separación entre estas se crean capacitancias parasitas haciendo que la distribución del voltaje sea distinta de la que fue diseñada (García et al., 2005). Por lo tanto, las fallas en el núcleo son causadas o empeoradas en parte por la vibración generada por las fuerzas de la magnetostricción y por la descompresión del mismo núcleo. La magnetostricción es un pequeño cambio en las dimensiones de un material ferromagnético cuando está bajo la influencia de un campo magnético (Moses et al., 2010). Mientras que las fallas en el devanado son causadas por la vibración generada por las fuerzas electrodinámicas, las cuales dependen directamente de la corriente y la misma descompresión de los embobinados, cuando se descomprimen los embobinados se genera una variación en sus dimensiones, lo que desbalancea las cargas y se sobrecarga en zonas que no debería hacerlo, tales como el neutro del transformador. Las fuerzas electrodinámicas causan estrés mecánico en los aislantes del embobinado, por lo que se genera la condición de SCTs.

En general, el diagnóstico de transformadores, así como de muchos otros tipos de equipos mecánicos y eléctricos, se basa en el análisis de distintas variables físicas como temperatura, corriente, vibraciones, etc. Para llevar a cabo el diagnóstico de falla en transformadores se han propuesto diferentes métodos, por ejemplo, análisis de gas disuelto, prueba del factor de potencia,

termografía, análisis de la respuesta en frecuencia, calidad del aislante, calidad del aceite aislante, corriente de energización, análisis de vibraciones, entre otras (Islam et al., 2018; Mejia-Barron et al., 2017; M. Wang et al., 2002; Z. Zhang et al., 2019). Aunque han sido obtenidos resultados bastante prometedores, algunos puntos se mantienen sin resolver en algunos métodos de diagnóstico. Sin embargo, como ya se mencionó, tanto las fallas en el núcleo como las de los devanados genera vibraciones, por lo que, en años recientes, el análisis de las vibraciones ha atraído el interés de los científicos debido a que es una variable que está directamente relacionada con la composición y desempeño mecánico/dinámico de los equipos y en particular del transformador (H. Zhou et al., 2016). Por lo tanto, el estudio de las fallas asociadas a la deformación estructural (deformación del núcleo y del embobinado) a través del análisis de vibraciones es un campo de oportunidad que se debe explorar en detalle ya que las vibraciones cambian cuando las propiedades mecánicas del núcleo o devanados son modificadas, como cuando aparece una falla (Zheng et al., 2018). También se debe mencionar que algunos estudios miden señales acústicas en lugar de señales de vibración. Se ha observado que las señales acústicas son producidas por una fuente de vibración, así que contienen la misma información del comportamiento de la fuente. De esta manera, las señales de vibración y acústicas están interrelacionadas y son homologas (Kim & Lee, 2022; Y. Zhou & Wang, 2022). Aunque con la información brindada tanto por las señales de vibración como por las vibro acústicas se puede realizar la detección de fallas, la detección de falla en un estado incipiente, es decir en un estado de severidad baja antes de que la falla sea más severa y con consecuencias mayores; desafortunadamente, representa aún un reto hoy en día.




Figura 1. Patrón de fallo de los transformadores (M. Wang et al., 2002).

1.1 Antecedentes de análisis de señales de vibración.

En esta sección se realizará una recopilación y descripción de los trabajos de investigación reportados en la literatura, enfocándose principalmente en las diferentes técnicas de análisis de vibración (VA, del inglés *vibration analysis*), cabe mencionar que estas se pueden separar en el

análisis basado en las señales, el basado en modelos y los basados en aprendizaje (Hong, Huang, & Zhou, 2015). Las técnicas basadas en señales extraen características directamente de las señales de vibración, mientras que las técnicas basadas en modelos de vibraciones son enfoques que establecen una relación entre las vibraciones generadas y los parámetros de entrada, esto permite evaluar la condición del transformador comparando los valores estimados con los medidos. Mientras que los algoritmos basados en el aprendizaje se enfocan en el reconocimiento de patrones y la toma de decisiones.

1.1.1. Análisis basado en señales.

El análisis de vibraciones basado en señales usualmente son algoritmos que extraen información de una señal, es decir miden algún parámetro que permite distinguir un comportamiento anómalo. Por ejemplo, Hong et al. (2016) utilizan cuatro distintas métricas de indicadores no lineales para mejorar el diagnóstico del transformador. La primera de ellas es el análisis de la complejidad en frecuencia, la cual utiliza la entropía de Shannon que describe la cantidad de información que proviene de la señal. La segunda es el análisis estacionario de vibraciones basado en el análisis gráfico de la recurrencia. La tercera es el análisis de la distribución de la energía la cual se concentra en la similitud de la energía de las vibraciones bajo diferentes cargas. Finalmente, el análisis de la correlación de las vibraciones basada en la relación de la frecuencia fundamental con los parámetros eléctricos, es decir, evalúa el grado de correlación ente los componentes del doble de la frecuencia fundamental. También, Z. Zhang et al. (2019) presentan métodos basados en estadísticas matemáticas de señales de vibración, donde se utiliza la distribución de probabilidad para identificar la falla de SCTs. Por otro lado, el análisis de las vibraciones en los embobinados causadas por el cambio de presión en el ajuste del núcleo es detectado por Zheng et al. (2015) utilizando un vibrométero Doppler láser (LVD, del inglés *Laser Doppler Vibrometer*), donde se menciona que la utilización del LVD es para evitar el contacto con los embobinados. De la misma manera, un sistema de medición de vibraciones basado en LVD, pero para 3 fases, fue desarrollado por Mizokami et al. (1997) . Una de las ventajas del LVD es que estará libre de efectos del campo magnético. En el trabajo presentado por Hong et al. (2015) se utilizan varios sensores para la adquisición de las vibraciones, además utilizan el análisis de las componentes principales (PCA, del inglés *Principal Component Analysis*) junto con una correlación entre las señales medidas, logrando obtener un parámetro para la distinción de un sensor donde pueden aparecer anomalías.

La extracción de información no solo suele ser en el dominio del tiempo, una técnica muy utilizada para extraer información, pero del dominio de la frecuencia es la transformada de Fourier (FT, del inglés *Fourier Transform*) y su algoritmo computacional la transformada rápida de Fourier (FFT, del inglés *Fast Fourier Transform*). Por ejemplo, en los trabajos García et al. (2005) y Yoon et al. (2013) extraen la información del dominio de la frecuencia para comparar un transformador sano de uno anómalo. Mientras que Bartoletti et al. (2004) incluye la correlación cruzada y algunas métricas tanto lineales como no lineales para distinguir entre distintas condiciones. En estos trabajos las anomalías no son distinguibles, es decir que no se logra especificar la falla. Sin embargo, presentan que el parámetro utilizado es una relación entre la

frecuencia fundamental y su segundo armónico, el cual está relacionado con la falla en el embobinado. Otro trabajo que utiliza directamente la información del dominio de la frecuencia es el de Bagheri et al. (2018) que analiza el espectro de las vibraciones para detectar el inicio de corto circuito. Hong et al. (2015) introducen el análisis complejo frecuencial empleando la entropía como una medida de incertidumbre frecuencial. En un trabajo más reciente, Zhou y Wang, (2022), estiman la distorsión armónica total (THD, del inglés *total harmonic distortion*) de las frecuencias dominantes y la razón de frecuencias del espectro de las señales vibro acústicas. Para determinar e identificar el estado de polarización de corriente continua establecen un umbral de advertencia. Aunque estas técnicas han presentado resultados promisorios, el desempeño de la FT se ve comprometido cuando la señal analizada presenta eventos no estacionarios, altos niveles de ruido, entre otras (Romero-Troncoso, 2017). Para cuando ocurren este tipo de eventos se prefiere utilizar una variante de la FT, la cual es llamada transformada de tiempo corto de Fourier (STFT, del inglés *Short-Time Fourier Transform*). La STFT ofrece la observación de la evolución en el tiempo de las propiedades no estacionarias de la señal. Una técnica de monitoreo no invasiva de la condición mecánica del núcleo y de los embobinados es la desarrollada por Borucki (2012). Esta técnica es llamada método vibro acústico modificado (MVM, del inglés *Modified Vibroacoustic Method*) el cual se basa en la medición de las vibraciones mecánicas del transformador en el estado transitorio junto con un procesamiento por medio de la STFT, esto para la evaluación tanto del núcleo como del embobinado. Realizar el MVM presenta un grado de inmunidad a las corrientes de carga, independencia de las señales vibro acústicas y de la potencia y construcción del transformador. También Borucki et al. (2017) utilizan la STFT para analizar una ahora una señal vibro acústica, donde los cambios en las frecuencias están asociados al comportamiento anómalo del transformador. En general, aunque la STFT es una herramienta potente y de baja complejidad para el análisis de señales no estacionarias, sin embargo, la resolución del tiempo y de la frecuencia se ve comprometida si la relación entre estas no es establecida adecuadamente, esto no suele ser una tarea sencilla cuando las propiedades de la señal son desconocidas (Valtierra-Rodríguez et al., 2020).

Existen trabajos en lo que se utilizan técnicas avanzadas de procesamiento de señales tales como la transformada Wavelet (WT, del inglés, *Wavelet Transform*) y la transformada de Hilbert Huang (HHT del inglés, *Hilbert Huang Transform*). En general, la WT descompone una señal no estacionaria en un conjunto de bandas frecuenciales sobre el tiempo y tiene mejor localización del tiempo y de la frecuencia lo que la hace más efectiva que la STFT en algunas aplicaciones (Goyal & Pabla, 2016). Algunos trabajos con los de Rivas et al. (2010) y Liu et al. (2018) utilizan la WT para descomponer señales de vibración, y de esta manera extraer indicadores que permitan detectar fallas en un transformador. Existen variaciones de la WT, por ejemplo, la WT por paquetes utilizada por Wu et al. (2010) y también por Wu et al. (2018) para extraer características de las señales de vibración. Por otro lado, la WT empírica empleada por Zhao y Xu (2018) donde también se extraen características y así diagnosticar diferentes condiciones de falla en los transformadores. Algunos trabajos como los de Wu y Huang (2009) y Kang y Birtwhistle (2001) mezclan ambas transformadas para un mejor análisis. El primer paso es obtener las bandas de frecuencia para después hacer la descomposición de la señal en cada una de esas bandas para así realizar la extracción de características de las señales de vibración del tanque del transformador. Sin embargo, debe ser notado que el éxito de los métodos basado en la WT depende de la adecuada selección de

la ondícula madre y del nivel de descomposición las cuales cambian dependiendo de la aplicación (Amezquita-Sanchez & Adeli, 2015; Shah et al., 2013). En respecto, las técnicas adaptativas han llegado a ser soluciones atractivas, donde la descomposición de modos empírica (EMD, del inglés *Empirical Mode Decomposition*) y los métodos basados en ella han sido ampliamente utilizados, por ejemplo, Liu et al. (2018) emplea la EMD para procesar las señales de vibración en un transformador con un sesgo de corriente directa. En el trabajo de Mejia-Barron et al. (2018) se presenta una comparación de los tres métodos basados en la EMD para la detección de SCT en transformadores. Mientras que Geng et al. (2014) y Duan y Wang (2016) utilizan una versión mejorada de la EMD para realizar el diagnóstico de falla y una estimación de parámetros modales, respectivamente. El análisis de vibraciones de los métodos basado en la EMD también ha sido reportado en otras áreas como los trabajos de Amarnath y Krishna (2013), Camarena-Martinez et al. (2016), Saxena et al. (2016), Valles-Novo et al. (2015). A pesar de las ventajas adaptativas de los métodos basados en la EMD presenta algunas desventajas como el mezclado de modos, ruido y carencia de significado físico de los modos descompuestos, esto puede comprometer la efectividad de la técnica. Recientemente, Iatsenko et al., (2015a) desarrollaron una técnica llamada descomposición de modos no lineales (NMD, del inglés *Nonlinear Mode Decomposition*) que resuelve las desventajas mencionadas de las técnicas basada en EMD. La NMD descompone una señal de una forma de onda bastante compleja en un conjunto de modos con un significado físico y simultáneamente remueve el ruido, haciéndola una solución potencial para analizar señales de vibración contaminadas con bastante ruido, con propiedades no lineales y no estacionarias tal como las que se presentan en los transformadores.

Otro punto que no debe dejarse de lado es la forma en la que se realiza la adquisición de las señales de vibración del transformador; es decir, las especificaciones del sensor, la ubicación, el rango de frecuencia, el cual oscila desde 1-2000 Hz, tipo de tecnología, etc., determinan que tanta información podrá ser extraída de la medición. Múltiples sensores son colocados en distintos puntos del transformador como lo hacen García et al. (2005) y Sanz-Bobi et al. (1997) donde de manera experimental encuentran puntos adecuados para la adquisición de las señales de vibración, tanto dentro como fuera del transformador, es decir, en los embobinados y en el tanque.

1.1.2. Análisis basado en modelos.

Por otro lado, los algoritmos basados en modelos establecen una relación directa entre las vibraciones y los parámetros de entrada, por ejemplo, el trabajo presentado por Zheng et al. (2018) donde se analizan las no linealidades causadas por distintos factores dentro de un transformador. Se enfoca principalmente en los cambios de la presión de sujeción de los embobinados (esta falta de presión genera una deformación estructural). Las vibraciones causadas por el embobinado están relacionadas a la parte lineal del modelo. Posteriormente extrae parámetros relacionados a la falla de la parte lineal del modelo. El trabajo presentado por Bagheri et al. (2018) se basa en modelo no paramétrico de vibraciones para analizar la condición de corto circuito de un transformador de tres fases. Ellos usan técnicas de procesamiento de señales y de máquinas de aprendizaje, realizando en línea el procesamiento en la nube. A su vez Zhou et al. (2016) proponen un modelo acoplado de vibración del embobinado y las fuerzas electromagnéticas con el que obtienen la distribución

de las vibraciones en la dirección axial durante el estado estable. Con esto, se estudian las fuerzas de sujeción en la misma dirección del embobinado. Las fallas estudiadas son la deformación, el aflojado parcial, pandeo parcial y movimiento radial del embobinado. Otro modelo basado en vibraciones es propuesto por Garcia et al. (2006). Este modelo considera no sólo las fuentes fundamentales en la generación de vibraciones del transformador, sino que también la influencia de la temperatura, ya que esta influye en el efecto de magnetostricción, así como en el cambio de la viscosidad del aceite de asilamiento. Estas vibraciones son adquiridas del tanque del transformador para determinar principalmente las deformaciones de los devanados. Posteriormente, realizaron la verificación experimental García et al. (2006). En cambio, Hong et al. (2015) adquieren las señales con varios sensores, llevando a cabo un análisis de correlación de vibraciones con el fin de proponer un modelo para evaluar la condición de los devanados. También un modelo acoplado con el análisis de las fuerzas electromagnéticas para detectar fallas en los devanados es presentado por Zhou et al. (2016). De la misma manera, el modelado por análisis de elemento finito ha sido bastante utilizado. Por ejemplo, el trabajo presentado por Haijun et al. (2014) realiza el análisis de estrés bajo la condición de corto circuito y la deformación del embobinado inmerso en aceite. Ahí se muestra que la deformación de los embobinados tiene una alta contribución para la inestabilidad del transformador. La misma técnica de elemento finito es utilizada por Ahn et al. (2011) y Ho et al. (2004) para el modelado de las fuerzas electromagnéticas en la condición de corto circuito que aparecen en los embobinados. Incluso, el análisis de elemento finito es utilizado para el cálculo de las capacitancias parasitas generadas en el embobinado como lo presenta Lambert et al. (2013). También Li et al. (2011) desarrollan una metodología para determinar la condición de corto circuito, sin embargo, estudian principalmente las vibraciones axiales que provocan la descompresión del embobinado.

Adicionalmente, una forma de conocer el grado de descompresión en el núcleo y embobinados es presentado por Suwanasri et al. (2007). Su modelo de diagnóstico es basado en el análisis de gas disuelto junto con mediciones de las corrientes de magnetización. Este método ha sido utilizado para la detección de fallas en transformadores con varios años de servicio, ya que es cuando algunos componentes del transformador generan esos gases. Después de la medición de los gases utilizan métodos como: método del gas clave, método de la razón de gas, método del combustible total. También utilizan la respuesta dieléctrica de los aislantes. Estos distintos métodos proveen de estimaciones relacionadas a los fallos.

1.1.3. Análisis basado en aprendizaje.

Por último, los trabajos que usan algoritmos basados en el aprendizaje para realizar el diagnóstico de los transformadores se enfocan en el reconocimiento de patrones y la toma de decisiones. (Hong, et al., 2015) presenta un modelo de clasificación basado en la probabilidad, extrayendo características de las señales de vibración, tanto en el dominio del tiempo como en el de la frecuencia, por ejemplo, energía y complejidad frecuencial. Estas características luego se introducen a una máquina de soporte vectorial (SVM, del inglés *support vector machine*) con la que se realiza la clasificación de la condición del transformador. Desafortunadamente, esto no es elegible en aplicaciones donde existen varias severidades de falla porque las características no

siempre son capaces de maximizar la separación entre las diferentes clases. El trabajo de Castro y Miranda (2005) se propone una nueva metodología para el mapeo de una red neuronal artificial (ANN, del inglés *artificial neural network*) con un sistema de reglas basado en un sistema de inferencia difuso (FIS, del inglés *fuzzy inference system*), es decir, las reglas utilizadas para el FIS se extraen de entrenar una ANN. Otro método que se ha presentado es un basado en la dimensión fractal y la minería de datos es el de Valtierra-Rodriguez (2020). Este método utiliza diferentes algoritmos para el cálculo de fractales como indicadores de falla y, además, para la clasificación utiliza y compara diferentes algoritmos de clasificación. Los mejores resultados se obtienen con el clasificador del k -ésimo vecino más cercano, el cual muestra la capacidad de detectar diferentes severidades de falla de SCTs. En el trabajo presentado por Bigdeli et al. (2012) desarrollan una clasificación de falla de devanados inteligente a través de un análisis de la función de transferencia. La información obtenida de las señales de vibración es por medio de índices matemáticos en el dominio de la frecuencia; frecuencia y variaciones en la amplitud. También realizan la comparación de desempeño de dos clasificadores; SVM y ANN, donde el SVM obtiene un mejor desempeño que la ANN. Finalmente, al igual que Contreras-Valdes et al. (2020) se remarca que uno de los factores más importantes para que un método de reconocimiento de falla basado algún algoritmo de aprendizaje sea exitoso es una selección apropiada de las características de entrada.

Con base a todo lo anterior y como ya se ha mencionado, el realizar un diagnóstico a los transformadores es importante para evitar tener cortes en la línea, así como fallas catastróficas, esto por ser uno de los elementos de la red de suministro más importantes y costosos. Por lo que las metodologías y técnicas de diagnóstico están en aumento tanto para las fallas desarrolladas e incipientes. Esta última permite realizar esquemas de mantenimiento en el mejor momento sin afectar la red eléctrica y así prolongar la vida de estos. Desafortunadamente, la mayoría de los métodos para fallas desarrolladas identifican sólo algunos casos donde la falla es con alteraciones severas y no con afectaciones menores, lo cual sería deseable en acciones de mantenimiento preventivo. La mayoría de las investigaciones existentes se enfocan en la vibración del embobinado y núcleo bajo condiciones de alimentación normales; es decir, la mayoría de las metodologías revisadas para este trabajo consideran alimentaciones nominales con ligeras variaciones del voltaje de entrada, dejando de lado las posibles repercusiones que puede tener una fuente desbalanceada o con armónicos, es decir, no consideran en los análisis frecuenciales la posibilidad de que la generación de las componentes armónicas de fallas tanto en embobinado y núcleo sean originadas de forma externa, así como el comportamiento que tendrán las metodologías convencionales cuando el transformador con deformación estructural es alimentado con condiciones no nominales o perturbaciones en la fuente de alimentación. Por tanto, una técnica de diagnóstico podría funcionar en condiciones nominales de alimentación, pero su desempeño podría verse afectado cuando el transformador es alimentado con condiciones no nominales (por ejemplo: una alimentación con distorsión armónica o con una alimentación desbalanceada en el caso de los sistemas trifásicos). Así mismo, los modelos realizados son basados en las vibraciones del embobinado despreciando las vibraciones generadas en el núcleo junto con las afectaciones en la estructura mecánica de sujeción de estos. Además, es claro que los criterios asumidos en la literatura cuentan con una dificultad de aplicación, esto es, por la extensa variedad de unidades en servicio con características diferentes donde la adquisición de señales de vibración se vuelve más compleja, siendo necesario incluso el estudio de la ubicación de un sensor en toda la estructura del

transformador. Por lo antes mencionado, el uso de algoritmos avanzados de procesamiento de datos ha sido limitado por el alto costo computacional, sin embargo, actualmente la tecnología no es una limitante para algoritmos como el análisis tiempo frecuencia, donde se puede observar la evolución frecuencial respecto al tiempo, podría ayudar a identificar los cambios generados en la fuente de alimentación y con esto desarrollar modelos tanto paramétricos como no paramétricos basados en frecuencia que describan el comportamiento del transformador bajo condiciones no nominales. Además, observar el efecto de estos cambios en el núcleo debido al efecto de la magnetostricción y las repercusiones que genera en la estructura de este. La adquisición de las señales de vibración deberá realizarse de una manera no invasiva y en la mejor posición para que un acelerómetro triaxial permita la adquisición de las señales de vibración con las mejores características para realizar un diagnóstico fiable y eficiente. Finalmente, hay algunos problemas que no ha sido completamente atendidos, por ejemplo, la detección del daño de baja severidad, el análisis del transformador bajo distintas condiciones de carga, lo cual es de suma importancia para llevar a cabo sistemas de monitoreo en línea para el mantenimiento predictivo. Es importante mencionar que la detección de fallas tempranas es una tarea desafiante ya que los cambios en el transformador son muy ligeros cuando se presentan este tipo de fallas. Además de que el desafío se incrementa si se considera que la señal de vibración está tanto embebida en un alto nivel de ruido, así como por el estrés eléctrico asociado a las diferentes condiciones de carga.

1.2. Descripción del problema.

El mantenimiento de una red eléctrica es fundamental para mantener un suministro adecuado y continuo, esto conlleva también a mantener el funcionamiento apropiado de los transformadores. Con el ingreso de las redes eléctricas inteligentes (REI) las variaciones que estas ingresan a la red son un reto para mantener al transformador en condiciones eficientes de operación, es por lo que, conocer el comportamiento de los transformadores bajo las condiciones de desbalance y presencia de armónicos será fundamental, ya que las variaciones en voltaje y corriente afectan directamente a los devanados y al núcleo del transformador, principalmente generando deformaciones. Estas deformaciones en los principales componentes del transformador pueden guiar a otro tipo de fallas, lo que podría afectar la calidad de la energía hasta causar fallas catastróficas. Es por lo que, se deben desarrollar distintas soluciones tecnológicas y científicas para prevenir y corregir las fallas que pudieran presentarse en los transformadores.

Para llevar a cabo posibles soluciones es necesario desarrollar sistemas de alimentación que permitan generar distintas condiciones, es decir: desbalance y armónicos, de manera controlada para su manipulación y estudio. Con este tipo de sistemas permitirá conocer los fenómenos y sus consecuencias tanto en el transformador como en la energía que este manipula. También es necesario crear de manera artificial las modificaciones en el transformador de una manera controlada. Esto permitirá manipular el grado de deformación y obtener así las firmas para distintos escenarios de variación geométrica (deformación) de los devanados. Entonces, es necesario adecuar el transformador para que permita generar las condiciones ya mencionadas, así mismo, que no cause algún otro fenómeno que modifique las condiciones nominales de operación. Por otro lado, el sistema de monitoreo y adquisición de las señales de vibración generadas en el

núcleo y devanados debe ser confiable y de gran precisión, es decir, que brinde seguridad de que las señales obtenidas brindan información con la que se sea capaz la extracción de características que ayuden al diagnóstico. Desarrollar un sistema eficiente de monitoreo y adquisición de las señales de vibración será de relevancia, debido a que en el caso de un transformador trifásico se deberán analizar cada una de las fases, esto implica la adquisición de hasta nueve canales de vibración; tres ejes en cada fase. Finalmente, la realización de un modelo basado en técnicas paramétricas o no paramétricas implicará una ardua investigación en la literatura, ya que es necesario tener una amplia selección de técnicas para el desarrollo del modelo. Al tener distintas opciones para el desarrollo de este, se podrá facilitar la obtención de un modelo de diagnóstico más aproximado a la realidad. A su vez, un buen modelo permitirá realizar el diagnóstico del transformador acertadamente ante las condiciones armónicas y de desbalance de la red eléctrica.

1.3. Justificación.

Como ya ha sido mencionado, el transformador es uno de los elementos eléctricos más importantes en una red de distribución eléctrica, el cual se encarga de entregar la potencia y voltaje requeridos por el usuario. Además de que este opera bajo distintas condiciones eléctricas y atmosféricas, lo que puede incurrir en la aparición de fallas que pueden causar cortes en el suministro de energía, causando pérdidas económicas importantes en la industria, comercios e incluso en hogares. En casos catastróficos, puede causar accidentes ya que el transformador puede estallar o incendiarse.

Las principales fallas en los transformadores son en los devanados; que alcanzan un 40%, y fallas en el núcleo; con un 2% (Secic et al., 2019). Mientras que en México los valores son muy parecidos (Figura 2), es decir que, las fallas en los devanados alcanzan un 53% y en el núcleo un 2% (Olivares-Galvan et al., 2016). Este tipo de fallas están altamente relacionadas con la deformación estructural del transformador provocando vibraciones en sus componentes. Es por esto mismo que es importante desarrollar técnicas y metodologías que permitan realizar la captura de señales de vibración, el diagnóstico eficiente y oportuno de los transformadores, utilizando técnicas avanzadas de procesamiento de señales como lo son representaciones tiempo-frecuencia y la aplicación de métodos paramétricos.

En cuanto a las fallas causadas por agentes externos tales como: el desbalance y la condición de armónicos en la fuente de alimentación no ha sido estudiada y es importante hacerlo ya que, con la introducción de la generación distribuida, el desarrollo de dispositivos basados en electrónica de potencia, y la intermitencia de las cargas y los generadores (fuentes de energía renovables o no convencionales) estos fenómenos aparecerán con mayor frecuencia. Bollen et al. (2017) mencionan las consecuencias adversas de la introducción de tecnologías y aplicaciones de la distribución en redes inteligentes si estas no son manejadas adecuadamente. Algunas de principales preocupaciones son el aumento de la dinámica de los flujos de energía bidireccionales, las mayores emisiones de armónicos, las compensaciones de corriente continua y los desequilibrios, así como la aparición más frecuente de variaciones de voltaje, transitorios de conmutación, caídas y aumentos (*sags, swells, etc.*) de voltaje e interrupciones momentáneas y cortas. Al tener en cuenta estas posibilidades en la red eléctrica es necesario entender cuál será el

comportamiento del núcleo y devanados del transformador antes de estos fenómenos y las consecuencias que podrá tener en condiciones nominales o de falla del transformador. Más aún, el desarrollo de metodologías y modelos de diagnóstico que sean inmunes a las condiciones adversas de la fuente de alimentación serán deseables en términos de confiabilidad y eficiencia.




Figura 2. Fallas en transformadores en México (Álvarez, 2017).

Es por lo ya mencionado que se debe mantener el transformador en buen estado, esto es realmente importante para evitar problemas en el suministro eléctrico. Monitorear la condición del transformador para dar un diagnóstico acertado y preciso ayuda a mantener al transformador en óptimas condiciones, así como evitar problemas en el suministro eléctrico, la prevención de accidentes y sobre todo un gran ahorro económico, ya que reparar o sustituir un equipo de estos es muy costoso.

1.4. Hipótesis y objetivos.

1.4.1 Hipótesis

El análisis de señales de vibración provenientes de los devanados y núcleo del transformador basado en modelos no paramétricos permitirá realizar el diagnóstico de fallas por deformación estructural bajo condiciones de desbalance y de distorsión armónica de la fuente de alimentación.

1.4.2 Objetivo general

Obtener modelos tiempo-frecuencia, basados en vibraciones y en el efecto de la magnetostricción, para el diagnóstico de transformadores en condiciones de deformación en el devanado bajo condiciones de alimentación armónica y de desbalance.

1.4.3 Objetivos particulares

- Desarrollar un sistema de alimentación que permita emular condiciones armónicas y de desbalance con los valores y normas permitidas por la Comisión Federal de Electricidad (CFE) para la experimentación con el transformador bajo prueba.
- Desarrollar un sistema de adquisición de datos de tres acelerómetros triaxiales para la medición simultánea en distintos puntos del transformador.
- Diseñar y construir un banco de transformadores 1ϕ - 3ϕ con condiciones controladas de operación para su análisis.
- Analizar exhaustivamente las señales de vibración con técnicas de procesamiento para la extracción de las características que permitan determinar la condición física del transformador.
- Desarrollar una metodología de diagnóstico de corto circuito considerando diferentes niveles de severidad.
- Obtener un modelo no paramétrico que permita realizar el diagnóstico del transformador monofásico y trifásico.

1.5 Planteamiento general.

El planteamiento general de este trabajo se muestra en la Figura 3. El primer paso se enfoca en las condiciones eléctricas de la fuente de alimentación con el propósito de obtener un sistema capaz de emular esas distintas condiciones de alimentación. El sistema de alimentación que se debe diseñar y construir debe alimentar de una manera controlada distintas condiciones de trabajo, como lo son: valores nominales, con armónicos y desbalance. Con esta fuente se podrá alimentar el transformador para posteriormente realizar las pruebas necesarias.

El siguiente paso es modificar un transformador para poder generar distintas condiciones de deformación estructural, es decir deformación de los devanados de manera artificial (inducida y controlada), las cuales permitan de manera fácil y segura cambiar de condiciones según sea

requerido. El tipo de deformación a analizar en el presente trabajo es la deformación de los devanados, considerando distintos niveles de severidad.




Figura 3. Diagrama del planteamiento general del proyecto.

Será también necesario desarrollar un sistema de adquisición de señales de vibración, en el cual se utilizarán tres sensores, es decir acelerómetros triaxiales, lo que permitirá adquirir señales en tres direcciones por cada sensor, obteniendo nueve señales de vibración y observar cual es la que brinda la mejor información e incluso la posible detección del mejor lugar para la colocación de los sensores.

Teniendo dichos elementos se podrán realizar distintas pruebas con las diferentes condiciones tanto en la fuente de alimentación como en la severidad de la falla de corto circuito en los devanados, dichas fallas generan la deformación de los devanados.

Una vez obtenida la base de datos de las pruebas, se comenzará el análisis de estas para desarrollar diferentes metodologías que permitan realizar el diagnóstico de un transformador, utilizando técnicas avanzadas de procesamiento de señales, como lo son las representaciones tiempo frecuencia, entre otras. Además, basado en estas señales de vibración se desarrollará un modelo con las diferentes condiciones ya mencionadas que permita verificar el diagnóstico realizado con la metodología generando señales de vibración de un transformador bajo distintas condiciones de alimentación y diferentes severidades de falla prescindiendo de un transformador y su montaje para realizar la experimentación.

De esta manera se podrán generar señales de vibración con distintos comportamientos, los cuales permitirán realizar una mejor selección de las técnicas para el análisis y diagnóstico de un transformador usando señales de vibración generadas por el modelo.

Capítulo 2. Fundamentación teórica.

Para dar soporte teórico a la presente investigación es necesario tener fundamentos científicos y matemáticos en temas como transformadores, fallas de transformadores, análisis de vibraciones, procesamiento de señales, entre otras técnicas. Estos temas son descritos a detalle en las siguientes subsecciones.

2.1 El transformador

El transformador es un dispositivo eléctrico que la vida cotidiana moderna se encuentra en casi cualquier campo, básicamente convierte energía eléctrica de corriente alterna de cierto nivel de voltaje en energía eléctrica de corriente alterna de otro nivel a través de la interacción de la inducción electromagnética.

Los campos magnéticos son el mecanismo fundamental del funcionamiento del transformador, sus cuatro principios básicos son (Harper, 2005):

1. Un conductor que conduce corriente produce un campo magnético alrededor de él.
2. Un campo magnético variable en el tiempo induce un voltaje en una bobina de alambre cuando pasa a través de esta.
3. Un conductor con corriente bajo la presencia de un campo magnético experimenta una fuerza inducida sobre él.
4. Bajo la presencia de un campo magnético un conductor en movimiento tendrá un voltaje inducido en él.

Un transformador consta de dos bobinas o devanados de alambre conductor enrolladas alrededor de un núcleo ferromagnético común. Estos devanados no están conectados de manera directa, la conexión entre ellos es por el flujo magnético que se encuentra dentro del núcleo, como se muestra en la Figura 4.

Existen dos maneras básicas de construir un transformador, ver la Figura 5. La primera de ellas consta de una pieza de acero rectangular laminada, con devanados enrollados sobre ambos lados del rectángulo, como se muestra en la Figura 5a. La otra forma consta de un núcleo laminado de

tres columnas, donde los devanados son enrollados en la columna central, este tipo se conoce como transformado tipo acorazado, ver Figura 5b. En ambos casos el núcleo se construye con delgadas láminas aisladas eléctricamente unas de otras para minimizar las corrientes parásitas. Sin embargo, la unión entre ellas puede verse afectada por cuestiones de diseño, condiciones de falla, golpes, etc., lo cual incrementa la aparición de estas corrientes parásitas.




Figura 4. Esquema básico de un transformador (Harper, 2005).




Figura 5. Tipos de transformadores (Chapman, 2000): (a) Transformador tipo núcleo y (b) transformador tipo acorazado.

Para realizar el análisis de un transformador podemos considerar que se comportará idealmente y no tendrá pérdidas, como se muestra en la Figura 6. La relación de voltaje del primario $v_p(t)$ y voltaje del secundario $v_s(t)$ junto con el número de vueltas del primario N_p y del secundario N_s está dada por la ecuación (1).

$$\frac{v_p(t)}{v_s(t)} = \frac{N_p}{N_s} = a \quad (1)$$

De (1) se observa la relación de vueltas (a) del transformador. Ahora, la relación de corriente que fluye del primario $i_p(t)$ al secundario $i_s(t)$ es dada por las ecuaciones mostradas en (2).




Figura 6. Transformador ideal (Chapman, 2000).

$$N_P i_P(t) = N_S i_S(t)$$

$$\frac{i_P(t)}{i_S(t)} = \frac{1}{a} \quad (2)$$

Las relaciones de vueltas en un transformador ideal afectan únicamente las magnitudes de voltajes y corriente, pero no los ángulos de estas.

Al contrario de un transformador ideal, en uno real hay que tener en cuenta distintos fenómenos. El primero es que el flujo magnético en cada espira del devanado no será el mismo, entonces el flujo magnético generado por el devanado primario depende del flujo en cada espira de este. El flujo medio por vuelta variante en el tiempo $d\bar{\phi} / dt$ multiplicado por el número de vueltas N nos proporciona el voltaje inducido ε_{in} como :

$$\varepsilon_{in} = N \frac{d\bar{\phi}}{dt} \quad (3)$$

donde el flujo medio es la suma del flujo de cada espira ϕ_i del devanado

$$\bar{\phi} = \sum_{i=1}^N \phi_i \quad (4)$$

Sin embargo, el flujo magnético creado en un devanado no siempre será el mismo que llegue al otro devanado. El flujo creado por un devanado y que logra atravesar al otro devanado se conoce como flujo mutuo ϕ_M , mientras que el flujo magnético que no logra atravesar al otro devanado se le llama flujo disperso ϕ_{LM} . El flujo medio en cada devanado es la suma del flujo disperso y el flujo mutuo.

$$V_P(t) = N_P \frac{d\bar{\phi}_M}{dt} + N_P \frac{d\bar{\phi}_{LP}}{dt} \quad (5)$$

Entonces el voltaje en el devanado primario y secundario es

$$\begin{aligned} V_P(t) &= \varepsilon_P(t) + \varepsilon_{LP}(t) \\ V_S(t) &= \varepsilon_S(t) + \varepsilon_{LS}(t) \end{aligned} \quad (6)$$

Por lo tanto, si el transformador está bien diseñado se tiene la siguiente relación:

$$\frac{V_P(t)}{V_S(t)} = \frac{N_P}{N_S} = a \quad (7)$$

Otra variable que tomar en cuenta es la corriente de magnetización i_M , esta es la corriente requerida para producir el flujo en el núcleo, ya que una parte de esta causa pérdidas tanto por la histéresis como las corrientes parásitas. La corriente de excitación es la suma de la corriente de magnetización y las corrientes de pérdida i_{h+ex} .

La relación entre las corrientes y el número de vueltas del primario y secundario es:

$$\frac{i_P}{i_S} = \frac{N_S}{N_P} = \frac{1}{a} \quad (8)$$

Por último, se debe tomar en cuenta las pérdidas en el cobre, las cuales se verán reflejadas en el calentamiento de los devanados ya que la energía disipada es proporcional al cuadrado de la corriente i^2R . Estas son las principales características para tomar en cuenta en el diseño y modelado de un transformador.

2.2 Transformador trifásico.

El transformador revisado hasta el momento es conocido como transformador monofásico (TM). Sin embargo, en ocasiones es necesario otro tipo de transformadores, como lo es el transformador trifásico (TT), este puede construirse de dos maneras. La primera es con tres TMs conectados en un banco trifásico, Figura 7a. En la segunda forma se construye un TT con tres conjuntos de devanados enrollados sobre el mismo núcleo, Figura 7b. Cabe mencionar que los TMs del banco trifásico mantienen el mismo comportamiento de un TM. Las conexiones internas de los TT pueden ser conectados en ye o estrella (Y) o en delta (Δ). Resultando en cuatro posibles maneras de conexión: (Y-Y), (Y- Δ), (Δ -Y) y (Δ - Δ). Un ejemplo de una conexión (Y- Δ) se muestra en la Figura 8. La conexión (Y-Y) tiene dos problemas, uno es que, con las cargas del circuito desbalanceadas, los voltajes de las fases pueden desbalancearse e incrementar los voltajes de los terceros armónicos. Las conexiones (Y- Δ) y (Δ -Y) tienen un desfase de 30° del voltaje primario. Finalmente, la conexión (Δ - Δ) no presenta desfase ni problemas con los armónicos. El funcionamiento está limitado a ser manejado con valores nominales. Tanto el voltaje nominal y la potencia aparente fijan el valor del flujo de corriente en los devanados. Al haber una corriente mayor a la nominal habrá calentamiento en los devanados, provocando desgaste en el aislamiento y posibles cortos circuitos, acortando la vida del transformador. Se debe notar que el voltaje y la frecuencia están relacionados de manera recíproca. Si aumenta el voltaje o la frecuencia el flujo máximo aumentará al igual que la corriente.




Figura 7. Construcción de los transformadores trifásicos: (a) Banco trifásico realizado con tres transformadores monofásicos y (b) Transformador trifásico realizado en un núcleo de tres columnas (Chapman, 2000).

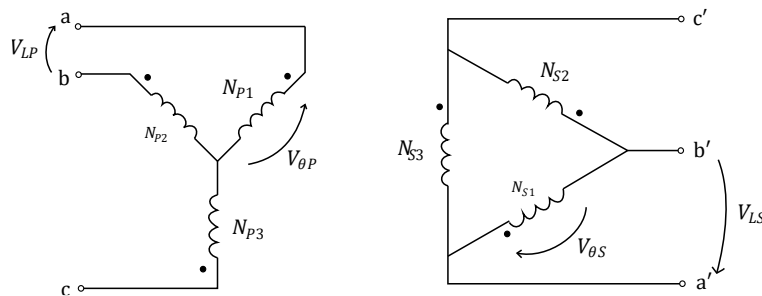


Figura 8. Conexión en Y-Δ (Chapman, 2000).

2.3 Fallas y vibraciones generadas en el núcleo y devanados del transformador.

Entre las fallas que pueden ocurrir en un transformador, se encuentran las fallas en la estructura interna las cuales son las de mayor problema. Comparados con otros componentes internos, los devanados son los elementos más importantes y vulnerables. En estos elementos y debido al flujos de fuga se generan vibraciones, las cuales se intensifican en la presencia de falla en los devanados. Por otro lado, el cambio de dimensiones en el núcleo provocado por el fenómeno de la magnetostricción tendrá efectos en el perno de sujeción de las laminillas del núcleo, es decir hará que haya descompresión sobre este y los devanados. Estos casos provocarán vibraciones en el transformador. Para inspeccionar de manera no invasiva el transformador, debe ser bajo la observación de estas vibraciones, por lo que es importante conocer de donde provienen y sus características.

2.3.1 Vibraciones

Una vibración se puede definir como cualquier movimiento que se repite después de un intervalo de tiempo. Esta puede verse como la transformación de su energía potencial en energía cinética y viceversa, de manera alterna. Si el sistema se amortigua, una parte de su energía se disipa en cada ciclo de vibración y se debe reemplazar por una fuerza externa para que se mantenga un

estado de vibración estable (Rao, 2012). Si a un sistema se le permite vibrar por sí solo después de una perturbación inicial, la vibración resultante se conoce como vibración libre. Por otro lado, si al sistema se le aplica una fuerza externa repetitivamente, a esta vibración se le conoce como vibración forzada. Para este caso las vibraciones del transformador son vibraciones forzadas, es decir que, las vibraciones se generan debido a una fuerza externa. Finalmente, si un sistema no pierde o disipa energía por fricción, gravedad u otra resistencia durante la oscilación, la vibración se conoce como vibración no amortiguada, o de lo contrario, vibración amortiguada.

El periodo T es el intervalo de tiempo necesario para realizar un ciclo de movimiento completo y se define como en (9).

$$T = \frac{2\pi}{\omega_0} \quad (9)$$

donde ω_0 es la frecuencia angular fundamental o natural. El número de ciclos por unidad de tiempo se define como frecuencia f .

$$f_0 = \frac{1}{T} = \frac{\omega_0}{2\pi} \quad (10)$$

donde f_0 es la frecuencia fundamental o natural.

En el diagnóstico por medio señales de vibración, la fuerza aplicada en la zona afectada define la falla y esta fuerza está relacionada con la aceleración de la oscilación de la fuerza. Normalmente, para la medición de las vibraciones se emplean sensores de vibración-aceleración basados en el efecto piezoeléctrico. En estos sensores la señal de vibración se convierte en señales eléctricas donde la salida es proporcional a la fuerza aplicada al sensor (Contreras, 2018). Las vibraciones también pueden adquirirse en forma de sonido, adquiridas por algún micrófono.

2.3.2. Vibraciones generadas en el núcleo del transformador.

Las vibraciones en el núcleo se crean principalmente por el fenómeno de la magnetostricción. Este fenómeno se describe como una propiedad de los materiales ferromagnéticos, en la cual el material cambia su forma y tamaño en algunas partes por millón al estar sujeto a un campo magnético (Hong et al., 2016). En la Figura 9 se muestra la relación entre el porcentaje de variación de la longitud y la inducción magnética en el núcleo de acero. El gráfico muestra que la magnetostricción presenta histéresis, si esta se desprecia la relación es aproximada a un polinomio cuadrático. Tomando en cuenta esta relación las fuerzas (F_{nucleo}) son proporcionales al cuadrado del voltaje (V) como se muestra en (11).

$$F_{nucleo} \propto V^2 \quad (11)$$

La frecuencia de las vibraciones del núcleo es el doble de la frecuencia del sistema y debido a las características no lineales del fenómeno las vibraciones en el núcleo tendrán armónicos en altas frecuencias. Además, si el núcleo fuese de acero homogéneo, la magnetostricción provocaría vibraciones en el plano del núcleo, pero el núcleo está compuesto de láminas; para eliminar corrientes parásitas, que son sobrepuestas y bajo estas condiciones hay un flujo magnético no uniforme, debido a esto se crean fuerzas de magnetostricción perpendiculares al núcleo.




Figura 9. Magnetostricción en el acero (García et al., 2005).

2.3.3. Vibraciones generadas en los devanados del transformador.

La deformación en los devanados es causada por las altas fuerzas electromecánicas ($F_{devanados}$), estas son directamente proporcionales a la corriente (I) que circula por los conductores al cuadrado, como muestra (12). Tiene componentes en las direcciones axial y radial. Las fuerzas axiales tienden a comprimir verticalmente los devanados, mientras que, las fuerzas radiales comprimen y expanden el devanado interno (Y. Wu et al., 2021). Estas fuerzas crean variaciones en las dimensiones del devanado. Las variaciones geométricas creadas llevan a un incremento en las vibraciones del devanado. El aumento de las vibraciones incrementa la fatiga o desgaste en el aislamiento de las espiras del devanado. Cuando se desgasta el aislamiento se producen corto circuitos entre las espiras. Por otro lado, el cambio entre las distancias de las espiras del devanado creará capacitancias parásitas haciendo que la distribución de voltaje sea diferente a la que fue diseñado el transformador causando sobre voltaje en el mismo. Ya que la forma de onda de la corriente es senoidal, la frecuencia de la fuerza electromagnética es el doble de la frecuencia fundamental. En México, la frecuencia fundamental es de 60 Hz.

$$F_{devanados} \propto I^2 \quad (12)$$

2.4 Desbalance de tensiones en sistemas trifásicos.

En sistemas trifásicos el desbalance ocurre cuando los voltajes y/o ángulos son diferentes entre las fases consecutivas (ECAMEC, 2009). Alcanzar un perfecto balance en los voltajes es prácticamente imposible, debido a que las cargas conectadas a la red cambian continuamente causando desbalance que a su vez también varía. Al momento de realizar la conexión de cargas residenciales; normalmente monofásica, provocan un estado de desequilibrio entre fases. Por el otro lado, un sistema simétrico es cuando los voltajes cuentan con una magnitud igual y sus fasores están a 120° entre sí (ECAMEC, 2009). Analizar sistemas desbalanceados pueden llevarse a cabo

por la representación de tres sistemas trifásicos como muestra la Figura 10, es decir, empleando dos ternas simétricas y una tercera terna de magnitud y fase iguales.




Figura 10. Ternas fasoriales, desbalanceadas (arriba) y simétricas (abajo) (ECAMEEC, 2009).

La medición de desbalance muestra la relación entre la tensión de la secuencia negativa respecto de la positiva, aunque esta relación se expresa de varias formas:

- Desbalance de secuencia negativa. IEC 61000-4-30 – IEEE P1159.1

$$u_N = \frac{|U^-|}{|U^+|} = \frac{\sqrt{1 - \sqrt{6 - 6\beta}}}{\sqrt{1 + \sqrt{6 - 6\beta}}} 100\%; \quad \beta = \frac{U_{AB}^4 + U_{BC}^4 + U_{CA}^4}{(U_{AB}^2 + U_{BC}^2 + U_{CA}^2)^2} \quad (13)$$

Para realizar la medición de desbalance únicamente deben considerarse las componentes de tensión de frecuencia fundamental y debido a que el desbalance provoca la aparición de componentes de secuencia negativa y homopolar, también se debe medir el desbalance homopolar.

$$u_0 = \frac{|U^0|}{|U^+|} 100\% \quad (14)$$

- IEC 61000-2-1 – IEC 61000-4-27 – NEMA – ANSI C84.1

El cociente entre la máxima diferencia entre las tensiones de fase y tensión promedio con la tensión promedio.

$$u_N = \frac{\Delta U_{MAX}}{\bar{U}}$$

$$\Delta U_{MAX} = \max (U_{AB} - \bar{U}, U_{BC} - \bar{U}, U_{CA} - \bar{U})$$

$$\bar{U} = \frac{U_{AB} + U_{BC} + U_{CA}}{3}$$
(15)

- IEC 61000-2-12

Utiliza la siguiente ecuación:

$$u_N = \sqrt{\frac{6(U_{AB}^2 + U_{BC}^2 + U_{CA}^2)}{U_{AB} + U_{BC} + U_{CA}} - 2}$$
(16)

- CFE L0000-45

El proveedor de la energía eléctrica (CFE) es esta especificación limita los valores del desbalance hasta en un 3% en la tensión y hasta un 20% en la corriente.

El desbalance se debe principalmente a la distribución no homogénea de las cargas de una fase del sistema trifásico. Además de que, el desbalance provoca la aparición de componentes de corriente de secuencia inversa y homopolar causando pérdidas de potencia y energía, calentamiento de máquinas, limitando la capacidad de carga nominal, propagación de desbalance, entre otros efectos adversos al sistema. Finalmente, si se considera la aparición o modificación del comportamiento de ciertas corrientes debido a los efectos de desbalance, es evidente que estas tendrán un impacto en el comportamiento del transformador.

2.5 Armónicos en sistemas eléctricos.

La presencia de elementos no lineales en los sistemas eléctricos genera formas de onda con diferentes frecuencias de la frecuencia de la red, a este fenómeno se le denomina armónico (Arcila, n.d.). Los armónicos generan problemas para los equipos conectados a la red, tanto a los usuarios como para el suministrador del servicio eléctrico. La forma de onda del voltaje debe tener amplitud y frecuencia constantes tal como se observa en la Figura 11a, la cual es una forma de onda que no contiene armónicos, tiene una frecuencia de 60 y amplitud constante.

Cuando el valor pico y/o el RMS muestran alteraciones se debe principalmente al contenido armónicos de la forma de onda con la que el equipo se alimenta, lo que causará alteraciones en el funcionamiento de este. Los armónicos tienen una frecuencia múltiplo entero de la frecuencia fundamental; la frecuencia de la forma de onda de la fuente de alimentación. En la Figura 11b se muestra una onda sinusoidal con contenido armónico; la cual contiene un 30% del 5^{to} armónico. Como se observa, la presencia del armónico aumenta el 30% del valor pico.




Figura 11. Formad de onda: (a) sin armónicos y (b) con armónicos.

Las cargas no lineales son la principal fuente de armónicos, presentando una respuesta no sinusoidal ante la entrada de una señal sinusoidal. Algunos elementos que presentan ese comportamiento no lineal y por consecuencia inyectan armónicos a la red son (Arcila, n.d.):

- Núcleos magnéticos en transformadores y máquinas rotativas.
- La corriente de magnetización de los transformadores.
- Elementos de descarga de arco.
- Controladores de velocidad.
- Conmutadores de estado sólido.
- Fuentes controladas de equipos electrónicos.
- Puentes rectificadores.
- Compensadores estáticos de potencia reactiva.
- Estaciones en DC de transmisión en alto voltaje.
- Convertidores de AC a DC.

Los efectos en los transformadores causados por los armónicos se reflejan en las pérdidas del transformador. En el núcleo las pérdidas son producidas debido al voltaje. Aunque el voltaje comúnmente es considerado sinusoidal e independientemente a la corriente porque en esta no se consideran aumentos significativos no sinusoidales. Sin embargo, la corriente de magnetización está contaminada de armónicos, pero suelen ser muy pequeños comparados con los de la corriente de carga. Sin embargo, debido a la contaminación armónica en la corriente de carga las pérdidas en el cobre definidas por i^2R aumentarán (Arcila, n.d.). También debido a estas existen las pérdidas por corrientes de Eddy, las cuales son proporcionales al cuadrado de la corriente y de la frecuencia, provocando la aparición de estas en los devanados. También, debido los armónicos aumentará la temperatura en diferentes partes estructurales del transformador e incluso en los devanados, lo que provocaría pérdida del recubrimiento aislante y en consecuencia cortos circuitos.

En cuanto a los sistemas trifásicos en condiciones nominales y balanceados, estos podrían presentar diferentes secuencias en sus fases debido a que los armónicos tienen una fase diferente de la fase fundamental. Para entender los efectos de estos es importante conocer la secuencia que

estos siguen, por ejemplo, el tercer armónico de la corriente únicamente logrará propagarse cuando pueda retornar por el neutro. Aunque normalmente existen diferencias en las fases de un sistema, las secuencias de los armónicos únicamente son válidas bajo un sistema balanceado (Arcila, n.d.).

Para cuantificar la contaminación armónica en las señales y estudiar los efectos que estos producen existen algunos indicadores normados para su comparación con los que se pudieran obtener. Algunos de los más utilizados son:

La distorsión armónica individual y la distorsión armónica total son comúnmente utilizados para medir la contaminación armónica en la corriente. La distorsión armónica individual D_i , es la relación entre corriente de cada armónico y la corriente nominal.

$$D_i = \frac{I_i}{I_n} 100\% \quad (17)$$

donde I_i : es la corriente de cada armónico. I_n : es la corriente de la fuente.

Por el otro lado, la distorsión armónica total THD_i , es la relación del contenido armónico de la señal y el armónico fundamental.

$$THD_i = \frac{1}{I_n} \sqrt{\sum_{i=2}^{\infty} I_i^2} 100\% \quad (18)$$

En ocasiones, con niveles bajos de carga se pueden encontrar valores de THD_i altos, los cuales podrían no afectar la operación de los equipos. Para evaluar de manera adecuada estas condiciones se define la distorsión de demanda total TDD , la cual es un indicador de los límites de distorsión en corriente aceptados en la norma IEEE519.

$$TDD = \frac{1}{I_d} \sqrt{\sum_{i=2}^{\infty} I_i^2} 100\% \quad (19)$$

donde I_d es la demanda máxima de la corriente fundamental de carga.

Debido a que los sistemas varían de uno a otro, es difícil predecir problemas relacionados a la contaminación armónica sin la necesidad de tomar mediciones. Sin embargo, algunos de los problemas causados por la contaminación armónica se podrían resolver con el simple hecho de reubicar los equipos o colocando filtros, pero es importante identificar la fuente de los armónicos y las distorsiones que producen, lo que podría lograrse con modelos o con una medición directa (Téllez, n.d.).

2.6 Características o indicadores de falla.

Para extraer información relacionada al comportamiento del sistema es necesario hacerlo midiendo algunas variables; en forma de señales. Cuando el sistema opera bajo distintas condiciones se verá reflejado en el comportamiento de esas señales. Sin embargo, encontrar la

información en una señal que describa el estado del sistema no es una tarea sencilla, mucho menos de señales de vibración debido al ruido o información proveniente de otras fuentes. Una manera de ver los distintos parámetros en una señal es por medio de algunos indicadores.

2.6.1 Indicadores estadísticos en el dominio del tiempo.

Los indicadores estadísticos son populares y sencillos de estimar, estos también son conocido como características estadísticas en el tiempo (STFs, del inglés *statistical time feature*). Estas STFs ayudan a la extracción de información de señales de vibración provenientes de transformadores con el objetivo de la detección de fallas por medio de parámetros que puedan reflejar correctamente la condición de operación de un sistema y, en consecuencia, identificar sus patrones de falla (Caesarendra & Tjahjowidodo, 2017). El uso de las características ha sido aplicado en el monitoreo de diferentes máquinas debido a su simplicidad, bajo costo computacional y principalmente, a su capacidad de estimar tendencias generales (Saucedo-Dorantes et al., 2018; Yanez-borjas et al., 2020).

En el análisis de señales de vibración, algunas STFs como la media, RMS, desviación estándar y varianza han sido investigadas para el estudio de las diferencias entre señales asociadas a una condición de falla (Caesarendra & Tjahjowidodo, 2017), mientras que, en señales que presentan comportamiento no estacionario se han utilizado STFs avanzadas como la oblicuidad y la curtosis, examinando la medida de la desviación de la distribución de una distribución normal (L. L. Zhang et al., 2017). A pesar de que han presentado buenos resultados, muchas otras características también han sido investigadas. Por lo tanto, en este trabajo, se utilizan otras STFs adicionales junto con las más representativas como: media, valor máximo, RMS, SMR, desviación estándar, varianza, factor de forma con RMS y SMR, cresta, factor de latitud e impulso, oblicuidad, factor de oblicuidad, curtosis, factor de curtosis, momentos normalizados quinto y sexto, entropía de Shannon y entropía de energía logarítmica. Estas han sido presentadas en distintos campos de investigación. En la Tabla 1 se presentan las ecuaciones matemáticas de las características ya mencionadas (Hasan & Kim, 2019; J. Liu, Xu, et al., 2019; Rostaminia et al., 2016; Saucedo-Dorantes et al., 2017; Sharma et al., 2016; X. Wang et al., 2015), donde x_i es la señal en tiempo para $i=1,2,\dots, N$, donde N es el número de muestras en la señal.

2.6.2 Indicador de contraste

Existen otro tipo de indicadores que podrían ser resultar útiles para llevar realizar un diagnóstico, por ejemplo, el contraste. El índice de contraste es una característica que mide las variaciones que presenta una imagen (Haralick et al., 1973). En una manera más sencilla, es la diferencia entre un punto blanco y uno negro. El valor del contraste puede ser máximo cuando un par de puntos tiene valores opuestos en la escala de grises, por ejemplo, 0 y 255, y puede ser mínimo cuando esos valores son similares. A pesar de que este índice es utilizado en imágenes,

Tabla 1. Características estadísticas en el dominio del tiempo.

| Característica o índice | Ecuación | Característica o índice | Ecuación |
|-------------------------|---------------------------------------------------------------------------------|---------------------------------------------|-----------------------------------------------------------------------------------|
| Media | $F_{mn} = \frac{1}{N} \sum_{i=1}^N \mathbf{x}_i$ (20) | Factor Impulso | $F_{if} = \frac{F_{\max}}{\frac{1}{N} \sum_{i=1}^N \mathbf{x}_i }$ (30) |
| Valor Máximo | $F_{\max} = \max(\mathbf{x})$ (21) | Oblicuidad (skewness) | $F_{skw} = \frac{\sum_{i=1}^N (\mathbf{x}_i - F_{mn})^3}{N \cdot F_{std}^3}$ (31) |
| RMS | $F_{rms} = \left(\frac{1}{N} \sum_{i=1}^N \mathbf{x}_i^2 \right)^{1/2}$ (22) | Factor Oblicuidad | $F_{skf} = \frac{F_{skw}}{F_{rms}^3}$ (32) |
| SRM | $F_{srm} = \left(\frac{1}{N} \sum_{i=1}^N \mathbf{x}_i ^{1/2} \right)^2$ (23) | Curtosis | $F_{kur} = \frac{\sum_{i=1}^N (\mathbf{x}_i - F_{mn})^4}{N \cdot F_{std}^4}$ (33) |
| Varianza | $F_{var} = \frac{1}{N} \sum_{i=1}^N (\mathbf{x}_i - F_{mn})^2$ (24) | Factor Curtosis | $F_{kcf} = \frac{F_{kur}}{F_{rms}^4}$ (34) |
| Desviación Estándar | $F_{std} = (F_{var})^{1/2}$ (25) | 5 ^{to} Momento Central Normalizado | $F_{5m} = \frac{\sum_{i=1}^N (\mathbf{x}_i - F_{mn})^5}{N \cdot F_{std}^5}$ (35) |
| Factor Forma para RMS | $F_{srms} = \frac{F_{rms}}{\frac{1}{N} \sum_{i=1}^N \mathbf{x}_i }$ (26) | 6 ^{to} Momento Central Normalizado | $F_{6m} = \frac{\sum_{i=1}^N (\mathbf{x}_i - F_{mn})^6}{N \cdot F_{std}^6}$ (36) |
| Factor Forma para SRM | $F_{ssrm} = \frac{F_{srm}}{\frac{1}{N} \sum_{i=1}^N \mathbf{x}_i }$ (27) | Entropía de Shannon | $F_{se} = - \sum_{i=1}^N \mathbf{x}_i^2 \log(\mathbf{x}_i^2)$ (37) |
| Factor Cresta | $F_{cf} = \frac{F_{\max}}{F_{rms}}$ (28) | Entropía de Energía Logarítmica | $F_{lee} = - \sum_{i=1}^N \log(\mathbf{x}_i^2)$ (38) |
| Factor Lalitud | $F_{lf} = \frac{F_{\max}}{F_{srm}}$ (29) | | |

también puede ser utilizado en señales. En este trabajo se presentan dos maneras de estimar el contraste, la de (Unser, 1986) y la de (Tamura et al., 1978).

Unser utiliza un histograma de diferencias para estimar el contraste, es decir, primero se calcula la variación (diferencia) entre dos puntos separados por d muestras de una señal $L(n)$ como se muestra en la ecuación (39), donde $n \in \{0, 1, \dots, N-1\}$.

$$D_{n,d} = L(n) - L(n+d) \quad (39)$$

Con estas deferencias se estima el histograma; como la ecuación (40), donde $j = -N_g + 1, -N_g + 2, \dots, N_g - 2, N_g - 1$ para al menos N_g niveles de gris. $card\{ \}$ se refiere a el número de elementos del conjunto.

$$h_d(j) = card\{n \in N, D_{n,d} = j\} \quad (40)$$

El histograma de diferencias normalizado es dado por (41).

$$P_D = \frac{h_d(j)}{T} \quad (41)$$

donde T es el número total de cuentas, y se calcula con la ecuación (42).

$$T = \sum_j h(j) \quad (42)$$

Finalmente, la ecuación (43) permite calcular el contraste.

$$C = \sum_j j^2 P_D(j) \quad (43)$$

Por el otro lado, Tamura et al. Proponen el contraste en función de:

1. Rango dinámico de niveles de gris;
2. Polarización de la distribución de negros y blancos en el histograma de niveles de grises o la razón entre las áreas blancas y negras.

Con respecto a esto, la curtosis provee el factor de polarización como:

$$\alpha_4 = \frac{\mu_4}{\sigma^4} \quad (44)$$

donde μ_4 es el cuarto momento alrededor de la media y σ^2 es la varianza que representa la distribución de los niveles de gris. Por lo que el contraste de Tamura se define como:

$$C = \frac{\sigma}{(\alpha_4)^n} \quad (45)$$

donde n es un número positivo, el cual es experimentalmente definido como $n = 1/4$.

Finalmente, utilizar un único indicador puede no ser suficiente para obtener la información necesaria del comportamiento del sistema, por lo que pueden usarse varios indicadores a la vez. Obtener toda la información posible del sistema con distintos indicadores como los STFs puede llegar a ser redundante al momento de llevar a cabo el diagnóstico. Con el propósito de obtener las características más relevantes, éstas deberán ser seleccionadas en un proceso posterior (Van & Kang, 2015), tal como se menciona en la siguiente subsección.

2.7 Reducción de características.

El desempeño de un sistema de identificación de fallas depende de las características de entrada. Un conjunto pequeño no asegura la completa descripción del sistema, esto puede llevar a una clasificación errónea. Mientras que, muchas características pueden incrementar la capacidad de discriminación tampoco se asegura que toda la información esté relacionada a la falla, es decir que, la información puede no ser útil o redundante. En suma, la construcción de modelos con un conjunto de datos muy grande es más demandante computacionalmente hablando (Korn et al., 2001). Por lo tanto, se deben aplicar algoritmos para obtener la mejor información y así evitar redundancia y reducir el conjunto de datos. La reducción de características se lleva a cabo a través del proceso de extracción y selección de características (Jović et al., 2015).

2.7.1 Selección de características

Lo que pretende la selección de características es maximizar la relevancia y minimizar la redundancia de la información, tomando un pequeño subconjunto de características del conjunto original (Sun et al., 2019). De manera general, puede considerarse como un filtrado de características. Algunos de los métodos que más se utilizan son basados en la información, distancia, consistencia, medidas estadísticas, entre otros (Saucedo-Dorantes et al., 2017). Una estrategia muy efectiva que se ha usado en diferentes aplicaciones obteniendo resultados satisfactorios junto con su facilidad de cálculo es el análisis del valor de Fisher (FS), el cual encuentra un subconjunto de características con la máxima distancia entre las clases mientras que la distancia entre los datos de la misma clase es lo más pequeña posible. El valor de FS^j de la característica j se calcula con (46) (Saucedo-Dorantes et al., 2018), donde μ_i^j , σ_i^j y n_i son la media, desviación estándar y tamaños de la clase i ésima clase c de la j ésima característica, respectivamente. μ^j es la media de todo el conjunto de datos de las j ésima característica. Después de calcular el FS, las características con los valores más altos son seleccionadas y extraídas en un nuevo subconjunto.

$$FS^j = \frac{\sum_{i=1}^c n_i (\mu_i^j - \mu^j)^2}{\sum_{i=1}^c n_i (\sigma_i^j)^2} \quad (46)$$

2.7.2 Extracción de características

La extracción de características busca transformar el conjunto original de características en uno nuevo, el cual se construye por la combinación del conjunto original (reducción de dimensión). Su propósito es descubrir la información más relevante y que se mantenga en el nuevo conjunto de características. Los métodos más utilizados son el análisis de componentes principales (PCA, del inglés *principal component analysis*) (Rostaminia et al., 2016; Van & Kang, 2015; Xue & Zhou, 2017) y el análisis de la discriminante lineal (LDA, del inglés *linear discriminant analysis*) (Mboo & Hameyer, 2016; Shahdoosti & Mirzapour, 2017; Wen et al., 2019; Xu, 2018). LDA es una técnica de extracción de características supervisada, la cual consiste en una combinación lineal

de las características donde se reduce el espacio de estas y se escalan de acuerdo con su importancia. De manera general, el objetivo de la LDA es encontrar una proyección de menor dimensión para maximizar la distancia entre las muestras de distintas clases y al mismo tiempo, minimizar la distancia entre muestras de la misma clase.

La proyección óptima del vector w para obtener clases bien separadas en un espacio de menor dimensión debe satisfacer el criterio de máxima separabilidad entre clases, el cual se da por el criterio de Fisher (Shahdoosti & Mirzapour, 2017) de la ecuación (47).

$$\mathbf{w} = \arg \max \left| \frac{\mathbf{w}^T \mathbf{S}_b \mathbf{w}}{\mathbf{w}^T \mathbf{S}_w \mathbf{w}} \right| \quad (47)$$

donde \mathbf{S}_b es la matriz de dispersión entre clases, la cual evalúa la separabilidad entre las diferentes clases, mientras que, \mathbf{S}_w es la matriz de dispersión de las muestras dentro de una clase, que evalúa cuan compactas son cada clase y la matriz de dispersión entre clases. Estas se definen con el conjunto de ecuaciones (48) (Mbooi & Hameyer, 2016).

$$\begin{aligned} \mathbf{S}_b &= \sum_{i=1}^c n_i (\boldsymbol{\mu}_i - \boldsymbol{\mu})(\boldsymbol{\mu}_i - \boldsymbol{\mu})^T \\ \mathbf{S}_w &= \sum_{i=1}^c \sum_{j=1}^{n_i} (x_j^i - \boldsymbol{\mu}_i)(x_j^i - \boldsymbol{\mu}_i)^T \end{aligned} \quad (48)$$

donde n_i es el número de muestras en la *jesima* clase c , $\boldsymbol{\mu}_i = \frac{1}{n_i} \sum_{j=1}^{n_i} x_j^i$ es la media de las muestras de una característica *iesima* clase c , and $\boldsymbol{\mu} = \frac{1}{n} \sum_{i=1}^c \sum_{j=1}^{n_i} x_j^i$ es la media de todas las muestras.

Resolviendo la ecuación (47), la proyección óptima del vector w es el eigenvector correspondiente al máximo eigenvalor λ de (49) (Wen et al., 2019).

$$\mathbf{S}_w \mathbf{w} = \lambda \mathbf{S}_b \mathbf{w} \quad (49)$$

Para clasificación multiclases, la matriz de proyección \mathbf{W} se construye como un conjunto de eigenvectores que corresponden a los valores k de los eigenvalores más grandes $\{\lambda_i | i = 1, 2, \dots, k\}$. Finalmente, la característica extraída \mathbf{Y} del nuevo espacio de menor dimensión por la proyección del conjunto original de datos \mathbf{x} se obtiene como se muestra en (50) (Saucedo-Dorantes et al., 2018).

$$\mathbf{Y} = \mathbf{W}^T \mathbf{x} \quad (50)$$

El nuevo conjunto de características contiene la mejor información y a su vez mejora la precisión del método de clasificación (X. Wang et al., 2015).

2.8 Técnicas avanzadas de procesamiento de señales.

2.8.1 Descomposición de modos no lineales.

Sistemas complejos como lo es un transformador generan señales compuestas de modos de diferentes oscilaciones, incluyendo el inevitable ruido de fondo (Iatsenko et al., 2015a); para un análisis correcto de esas señales, esos modos deben ser correctamente separados de entre ellos. El método del NMD es presentado como una herramienta adaptativa de descomposición de señales no lineales y no estacionarias, el cual descompone una señal en un conjunto de modos con modos físicamente significativos, y al mismo tiempo, remueve el ruido. Este método sigue los siguientes pasos (Iatsenko et al., 2013, 2015a, 2015b, 2016):

(I) *Preprocesamiento.* Para obtener una representación tiempo-frecuencia (TFR, del inglés *Time Frequency-Representation*), debe llevarse a cabo un preprocesamiento a la señal de entrada. Un paso esencial es eliminar las tendencias usando un polinomio de tercer orden por medio de un filtro pasa banda extraer la banda frecuencial de interés.

(II) *Representación tiempo-frecuencia.* Una TFR permite estudiar simultáneamente las propiedades de la señal; amplitud, frecuencia y fase, tanto en el dominio del tiempo como en el de la frecuencia. El NMD usa la STFT, es decir la transformada corta de Fourier de una señal de entrada. La STFT es típicamente construida como en la ecuación (51).

$$G(\omega, t) = \int s^+(u)g(u-t)e^{-i\omega(u-t)} du = e^{-i\omega t} \frac{1}{2\pi} \int_0^\infty e^{-i\xi t} \hat{s}(\xi) \hat{g}(\omega - \xi) d\xi \quad (51)$$

donde $G(\omega, t)$ es la TFR, ω es la frecuencia, t el tiempo, $s^+(u)$ representa el uso de las frecuencias positivas, $g(u)$ es una función de ventana (la parte positiva) y $\hat{g}(\xi)$ es su FT o transformada de Fourier. La ventana utilizada es una Gaussiana que se representa como:

$$g(u) = \frac{B_{f_0}}{f_0 \sqrt{2\pi}} e^{-u^2/2f_0} \Leftrightarrow \hat{g}(\xi) = B_{f_0} e^{-f_0^2 \xi^2/2} \quad (52)$$

donde f_0 es el parámetro de resolución que controla la extensión de la ventana Gaussiana en tiempo y frecuencia, es decir, controla la resolución del tiempo y de la frecuencia que son inversamente proporcionales entre ellas, y B_{f_0} es un factor de normalización. La selección de los parámetros de la ventana es discutida en (Iatsenko et al., 2016).

(III) *Extracción y reconstrucción de componentes.* El siguiente paso se lleva a cabo para obtener los componentes de mayor energía, es decir, el componente fundamental de la TFR. Para extraer los componentes de una TFR es necesario encontrar su curva de crestas como:

$$s[\omega_p(t)] = \sum_{n=1}^N \left[\log |G_s(\omega_p(t_n), t_n)| - \frac{1}{2} \left(\frac{|\Delta\omega_p(t_n) - \langle \Delta\omega_p \rangle|}{std[\Delta\omega_p]} \right)^2 - \frac{1}{2} \left(\frac{\omega_p(t_n) - \langle \omega_p \rangle}{std[\omega_p]} \right)^2 \right] \quad (53)$$

donde $\omega_p(t)$ es un punto de la cresta, el cual es una secuencia exclusiva picos de amplitud de la TFR, $\Delta\omega_p$ es igual a $\omega_p(t_n) - \omega_p(t_{n-1})$, $\langle f(t) \rangle$ es la media de $f(t)$ y $std[f(t)]$ su desviación estándar. De la curva de crestas se pueden reconstruir la amplitud instantánea $A(t)$, fase $\phi(t)$ y la frecuencia $\nu(t)$. Esto se puede hacer por dos métodos: el método de crestas o el método directo, la primera se da como:

$$\nu(t) = \omega_p(t) + \delta\nu(t), \quad A(t)e^{i\phi(t)} = \frac{2G_s(\omega_p(t), t)}{\hat{g}(\omega_p(t) - \nu(t))} \quad (54)$$

donde $\delta\nu(t)$ es una corrección para mitigar efectos de la discretización y se hace por medio de una interpolación cuadrática. Por otro lado, el método directo utiliza una región de la TFR llamado soporte tiempo-frecuencia $[\omega_-(t), \omega_+(t)]$. Los parámetros se pueden reconstruir como:

$$A(t)e^{i\phi(t)} = C_g^{-1} \int_{\omega_-(t)}^{\omega_+(t)} G_s(\omega, t) d\omega, \quad C_g \equiv \frac{1}{2} \int_{-\infty}^{\infty} \hat{g}(\xi) d\xi = \pi g(0)$$

$$\nu(t) = \text{Re} \left[\frac{\int_{\omega_-(t)}^{\omega_+(t)} \omega G_s(\omega, t) d\omega}{\int_{\omega_-(t)}^{\omega_+(t)} G_s(\omega, t) d\omega} \right] \quad (55)$$

La elección entre los dos métodos depende de la cantidad de ruido y las variaciones de la amplitud/frecuencia del componente a extraer. El criterio que utilizado para una selección adaptativa se muestra en (Iatsenko et al., 2016).

Prueba de los parámetros contra ruido. Después de extraer cada NM, los parámetros extraídos deben pasar una prueba de ruido para decidir si la descomposición continua o no, es decir, si la señal residual está compuesta por ruido la descomposición termina. Para realizar esto, la prueba de sustitutos es usada. Esta prueba toma la transformada inversa de Fourier (IFT, del inglés *Inverse Fourier Transform*) de la FT resultante de la señal en prueba, pero con fases aleatoria. El estadístico discriminante, D, para la prueba de sustitutos se calculan una combinación de entropías espectrales, Q, los valores para la amplitud y frecuencia se obtienen como sigue:

$$D(\alpha_A, \alpha_f) = \alpha_A Q[\hat{A}(\omega)] + \alpha_f Q[\hat{f}(\omega)] \quad (56)$$

donde $Q|f(x)|$ es la entropía espectral y se define como sigue:

$$Q[f(x)] = - \int \frac{|f(x)|^2}{\int |f(x)|^2 dx} \ln \frac{|f(x)|^2}{\int |f(x)|^2 dx} dx \quad (57)$$

En (Valles-Novo, et al., 2015), es recomendado llevar a cabo tres pruebas y seleccionar el máximo valor. Estas pruebas usan $D(1,0)$, $D(0,1)$, and $D(1,1)$. Si la hipótesis nula es rechazada por alguna de las pruebas, el componente no es ruido y la descomposición ha de continuar.

(IV) *Extracción de armónicos*. El componente extraído e identificado como genuino representará un armónico de algún NM. Asumiendo que el armónico extraído es el de la

componente fundamental con frecuencia instantánea $v^{(1)}(t)$, entonces los armónicos $h = 2, 3, \dots, N$ y sus frecuencias instantáneas $hv^{(1)}(t)$ también se pueden obtener; por lo tanto, la curva de crestas $\omega_p^h(t)$ del armónico h puede ser extraída. N se establece de acuerdo con el teorema de Nyquist. Sin embargo, si la suposición es incorrecta, es necesario encontrar la componente fundamental aplicando el mismo procedimiento, pero en dirección opuesta, es decir, $h = 1/2, 1/3, \dots$ y así identificar un componente armónico como genuino como se hace en (Iatsenko et al., 2015a). Los siguientes parámetros se usan para cuantificar el grado de consistencia entre dos armónicos, es decir, el primero y el último de los armónicos extraídos, usando su amplitud, fase y frecuencia.

$$\begin{aligned}
 q_A^h &\equiv \exp \left[-\frac{\sqrt{\langle [A^h(t)\langle A^1(t) \rangle - A^1(t)\langle A^h(t) \rangle]^2 \rangle}}{\langle A^1(t)A^h(t) \rangle} \right] \\
 q_\phi^h &\equiv \left| \exp [i(\phi^h(t) - h\phi^1(t))] \right| \\
 q_v^h &\equiv \exp \left[-\frac{\sqrt{\langle [v^h(t) - hv^1(t)]^2 \rangle}}{\langle v^h(t) \rangle} \right]
 \end{aligned} \tag{58}$$

Una medida general de interdependencia entre los armónicos se construye por:

$$\rho^h(w_A, w_\phi, w_v) = (q_A^h)^{w_A} (q_\phi^h)^{w_\phi} (q_v^h)^{w_v} \tag{59}$$

donde $w_{A,\phi,v}$ representa los pesos de cada valor de consistencia $q_{A,\phi,v}^h$. El valor de $\rho^h(1,1,0)$ puede ser usado por defecto (Iatsenko et al., 2015a).

(V) *Reconstrucción del NM*. Después de haber extraído todos los armónicos genuinos, el NM puede ser construido. Además, se espera que los componentes con las mayores amplitudes tengan menos ruido; sin embargo, los parámetros de los armónicos de cada componente son refinados a través de un promedio ponderado sobre todos los parámetros de los armónicos como muestra la ecuación (60), donde $\Delta\phi_{h,h} = \arg \left(\exp \left\{ j \left[h\phi^{(h)}(t) - h'\phi^{(h)}(t) \right] \right\} \right)$.

(VI) *substraer el NM de la señal*. El NM encontrado y construido debe ser extraído de la señal de entrada antes de repetir el proceso de extraer el siguiente NM de la señal residual. Para más información acerca del NMD puede consultar (Iatsenko et al., 2013, 2015a, 2015b, 2016).

$$\begin{aligned}
\tilde{A}^{(h)}(t) &= \langle A^{(h)}(t) \rangle \frac{\sum h' A^{(h')}(t)}{\sum h' \langle A^{(h')}(t) \rangle} \\
\tilde{\phi}^{(h)}(t) &= \arg \left(\sum_{h'} \min \left(1, \frac{h'}{h} \right) \langle A^{(h')}(t) \rangle \exp \left[j \frac{h\phi^{(h')}(t) - \Delta\phi_{h',h}}{h'} \right] \right) \\
&\quad \times \exp \left\{ -j \frac{2\pi}{h'} \text{round} \left[\frac{h\phi^{(h')}(t) - h'\phi^{(h)} - \Delta\phi_{h',h}}{2\pi} \right] \right\} \\
\tilde{\nu}^{(h)}(t) &= \frac{\sum h' \min \left(1, \frac{h'}{h} \right) A^{(h')}(t) h\nu^{(h')} / h'}{\sum h' \min \left(1, \frac{h'}{h} \right) \langle A^{(h')}(t) \rangle}
\end{aligned} \tag{60}$$

2.8.2 Transformada Hilbert

Para métodos de descomposición, es necesario realizar más procesamiento y en varios casos extraer y cuantificar diferentes características o patrones. La transformada Hilbert (HT, del inglés *Hilbert Transform*) es una operación lineal empleada para calcular la amplitud, fase y frecuencia instantáneas de una señal en el tiempo. En general, HT convierte una señal de entrada $x(t)$ a una señal $y(t)$ aplicando una convolución entre la señal $x(t)$ y la respuesta al impulso $h(t) = 1/\pi t$ que se define como en (X. Wang et al., 2019).

$$y(t) = H[x(t)] = \frac{1}{\pi} P \int \frac{x(t')}{t-t'} dt' \tag{61}$$

donde P es el valor principal de Cauchy. De esta manera, $x(t)$ y $y(t)$ forman un par complejo conjugado, también llamado como señal analítica (Urbina-Salas et al., 2017) dada por:

$$z(t) = x(t) + jy(t) = A(t)e^{i\phi(t)} \tag{62}$$

donde $A(t) = [x^2(t) + y^2(t)]^{1/2}$ es la amplitud, $\phi(t) = \arctan[y(t)/x(t)]$ es la fase y $\nu(t) = d\phi(t)/dt$ es la frecuencia. De la amplitud o de la envolvente de la señal el valor de RMS puede ser calculado usando (63).

$$RMS(t) = A(t) / \sqrt{2} \tag{63}$$

2.8.3 Filtro de promedio móvil

Cuando una señal presenta variaciones sobre el tiempo, un filtro de promedio móvil (MAF, del inglés *moving average filter*) puede ser usado para suavizar o eliminar esas variaciones en tiempo. Este tipo de filtro se implementa como un filtro de respuesta finita (FIR, del inglés *finite impulse filter*) usando (64) (Golestan et al., 2014). La longitud de la ventana tiene N muestras y define el orden del filtro, mientras que x es la señal de entrada. En el filtro se consideran tanto la muestra presente n como la muestra previa k .

$$y(n) = \frac{1}{N} \sum_{k=1}^N x(n-k) \quad (64)$$

2.9 Algoritmos de aprendizaje de automático.

Tratando de imitar la capacidad del cerebro humano para resolver problemas; pensando y recordando, los científicos han desarrollado algoritmos que permiten el aprendizaje automático como alternativas. Estos algoritmos pretenden desarrollar máquinas que presenten un comportamiento inteligente, para resolver problemas complejos y que aprendan en el transcurso. En general, algunos de las capacidades otorgadas a estos algoritmos son el reconocimiento de patrones, la toma de decisiones, el aprendizaje, entre otros. Algunos de estos algoritmos son: las redes neuronales artificiales, las máquinas de soporte vectorial, la lógica difusa, entre otras.

2.9.1 Redes neuronales artificiales.

Las redes neuronales artificiales (ANNs, del inglés *artificial neural network*) son estructuras computacionales diseñadas para emular la estructura neurológica de un cerebro humano, esta está construida por elementos de un comportamiento similar a una neurona biológica también llamada neurona, la cual tiene la capacidad de aprender y resolver problemas (Amezquita-Sanchez et al., 2016).

La capacidad de cálculo de una ANN es posible por las múltiples conexiones entre las neuronas que la constituyen. Una de las más simples configuraciones de una red neuronal es un conjunto de neuronas ordenadas en una única capa. Sin embargo, estas configuraciones pueden cambiar, donde existen varias capas con diferente número de neuronas. Dichas configuraciones en varias capas o que comúnmente son llamadas multicapa, suelen obtener mejores resultados que las más simples. Una de las arquitecturas más empleadas es la red neuronal multicapa debido a su baja carga computacional y su simplicidad para ser usada como un clasificador. La Figura 12a muestra la arquitectura de la ANN. Esta arquitectura incluye una capa de entrada, capas ocultas y una capa de salida. La información se mueve de la capa de entrada a la de salida. En cada capa puede haber una o varias neuronas. En la ecuación (65) se describe la función matemática de una neurona y en la Figura 12b se muestra su estructura. Una neurona consiste en una unidad de proceso, en la cual se realiza una sumatoria de productos entre la entrada x_i y los pesos w_i ; los cuales emulan el proceso sináptico o la conexión entre las neuronas, y un valor de desviación b . El resultado se evalúa por una función de activación $f(\cdot)$, la cual es una función no lineal que tiene la capacidad de modelar relaciones no lineales.

$$O_1 = f \left(\sum_{i=1}^l w_i x_i + b \right) \quad (65)$$

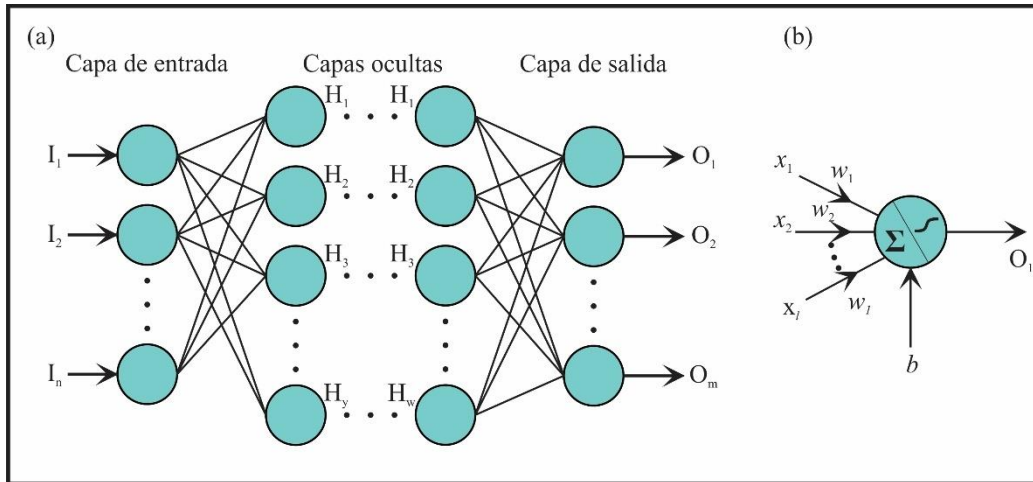


Figura 12. Arquitectura de una ANN. (a) ANN multicapa con capas de entrada, ocultas y de salida; y (b) Una neurona.

Las funciones de activación más utilizadas son la Sigmoide y tangente hiperbólica que se muestran en la Tabla 2.

Tabla 2. Funciones de activación.

| Función | Ecuación |
|----------------------|-------------------------------------------------------|
| Sigmoide | $Y(x) = \frac{1}{1 + e^{-x}}$ |
| Tangente Hiperbólica | $Y(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$ |

Teniendo la estructura definida, el siguiente paso es el que la ANN aprenda, para esto se debe entrenar. El objetivo de entrenar una ANN es para que, en alguna aplicación específica, con ciertos valores de entrada se produzca un conjunto de salidas deseadas. Para que se produzcan los valores de salida deseados, los pesos de las interconexiones se ajustarán para que gradualmente converjan a los valores de salida.

El entrenamiento supervisado es un proceso que se realiza mediante un entrenamiento controlado externamente, es decir que, por cada dato de entrada a la red, también debe haber un dato de salida que enseña o indica a la red que clase de dato es. Para realizar esto, las parejas de datos se aplican secuencialmente para poder comparar la salida producida con la salida deseada, es decir que, se estima el error entre las salidas y con este error se ajustan los pesos de la red hasta que sea aceptable. Por el otro lado, en el entrenamiento no supervisado sucede lo contrario que en el supervisado, es decir, no cuenta con un agente externo que le enseñe como deben ser las salidas deseadas. Debido a que sólo tendrá datos de entrada, el algoritmo modifica los pesos extrayendo propiedades de los datos y agrupándolos en clases.

De manera general los pasos para desarrollar una ANN son:

1. Obtener un conjunto de datos, una parte se destina para entrenamiento y otra para la validación.
2. Diseñar una red (arquitectura).
3. Entrenar la red con los datos de entrenamiento.
4. Validar que la red aprendió probando con los datos de validación.
5. Usar la red con datos nuevos.

Es importante verificar que la red no sé sobre entreno, es decir que, produce buenos resultados con los datos de entrenamiento, pero son malos con los datos de validación. para evitar el sobre entrenamiento se deben usar grandes conjuntos de datos si la red es grande de lo contrario, utilizar conjuntos de datos no muy grandes.

2.9.2 Lógica Difusa.

Entre los diferentes algoritmos de clasificación, los sistemas de lógica difusa (FL, del inglés *fuzzy logic*) pueden ser diseñados aun cuando algunas de las características de los datos de entrada no son conocidas. Esto se logra generalizando la lógica clásica con estados intermedios, es decir que, utiliza expresiones que no son ni completamente ciertas ni completamente falsas para llegar a soluciones que con la lógica clásica no se alcanzan (Kuncheva, 2000).

En general, para la implementación de un sistema FL se requieren cuatro pasos (Kuncheva, 2000; Valtierra-Rodriguez et al., 2016): (i) Fusificación de las variables de entrada, (ii) evaluar reglas, (iii) agregar salidas a las reglas y (iv) defusificación. La fusificación convierte los datos de entrada x en variables difusas, asignando valores a partir de un conjunto funciones de membresía. Una vez que los datos de entrada han sido fusificados se evalúan las reglas lingüísticas para obtener una salida. El proceso de agregar una laida consisten en combinar las funciones de pertenencia para obtener un único valor difuso. Posteriormente, ese único valor difuso debe ser defusificado para obtener un valor discreto, con el cual se será parte de un conjunto determinado con cierto grado de pertenencia con valores desde el 0 hasta 1, donde 0 representa un hecho totalmente falso, el 1 representa un hecho totalmente cierto y los valores intermedios serán parcialmente ciertos o falsos.

Los valores de cada función se etiquetan por la $\mu(x)$ y por los valores de x se obtiene la gráfica. Las diferentes funciones de membrecía pueden ser de forma Gaussiana, triangular, trapezoidal, entre otras. La elección de la función depende de la experiencia del diseñador o a base de prueba y error. Para cada entrada x se tienen valores que indican el grado de pertenencia, estos van al de justificador para obtener un valor de salida. Uno de los métodos más empleados ese del centro de gravedad que se muestra en la ecuación (66).

$$u = \frac{\sum_{i=1}^n u_i \mu_i}{\sum_{i=1}^n u_i} \quad (66)$$

donde μ_i son los valores de las funciones de membresía década i clase, mientras que u_i son los valores centrales de cada clase.

2.9.3 Máquinas de soporte vectorial.

La aplicación de las SVMs para el diagnóstico de fallas ha atraído la atención de los investigadores a nivel mundial debido a su excelente desempeño en solución de problemas con pequeños grupos de muestras, alta dimensión y problemas no lineales. La SVM puede resolver problemas de clasificación lineal fácilmente y también cuando no lo son. Una SVM logra convertir un problema no lineal y de clasificación inseparable a un problema no lineal y de clasificación separable (Kari et al., 2018). Una SVM es un clasificador lineal cuyo objetivo es encontrar un hiperplano óptimo entre dos clases diferentes para obtener una función de decisión que permita clasificar cada muestra en una clase específica. Normalmente dicha función $g(x)$ se construye como se muestra en (67) (Jan et al., 2017; Y. Zhang et al., 2017).

$$g(x) = \boldsymbol{\omega}^T \mathbf{x} + \omega_0 = 0 \quad (67)$$

donde $\boldsymbol{\omega}$ es el vector de pesos, \mathbf{x} es el vector de entrada y ω_0 es un valor de desviación. La meta es buscar una dirección en la que se consiga el máximo margen posible entre los vectores de soporte y el hiperplano. Las ecuaciones de los vectores de soporte de cada clase son dadas por (68).

$$\begin{aligned} \boldsymbol{\omega}^T \mathbf{x} + \omega_0 &\geq 1, \quad \forall \mathbf{x} \in \omega_1 \\ \boldsymbol{\omega}^T \mathbf{x} + \omega_0 &\leq -1, \quad \forall \mathbf{x} \in \omega_2 \end{aligned} \quad (68)$$

donde ω_1 y ω_2 corresponden a cada clase. Es por esto por lo que, encontrar el hiperplano óptimo (entrenar), se debe resolver el problema cuadrático de minimización que se presente en (69).

$$J(\boldsymbol{\omega}) = \frac{1}{2} \|\boldsymbol{\omega}\|^2 \quad (69)$$

sujeto a

$$y_i \left(\boldsymbol{\omega}^T \mathbf{x}_i + \omega_0 \right) \geq 1 \quad (70)$$

entonces, la función final de decisión se puede obtener como

$$\boldsymbol{\omega} = \sum_{i=1}^N y_i \alpha_i \mathbf{x}_i \quad (71)$$

donde α_i son los multiplicadores de Lagrange, $y_i = \pm 1$ el cual es el indicador de clase para cada dato de entrenamiento \mathbf{x}_i , los cuales también son conocidos como vectores de soporte. En

contraste, el hiperplano óptimo del clasificador es conocido como máquina de soporte vectorial. Cuando aparecen patrones no lineales y no separables, el resultado del clasificador lineal es:

$$g(\mathbf{x}) = \sum_{i=1}^N y_i \alpha_i K(\mathbf{x}_i, \mathbf{x}) + \omega_0 \quad (72)$$

donde \mathbf{x}_i se asigna a ω_1 si $g(\mathbf{x}) > 1$ o, por el contrario, se asigna a ω_2 si $g(\mathbf{x}) < 0$, y $K(\mathbf{x}_i, \mathbf{x})$ es una función *kernel*. La función *kernel* más ampliamente utilizada es la función de base radial (RBF, del inglés *radial basis function*) (J. Liu, Zhao, et al., 2019; Y. Zhang et al., 2017), por lo que se utiliza en este estudio y se define como en (73).

$$K(\mathbf{x}_i, \mathbf{x}) = \exp\left(-\frac{\|\mathbf{x} - \mathbf{x}_i\|^2}{\sigma^2}\right) \quad (73)$$

El parámetro σ es conocido como como la escala del *kernel*. Para controlar la capacidad de generalización de la SVM, se define un parámetro de error en la clasificación C . Este parámetro controla el equilibrio entre el margen y el tamaño de las variables de holgura. La adecuada selección de los parámetros C y σ tienen una gran influencia en la precisión de la clasificación, ambos parámetros suelen ser elegido por el usuario (Bigdeli et al., 2012). En la Figura 13, se muestra la arquitectura de una SVM.




Figura 13. Arquitectura de la SVM.

La SVM se emplea comúnmente para clasificación binaria, es decir, para la clasificación de dos clases, pero también, puede ser usada para la clasificación de múltiples clases. Para esta última tarea, se opta por clasificadores múltiples de uno contra otros. Existen dos maneras de llevar a cabo esta clase de clasificadores. La primera forma es colocar cada clasificador en serie, mientras que en el segundo, cada clasificador es colocado en paralelo. En este trabajo se emplea la estrategia de uno contra todos colocados de forma paralela, esto para que la muestra de entrada sea evaluada en cada clasificador al mismo tiempo ayudando a ahorrar tiempo y explotando al máximo las propiedades y capacidad de la FPGA donde serán implementados. El esquema para esta arquitectura se muestra en la Figura 14 (C. Liu et al., 2014).

Cada clasificador de la Figura 14 es diseñado por separado, clasifica una clase contra las demás. Como ya se mencionó, se espera que todos los puntos de la clase ω_i del clasificador SVM_i

produzca $g(\mathbf{x}) > 0$, mientras que para el resto de las clases un valor negativo. Entonces, los datos \mathbf{x} se clasifican en ω_i si se cumple la ecuación (74).

$$\omega_i^T \mathbf{x} + \omega_{i0} > \omega_j^T \mathbf{x} + \omega_{j0}, \forall i \neq j \quad (74)$$

Para evaluar el desempeño de la SVM, se utiliza una validación cruzada k -fold. Las muestras del experimento se dividen en k grupos. El i ésimo grupo se deja fuera y la SVM se entrena con los $k-1$ grupos restantes. El grupo que fue separado se utiliza para realizar el proceso de validación y así medir el error de clasificación. El proceso se repite k veces con los datos para validación $(i-1)$ donde $i=1, \dots, k$. Finalmente, el error de cada validación k es promediado (Hostetter et al., 2019). En este trabajo, se usa la validación cruzada de 5-fold porque nos permite entrenar el clasificador con un gran número de muestras por clase; alrededor del 80% de los datos, de esta manera se mantiene la estimación de error y su varianza bajas (Tarimoradi et al., 2017).

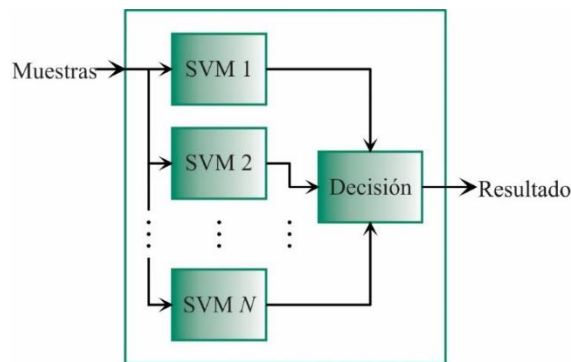


Figura 14. Esquema de las SVMs en paralelo.

2.10 Modelado de Sistemas

Con el propósito de obtener una respuesta que cumpla con las especificaciones de diseño del sistema, el modelado permitirá realizar y validar por medio de la simulación probar y ajustar diferentes parámetros del equipo. Un sistema está compuesto de diferentes dispositivos o subsistemas interconectados en los que interactúan variables que producen diferentes señales que pueden ser monitoreadas (Oppenheim, Willsky, & Nawab, 1998). Las señales que resulten de interés para el observador son conocidas como salidas del sistema, mientras que las señales que se pueden manipular son las señales de entrada. Finalmente, las señales que influyen en el comportamiento del sistema, pero no pueden manipularse se conocen como perturbaciones (Figura 15).




Figura 15. Diagrama de bloque de un sistema (López, 2008).

Cuando se necesita obtener información del comportamiento de un sistema en determinada condición y con determinadas entradas, se podría obtener por medio de la experimentación. Sin embargo, la experimentación podría ser bastante compleja, por lo que utilizar un modelo podría resultar más sencillo, debido a que el modelo permite trabajar con una representación muy aproximada a la realidad del comportamiento del sistema. De manera muy general, un modelo permite reproducir y/o predecir el comportamiento de un sistema sin la necesidad de experimentar con él. Los modelos pueden ser clasificados de acuerdo con el formalismo matemático que presentan. Algunos tipos de modelos son (López, 2008):

- a) *Modelos mentales*: estos carecen de formalismo matemático.
- b) *Modelos no paramétricos*: en estos modelos los sistemas son caracterizados por medio de gráficos o tablas con una cantidad de parámetros finita.
- c) *Modelos paramétricos (matemáticos)*: por medio de expresiones matemáticas estos modelos describen la relación entre las variables del sistema. Estos pueden ser: determinísticos o estocásticos, dinámicos o estáticos, y continuos o discretos.

2.10.1 Métodos de obtención de modelos.

Para la obtención de un modelo existen dos métodos principales (López, 2008): el modelado teórico y la identificación del sistema. El modelado teórico es analítico, utiliza las leyes físicas básicas para la descripción del comportamiento del sistema. Mientras que, la identificación del sistema obtiene el modelo a partir de datos reales capturados del sistema.

El modelado teórico tiene un campo de aplicación limitado a procesos sencillos en los que no sea necesaria una gran exactitud. Mientras que, los modelos que se obtienen con técnicas de identificación tienen un rango de validez limitado, ya que es aplicable bajo ciertas condiciones y entradas. Dar un significado físico del modelo construido no suele ser una tarea sencilla debido a que algunos parámetros no presentan una relación directa con alguna magnitud física. Para obtener un modelo final lo ideal es aplicar una mezcla de ambos métodos de modelado (López, 2008).

2.10.2 identificación de sistemas.

La identificación del sistema comprende la obtención de un modelo capaz de reproducir las características del sistema con gran exactitud de una manera experimental. Para la identificación del sistema se aplican los siguientes pasos (López, 2008):

1. Obtener los datos de entrada y salida del sistema. Por medio de la aplicación de una señal de entrada conocida ir registrando la evolución de las salidas durante algún intervalo de tiempo conocido.
2. Tratar previamente de los datos adquiridos.
3. Elegir la estructura del modelo.
4. Obtener los parámetros del modelo.
5. Validar el modelo.

En caso de que el modelo construido no sea aceptable, este se debe revisar considerando los siguientes aspectos:

1. Los datos adquiridos de entrada y salida no proporcionan la información adecuada sobre el comportamiento del sistema.
2. La estructura seleccionada no logra proporcionar una buena descripción del sistema.
3. El ajuste de los parámetros no resulta adecuado.
4. Repetir el proceso de identificación desde el punto correspondiente.

Existen diversos métodos de identificación, estos se clasifican por distintos criterios (López, 2008):

1. Según el tipo de modelo que se obtuvo.
2. Según la aplicación.
3. Según el criterio para el ajuste de los parámetros.

Dentro de los que dependen del tipo de modelo se encuentran los métodos paramétricos y no paramétricos. En los métodos paramétricos se necesitan elegir una estructura para el modelo, un criterio para el ajuste de los parámetros, además la estimación de los parámetros que mejor se ajustan al modelo y a los datos experimentales. Por otro lado, los métodos que dependen de la aplicación se dividen en métodos *off-line* y *on-line*. Los métodos *off-line* se utilizan cuando no es necesario ajustar continuamente el modelo. Mientras que los modelos *on-line* ajustan los parámetros del modelo de manera continua. Finalmente, los modelos que dependen del criterio de ajuste emplean métodos matemáticos realizar dicho ajuste de los parámetros.

Modelos no paramétricos

Los métodos de identificación no paramétricos permiten obtener modelos de los sistemas analizados. Estos pueden realizarse en los diferentes dominios; del tiempo, de la frecuencia y del tiempo-frecuencia.

Identificación en el dominio del tiempo. Con esta técnica debe registrarse la evolución de la salida del sistema en el tiempo cuando a este se le aplica una señal impulso o escalón. Aunque en la práctica es muy difícil obtener este tipo de respuestas una solución es el empleo de métodos indirectos para obtener la respuesta al impulso, una técnica bastante conocida es el análisis de correlación, el cual resulta apropiado para obtener una relación entre las distintas señales del sistema, ganancias, retardos, entre otros parámetros.

Identificación en el dominio de la frecuencia. La principal herramienta para llevar a cabo este análisis es la transformada de Fourier. Una de las principales ventajas es que con esta técnica no es necesario tener algún conocimiento previo del sistema; siempre y cuando sea lineal. El procesamiento de los datos no suele ser complejo y permite concentrar los datos en torno de las frecuencias de interés.

Para construir un modelo con información que se obtuvo del dominio de la frecuencia y reproducir señales de vibración de un transformador bajo distintas condiciones de alimentación son necesarios tres parámetros; los cuales son los más importantes de una señal, amplitud, frecuencia y fase. Las frecuencias que se generan en las vibraciones son conocidas, ya que son del doble de la frecuencia de la frecuencia fundamental de la alimentación, además de que el ancho de banda también es conocido: 1000 Hz. Es por esto por lo que únicamente se deben extraer la amplitud y fase de los armónicos dentro del ancho de banda de la transformada de Fourier de la señal de vibración. Además, para la reproducción de dichos valores para alguna entrada específica puede usarse una ANN (Mejia-Barron, 2021); que en la mayoría de ocasiones se utiliza para el reconocimiento de patrones, también puede ser utilizada para generar la información (amplitudes y fases) y comportarse como un modelo no paramétrico en el que para entradas específicas se busca obtener salidas específicas, e incluso podría ser capaz de predecir valores de salida que no se le presentaron para entradas específicas en el entrenamiento.

Identificación en el dominio del tiempo y de la frecuencia. Resulta más útil estudiar simultáneamente las propiedades que se obtienen tanto en el dominio del tiempo como en el de la frecuencia. Esto se logra realizar considerando proyecciones de la señal sobre el plano bidimensional tiempo-frecuencia; construyendo así las representaciones tiempo-frecuencia o TFR (del inglés *Time-Frequency Representation*) (Jiang & Adeli, 2007). Las TFRs combinan el análisis en el dominio del tiempo y dominio de la frecuencia para producir una imagen relevante de la localización temporal de los componentes espectrales de la señal.

El análisis tiempo-frecuencia es muy utilizado en señales que contienen muchos componentes oscilatorios con amplitud y frecuencia variantes en el tiempo; ya que es un escenario muy común en las señales reales. Las TFRs tienen características únicas, por ejemplo, la resolución entre el tiempo y la frecuencia no son independientes, es decir, que la resolución entre el tiempo y la frecuencia son inversamente proporcionales, esto es, sí se incrementa la resolución en tiempo disminuye la resolución en frecuencia y viceversa.

Algunas de las técnicas comunes son las ya mencionadas en subsecciones previas, como lo son: la NMD (subsección 2.8.1), la cual utiliza otra técnica bastante utilizada, la transformada de Fourier ventaneada o transformada de tiempo corto de Fourier. Otra técnica es la HT (subsección 2.8.2).

Modelos paramétricos.

Un modelo paramétrico relaciona las señales de entrada, salida y perturbaciones por medio de parámetros finitos y una estructura bien definida (López, 2008). Para esto primero debe

realizarse la identificación de un sistema sin ningún tipo de información previa. utilizando modelos estándar cuya validez para diferentes tipos sistemas ya ha sido comprobada, estos modelos describen adecuadamente el comportamiento de algún sistema lineal. Sin embargo, la selección del modelo que se ajuste a los datos tanto de entrada como de salida; los cuales se obtienen de manera experimental, representa un grado de dificultad. De una manera general, los modelos se describen en un dominio discreto, ya que los datos se obtienen por muestreo, aunque se puede obtener modelo continuo por medio de una transformación del dominio discreto al continuo.

La expresión más general es:

$$s(t) = \eta(t) + w(t) \quad (75)$$

donde $w(t)$ es la respuesta debida a las perturbaciones, $\eta(t)$ es la respuesta debida a la entrada y $s(t)$ es la salida del sistema.

Algunos tipos de modelos son: ARX, Output Error, ARMAX y Box Jenkins. Cada estructura tiene sus propias características. Para la elección de alguna de las estructuras podría ser necesario probar con varias estructuras y con diferentes órdenes hasta lograr obtener un modelo adecuado que satisfaga los parámetros (López, 2008).

Capítulo 3. Metodología.

En este capítulo se describe la metodología propuesta para probar y validar la hipótesis planteada, así como cada experimento realizado para dicho propósito. Además, se describen las características y especificaciones de los instrumentos utilizados en los experimentos.

3.1. Descripción general de la metodología.

En la Figura 16 se muestra el diagrama de la metodología empleada para verificar la hipótesis, y desarrollar los objetivos, los cuales ya fueron mencionados en el capítulo 1. El primer bloque es la fuente de alimentación, en la cual se tienen dos condiciones: la nominal y con desbalance; esta última para tres fases. Debe notarse, que, como se mencionó, también se deben considerar armónicos en la fuente de alimentación, sin embargo, es más común que estos ingresen por cargas conectadas a la red eléctrica, por lo que para dicho propósito se utilizan cargas no lineales conectadas al transformador en lugar de tener una fuente que cree armónicos. Esto es lo que se muestra en el segundo bloque, donde un banco de transformadores (tres monofásicos) se utiliza para crear el transformador trifásico, mientras que utilizando únicamente uno se obtiene el monofásico. Debe notarse que sólo uno de ellos tiene una falla por deformación en los devanados, es decir, falla de corto circuito. También, debe notarse que se consideran dos tipos de carga; lineal y no lineal, con las que se obtienen cuatro diferentes condiciones: sin carga, carga lineal, carga no lineal y la mezcla de la lineal y de la no lineal.

El tercer bloque es la adquisición de las señales de vibración, para este caso se utilizan dos tipos de sensores un acelerómetro triaxial y un micrófono de contacto. Como previamente ya ha mencionado, las señales de vibración captadas por el acelerómetro o el micrófono son las mismas, por lo que se puede decir que las señales de vibración y las acústicas o vibró acústicas son homólogas y contienen la misma información.

Una vez adquiridas las señales vibración, el siguiente paso es realizar el análisis y procesamiento de estas, con el propósito de diagnosticar distintos tipos de fallas; deformación en devanados (corto circuito), cuando el transformador se alimenta con distintas condiciones; nominal

y desbalanceada, además de contenido armónico, todo esto cuando el transformador se está bajo diferentes condiciones de carga.

De manera más específica, algunos dispositivos y equipo utilizado en la metodología son descritos a continuación. Para la fuente de alimentación se utiliza la alimentación del proveedor; que en México es CFE. Esta es usada íntegramente (nominal) cuando se analizan las deformaciones en los devanados o SCTs de un transformador monofásico. Por el otro lado, cuando se analiza la fuente de alimentación con desbalance se tiene que usar una red trifásica, la cual se toma del proveedor; CFE, sin embargo, esta no presenta desbalance por lo que se utilizan autotransformadores que permiten generar el desbalance de la fuente de alimentación y de esta manera, poder estudiar el comportamiento de un transformador trifásico alimentado por una fuente desbalanceada.

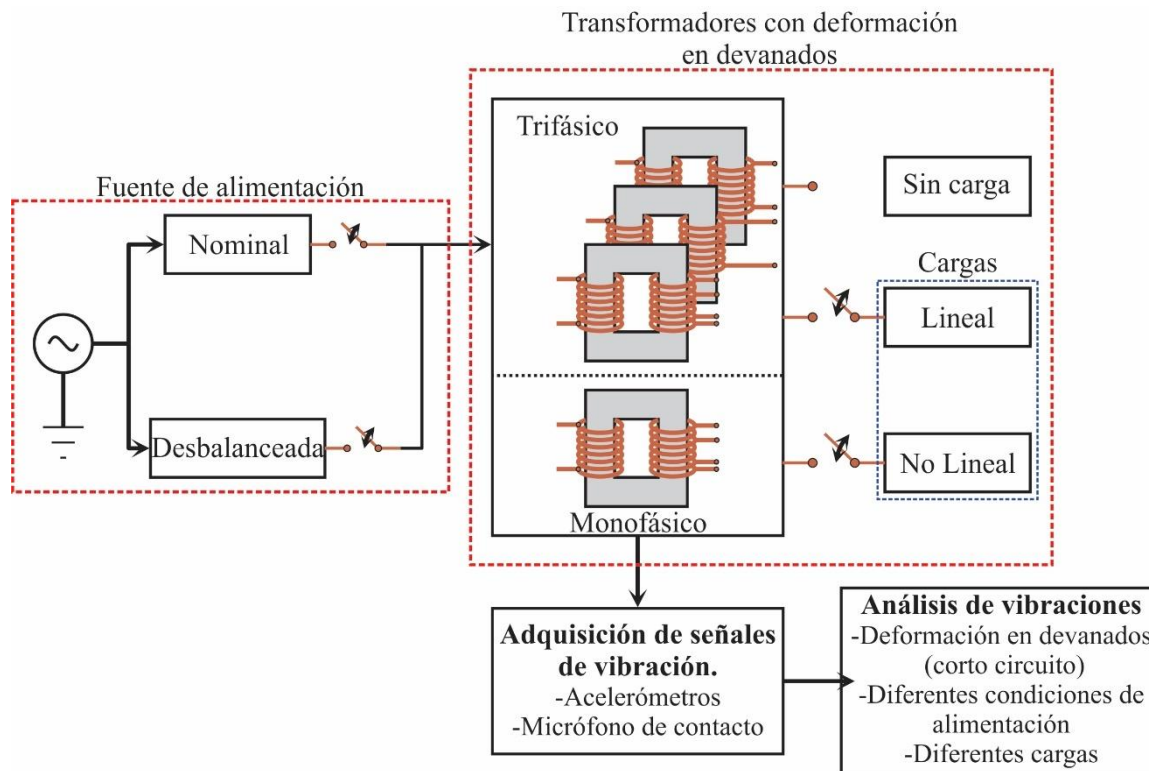


Figura 16. Diagrama metodológico.

En cuanto a los transformadores, es decir, monofásico y trifásico, para ambos casos se utilizan transformadores monofásicos, en el caso del trifásico se utilizan tres. En total se utilizan tres transformadores monofásicos, los tres son idénticos, tienen una potencia de 1.5 kVA y operan a distintos voltajes; 220 y 120 V, todo dependiendo de la aplicación. Su relación de transformación es de 2:1 si se configura como transformador reductor y de 1:2 si se configura como transformador elevador. Uno de estos tres transformadores es capaz de emular un cortocircuito en sus devanados,

el SCT puede ser desde una falla incipientes, hasta fallas desarrollados, es decir, puede emular 0, 1, 2, 3, 4, 5, 8, 9, 10, 15, 20, 25, 30 y 35 SCTs, donde 0 SCT es la condición sana.

Estos transformadores se van a conectar dos tipos de cargas: cargas lineales y no lineales. Las cargas lineales son arreglos de resistencias, mientras que, las cargas no lineales son una combinación de un arreglo resistivo, un capacitor y un rectificador, este último, consta de un arreglo de diodos. En los diferentes casos de estudio, los valores resistivos, capacitores y rectificador cambian en cada uno de ellos. Finalmente, como se mencionó previamente el uso de las cargas no lineales es principalmente para introducir armónicos al transformador, ya que esto es un efecto muy común en la vida real, es decir que las cargas no lineales introducen armónicos a la red eléctrica.

El monitoreo de las señales de vibración se ha convertido en un elemento clave para el diagnóstico de máquinas eléctricas tanto en aplicaciones científicas e industriales, debido a que la relación entre las vibraciones y el estado del sistema es directa. Muchos de los sistemas comerciales utilizan alguna otra variable física que les permite observar el estado del sistema, sin embargo, pueden llegar a ser invasivos, esto se evita con la medición de vibraciones, ya que se pueden medir directamente de algún elemento de la máquina o a la distancia con un micrófono. Para este trabajo, se utilizan acelerómetros triaxiales modelo 8395A de KISTLER, estos pueden medir $\pm 10g$ con una resolución de 400 mV/g y un ancho de banda de 1000 Hz. Estos se basan en tecnología capacitiva junto con un sistema microelectromecánico. Otro tipo de sensor utilizado es un micrófono de contacto basado en el efecto piezoeléctrico, es decir que utiliza una membrana piezoeléctrica para adquirir las vibraciones con un ancho de banda máximo de 6.4 kHz; lo cual es suficiente para el ancho de banda de interés del transformador (1 kHz). Este sensor es un micrófono comercial, económico y muy sencillo de utilizar. Dicho micrófono es del modelo TP-6 de RECKLESS. Para la adquisición de las señales se utiliza una tarjeta de adquisición de señales de *National Instruments* modelo NI-USB-6211, el cual cuenta con un convertidor analógico a digital de 16 bits, a una máxima frecuencia de muestreo de 250 kmuestras/s. Sin embargo, esta frecuencia puede ser manipulada dependiendo de la aplicación.

Finalmente, y de acuerdo con cada caso de estudio, el análisis y procesamiento de señales de vibración es distinto. Por ejemplo, en un caso se utilizan algunos índices estadísticos para observar el comportamiento del transformador; todos en el dominio del tiempo. Por otro lado, en otro caso se utilizan técnicas avanzadas de procesamiento de señales, tal como lo es la descomposición de modos no lineales y la transformada Hilbert. También se utiliza un índice que no es comúnmente utilizado en el procesamiento de señales; el contraste, el cual suele utilizarse en procesamiento de imágenes. En cada uno de los casos se utiliza la clasificación automática, los algoritmos utilizados para llevar a cabo este proceso son la lógica difusa, máquinas de soporte vectorial y redes neuronales artificiales. En cada caso de estudio se detallará los elementos, técnicas y algoritmos utilizados en su proceso.

3.2. Casos de estudio.

A continuación, se describen cuatro casos de estudio realizados para probar y validar la metodología, así como la hipótesis, también se describen los instrumentos utilizados en el desarrollo de cada uno. En estos casos se investiga la falla de corto circuito, ya que esta provoca deformación en los devanados del transformador. En el primer caso, se busca generar un dispositivo capaz de realizar de manera automática el diagnóstico y clasificación de diferentes niveles de seguridad SCTs utilizando diferentes índices estadísticos, además de construir la arquitectura de dichos índices, el procesamiento de estos mismos y el algoritmo de clasificación automática, para ser implementado dentro de una FPGA. El algoritmo de clasificación utilizado en este caso de estudio es una SVM. En el segundo caso se busca realizar el diagnóstico y clasificación de distintos niveles de severidad de SCTs aplicando técnicas avanzadas de procesamiento de señales, como lo son la NMD y la transformada Hilbert. Como algoritmo de clasificación automático, se utiliza la lógica difusa. En tercer caso de estudio se busca desarrollar un modelo no paramétrico basado en frecuencias cuando el transformador se encuentra bajo las condiciones de desbalance y con contenido armónico en la fuente de alimentación, mientras existe deformación en el devanado; como lo es el corto circuito y, además, presenta diferentes niveles de severidad. Finalmente, el último caso busca cubrir severidades incipientes, es decir, fallas que comienzan a desarrollarse o son muy pequeñas; tal como lo son 1 o 2 STCs, se utiliza un indicador de falla comúnmente utilizado en el procesamiento de imágenes; el contraste. Debido a que este indicador puede ser aplicado también para señales y junto con un algoritmo automático de clasificación como lo es una ANN, se logra obtener buenos resultados.

3.2.1. Caso de estudio 1: Metodología de diagnóstico en el dominio del tiempo.

En este segundo caso de estudio se propone una metodología basada en STFs (Tabla 1), SVM y su implementación en una FPGA para diagnosticar un transformador bajo diferentes condiciones de SCTs usando señales de vibración. La metodología enfatiza la selección de características para obtener las mejores que describan adecuadamente la condición del transformador. Estas características maximizan la separación entre clases o condiciones. Las señales de vibración se adquieren de un transformador modificado para emular distintas condiciones de SCTs. El rango de SCTs va desde 0 hasta 35 SCTs con saltos de 5 SCTs, donde la condición de 0 SCTs representa la condición sana del transformador. El primer paso es calcular 19 STFs (Tabla 1) de las señales de vibración, entonces, ese conjunto de características es examinado por un método de reducción de características para así tomar únicamente las características más representativas. Este proceso de reducción se realiza utilizando el análisis FS y la extracción de características se realiza utilizando el LDA. Con estos resultados se implementa una SVM como algoritmo de clasificación y su desempeño se compara con el de una ANN. La metodología presentada se implementa en una FPGA para proveer una solución de un sistema en un chip para un futuro desarrollo de sistemas de monitoreo en línea. Seleccionar y utilizar esta tecnología es debido a su paralelismo, alta velocidad, reconfigurabilidad y bajo costo (Santos-Hernandez et al., 2019), lo que la hace una herramienta prometedora para el desarrollo de sensores inteligentes (Martinez-Figueroa et al., 2017).

De manera general, la metodología para el segundo caso de estudio se muestra en la Figura 17. Se adquieren las señales de vibración que provienen de un transformador bajo diferentes condiciones de falla de SCT. Entonces, esas señales se analizan en la etapa de diseño para obtener las mejores STFs y los parámetros de las SVMs, tales parámetros se implementarán en una FPGA para cálculo en hardware. El resultado en la etapa de diseño y en la implementación es el diagnóstico del transformador.

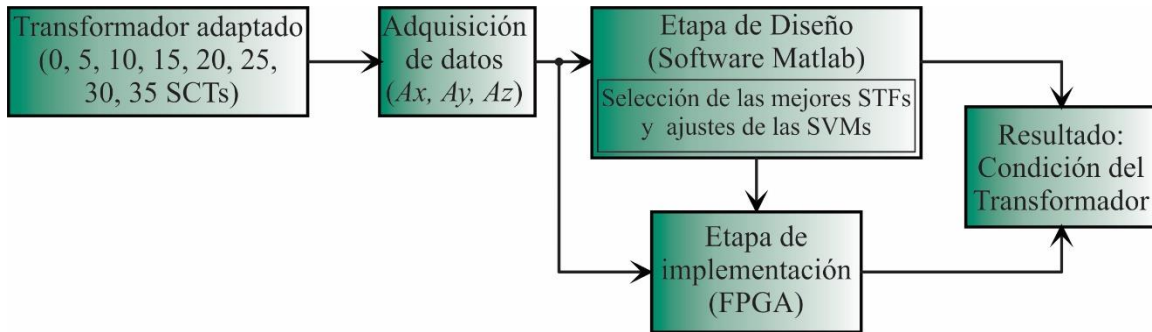


Figura 17. Diagrama de bloques de la metodología del segundo caso de estudio.

A su vez, en la etapa de diseño y la etapa de implementación se desarrollan distintos pasos para completar sus tareas. En la etapa de diseño; Figura 18a, las señales de vibración de adquieren de tres ejes (A_x , A_y , A_z). Estas señales se adquieren de un transformador monofásico sin carga mientras está energizado, por lo que, las señales de vibración incluyen los estados transitorio y estable. El transformador puede emular diversas condiciones de falla de SCTs: 0, 5, 10, 15, 20, 25, 30, y 35, donde 0 SCT es la condición sana del transformador. El transformador se energiza por medio de un relevador de estado sólido. También en esta etapa, se calculan las 19 STFs para cada eje, de esta manera se encuentran las propiedades en cada eje que describen el comportamiento del transformador por medio de las señales de vibración. Las STFs analizadas se especifican en la Tabla 1 de la sección 2.6.1. Cuando las STFs son calculadas, también son normalizadas con el fin de obtener una forma de comparar las mediciones de las características extraídas. Posteriormente, se realiza la reducción de características, lo que consiste en la selección y extracción de características. En la selección de características, se selecciona el subconjunto de características que maximiza las distancias entre las clases y que al mismo tiempo minimiza la distancia entre esos mismos puntos. Mientras que la extracción de características utiliza una matriz de transformación para disminuir el espacio de n dimensiones a un espacio de 2 dimensiones: característica 1 (f_1) y característica 2 (f_2). Una vez que los datos han sido obtenidos son separados en dos grupos: un conjunto para entrenamiento y otro para validar o probar. El conjunto de datos de entrenamiento se usa para construir los modelos de las SVMs, es decir, entrenar las SVMs, mientras que el conjunto de validación o prueba se usan para evaluar los modelos de SVMs y a su vez evaluar los resultados de clasificación.

Por otro lado, la etapa de implementación (Figura 18b) utiliza las mejores características encontradas en la etapa de diseño. En esta etapa, las características son únicamente adquiridas de dos ejes (A_x , A_y); se observó que las características estimadas del eje z no presentan información relevante y por lo mismo, fueron descartadas. Ahora, siguiendo el proceso, las características

calculadas en el primer paso deben ser normalizadas. Consecuentemente, los datos deben ser reducidos a un espacio de 2 dimensiones usando la matriz de transformación calculada en la etapa de diseño. Finalmente, para diagnosticar la condición del transformador, se implementa la unidad de clasificación basada en los clasificadores SVM, los cuales fueron construidos y validados en la etapa de diseño. Debe ser notado que la etapa de implementación puede ser llevada a cabo en una PC, por ejemplo, usando el software de Matlab tal como fue usado en la etapa de diseño, pero en este trabajo, con el fin de proveer una solución de un sistema en un chip para desarrollo de equipo en un futuro, se desarrolla la implementación en una FPGA. Con respecto a esto, la información que se utiliza para normalizar las características, la matriz de transformación y los valores que describen los modelos de las SVMs se almacenan en una memoria de lectura (ROM, del inglés *read-only memory*) dentro de la FPGA. La etapa clasificación basada en SVM determina la condición de las SCTs, mostrando el valor de 0, 1, 2, 3, 4, 5, 6 o 7, donde 0 representa la condición sana, la clase 1 representa 5 SCTs y así sucesivamente.

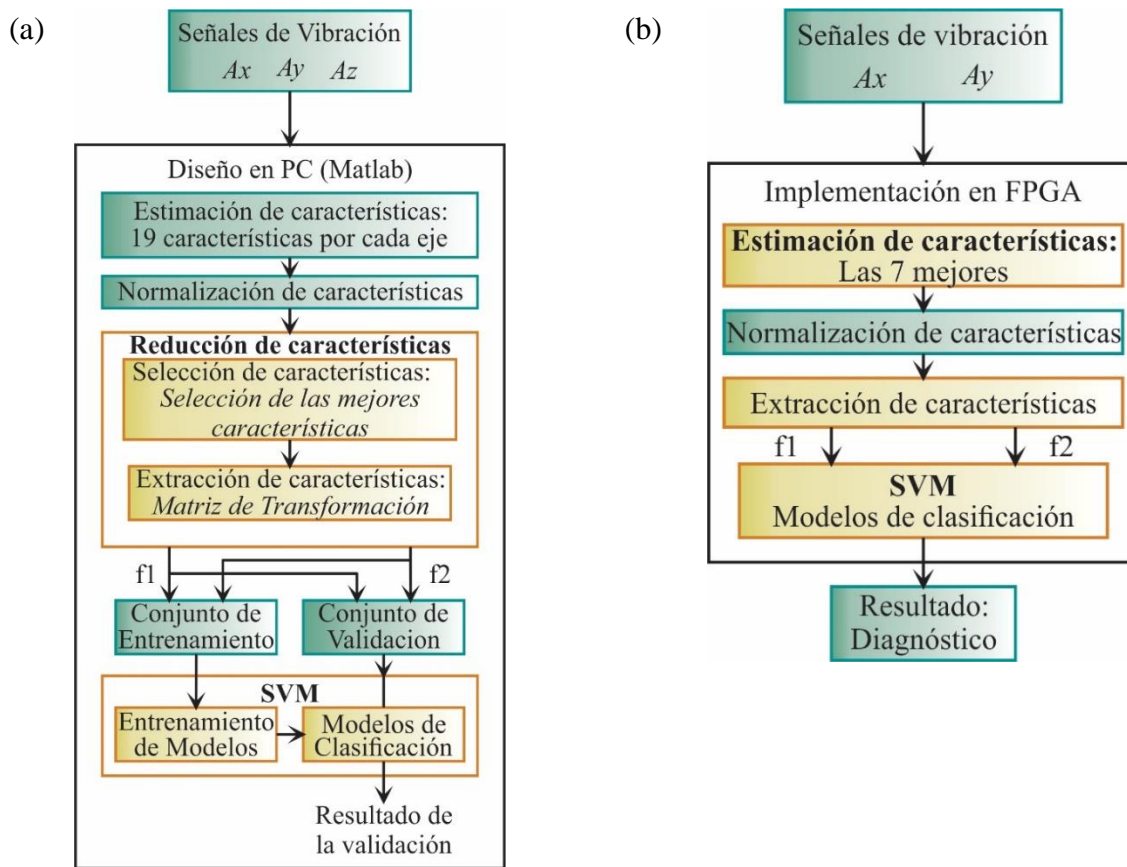


Figura 18. Diagrama de bloques para (a) metodología de la etapa de diseño; (b) metodología para etapa de implementación.

En la Figura 19 se muestra la configuración del experimento realizado para probar la metodología propuesta para este caso de estudio. Se utiliza un transformador monofásico de 1.5 kVA operado a 120 V. El transformador tiene 135 espiras en su devanado primario, el cual está modificado para emular diversas fallas de SCTs. Las condiciones son 0, 5, 10, 15, 20, 30 y 35 SCTs, donde 0 SCT es la condición de operación sana. Las señales de vibración se adquieren

usando un acelerómetro triaxial modelo 8395A de KISTLER, el cual puede medir ± 10 g con una resolución de 400 mV/g con un ancho de banda de 1000 Hz. El acelerómetro se posiciona en el marco de sujeción del transformador para recibir las vibraciones del núcleo y devanados de una manera simétrica. Los datos del acelerómetro para la etapa de diseño (Figura 18a) se adquieren empleando un sistema de adquisición de datos (DAS, del inglés *data acquisition system*) de la marca National Instruments modelo NI-USB6211, que tiene un convertidor analógico digital de 16 bits configurado con una frecuencia de muestreo de 6000 muestras/s. Para iniciar la prueba se utiliza un relevador de estado sólido modelo SAP4050D. El tiempo de adquisición es de 5s, el cual es suficiente para incluir tanto el estado transitorio y el estable durante cada prueba que el transformador este energizado. La Figura 20 muestra un ejemplo de las señales de vibración adquiridas en la condición sana y en condición de falla, respectivamente. Se realizaron 20 pruebas para cada condición de falla. Los datos obtenidos se procesan en una PC usando el software Matlab. La PC tiene Windows 10 con un procesador i7-4510U a 2.6 GHz con 8 GB de RAM. Por otro lado, durante la etapa de implementación, todo el procesamiento se realiza dentro de una FPGA considerando el proceso propuesto en la metodología previamente diseñada. La FPGA utilizada es una Cyclone IV EPACE115F29C7 de una tarjeta de desarrollo DE2-115 de Altera. En la Figura 19 se muestra una zona con aumento de la pantalla de cristal líquido de la tarjeta en la que se muestran la identificación de clases de SCTs cuando la falla de 5 SCTs ocurre. Debe notarse que el sistema propuesto puede ser considerado como un sensor inteligente ya que contiene un acelerómetro como sensor primario, un DAS y capacidad de procesamiento con protocolos de comunicación. Sin embargo, el desarrollo de un sensor inteligente necesitará ser optimizado y también el diseño de algunas etapas para que pueda convertirse en un sistema de monitoreo por medio de un sensor inteligente.

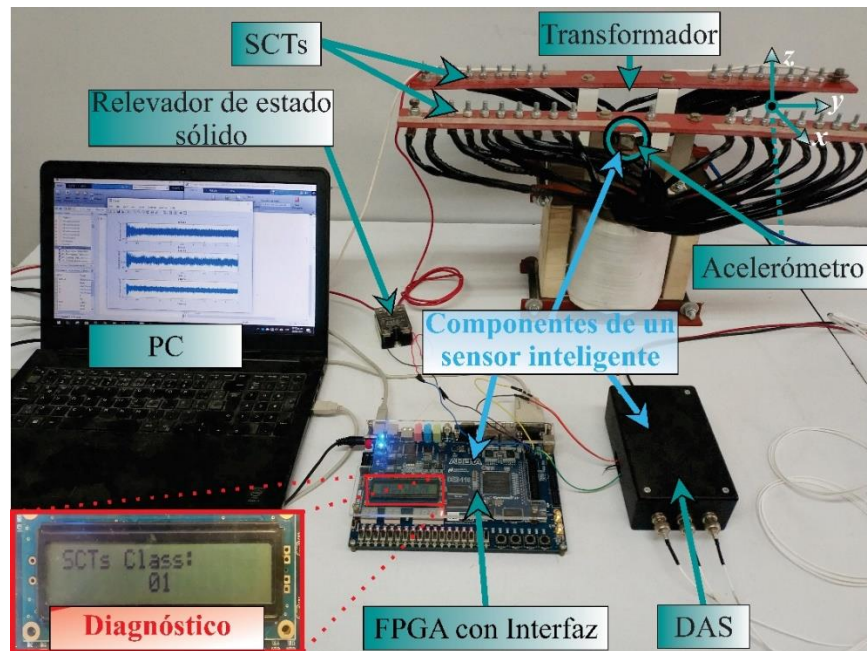


Figura 19. Configuración del experimento del caso del segundo caso de estudio.

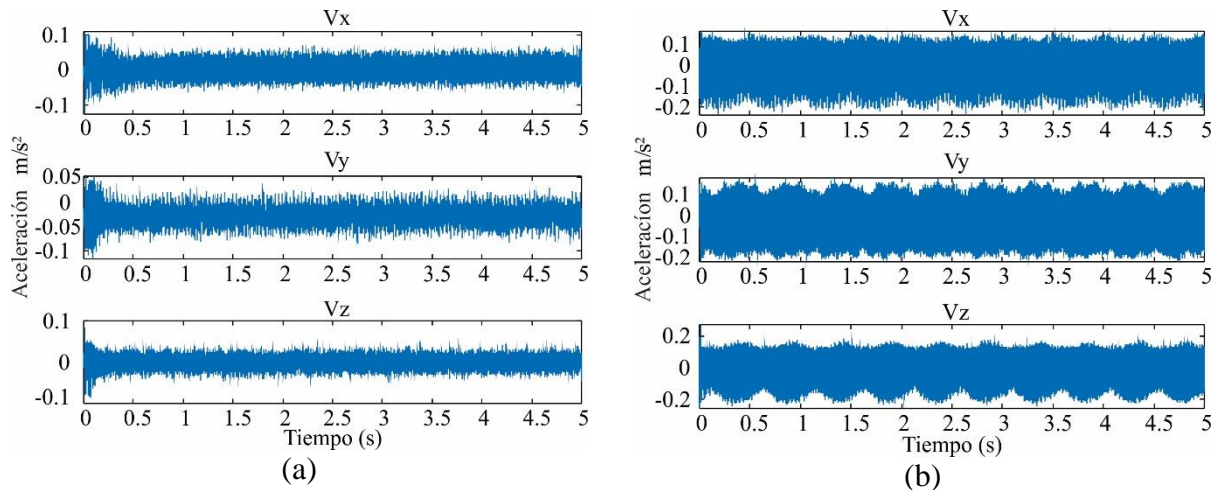


Figura 20. Señales de vibración adquiridas en tres direcciones, (a) condición sana y (b) daño de 35 SCTs.

3.2.2. Caso de estudio 2: Metodología de diagnóstico con transformación de dominio.

El segundo caso de estudio desarrolla y plantea una metodología para el diagnosticar falla por cortocircuito en transformadores usando señales de vibración. Debido a que las señales de vibración mantienen una relación directa con el desempeño mecánico de los devanados, lo que desde un punto de vista muestra que los cambios o alteraciones en los devanados modificarán los patrones de vibración. Sin embargo, debido a que las señales de vibración pueden estar embebidas un alto nivel de ruido, así como contaminadas por vibraciones de otros elementos y a su comportamiento no lineal y no estacionario resulta no ser una tarea sencilla. Es por lo que emplear una técnica avanzada de procesamiento de señales; como lo es la NMD, permite extraer la información proveniente de los devanados retirando al mismo tiempo información de otra fuente, además del ruido. Una vez que la NMD extrajo los modos no lineales, se emplea la transformada Hilbert para obtener la amplitud instantánea de cada uno de los modos y así estima el valor RMS como indicador de falla de SCT con diferentes severidades. Por la misma naturaleza de las señales de vibración, estas presentan variaciones el tiempo y para permitir una mejor discriminación entre las diferentes severidades de SCTs, el valor RMS se suaviza aplicando un filtro de promedio móvil, de esta manera los valores RMS están separados y permite aplicar un algoritmo de clasificación automático; como lo es un sistema de lógica difusa. En la Figura 21 se muestra el diagrama de la propuesta metodológica.

En la Figura 22 se muestra el experimento montado para desarrollar la metodología propuesta, en la cual se utiliza un transformador monofásico de 1.5kVA con 135 espiras en su devanado primario, el cual es operado a 120V. Dicho transformador es modificado para emular diferentes severidades de falla de manera controlada, es decir, puede emular 0, 5, 10, 15, 20 y 25 SCTs. Para medir las vibraciones generadas en el transformador se utiliza un acelerómetro triaxial; modelo 8395A de KISTLER, midiendo $\pm 10g$ con una resolución de 400 mV/g con un ancho de banda de 1000 Hz. Para llevar a cabo la adquisición de las señales de vibración, el acelerómetro

se coloca sobre el núcleo, en su centro para recibir las vibraciones tanto del núcleo como de los devanados en una forma simétrica. Las vibraciones se adquieren con un sistema de adquisición de datos (DAS, del inglés *data acquisition system*) que utiliza un convertidor de analógico a digital de 16 bits y con una frecuencia de muestreo de 6000 muestras/s. Esta frecuencia de muestreo cumple adecuadamente con el teorema de Nyquist para el ancho de banda del acelerómetro. El DAS es del modelo NI-USB 6211 de *National Instruments*. También se utilizan dos relevadores de estado sólido del modelo SAP4050D, el primero se utiliza para activar el transformador y así iniciar la prueba, el segundo activa un autotransformador para desenergizar el transformador al finalizar cada prueba y eliminar el flujo remanente. Por propósitos estadísticos se realizaron 20 pruebas de cada condición, adquiriendo 5 segundos en cada una de ellas, es decir, 30,000 muestras por prueba. Un ejemplo de las señales adquiridas se muestra en la Figura 23. Todo el procesamiento de las señales se realizó en una computadora personal (PC del inglés *personal computer*) con el software de Matlab.




Figura 21. Diagrama de bloques de la metodología propuesta.

3.2.3. Caso de estudio 3: Modelo basado en vibraciones.

Con el propósito de emular diferentes condiciones de trabajo de un transformador de manera muy cercana a las reales, de manera segura y económica en este caso de estudio se desarrolla un modelo no paramétrico basado en la frecuencia de las vibraciones cuando se alimenta con diferentes condiciones y se provoca falla de corto circuito. En la Figura 24 se muestra el diagrama de la metodología para el desarrollo y validación de este caso de estudio. La fuente de alimentación tiene distintas condiciones de alimentación; nominal, con desbalance y contenido armónico. En busca de tener una similitud con escenarios reales el ingreso de armónicos no será por la fuente de alimentación, sino que, será por cargas no lineales conectadas al transformador. Por otro lado, el desbalance se genera por medio de un banco de auto transformadores, estos permiten emular tanto la condición nominal como la de desbalance.

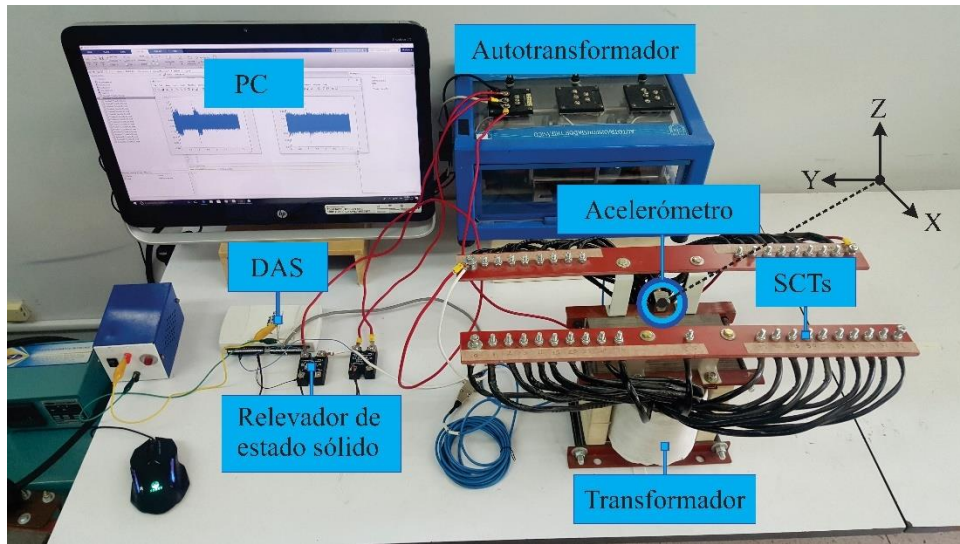


Figura 22. Montaje del experimento.




Figura 23. Señales de vibración adquiridas del eje x del acelerómetro triaxial.




Figura 24. Metodología para el desarrollo de un modelo basado en vibraciones.

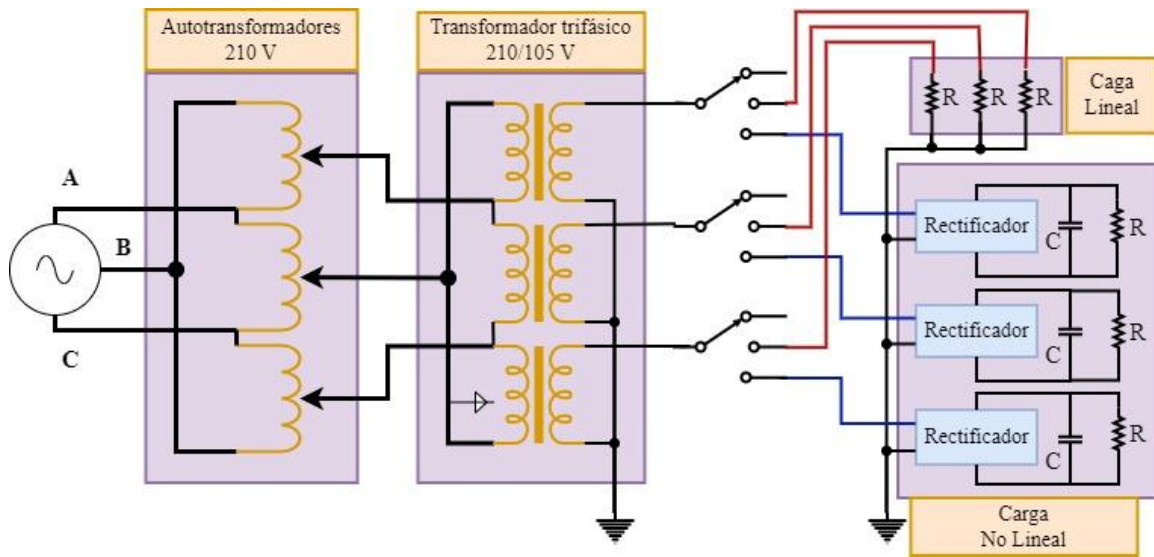


Figura 25. Diagrama eléctrico de la alimentación, interconexión del transformador trifásico.

El transformador trifásico se conforma de tres transformadores monofásicos interconectados entre sí, uno de ellos puede emular la condición de falla por corto circuito con diferentes niveles de severidad: 0 (sano), 1, 2, 3, 4, 5, 8, 9 y 10 SCT. El diagrama eléctrico de las interconexiones se muestra en la Figura 25. La adquisición de las señales se realiza por medio de un acelerómetro triaxial; uno en cada fase, es decir en cada transformador monofásico. Como se mencionó previamente, para la introducción de contenido armónico se realiza por medio de cargas no lineales, por lo que cada fase es rectificadora y conectada a una carga. Con el fin de tener distintas condiciones, también se utilizan cargas lineales y una condición sin carga, tal como se muestra en el diagrama de la Figura 25.

El modelo basado en la frecuencia de vibraciones propuesto se muestra en las Figuras 26 y 27. Hay cinco condiciones de desbalance: 0, 2.5, 5, 7.5 y 10%; estos valores son los permitidos por la CFE en la especificación CFE L0000-45. En cada una de las condiciones de desbalance puede haber o no carga, es decir, habrá tres condiciones de carga: sin carga, carga lineal y carga no lineal; que introduce contenido armónico al sistema. También se consideran las condiciones de corto circuito en cada condición de desbalance con algún tipo de carga. Se generan nueve fallas: 0 (sana), 1, 2, 3, 4, 5, 8, 9 y 10 espiras en corto circuito. Finalmente, con éstas se realizan distintas pruebas para obtener suficientes datos para alimentar la red neuronal.

A cada prueba de cada una de las distintas condiciones se les aplica la transformada de Fourier, con esto se obtiene su espectro de frecuencias, del cual se toman los armónicos de las vibraciones, es decir, la frecuencia fundamental de las vibraciones en un transformador es 120Hz y sus armónicos son 240Hz, 360Hz, etc. Al ancho de banda de interés es de 1000Hz, siendo el último armónico dentro del ancho de banda de interés el de 960 Hz. En total se extraen las amplitudes de ocho armónicos (el fundamental y siete armónicos), junto con estos también se extraen las fases de esos armónicos. El modelo se divide en dos, una red neuronal para las amplitudes y una para las fases. Los datos de entrada correspondientes a cada condición de desbalance, carga y falla por corto circuito se muestran en la Tabla 3. Lo que entrega el modelo son ocho valores de salida para

las amplitudes y ocho valores para las fases, cada uno de ellos correspondientes a una componente frecuencial múltiplo de 120 Hz. Una vez que las redes fueron entrenadas el modelo propuesto puede ser completado como se muestra en la Figura 27.

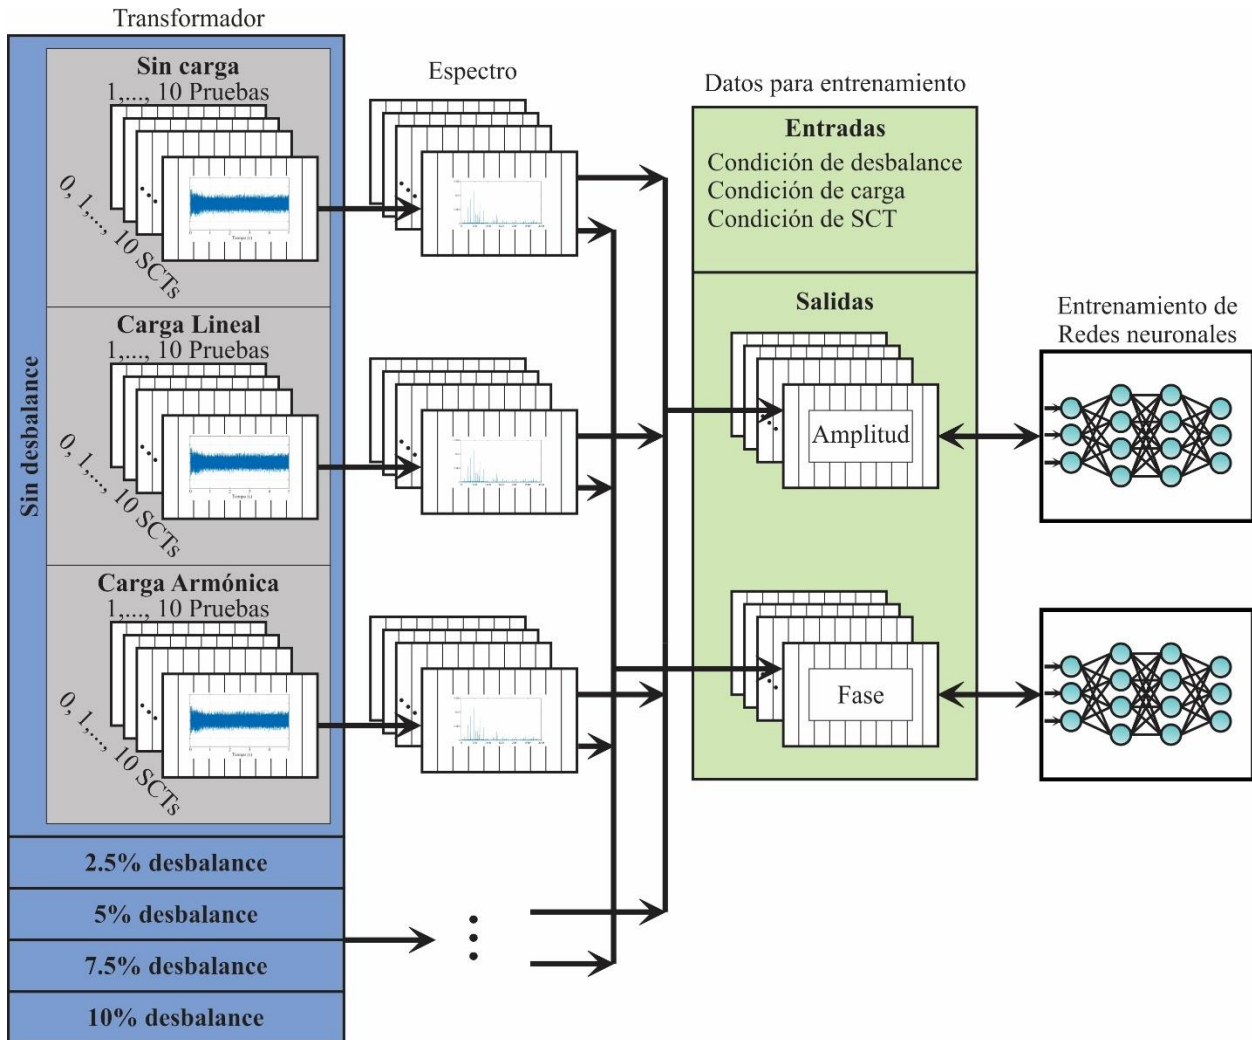


Figura 26. Metodología para la obtención del modelo no paramétrico basado en redes neuronales artificiales.




Figura 27. Modelo no paramétrico basado en redes neuronales artificiales, entradas y salida.

Tabla 3. Valores de entrada para la red neuronal.

| Desbalance | | | | | | | | | |
|---------------------------|-----------|--------|-----------|-----|----|---|---|---|----|
| % | 0 | 2.5 | 5 | 7.5 | 10 | | | | |
| Entrada | 1 | 2 | 3 | 4 | 5 | | | | |
| Cargas | | | | | | | | | |
| Tipo | Sin carga | Lineal | No Lineal | | | | | | |
| Entrada | 1 | 2 | 3 | | | | | | |
| Espiras en corto circuito | | | | | | | | | |
| # | 0 | 1 | 2 | 3 | 4 | 5 | 8 | 9 | 10 |
| Entrada | 0 | 1 | 2 | 3 | 4 | 5 | 8 | 9 | 10 |

Donde para alguna entrada; como las que se describen en la Tabla 3, las redes neuronales entregarán los valores tanto de amplitud como de fase para cada uno de los armónicos de la señal.

Finalmente, con cada componente del h armónico de Amplitud (A_h) y fase ϕ_h la función con la que se reconstruye la señal es:

$$v(t) = \sum_{h=1}^H A_h \sin(2\pi f_0 h t + \phi_h) \quad (76)$$

donde H es el número de armónicos; en este caso $H=8$, f_0 es la frecuencia fundamental de las vibraciones del transformador.

3.2.4. Caso de estudio 4: Metodología de diagnóstico temprano en el dominio del tiempo.

En este tercer caso de estudio se explora el contraste como indicador de falla y su aplicación para el diagnóstico temprano de SCTs, donde se propone una metodología (procesamiento de la señal y reconocimiento automático de patrones). También, la propuesta es evaluada cuando el transformador está bajo diferentes condiciones de carga, incrementando su aplicabilidad y operación en escenarios reales. En esta etapa, se consideran cuatro diferentes condiciones de carga, es decir, (1) sin carga, (2) carga lineal, (3) carga no lineal y (4) la combinación de las cargas lineal y no lineal. En general, estas cargas representan condiciones de operación de la vida real (Granados-Lieberman et al., 2021). Debe ser notado que la detección temprana de la falla SCTs no es un proceso sencillo debido a los cambios imperceptibles en el transformador y el alto nivel de ruido en las señales VA. Una vez que las señales han sido adquiridas, dos definiciones de contraste son utilizadas, es decir, Unser y Tamura, estas se calculan y comparan para observar cual provee la mejor sensibilidad a la falla. Finalmente, los diferentes valores de contraste para las diferentes condiciones de falla son procesados por una red neuronal artificial (ANN, del inglés *artificial neural network*) para el reconocimiento automático de patrones, donde también se compara con el desempeño de una máquina de soporte vectorial (SVM, del inglés *support vector machine*).

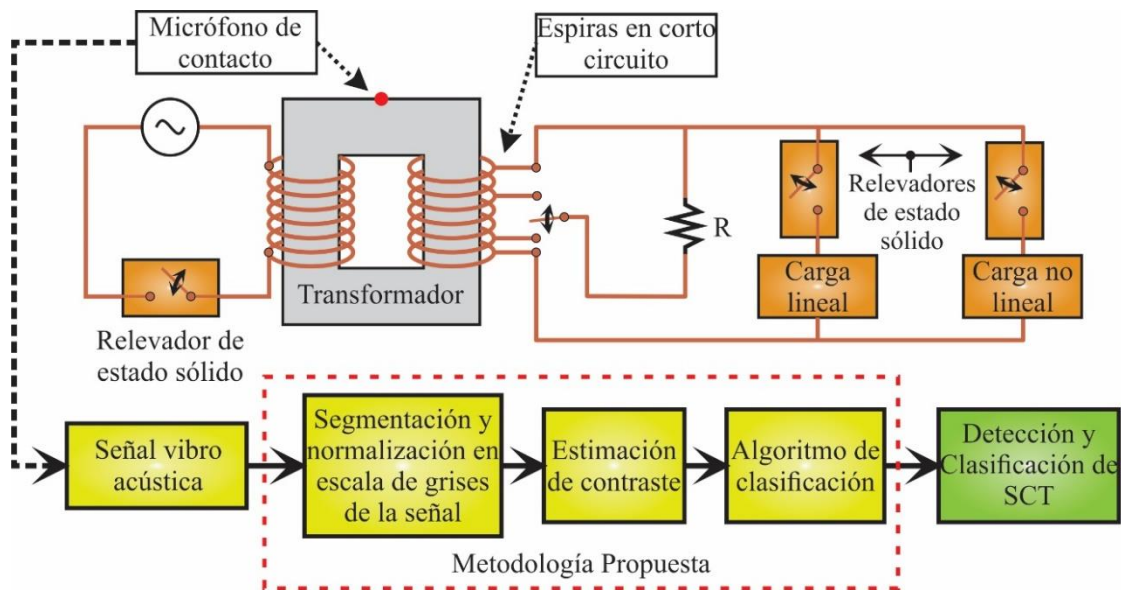


Figura 28. Diagrama de flujo de la metodología propuesta en el caso de estudio 3.

En el rectángulo punteado de rojo de la Figura 28 se muestra el diagrama de flujo de la metodología propuesta. En general, es un proceso de tres pasos: (1) procesamiento de la señal, el cual consiste en la segmentación de la señal y la normalización en la escala de grises, (2) estimación del contraste como indicador de falla y (3) diseño y validación del algoritmo de clasificación. También en la parte superior de la Figura 28 se muestra cómo se adquieren las señales VA del transformador, el cual es un transformador monofásico que puede emular diferentes fallas tempranas de SCTs: 0, 1 y 2 SCTs, donde 0 SCTs es la condición sana. Para seleccionar la condición SCT, un cable conductor se conecta entre las diferentes derivaciones del transformador con un resistor R. Este resistor ayuda a limitar la corriente de corto circuito y proteger el transformador. Para energizar el transformador y conectar/desconectar las diferentes cargas, se utilizan tres relevadores de estado sólido. Una vez que las señales VA son adquiridas se segmentan, es decir, se toma un segundo de la señal en cada diferente caso de carga: (1) sin carga, (2) carga lineal, (3) cargas lineal y no lineal y (4) carga no lineal. Este proceso se repite para todas las condiciones SCT. Como parte de la metodología propuesta, las señales VA son normalizadas en la escala de grises, es decir, la señal VA toma valores desde 0 a 255. Para cada nueva señal (segmentada y normalizada), se obtiene dos diferentes indicadores de contraste (Tamura y Unser) para obtener el mejor indicador de falla. Finalmente, en el paso de clasificación automática se evalúan dos distintos algoritmos de clasificación (ANN y SVM) para detectar y clasificar la condición del transformador bajo diferentes condiciones de carga. Los resultados demuestran que el contraste de Unser y el algoritmo ANN presentan los mejores resultados para la detección y clasificación de las condiciones de falla SCT sin importar el tipo de carga.

La configuración del experimento se muestra en la Figura 29. Se utiliza un transformador de 1.5 kVA que opera a 220V con una relación de 2:1. El transformador fue modificado para emular condiciones de falla de SCTs incipientes, es decir que comienzan a desarrollarse. Para proteger los devanados durante la falla de SCTs, se utiliza una resistencia de 2 ohms. Para la energización del transformador, conexión y desconexión de las cargas se utilizan relevadores de

estado sólido modelo SAOP4050D. Las cargas lineal y no lineal representan un 93% de la carga total del transformador; 900 W y 500 W, respectivamente. La carga lineal es un arreglo resistivo de 15 Ohms y la carga no lineal es la combinación de un arreglo resistivo de 24 Ohms y un rectificador. El rectificador es un arreglo de diodos de 800V y 8ª junto con un capacitor de 210microF y 450V. Para la medición de las señales vibro acústicas se utiliza un micrófono de contacto piezoeléctrico (modelo TP-6 de RECKLESS), este proporciona una solución comercial, fácil de usar y de bajo costo. El micrófono toma las vibraciones de la zona de contacto con un ancho de banda máximo de 6.4 kHz, el cual es suficiente para capturar el rango de frecuencias de interés (1kHz). El micrófono se coloca sobre el núcleo del transformador, en el centro de este. En esta posición las vibraciones del núcleo y devanados se adquieren de manera similar. Los datos se adquieren usando una tarjeta adquisición de datos DAS modelo NI-USB-6211 de *National Instruments*, la cual se configura con una frecuencia de muestreo de 7812.5 muestras/s. Para cada condición de falla; 0, 1, y 2 SCTs, y para las diferentes condiciones de carga se realizan 20 pruebas. Todos los datos se adquieren y procesan utilizando MATLAB en una computadora personal (PC), que utiliza Windows 10, un procesador i7-4510U a 2.6GHz y 8GB de RAM.

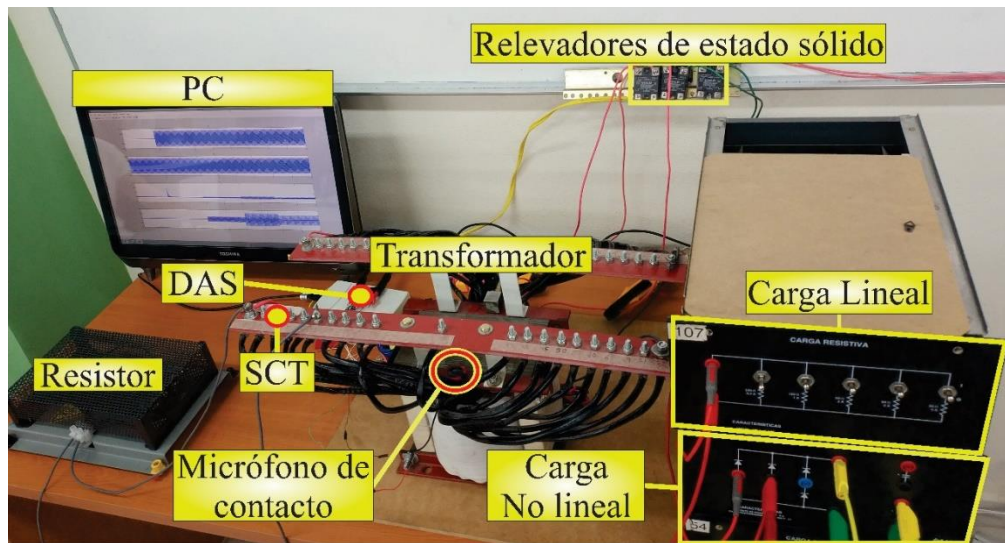


Figura 29. Configuración del experimento.

En la Figura 30 se muestran las señales que se adquieren. El tiempo de adquisición es de 10 segundos, de esta manera se capturan tanto el estado transitorio como el estable. Para observar los cambios en las cargas se utiliza una señal de corriente; únicamente de manera ilustrativa. Hay cuatro condiciones de carga: (I) sin carga (S0), (II) carga lineal (S1), (III) combinación de cargas lineales y no lineales (S3) y (IV) carga no lineal (S4), donde el tiempo de activación/desactivación de las cargas es a los 2, 4, 6 y 8 s, respectivamente. De cada sección se toma una ventana de tiempo de 1s. Esta ventana de tiempo contiene la suficiente información del estado estable y se evitan las transiciones de las cargas (ver el rectángulo punteado rojo en la Figura 30). Una vez que la señal ha sido segmentada, se lleva a cabo el procesamiento de datos, es decir, la metodología propuesta.

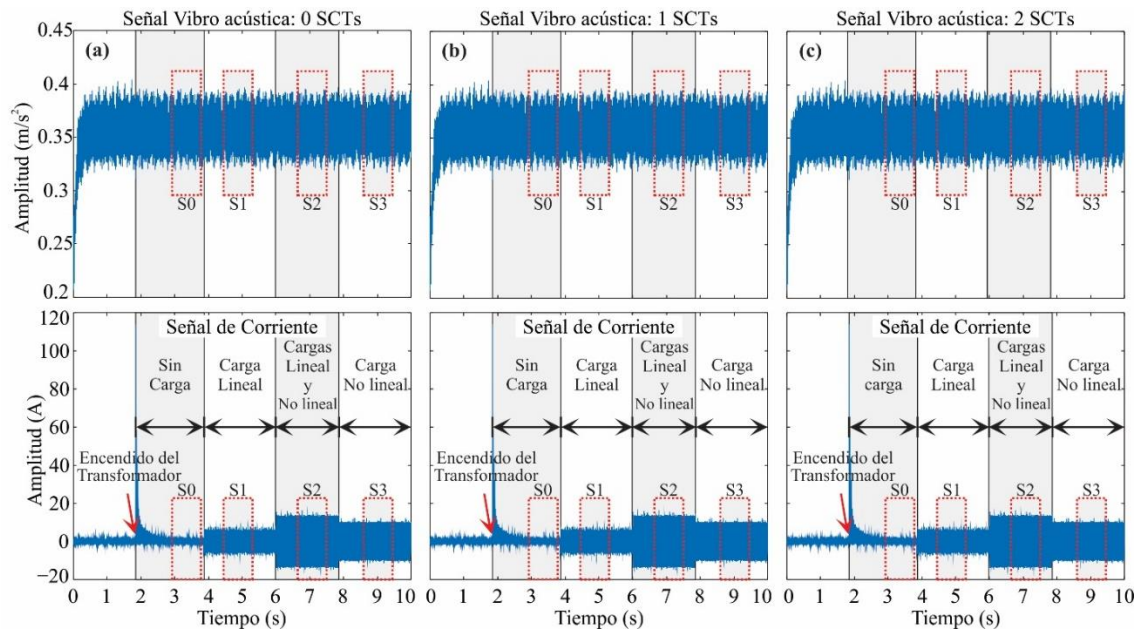


Figura 30. Señales adquiridas del transformador: señales VA para (a) 0 SCTs, (b) 1 SCTs y (c) 2 SCTs.

Capítulo 4. Resultados.

En este capítulo se analizan y discuten los resultados de cada caso de estudio presentados en este trabajo. El primer paso es mostrar los resultados en cada paso de las metodologías propuestas en cada caso de estudio y comparándolas contra otras técnicas. Finalmente se describirán sus ventajas.

4.1 Caso de estudio 1: Análisis de la metodología de diagnóstico en el dominio del tiempo.

Lo primero que se realiza después de que las señales de vibración fueron adquiridas es la estimación de características, lo cual se lleva a cabo tomando ventanas de 0.5 s. La longitud de la ventana se selecciona debido a que el estado transitorio dura aproximadamente ese tiempo, de esta manera, las características serán capaces de describir el comportamiento del transformador en estado transitorio y estable. Cada señal tiene una duración de 5 s, entonces se obtienen 10 ventanas de tiempo de cada señal. Por cada ventana de tiempo se calculan 19 STFs. Por lo que se produce una matriz de 1600X57, es decir, que se tienen 20 pruebas con 10 ventanas de tiempo para 8 diferentes condiciones con 19 STFs de tres ejes. Aunque en un paso subsecuente se observó que las características estimadas del eje z no presentan información relevante, por lo que esas características son descartadas para evitar carga computacional en la etapa de diseño. La matriz resultante es de 1600X38 y para que estén en el mismo marco de referencia, todas las características se normalizan utilizando la ecuación (77) (Bigdeli et al., 2012). Donde x representa cada columna de la matriz de datos, μ_0 y σ_0 son la media y la desviación estándar de X ; es decir, de la condición sana, para únicamente toma esta condición como referencia. Como ejemplo de los resultados obtenidos, las características, es decir, valores entre -1 y 1 sin unidades para 0 y 35 SCTs se muestran en la Figura 31, en la que puede ser observado que existe una clara diferencia entre las clases, lo que indica la posibilidad de establecer un clasificador automático.

$$\mathbf{X} = \frac{\mathbf{x} - \mu_0}{\sigma_0} \quad (77)$$

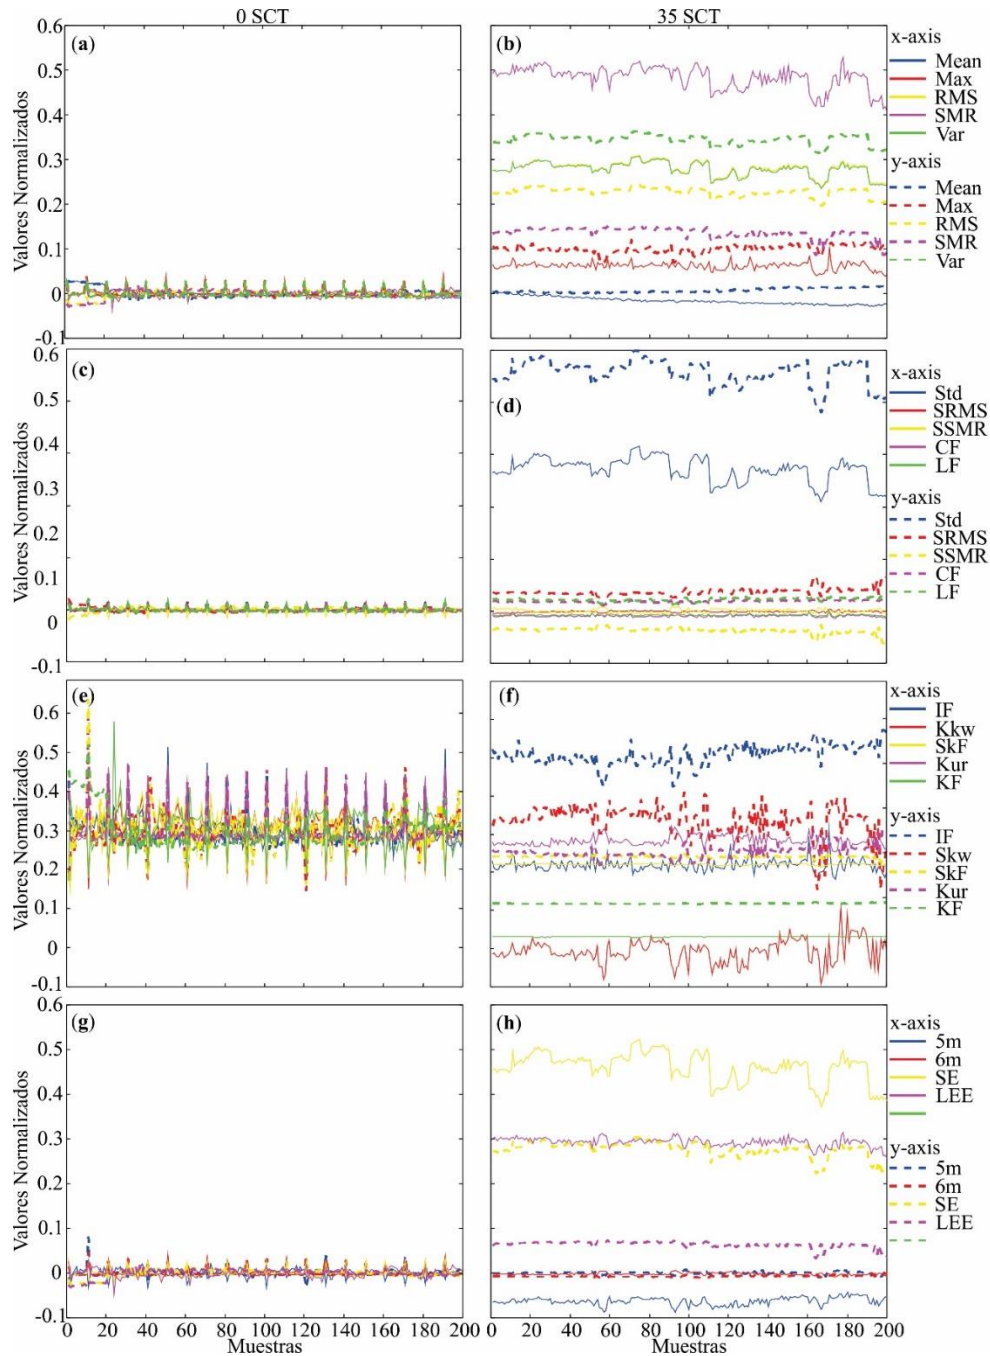


Figura 31. Características estimadas normalizadas en la condiciones sana y de 35 SCTs de falla: (a) Media, valor máximo, RMS, SMR y varianza para 0 SCTs; (b) Media, valor máximo, RMS, SMR y varianza para 35 SCTs; (c) desviación estándar (Std), factor forma (RMS) (SRMS), factor forma (SRM) (SSRM), fator cresta (CF) y factor latitud para 0 SCT; (d) desviación estándar (Std), factor forma (RMS) (SRMS), factor forma (SRM) (SSRM), fator cresta (CF) y factor latitud para 35 SCT; (e) factor impulso (IF), oblicuidad (Skw), factor de oblicuidad (SkF), curtosis (Kur) y factor curtosis (KF) para 0 SCTs; (f) factor impulso (IF), oblicuidad (Skw), factor de oblicuidad (SkF), curtosis (Kur) y factor curtosis (KF) para 35 SCTs; (g) 5to momento normalizado (5m), 6to momento normalizado (6m), entropía de Sahnnon (SE) y energía de

entropía logarítmica (LEE) para 0 SCTs; (h) 5to momento normalizado (5m), 6to momento normalizado (6m), entropía de Sahnnon (SE) y energía de entropía logarítmica (LEE) para 35 SCTs.

Un gran número de características no significa que todas ellas provean información representativa que logre describir el comportamiento del sistema, por lo que el objetivo de la selección de características es filtrar esas características para obtener un subconjunto más informativo. Este proceso se lleva a cabo por medio del cálculo del valor de Fisher, que es una medida en términos de distancia entre los datos de diversas clases. Un valor de Fisher grande representa una gran distancia entre las características, lo que significa que esas características son más relevantes. Sin embargo, el método debería ser evaluado en $2^m - 1$ subconjuntos, donde m representa el número total de características en el conjunto de datos. Para este caso, el número de características es de 38, es decir, 19 del eje x y 19 para el eje y . El cálculo de todos esos subconjuntos es computacionalmente inviable, por lo que se propone un método heurístico para encontrar el subconjunto de características más apropiado sin un alto costo computacional (Jović et al., 2015). Se genera un subconjunto de la combinación de tres características, es decir, se crean 8436 diferentes subconjuntos. Consecuentemente, esos subconjuntos son evaluados a través del valor de Fisher, y las mejores 10 combinaciones son elegidas, es decir, los subconjuntos con los 10 valores de Fisher más altos. Este proceso será replicado para todas las combinaciones de las condiciones para encontrar la máxima separabilidad entre clases. De esta manera, teniendo 8 condiciones de falla, el número de combinaciones es 28, lo que implica 236,208 cálculos del valor de Fisher, lo que es despreciable comparado con las $2^m - 1$ combinaciones. Ahora, las características el mayor número de apariciones sobre un valor de umbral, se toman como parte de un nuevo subconjunto, en este trabajo se considera un valor de umbral de 35. El nuevo subconjunto de características se selecciona y contiene las características 4, 15, 19, 22, 24, 25 y 34, como se muestra en el histograma de apariciones (Figura 32). Estas características corresponden a SRM, factor curtosis y LEE del eje x , mientras que para el eje y son RMS, desviación estándar, varianza y factor curtosis.




Figura 32. Histograma de las mejores características.




Figura 33. Comparación de desempeño entre (a) transformación PCA y (b) transformación LDA.

Tabla 4. Porcentajes de precisión de la SVM y ANN con diferentes valores de umbral de acuerdo con lo que se muestra en la Figura 31.

| Umbral de características | Características | SVM (%) | ANN (%) |
|---------------------------|-----------------|---------|---------|
| 0 | 38 | 97.76 | 95.29 |
| 30 | 10 | 96.76 | 93.98 |
| 35 | 7 | 96.82 | 94.97 |
| 40 | 5 | 96.64 | 94.33 |

El siguiente paso es extraer las características, en este proceso se obtiene un nuevo subconjunto de características en dos dimensiones a través de una transformación del subconjunto original de datos. Como fue mencionado anteriormente, LDA y PCA pueden ofrecer diferentes transformaciones del conjunto de datos. En la Figura 33 se muestran las transformaciones obtenidas usando ambas técnicas. En la Figura 33a se muestra la transformación realizada con la técnica PCA, mientras que en la Figura 33b se observa la transformación realizada con la técnica LDA. Aunque en ambas transformaciones se obtienen buenos resultados, para LDA se observa la mejor agrupación en términos de área, por lo que esta se selecciona para el paso de transformación de los datos para la reducción de dimensiones.

Para el entrenar el algoritmo de clasificación (SVM) se utilizó el software de Matlab. Los parámetros de mayor influencia para lograr una clasificación precisa son σ and C , para encontrar los mejores valores de estos parámetros se llevó a cabo un análisis exhaustivo de prueba y error, donde los valores encontrados fueron de 0.25 y 50, respectivamente. El entrenamiento y validación se realizó la validación k -fold donde k tiene un valor de cinco. Para comparar el desempeño de la SVM, se utilizó una ANN. Los parámetros de la ANN se eligen por prueba y error, obteniendo

una ANN con siete entradas (siete características), en la capa oculta tiene nueve neuronas y ocho neuronas (ocho condiciones de SCTs) en la capa de salida. La función de activación es log-sigmoide en la capa oculta y lineal en capa de salida. Los resultados muestran que la SVM tiene un mejor desempeño que la ANN cuando se utiliza el mismo número de características. Los resultados de ambos clasificadores se muestran en la Tabla 4.

Como se observa en la Tabla 4, la SVM tiene mejor desempeño que la ANN en cada subconjunto de características seleccionadas. El número de características en cada subconjunto se define por el valor de umbral que se obtuvo en la selección de características (ver la Figura 32). Para ambos clasificadores, los mejores resultados son cuando se utilizan todas las características, es decir cuando el valor de umbral es cero. Para mantener el balance entre el número de características y el desempeño del clasificador, el valor de umbral seleccionado es de 35, es decir el valor para obtener siete características. Este subconjunto de características brinda el mejor desempeño que el conjunto de 10 características, disminuyendo sólo uno por ciento comparado con el subconjunto de 38 características, lo que implica una reducción bastante notable de la carga computacional. En la Tabla 5 se observa la matriz de confusión usando la validación k -fold y específicamente cuando $k = 3$ y como se puede observar, únicamente un dato fue mal clasificado, obteniendo una efectividad de 99.7%. Debe notarse que para cualquier condición que no haya sido contemplada en el proceso de entrenamiento, la clase resultante será *No clasificado* o ser de alguna de las clases adyacentes (por ejemplo, para una condición de 7 SCTs, la clase resultante podría ser 5 SCTs o 10 SCTs dependiendo de la región de decisión). Para una mejor resolución y efectividad en la clasificación de la severidad de la falla, se deberá profundizar en la investigación para clasificar condiciones interpoladas y extrapoladas.

En la Figura 34 se muestran las agrupaciones y sus regiones de decisión que resultan de la SVM usando una validación k -fold. En particular, la Figura 34a muestra las agrupaciones que se producen cuando el valor de umbral es de 35, es decir 7 características, a las cuales se les aplica la transformación LDA. también puede notarse que para las condiciones iniciales; sano (azul), 5 SCTs(amarillo), 10 SCTs(rojo) y algunos puntos de 15 SCTs (verde), las agrupaciones están muy cerca entre ellas, incluso algunos puntos se mezclan, sin embargo, aún es posible diferenciarlas y definir las fronteras entre las regiones de decisión tal como se muestra en la Figura 34b. el resto de agrupaciones (20, 25, 30 y 35) no presentan complicaciones. Las Figuras 34c-d muestran los resultados de diferentes k validaciones. En la Figura 34c se muestran los resultados para $k=4$, donde se observa que algunos puntos son mal clasificados, principalmente puntos de las condiciones 5 SCTs y 10 SCTs, aunque la precisión se mantiene por encima del 90%. La Figura 34d muestra los resultados para $k=3$, en la que se observa que los puntos de validación son clasificados adecuadamente.

Tabla 5. Matriz de confusión de la clasificación SCTs usando validación cruzada k -fold cuando $k=3$.

| SCTs | 0 | 5 | 10 | 15 | 20 | 25 | 30 | 35 |
|------|----|----|----|----|----|----|----|----|
| 0 | 40 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| 5 | 0 | 40 | 1 | 0 | 0 | 0 | 0 | 0 |
| 10 | 0 | 0 | 39 | 0 | 0 | 0 | 0 | 0 |
| 15 | 0 | 0 | 0 | 40 | 0 | 0 | 0 | 0 |
| 20 | 0 | 0 | 0 | 0 | 40 | 0 | 0 | 0 |
| 25 | 0 | 0 | 0 | 0 | 0 | 40 | 0 | 0 |
| 30 | 0 | 0 | 0 | 0 | 0 | 0 | 40 | 0 |
| 35 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 40 |




Figura 34. Clasificación de la SVM: (a) usando un conjunto de 7 características; (b) proyección de las regiones de decisión y su entrenamiento cuando se utiliza un 5-fold; (c) proyección de las regiones de decisión y su entrenamiento cuando $k=4$ y (d) proyección de las regiones de decisión y su entrenamiento cuando $k = 3$.

Una vez que la metodología ha sido desarrollada y validada, también la solución basada en FPGA es implementada para desarrollo futuro de equipo tal como sensores inteligentes, sistemas flexibles que incluyen software, algunos sensores con implementaciones reales, entre otras. La Figura 35 muestra la arquitectura principal del procesador en la FPGA propuesta. En general, el procesador basado en FPGA consiste en cuatro principales pasos. El primer paso es la estimación de características en la que las STFs se calculan de las señales de vibración de los ejes x y y . El segundo y tercer paso son la normalización y extracción de características. Finalmente, la etapa de clasificación SVM clasifica la nueva muestra dentro de alguna particular condición de SCTs.

Los tiempos de procesamiento de cada núcleo y sus errores relativos se muestra en la Tabla 6. Se puede notar que el tiempo de procesamiento (en ciclos de reloj) depende de: el número de datos N , el ancho de cada dato (es decir, e y f , los cuales son las partes enteras y fraccionarias de cada dato, respectivamente) y el número máximo de vectores de soporte. En este trabajo, $N=3000$ y $N_{sv}=192$, donde N_{sv} es el número de vectores de soporte. El tiempo de procesamiento de la característica SRM es el mayor de las siete características atendidas, es por eso que este tiempo se toma como el tiempo de la etapa de estimación de características. Aunque, el número total de ciclos corresponde a la suma de los ciclos de reloj de la SMR, de las etapas de normalización de características, de la extracción de características y la SVM. El número total de ciclos de la etapa de la SVM es el número de ciclos de la SVM con el mayor número de vectores de soporte. Consecuentemente, el tiempo total cuando se emplea un reloj de 50 MHz es alrededor de 1.24 ms (806 Hz). El error relativo se obtiene comparando los valores estimados en Matlab usando punto flotante y los estimados por los núcleos de procesamiento que utilizan punto fijo. Por otro lado, a pesar de que el máximo error relativo es dos por ciento, este resultado puede ser considerado suficientemente preciso ya que la diferencia entre los valores es de un orden de magnitud de 10^{-3} .

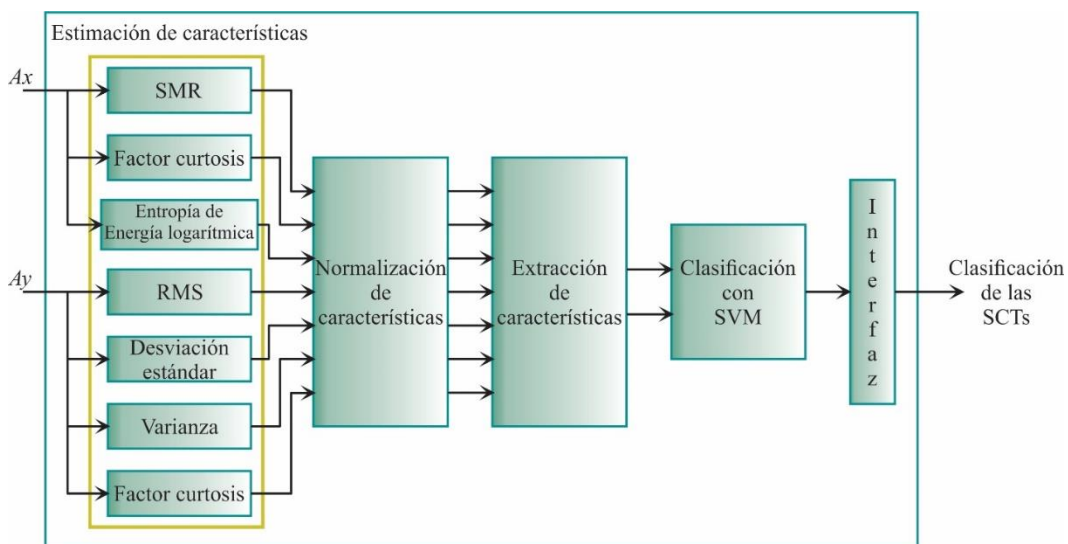


Figura 35. Arquitectura principal del procesador basado en FPGA.

Tabla 6. Tiempo y error relativo de cada núcleo de procesamiento.

| Estructura Digital | Ancho de palabra | Tiempo (Ciclos de reloj) | Error Relativo (%) |
|-------------------------------------|------------------|----------------------------------------|--------------------|
| SVM | $e = 7, f = 20$ | $2 + 10N_{sv}$ | 0.33 |
| Extracción de Características | $e = 2, f = 16$ | 14 | 0.3 |
| Normalización de Características | $e = 2, f = 16$ | 10 | 1.67 |
| SRM | $e = 2, f = 16$ | $(N+1)(e+f+2)+1$ | 2 |
| Factor Curtosis | $e = 24, f = 16$ | $4(e+f)+3N+35$ | 0.05 |
| Entropía de Energía logarítmica | $e = 16, f = 16$ | $N(f+2)+2$ | 1.11 |
| RMS | $e = 2, f = 16$ | $2(e+f)+N+5$ | 0.004 |
| Desviación Estándar | $e = 2, f = 16$ | $2(e+f)+N+6$ | 0.002 |
| Varianza | $e = 2, f = 16$ | $e+f+N+5$ | 0.0002 |
| Tiempo total con un Reloj de 50 MHz | | 61,967 ciclos de reloj 1,239,340 ns | |

Tabla 7. Recursos de la FPGA utilizados.

| Estructura Digital | Elementos Lógicos (%) | Registros (%) | Multiplicadores 9-bit (%) | Bits de Memoria (%) |
|----------------------------------|-----------------------|---------------|---------------------------|---------------------|
| SVM | 6361 (6%) | 1564 (1%) | 256 (48%) | 0 (0%) |
| Extracción de Características | 178 (<1%) | 101 (<1%) | 4 (<1%) | 73,728 (2%) |
| Normalización de Características | 478 (<1%) | 144 (<1%) | 20 (4%) | 0 (0%) |
| SRM | 360 (<1%) | 166 (<1%) | 6 (1%) | 0 (0%) |
| Factor Curtosis | 1818 (2%) | 870 (<1%) | 35 (7%) | 0 (0%) |
| Energía de Entropía Logarítmica | 221 (<1%) | 121 (<1%) | 6 (1%) | 0 (0%) |
| RMS | 315 (<1%) | 184 (<1%) | 6 (1%) | 0 (0%) |
| Desviación estándar | 577 (<1%) | 336 (<1%) | 10 (2%) | 0 (0%) |
| Varianza | 513 (<1%) | 300 (<1%) | 8 (2%) | 0 (0%) |
| Total del Procesador | 12,639 (12%) | 4656 (5%) | 386 (73%) | 73,728 (2%) |

La Tabla 7 resume los recursos de la FPGA utilizados por cada núcleo de procesamiento. Como se puede observar, la mayoría de los núcleos ocupan menos del 2% de los recursos disponibles, excepto por el número de multiplicadores. Esos resultados indican que el procesador

basado en FPGA puede ser implementado tanto en la FPGA utilizada en este trabajo o algunas otras FPGA disponibles comercialmente que tengan un número equivalente de multiplicadores, pero con muchos menor elementos, registros y bits de memoria, lo que podría reducir los costos de implementación

4.2 Caso de estudio 2: Análisis de la metodología de diagnóstico con transformación de dominio.

Como se mencionó en la metodología de este primer caso de estudio, una vez adquiridas las señales de vibración hay que aplicar la técnica NMD, la cual descompondrá la señal sus modos no lineales. Las señales de vibración se componen tanto del estado transitorio como del estado estable, debido al transitorio del arranque aplicar técnicas convencionales como lo es la FT arrojará información no fidedigna debido a su desventaja inherente de las señales transitorias, por lo que aplicar la NMD arrojará mejor información. En la Figura 36 se muestran tanto la señal analizada como modos no lineales extraídos de esta, aunque sólo se muestran los casos extremos, es decir, la condición sana; 0 SCTs y la condición más extrema de falla; 25 SCTs. A las señales de la Figura 36a se les aplica la NMD. Los resultados se muestran en las Figuras 36b-f, donde se observa cuatro descomposiciones (modos no lineales) y un residuo. Aunque, para algunos ejes se podrían extraer más NMs, pero la información no es relevante para realizar la clasificación, por lo que toda esa información se quedará en el residuo. En esas gráficas, y comparando cada condición de SCT de cada eje se observa que existe cierto nivel de amplitud que difiere entre las condiciones, esto puede ser de utilidad para identificar la severidad de la falla.

Sin embargo, si se aplica la HT a los modos y residuos se obtiene un parámetro relacionado a la amplitud, es decir, el valor RMS instantáneo; estimado con la ecuación (63) y mostrado en la Figura 37. Con el fin de reducir el número de modos analizados, los modos más significativos deben ser seleccionados. Con una inspección visual, el NM1 de A_y (los gráficos sombreados) muestran la máxima separación entre condiciones; por eso mismo, es seleccionado para llevar a cabo la clasificación incluyendo otros niveles de severidad de la falla. Con el fin de mejorar la separación de las amplitudes suavizando las variaciones se aplica un MAF de orden 100. El orden se selecciona entre el tiempo de convergencia y el nivel de suavidad de la señal por el tiempo en que converge a un nivel de suavizado deseado; en esta etapa, el contenido frecuencial no es tan importante ya que ya se ha aplicado el NMD. Después de un exhaustivo análisis, se identificó los mejores resultados, que se obtienen dos modos, el NM4 del eje A_x y el NM1 del A_y . La Figura 38 muestra los resultados para todas las condiciones de falla de SCT, en general se observa una tendencia proporcional debida a la severidad de la falla, esto indica que el índice RMS es sensitivo a la severidad de la falla tanto en estado transitorio como estable, lo cual es posible porque el método NMD permite analizar señales no estacionarias. En particular, la tendencia no es proporcional para las condiciones de 20 SCT y 15 SCT del NM4 del eje A_x , pero con la separación entre ellas permite su correcta identificación.

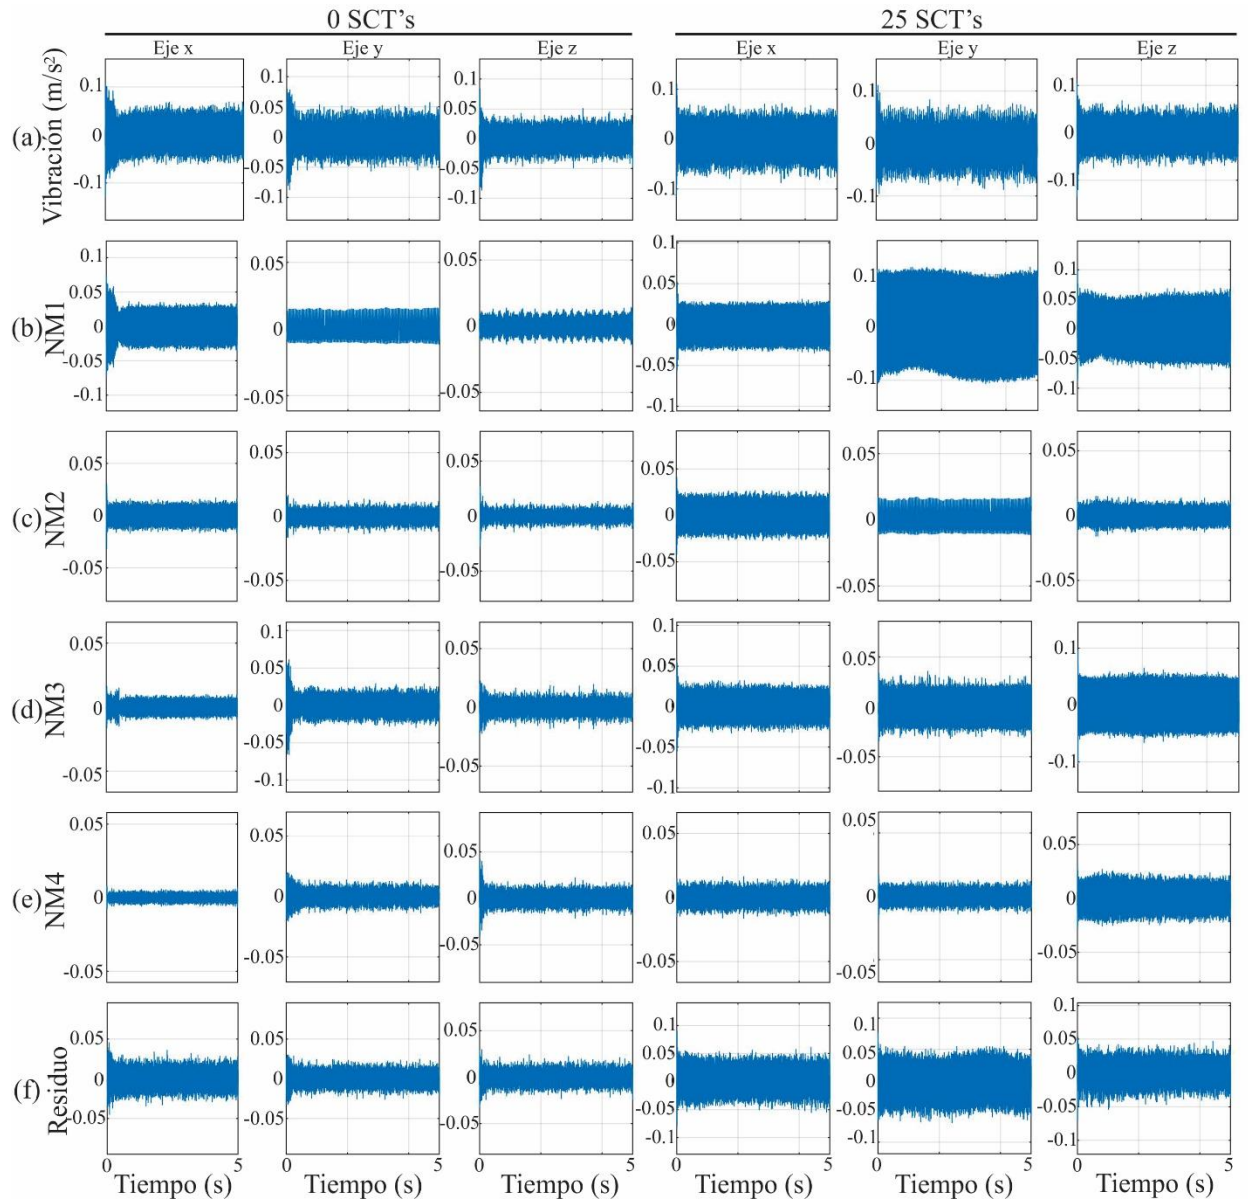


Figura 36.(a) Señales de vibración, (b) modo no lineal 1 (NM1), (c) modo no lineal 2 (NM2), (d) modo no lineal 3 (NM3), (e) modo no lineal 4 (NM4) y (f) residuos.

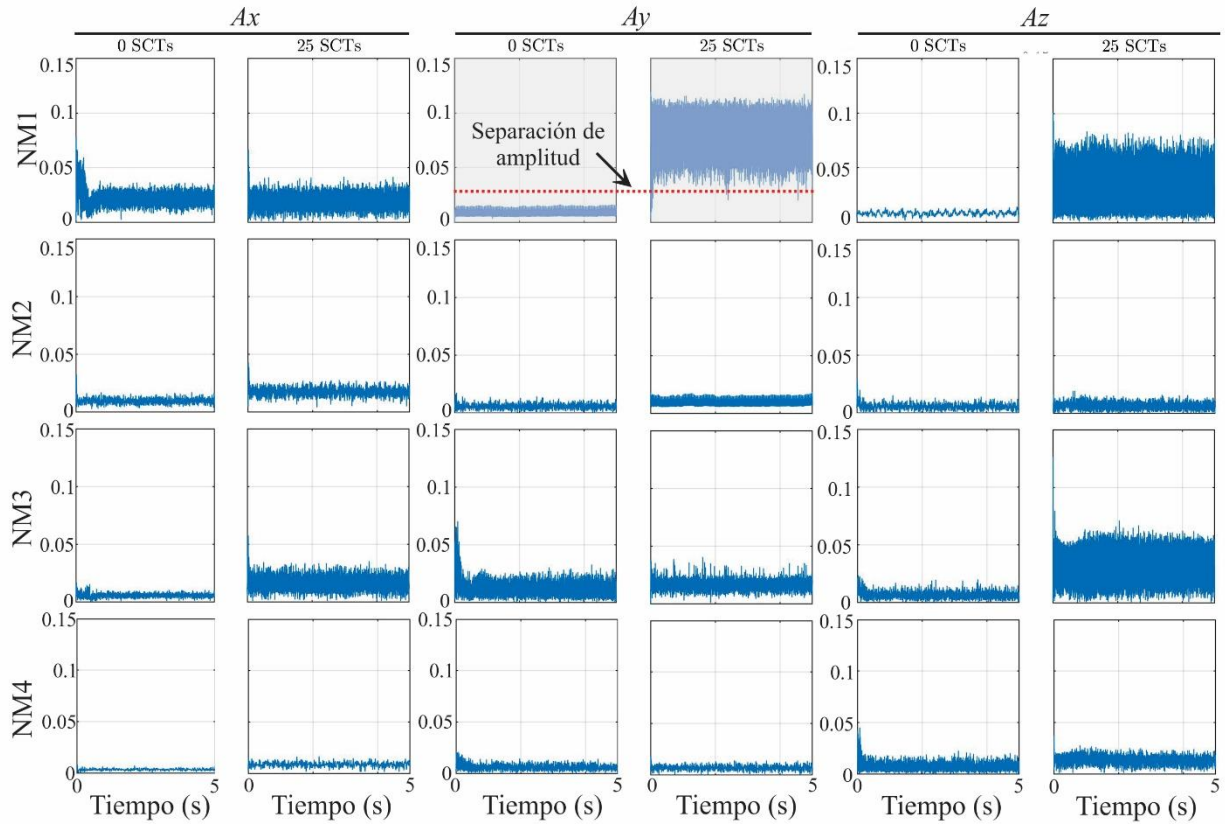


Figura 37. Valor cuadrático medio (RMS) de los diferentes NMs.




Figura 38. Valores RMS de todas las condiciones SCTs: (a) NM4 del eje x y (b) NM1 del eje y.

Para la clasificación automática es propuesto un sistema FL. Para obtener información de los datos de entrada, se calculan la media y desviación estándar de los valores RMS de cada una de las 20 pruebas de cada condición. En la Tabla 8 se muestran los valores obtenidos. De esos

resultados es evidente que, se puede llevar a cabo un proceso de fusificación por medio de funciones de membresía Gaussianas. Para esto se usa un sistema de inferencia difusa tipo Mamdani. Tiene dos entradas, 36 reglas y una salida. En la Figura 39 se muestran las funciones de membresía propuestas para dos entradas, NM1 A_y y NM4 A_x , además de la una salida que será la condición del transformador. Las funciones de membresía de la Figura 39a se etiquetan como: valor muy pequeño (VS, del inglés *very small*), valor pequeño (S, del inglés *small*), valor normal (N), valor alto (H, del inglés *high*), valor muy alto (VH, del inglés *very high*) y valor extremadamente alto (VMH, del inglés *very much high*). Por otro lado, la salida más nítida mostrada en la Figura 39b puede tener valores en el rango de 0.5 a 6.5, donde 0 SCTs = 1, 5 SCTs = 2, 10 SCTs = 3, 15 SCTs = 4, 20 SCTs = 5 y 25 SCTs = 6. En la Tabla 9 se muestran las reglas de inferencia usadas, donde cada regla se lee como sigue (marcadas en gris), si NM4 es N y NM1 es N entonces la salida es 10 SCTs. El mecanismo de inferencia lleva a cabo una composición mínima para cuantificar el valor de salida y la defusificación usa el centro de gravedad.

Finalmente, para probar la metodología general, se evalúan 20 pruebas de cada condición (0, 5, 10, 15, 20, 25 y 30 SCTs). La Tabla 10 muestra los resultados obtenidos como una matriz de confusión. En la diagonal de la matriz de confusión, se presenta el número de pruebas que han sido correctamente clasificadas. Como se observa, hay una efectividad de 100% para las condiciones a partir de 10 SCTs, lo cual es esperado ya que, a mayor severidad de falla, es más fácil detectarla. Sin embargo, para 5 SCTs se alcanza una efectividad de 90% lo que es bastante bueno, principalmente considerando que a menor severidad de falla se pueden generar cambios imperceptibles en las vibraciones. Es importante mencionar que, la mayoría de las severidades en las fallas podrían ser identificadas sólo usando la información que provee el NM1 A_y ; como muestran los resultados en la Figura 39b, sin embargo, en los casos donde la funciones Gaussianas se traslapan, es necesario otra fuente de información para facilitar el proceso de toma de decisiones.

Tabla 8. Media (\bar{x}) y desviación estándar (σ) para los valores RMS.

| SCT | | A_x | | | | A_y | | | |
|-----|-----------|--------|----------|----------|----------|----------|----------|----------|----------|
| | | NM1 | NM2 | NM3 | NM4 | NM1 | NM2 | NM3 | NM4 |
| 0 | \bar{x} | 0.0186 | 0.0125 | 0.0103 | 0.0037 | 0.0103 | 0.0059 | 0.0098 | 0.0024 |
| | σ | 0.0021 | 0.0012 | 0.000669 | 0.000544 | 0.000734 | 0.000711 | 0.0025 | 0.00028 |
| 5 | \bar{x} | 0.0124 | 0.012 | 0.0075 | 0.0044 | 0.0118 | 0.0115 | 0.0116 | 0.0057 |
| | σ | 0.0019 | 0.0021 | 0.000657 | 0.000411 | 0.000992 | 0.000914 | 0.0013 | 0.000652 |
| 10 | \bar{x} | 0.0194 | 0.0106 | 0.0092 | 0.0074 | 0.0167 | 0.0156 | 0.0102 | 0.0052 |
| | σ | 0.0016 | 0.0012 | 0.000789 | 0.000536 | 0.001 | 0.0014 | 0.000627 | 0.000537 |
| 15 | \bar{x} | 0.0215 | 0.0114 | 0.0113 | 0.0096 | 0.0376 | 0.0191 | 0.0104 | 0.0114 |
| | σ | 0.0024 | 0.000659 | 0.000934 | 0.000781 | 0.0023 | 0.001 | 0.000744 | 0.000971 |
| 20 | \bar{x} | 0.0151 | 0.0152 | 0.0116 | 0.0092 | 0.0611 | 0.0195 | 0.0104 | 0.0115 |
| | σ | 0.0021 | 0.0018 | 0.000997 | 0.000841 | 0.004 | 0.0011 | 0.000796 | 0.000709 |
| 25 | \bar{x} | 0.0219 | 0.0179 | 0.0097 | 0.0178 | 0.0753 | 0.0107 | 0.0165 | 0.0092 |
| | σ | 0.0019 | 0.0013 | 0.0011 | 0.0013 | 0.0044 | 0.000566 | 0.000888 | 0.000585 |




Figura 39. Funciones de membresía para (a) entradas y (b) salidas.

Tabla 9. Reglas para el Sistema de lógica difusa propuesto.

| Entradas | NM1 | | | | | |
|----------|-----|----|----|----|----|----|
| | NM4 | VS | S | N | H | VH |
| VS | 0 | 5 | 10 | 15 | 20 | 25 |
| S | 0 | 5 | 10 | 15 | 20 | 25 |
| N | 0 | 5 | 10 | 15 | 20 | 25 |
| H | 0 | 10 | 10 | 15 | 20 | 25 |
| VH | 0 | 10 | 10 | 15 | 20 | 25 |
| VMH | 5 | 10 | 15 | 20 | 25 | 25 |

Todos los valores numéricos son SCTs.

Tabla 10. Matriz de confusión.

| | 0 SCTs | 5 SCTs | 10 SCTs | 15 SCTs | 20 SCTs | 25 SCTs | Efectividad (%) |
|---------|--------|--------|---------|---------|---------|---------|-----------------|
| 0 SCTs | 19 | 1 | 0 | 0 | 0 | 0 | 95 |
| 5 SCTs | 1 | 18 | 1 | 0 | 0 | 0 | 90 |
| 10 SCTs | 0 | 0 | 20 | 0 | 0 | 0 | 100 |
| 15 SCTs | 0 | 0 | 0 | 20 | 0 | 0 | 100 |
| 20 SCTs | 0 | 0 | 0 | 0 | 20 | 0 | 100 |
| 25 SCTs | 0 | 0 | 0 | 0 | 0 | 20 | 100 |

En este caso, el sistema FL propuesto junto con la información que proveen las dos entradas permiten superar de una mejor manera la incertidumbre generada cuando las clases se traslapan.

En particular, el trabajo propuesto tiene algunas ventajas que deben ser resaltadas. Por ejemplo, este trabajo logra identificar diferentes niveles de falla de corto circuito en los devanados

del transformador. También, este caso de estudio puede detectar la falla considerando tanto el estado transitorio como el estable. Por otro lado, este caso de estudio ofrece un diagnóstico automático lo que evita la necesidad de un usuario experto. Finalmente, el trabajo puede ser considerado como una solución de baja complejidad ya que únicamente requiere de tres pasos (I) procesar la señal (con el NMD), (II) obtener un indicador de falla (HT-RMS) y (III) un diagnóstico automático (FLS) considerando diferentes niveles de severidad tanto en el estado transitorio como el estable.

4.3 Caso de estudio 3: Análisis del modelo basado en vibraciones.

Habiendo obtenido las señales de vibración; como la que se muestra en la Figura 40, se debe obtener su espectro con la finalidad de extraer la amplitud y fase de cada uno de los armónicos; 120, 240, 360, 480, 600, 720, 840 y 960 Hz, dentro del ancho de banda de interés. Las amplitudes y fases extraídas son como se muestran en la Figura 41a-b. Estos valores de amplitud y fase extraídos serán con los que se entrena la red neuronal; específicamente, estos valores son los de la salida de la red neuronal, mientras que, los valores de entrada dependerán de cada condición, tal como se muestra en la Tabla 3. Por ejemplo, si se desea seleccionar que el transformador sea alimentado con una fuente que contenga un 5% de desbalance, la primera entrada; desbalance debe ser 3. La segunda entrada se define por la carga, si se desea que contenga armónicos debe seleccionarse la carga no lineal, entonces la entrada es un 3. Finalmente, en la última entrada se selecciona la severidad del SCT, si se desea que contenga 5 SCTs la entrada deberá ser 5. Esta combinación será [3;3;5]; 5% de desbalance con contenido armónico y 5 SCTs. Posterior a esto, se agrupan todos los datos de entrada (tres en cada muestra) y todos los valores de salida, que son tanto para la amplitud y para fase (ocho de cada muestra). De esta manera se genera una matriz de datos de entrada de 3 x 720; con esta matriz se entrenan las ANN de amplitudes y de fases, mientras que, para las salidas, se construye una matriz de salidas de 8 x 720; una para amplitudes y una para fases.




Figura 40. Señal de vibraciones en estado estable de la fase del transformador que emula SCTs.




Figura 41. a) Amplitudes de los armónicos y b) fases de los armónicos.

El siguiente paso es entrenar las redes neuronales y con el propósito de encontrar la mejor estructura de estas, se prueban tres estructuras; es decir, ANNs de 1, 2 y 3 capas ocultas. La ANN es alimentada hacia adelante y entrenada con el algoritmo de retro propagación. Para las ANNs de una capa oculta se prueban desde una neurona hasta 20 en esa capa oculta, mientras que, para las ANNs de dos capas ocultas, se prueban las condiciones de una hasta 20 neuronas tanto en la primera capa oculta como en la segunda capa oculta, de la misma manera para las ANNs de 3 capas ocultas; desde una hasta 30 neuronas en cada una de sus capas ocultas.

En cada una de las estructuras de las ANNs entrenadas se busca la que tenga el menor error cuadrático medio (MSE, del inglés *mean squared error*), tal como se muestra en las Figuras 42a-f. En la Figura 42a se muestra el MSE para las diferentes ANNs con diferente número de neuronas en la su capa oculta, mientras que en la Figura 42b se muestra el MSE para las diferentes ANNs con los diferentes combinaciones de neuronas en su capas ocultas, en la Figura 42c el MSE para las diferentes combinaciones de número de neuronas en cada capa de una ANN con tres capas ocultas, estas combinaciones son para buscar la mejor estructura de ANN para la amplitud de las frecuencias de las vibraciones. De la misma manera, pero para las fases, en las Figuras 42d-f se busca la mejor estructura de la ANN. De estas figuras se logra observar que las mejores estructuras de las redes neuronales son: para la amplitud, la estructura de dos capas ocultas, con 16 neuronas en la primera capa oculta y 20 en la segunda capa oculta, mientras que, para las fases la mejor configuración es la estructura con dos capas ocultas, la cual tiene 20 neuronas en la primera capa y 18 en la segunda capa oculta. Con estos valores en las estructuras de las ANNs el modelo puede ahora entregar las amplitudes y fases para reconstruir la señal.

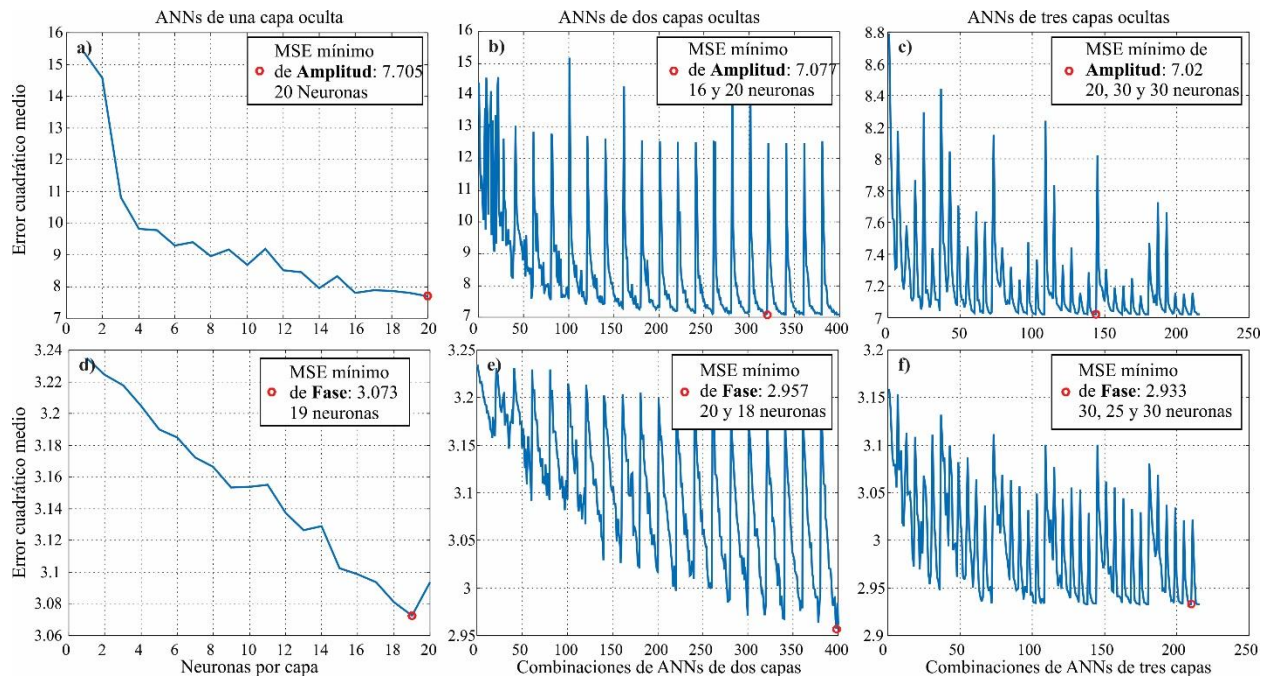


Figura 42. Desempeños de las distintas estructuras de las ANN (a) Amplitud de ANN con una capa oculta, (b) Amplitud de ANN con dos capas ocultas, (c) Amplitud de ANN con tres capas ocultas, (d) Fase de ANN con una capa oculta, (e) Fase de ANN con dos capas ocultas y (f) Fase de ANN con tres capas ocultas.

Con las arquitecturas de las ANNs se obtienen los valores tanto de las amplitudes como de las fases, con estos se pudo reconstruir la señal de vibración para diferentes condiciones de desbalance en la fuente de alimentación, así como con o sin carga, con contenido armónico y diferentes fallas por SCT. En la Figura 43, se muestran los valores que se predicen con el modelo de las amplitudes y de las fases donde se comparan a su vez con los valores reales de las diferentes pruebas realizadas. En esta imagen se estimaron los valores para la condición donde la fuente de alimentación no contiene desbalance, tampoco tiene carga y tampoco tiene espiras en corto circuito en los devanados del transformador; es decir la condición sana, que tiene como entrada para la red neuronal los valores (1;1;0), estos se estiman como se observa en la Tabla 3. En esta prueba se observa que la ANN aprendió correctamente los valores de las amplitudes, ya que estos tienen valores muy similares a los valores reales obtenidos de las pruebas experimentales. Por otro lado, los valores estimados para las fases no son buenos, no precisamente porque la red neuronal este mal, sino porque los valores de las fases de las pruebas con que se entrena la ANN no están sincronizados y tienen una gran dispersión, esto no le facilita a la ANN aprender de manera adecuada causando que los valores estimados junto con los valores reales de las fases varíen. Mientras que, en la Figura 44 se muestran los valores estimados con el modelo para las amplitudes y fases y que a su vez se comparan con los valores reales obtenidos en las pruebas realizadas, sin embargo, la condición que se pide es para valores de interpolación, es decir valores de entrada y salida para los cuales la ANN no fue entrenada, tal como lo es la condición de 7.5% de desbalance, con carga no lineal y 5 SCTs, que corresponde a la entrada (4; 2; 5). Aunque para las amplitudes el MSE aumenta ligeramente el valor estimado es muy cercano al valor que se debería haber

obtenido, esto indica que la interpolación del modelo es buena y el modelo resulta adecuado para obtener señales de vibración bajo diferentes condiciones en fuente de alimentación, carga y SCT. Por el otro lado, las fases siguen mostrando un comportamiento no adecuado impidiendo el aprendizaje correcto de la ANN, en consecuencia, el MSE es mayor y no se logra identificar algún patrón del comportamiento, lo que resulta en valores estimados muy alejados de lo real.

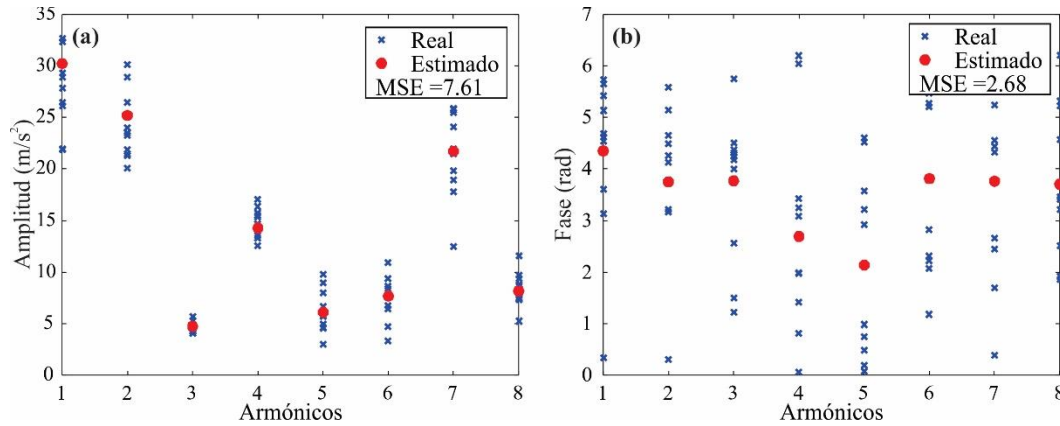


Figura 43. Estimaciones para la entrada en condiciones nominales, sin carga y sin espiras en corto circuito de (a) amplitudes y (b) fases.

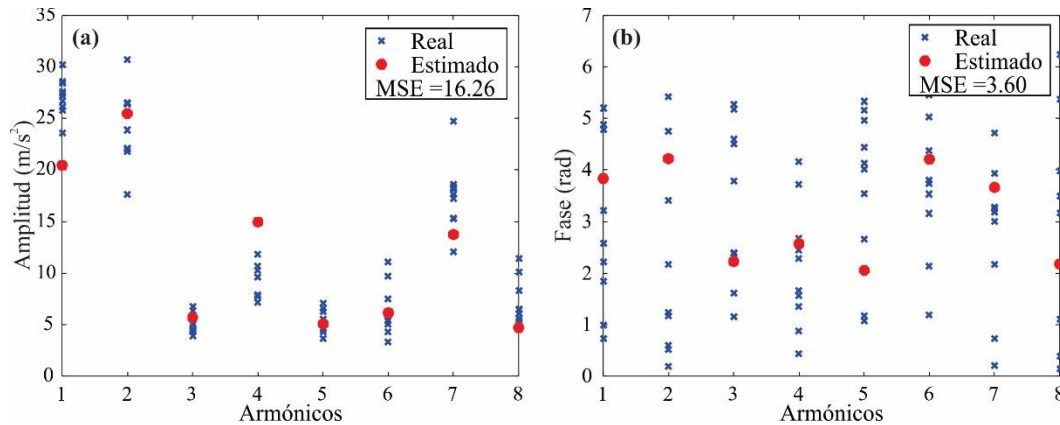


Figura 44. Amplitudes y fases estimadas para una entrada de interpolación de 7.5% de desbalance, con contenido armónico y cinco espiras en corto circuito.

Como se observa en las Figuras 43 y 44, en ambos casos la amplitud se estima adecuadamente mientras que las fases no, esto se debe principalmente a la variación en las fases lo que impide que la ANN aprenda de manera adecuada y por lo mismo genera un error mayor. Por otro lado, ya que el modelo estima los valores de las amplitudes de una manera precisa indica que, la metodología seguida es efectiva. Sin embargo, por falta de sincronía en las pruebas, las fases de las señales de vibración también presentan dicho problema, en consecuencia, las ANNs no aprenden de manera adecuada generando MSE altos.

En las Tablas 11 a 12 se muestra el MSE de las estimaciones de las amplitudes del modelo contra los valores reales, es decir, los valores que se obtuvieron de las distintas pruebas realizadas. En ellas se comparan distintas condiciones, por ejemplo, en la Tabla 11 no hay desbalance en la fuente de alimentación del transformador, pero si se encuentra bajo diferentes condiciones de carga; sin carga, carga lineal y carga no lineal, y con distintas condiciones de falla por corto circuito. Los valores de las tablas se estiman, por ejemplo, para el renglón de 0 SCT, con modelo se estiman las amplitudes bajo la condición sin desbalance, con 0 SCT y para alguna condición de carga, esto arroja ocho valores de amplitud que son comparados con los valores reales de las diferentes condiciones de SCT. Esto es muy semejante a una matriz de confusión.

También en las tablas se observan algunos valores en verde, rojo y amarillo. Los valores en verde son los que presentan el valor MSE mínimo de la comparación alguna condición SCT con las diferentes condiciones de SCT, pero este valor coincide con la condición estimada y real, es decir, cuando el valor es mínimo al comparar un valor estimado de alguna condición con los valores reales de esa misma condición. Por ejemplo, en la Tabla 11 el valor estimado para 0% de desbalance, con 0 SCT y sin carga se compara con los valores reales de esa misma condición (0% de desbalance, 0 SCT y sin carga) dando un valor de 3.331 de MSE, este es el valor mínimo una vez que dicha condición fue comparada con todas las demás condiciones, esto indica que los valores estimados son muy parecidos a los valores reales de esa misma condición. En cambio, los valores en rojo son cuando el valor estimado obtiene el valor MSE mínimo con otra condición, es decir, que los valores estimados para dicha condición se parecen más a los valores de otra condición. Por ejemplo, En la Tabla 11 para la condición de 0% de desbalance, 0 SCT y carga no lineal se parece más a la condición de 0% de desbalance, 2 SCT y carga lineal. Por otro lado, los valores en amarillo representan al segundo valor más pequeño de MSE y que coinciden con la estimación del modelo y los valores reales. Por ejemplo, En la Tabla 11, el valor estimado para 0% de desbalance, con 2 SCT y sin carga comparado con las otras condiciones, muestra que se parece más a la condición de 5 SCT, pero tampoco está muy alejado de parecerse a los valores reales de su misma condición. Esto ayuda a visualizar que el valor estimado no se aleja demasiado de los valores reales.

Lo más deseable sería ver el color verde en la diagonal de cada tabla, pero al ser demasiadas condiciones (135) utilizar únicamente la amplitud del modelo con característica para diferenciarlas podría resultar complicado. Sin embargo, en la mayoría de las Tablas 11 a 17 se observa una tendencia hacia la diagonal, lo que indica que la estimación tiene a ser buena.

Finalmente, las Tablas 11 a 15 mantienen el desbalance y cambian las condiciones de falla de SCT, mientras que en las Tablas 16 a 17 se mantienen en la condición de falla de SCT y cambia el porcentaje de desbalance en la fuente de alimentación; para no colocar 9 tablas por cada condición de SCT sólo se muestran las de 0 SCT (Tabla 16), 5 SCT (Tabla 17) y 10 SCT (Tabla 18). En estas últimas, aunque se logra ver la tendencia hacia la diagonal, los valores están más dispersos complicando lograr identificar correctamente la condición.

Tabla 11. Errores del modelo en diferentes condiciones de SCT, cargas y 0% de desbalance, valores estimados vs. valores reales.

| 0% de desbalance | | 0 SCT | 1 SCT | 2 SCT | 3 SCT | 4 SCT | 5 SCT | 8 SCT | 9 SCT | 10 SCT |
|------------------|-----------------|---------|---------|---------|---------|---------|---------|---------|---------|---------|
| 0 SCT | Sin carga | 3.331 | 23.126 | 14.377 | 9.276 | 17.787 | 14.945 | 8.744 | 9.038 | 9.483 |
| | Carga Lineal | 10.274 | 8.481 | 6.014 | 13.933 | 17.498 | 13.191 | 8.664 | 12.752 | 9.083 |
| | Carga No Lineal | 7.835 | 8.805 | 8.555 | 15.530 | 33.150 | 9.001 | 19.079 | 15.493 | 12.136 |
| 1 SCT | Sin carga | 5.772 | 33.993 | 23.720 | 10.936 | 20.987 | 24.356 | 14.222 | 14.992 | 15.528 |
| | Carga Lineal | 11.916 | 11.240 | 12.063 | 23.293 | 24.307 | 26.567 | 13.854 | 25.313 | 22.223 |
| | Carga No Lineal | 9.812 | 7.905 | 6.262 | 15.850 | 38.895 | 7.193 | 20.709 | 17.256 | 15.551 |
| 2 SCT | Sin carga | 10.119 | 9.950 | 6.742 | 12.489 | 16.857 | 5.228 | 7.371 | 7.128 | 8.440 |
| | Carga Lineal | 9.629 | 7.828 | 9.302 | 15.083 | 20.285 | 17.216 | 10.653 | 17.580 | 14.843 |
| | Carga No Lineal | 14.578 | 9.360 | 4.455 | 17.175 | 42.239 | 9.129 | 28.015 | 20.386 | 19.224 |
| 3 SCT | Sin carga | 18.977 | 9.043 | 15.003 | 12.896 | 12.748 | 11.465 | 9.382 | 10.606 | 14.425 |
| | Carga Lineal | 35.593 | 26.632 | 32.655 | 28.779 | 32.435 | 32.595 | 40.397 | 37.216 | 38.476 |
| | Carga No Lineal | 17.747 | 14.274 | 8.761 | 24.394 | 24.036 | 15.514 | 41.818 | 27.460 | 22.287 |
| 4 SCT | Sin carga | 11.573 | 15.057 | 18.540 | 5.550 | 7.508 | 13.845 | 5.935 | 8.758 | 12.529 |
| | Carga Lineal | 21.840 | 14.735 | 10.148 | 13.756 | 14.941 | 17.358 | 18.289 | 23.310 | 11.240 |
| | Carga No Lineal | 26.255 | 28.517 | 30.790 | 49.501 | 8.182 | 29.013 | 62.734 | 48.218 | 39.856 |
| 5 SCT | Sin carga | 22.070 | 41.232 | 39.469 | 17.763 | 22.547 | 33.509 | 21.963 | 25.311 | 29.281 |
| | Carga Lineal | 149.531 | 144.109 | 124.618 | 153.572 | 136.619 | 170.503 | 138.828 | 176.312 | 138.076 |
| | Carga No Lineal | 26.762 | 22.830 | 27.028 | 49.627 | 31.533 | 20.748 | 58.031 | 47.306 | 47.540 |
| 8 SCT | Sin carga | 12.400 | 7.943 | 10.458 | 7.783 | 8.652 | 6.070 | 5.105 | 5.616 | 9.952 |
| | Carga Lineal | 11.628 | 11.414 | 9.805 | 15.113 | 23.541 | 14.836 | 8.348 | 14.547 | 10.249 |
| | Carga No Lineal | 16.566 | 18.066 | 15.947 | 14.873 | 65.867 | 16.133 | 9.141 | 17.850 | 15.736 |
| 9 SCT | Sin carga | 8.480 | 13.026 | 11.032 | 7.484 | 10.256 | 8.162 | 5.753 | 4.684 | 9.378 |
| | Carga Lineal | 13.233 | 13.377 | 11.767 | 18.777 | 24.885 | 14.210 | 10.096 | 8.620 | 13.869 |
| | Carga No Lineal | 12.162 | 12.092 | 9.720 | 11.677 | 48.481 | 14.926 | 17.067 | 11.033 | 8.976 |
| 10 SCT | Sin carga | 6.904 | 10.571 | 9.603 | 6.847 | 11.038 | 7.350 | 3.970 | 5.575 | 7.101 |
| | Carga Lineal | 12.680 | 9.800 | 8.339 | 10.891 | 18.317 | 11.843 | 10.381 | 15.990 | 7.617 |
| | Carga No Lineal | 9.957 | 9.961 | 7.425 | 11.244 | 43.293 | 10.912 | 15.238 | 12.388 | 9.412 |

Tabla 12. Errores del modelo en diferentes condiciones de SCT, cargas y 2.5% de desbalance, valores estimados vs. valores reales.

| 2.5% de desbalance | | 0 SCT | 1 SCT | 2 SCT | 3 SCT | 4 SCT | 5 SCT | 8 SCT | 9 SCT | 10 SCT |
|--------------------|-----------------|--------|--------|--------|--------|--------|--------|--------|--------|--------|
| 0 SCT | Sin carga | 7.997 | 10.622 | 11.646 | 11.984 | 15.381 | 10.589 | 14.593 | 13.435 | 10.045 |
| | Carga Lineal | 15.620 | 12.950 | 28.529 | 12.506 | 8.954 | 10.198 | 14.208 | 18.998 | 16.342 |
| | Carga No Lineal | 8.526 | 8.250 | 10.514 | 17.991 | 17.257 | 14.992 | 11.250 | 9.138 | 12.968 |
| 1 SCT | Sin carga | 17.428 | 16.746 | 15.905 | 16.244 | 16.708 | 14.072 | 23.441 | 13.619 | 15.694 |
| | Carga Lineal | 17.729 | 15.799 | 30.501 | 16.192 | 10.179 | 17.574 | 14.073 | 17.739 | 20.819 |
| | Carga No Lineal | 9.809 | 9.768 | 11.600 | 20.753 | 17.422 | 15.600 | 14.708 | 10.805 | 11.844 |
| 2 SCT | Sin carga | 10.783 | 11.157 | 10.853 | 11.731 | 12.176 | 9.039 | 15.289 | 10.979 | 9.136 |
| | Carga Lineal | 29.302 | 19.723 | 11.203 | 19.039 | 23.254 | 17.701 | 22.404 | 14.333 | 11.048 |
| | Carga No Lineal | 10.880 | 4.938 | 8.590 | 12.810 | 14.333 | 9.125 | 13.653 | 10.122 | 11.734 |
| 3 SCT | Sin carga | 11.513 | 11.907 | 10.645 | 11.204 | 10.364 | 8.641 | 13.631 | 11.292 | 8.919 |
| | Carga Lineal | 46.609 | 36.585 | 16.919 | 31.291 | 46.171 | 29.324 | 39.865 | 28.871 | 22.567 |
| | Carga No Lineal | 14.706 | 6.069 | 7.250 | 7.761 | 8.550 | 6.452 | 17.657 | 18.993 | 16.459 |
| 4 SCT | Sin carga | 14.767 | 14.977 | 12.622 | 12.609 | 10.003 | 10.263 | 14.966 | 12.038 | 10.516 |
| | Carga Lineal | 18.537 | 15.218 | 26.013 | 11.101 | 8.463 | 8.694 | 19.589 | 21.643 | 14.911 |
| | Carga No Lineal | 17.313 | 10.912 | 7.806 | 8.515 | 4.537 | 6.522 | 24.518 | 27.221 | 17.811 |
| 5 SCT | Sin carga | 14.665 | 15.116 | 12.381 | 12.067 | 9.380 | 9.772 | 14.224 | 12.419 | 10.526 |
| | Carga Lineal | 35.991 | 36.944 | 59.960 | 28.130 | 20.843 | 24.666 | 43.975 | 52.174 | 39.540 |
| | Carga No Lineal | 24.103 | 22.134 | 14.059 | 20.196 | 8.846 | 17.477 | 36.578 | 39.156 | 26.981 |
| 8 SCT | Sin carga | 10.376 | 12.764 | 11.198 | 10.477 | 10.440 | 9.223 | 11.397 | 12.802 | 9.291 |
| | Carga Lineal | 15.609 | 14.940 | 19.743 | 10.369 | 16.832 | 12.728 | 9.096 | 12.385 | 16.643 |
| | Carga No Lineal | 13.472 | 10.528 | 17.417 | 20.536 | 25.425 | 19.737 | 8.816 | 10.978 | 18.849 |
| 9 SCT | Sin carga | 9.935 | 11.664 | 11.026 | 11.073 | 11.799 | 8.613 | 13.451 | 11.299 | 8.386 |
| | Carga Lineal | 18.879 | 14.431 | 13.489 | 14.842 | 18.378 | 16.617 | 13.214 | 9.505 | 12.810 |
| | Carga No Lineal | 10.670 | 7.615 | 12.747 | 18.459 | 20.989 | 14.409 | 11.961 | 7.542 | 12.235 |
| 10 SCT | Sin carga | 11.981 | 12.620 | 11.650 | 11.756 | 11.850 | 9.720 | 15.929 | 10.913 | 10.237 |
| | Carga Lineal | 19.929 | 14.766 | 14.264 | 13.285 | 18.994 | 10.065 | 20.882 | 16.846 | 10.188 |
| | Carga No Lineal | 11.098 | 7.214 | 10.202 | 13.975 | 13.983 | 8.568 | 15.357 | 11.577 | 8.743 |

Tabla 13. Errores del modelo en diferentes condiciones de SCT, cargas y 5% de desbalance, valores estimados vs. valores reales.

| 5% de desbalance | | 0 SCT | 1 SCT | 2 SCT | 3 SCT | 4 SCT | 5 SCT | 8 SCT | 9 SCT | 10 SCT |
|------------------|-----------------|--------|--------|--------|--------|--------|--------|--------|--------|--------|
| 0 SCT | Sin carga | 11.012 | 11.473 | 8.649 | 17.279 | 13.474 | 13.512 | 16.732 | 15.870 | 17.914 |
| | Carga Lineal | 11.635 | 18.366 | 21.235 | 14.928 | 16.113 | 8.301 | 10.180 | 14.515 | 17.283 |
| | Carga No Lineal | 5.514 | 16.620 | 11.568 | 16.883 | 11.897 | 17.930 | 9.859 | 11.563 | 14.421 |
| 1 SCT | Sin carga | 14.343 | 13.625 | 10.199 | 18.972 | 13.741 | 15.795 | 18.445 | 16.325 | 19.190 |
| | Carga Lineal | 14.328 | 13.170 | 10.936 | 18.193 | 28.671 | 10.190 | 14.269 | 12.304 | 12.348 |
| | Carga No Lineal | 10.103 | 15.355 | 7.864 | 12.411 | 10.219 | 13.014 | 7.965 | 8.728 | 10.122 |
| 2 SCT | Sin carga | 11.979 | 10.262 | 8.362 | 14.217 | 10.630 | 12.210 | 13.709 | 13.401 | 14.545 |
| | Carga Lineal | 24.406 | 13.589 | 9.533 | 29.181 | 38.889 | 21.022 | 24.032 | 21.119 | 15.391 |
| | Carga No Lineal | 11.217 | 15.750 | 7.712 | 12.401 | 10.318 | 12.517 | 9.438 | 9.663 | 10.755 |
| 3 SCT | Sin carga | 11.338 | 9.613 | 7.985 | 13.732 | 9.276 | 11.242 | 12.400 | 12.402 | 14.384 |
| | Carga Lineal | 33.839 | 19.656 | 18.000 | 31.136 | 26.050 | 26.926 | 25.199 | 30.250 | 18.634 |
| | Carga No Lineal | 13.135 | 12.517 | 6.638 | 9.238 | 7.512 | 8.314 | 12.245 | 13.908 | 10.601 |
| 4 SCT | Sin carga | 14.059 | 12.257 | 10.561 | 16.957 | 8.025 | 13.221 | 12.846 | 12.606 | 17.755 |
| | Carga Lineal | 16.973 | 24.362 | 26.274 | 13.107 | 11.634 | 9.180 | 12.246 | 18.307 | 17.348 |
| | Carga No Lineal | 17.374 | 6.320 | 11.184 | 7.013 | 4.899 | 6.356 | 20.033 | 27.715 | 15.360 |
| 5 SCT | Sin carga | 19.371 | 17.384 | 15.478 | 22.279 | 9.462 | 17.988 | 16.004 | 15.401 | 22.852 |
| | Carga Lineal | 11.271 | 28.447 | 34.748 | 26.423 | 34.057 | 16.811 | 23.177 | 25.172 | 33.242 |
| | Carga No Lineal | 23.421 | 9.498 | 19.136 | 12.087 | 9.185 | 11.354 | 29.787 | 40.224 | 23.880 |
| 8 SCT | Sin carga | 11.872 | 8.810 | 9.215 | 11.211 | 9.584 | 10.088 | 10.421 | 12.567 | 12.495 |
| | Carga Lineal | 9.978 | 21.088 | 21.811 | 18.646 | 31.897 | 8.224 | 9.104 | 7.455 | 22.501 |
| | Carga No Lineal | 11.533 | 20.232 | 15.809 | 20.239 | 17.726 | 24.509 | 5.318 | 7.903 | 13.378 |
| 9 SCT | Sin carga | 11.678 | 9.845 | 7.686 | 13.801 | 8.998 | 11.051 | 12.511 | 11.910 | 15.145 |
| | Carga Lineal | 13.611 | 22.915 | 21.343 | 17.393 | 32.246 | 8.019 | 9.326 | 6.677 | 20.394 |
| | Carga No Lineal | 10.863 | 25.216 | 14.634 | 22.491 | 19.437 | 24.985 | 7.656 | 6.413 | 14.932 |
| 10 SCT | Sin carga | 13.956 | 10.692 | 9.904 | 12.225 | 15.194 | 13.610 | 15.822 | 16.355 | 12.332 |
| | Carga Lineal | 13.939 | 13.997 | 11.357 | 21.013 | 35.181 | 11.793 | 17.030 | 13.299 | 14.722 |
| | Carga No Lineal | 11.325 | 11.777 | 8.316 | 10.484 | 8.681 | 11.726 | 7.043 | 10.177 | 8.262 |

Tabla 14. Errores del modelo en diferentes condiciones de SCT, cargas y 7.5% de desbalance, valores estimados vs. valores reales.

| 7.5% de desbalance | | 0 SCT | 1 SCT | 2 SCT | 3 SCT | 4 SCT | 5 SCT | 8 SCT | 9 SCT | 10 SCT |
|--------------------|-----------------|--------|--------|--------|--------|--------|--------|--------|--------|--------|
| 0 SCT | Sin carga | 10.566 | 12.311 | 18.733 | 15.353 | 23.506 | 20.888 | 20.730 | 18.362 | 17.629 |
| | Carga Lineal | 18.989 | 26.287 | 42.617 | 18.522 | 17.820 | 46.325 | 30.267 | 20.189 | 23.495 |
| | Carga No Lineal | 8.093 | 13.027 | 14.835 | 17.866 | 25.337 | 19.238 | 14.521 | 14.792 | 15.544 |
| 1 SCT | Sin carga | 7.963 | 13.109 | 15.340 | 11.831 | 14.610 | 13.575 | 17.431 | 12.449 | 10.584 |
| | Carga Lineal | 9.869 | 13.769 | 16.861 | 10.321 | 11.038 | 19.031 | 14.627 | 10.246 | 12.918 |
| | Carga No Lineal | 8.227 | 11.297 | 9.846 | 13.817 | 21.588 | 15.158 | 11.889 | 11.276 | 12.734 |
| 2 SCT | Sin carga | 7.657 | 13.069 | 14.365 | 11.529 | 13.451 | 12.731 | 16.559 | 11.999 | 10.074 |
| | Carga Lineal | 28.422 | 29.592 | 12.168 | 25.768 | 26.334 | 23.502 | 30.887 | 24.280 | 32.518 |
| | Carga No Lineal | 11.105 | 9.656 | 6.322 | 9.341 | 16.601 | 9.672 | 10.428 | 9.558 | 10.873 |
| 3 SCT | Sin carga | 8.057 | 13.999 | 12.189 | 12.121 | 11.353 | 11.782 | 15.228 | 12.355 | 10.466 |
| | Carga Lineal | 30.721 | 31.422 | 13.278 | 27.291 | 27.948 | 25.480 | 33.729 | 26.018 | 34.065 |
| | Carga No Lineal | 14.088 | 8.111 | 5.740 | 6.441 | 12.150 | 6.776 | 12.161 | 11.576 | 10.191 |
| 4 SCT | Sin carga | 11.060 | 17.433 | 13.186 | 15.275 | 12.296 | 13.682 | 16.928 | 15.189 | 13.461 |
| | Carga Lineal | 10.779 | 13.205 | 17.038 | 10.616 | 10.647 | 22.403 | 16.220 | 11.765 | 18.031 |
| | Carga No Lineal | 16.764 | 5.858 | 9.359 | 5.647 | 7.493 | 7.160 | 17.873 | 19.073 | 10.670 |
| 5 SCT | Sin carga | 12.130 | 19.103 | 14.148 | 16.017 | 12.235 | 14.035 | 17.934 | 15.563 | 13.844 |
| | Carga Lineal | 11.980 | 11.780 | 14.973 | 12.776 | 15.170 | 14.975 | 11.687 | 12.879 | 16.251 |
| | Carga No Lineal | 27.372 | 13.402 | 25.033 | 16.835 | 15.106 | 16.261 | 29.485 | 34.280 | 21.879 |
| 8 SCT | Sin carga | 8.424 | 15.009 | 12.340 | 12.270 | 10.919 | 11.134 | 13.916 | 12.457 | 9.725 |
| | Carga Lineal | 24.342 | 23.868 | 25.125 | 27.657 | 33.019 | 17.779 | 13.061 | 23.717 | 26.927 |
| | Carga No Lineal | 9.443 | 16.814 | 11.864 | 19.294 | 27.957 | 22.570 | 12.315 | 11.735 | 14.399 |
| 9 SCT | Sin carga | 9.747 | 16.331 | 12.778 | 13.838 | 11.470 | 11.510 | 12.981 | 13.307 | 10.752 |
| | Carga Lineal | 18.802 | 19.849 | 21.826 | 21.194 | 26.181 | 15.632 | 10.224 | 17.405 | 19.625 |
| | Carga No Lineal | 9.293 | 16.690 | 11.354 | 17.730 | 28.548 | 20.047 | 11.980 | 9.891 | 14.957 |
| 10 SCT | Sin carga | 9.228 | 14.492 | 12.195 | 13.926 | 12.782 | 12.091 | 11.587 | 13.412 | 11.725 |
| | Carga Lineal | 16.266 | 20.944 | 20.947 | 17.585 | 21.168 | 18.700 | 11.473 | 13.260 | 16.936 |
| | Carga No Lineal | 10.631 | 10.485 | 9.330 | 10.282 | 17.753 | 14.128 | 14.522 | 13.141 | 10.852 |

Tabla 15. Errores del modelo en diferentes condiciones de SCT, cargas y 10% de desbalance, valores estimados vs. valores reales.

| 10% de desbalance | | 0 SCT | 1 SCT | 2 SCT | 3 SCT | 4 SCT | 5 SCT | 8 SCT | 9 SCT | 10 SCT |
|-------------------|-----------------|--------|--------|--------|--------|--------|--------|--------|--------|--------|
| 0 SCT | Sin carga | 9.505 | 8.981 | 12.905 | 16.669 | 14.070 | 9.273 | 17.800 | 13.467 | 19.095 |
| | Carga Lineal | 7.601 | 9.430 | 23.650 | 8.552 | 13.404 | 16.971 | 12.157 | 11.706 | 9.687 |
| | Carga No Lineal | 6.854 | 9.042 | 11.786 | 17.694 | 17.629 | 12.800 | 9.079 | 10.757 | 11.177 |
| 1 SCT | Sin carga | 9.708 | 7.374 | 11.241 | 14.678 | 12.771 | 8.954 | 15.728 | 12.002 | 17.220 |
| | Carga Lineal | 15.327 | 16.902 | 14.152 | 13.242 | 22.425 | 12.020 | 17.616 | 19.392 | 16.336 |
| | Carga No Lineal | 7.742 | 6.407 | 8.604 | 13.957 | 14.864 | 9.316 | 7.851 | 8.405 | 9.044 |
| 2 SCT | Sin carga | 10.208 | 8.623 | 10.593 | 13.497 | 9.662 | 9.690 | 11.176 | 8.854 | 12.701 |
| | Carga Lineal | 23.437 | 25.624 | 16.185 | 20.155 | 31.325 | 14.922 | 25.719 | 27.667 | 24.523 |
| | Carga No Lineal | 10.069 | 5.721 | 7.239 | 11.164 | 12.878 | 7.389 | 9.330 | 9.112 | 8.849 |
| 3 SCT | Sin carga | 11.392 | 10.308 | 11.793 | 13.834 | 9.653 | 10.736 | 11.137 | 8.993 | 12.306 |
| | Carga Lineal | 9.691 | 11.911 | 17.059 | 10.661 | 15.984 | 12.945 | 15.608 | 14.650 | 12.016 |
| | Carga No Lineal | 9.088 | 5.411 | 6.584 | 8.618 | 9.899 | 5.842 | 10.982 | 11.494 | 8.395 |
| 4 SCT | Sin carga | 12.227 | 11.512 | 13.030 | 14.245 | 10.073 | 11.279 | 11.848 | 9.546 | 12.598 |
| | Carga Lineal | 12.061 | 16.379 | 34.498 | 8.873 | 17.812 | 22.007 | 14.797 | 15.233 | 13.726 |
| | Carga No Lineal | 11.310 | 8.970 | 8.780 | 5.423 | 4.740 | 5.632 | 18.893 | 22.362 | 10.889 |
| 5 SCT | Sin carga | 17.139 | 17.272 | 19.440 | 17.496 | 13.604 | 14.771 | 16.710 | 13.659 | 15.998 |
| | Carga Lineal | 29.088 | 33.169 | 62.030 | 18.313 | 32.861 | 42.140 | 24.539 | 30.257 | 25.554 |
| | Carga No Lineal | 38.643 | 31.239 | 29.505 | 16.311 | 13.965 | 21.197 | 51.655 | 59.496 | 34.841 |
| 8 SCT | Sin carga | 14.288 | 12.255 | 11.809 | 16.926 | 10.394 | 14.193 | 8.861 | 8.684 | 11.537 |
| | Carga Lineal | 11.624 | 10.592 | 23.838 | 8.281 | 16.228 | 18.704 | 7.899 | 12.041 | 9.006 |
| | Carga No Lineal | 8.349 | 7.173 | 10.682 | 16.763 | 16.848 | 12.389 | 5.860 | 8.661 | 11.622 |
| 9 SCT | Sin carga | 12.569 | 11.437 | 12.381 | 14.525 | 9.875 | 11.792 | 10.550 | 9.008 | 11.698 |
| | Carga Lineal | 9.840 | 9.063 | 18.550 | 10.174 | 15.325 | 15.605 | 10.772 | 11.709 | 9.216 |
| | Carga No Lineal | 11.203 | 9.451 | 12.206 | 21.039 | 23.164 | 14.766 | 7.534 | 6.228 | 12.173 |
| 10 SCT | Sin carga | 13.481 | 11.783 | 12.694 | 14.459 | 9.715 | 12.365 | 10.517 | 8.988 | 11.860 |
| | Carga Lineal | 11.173 | 10.413 | 23.482 | 8.025 | 15.240 | 16.667 | 11.103 | 14.146 | 7.379 |
| | Carga No Lineal | 10.261 | 8.007 | 8.042 | 12.477 | 14.356 | 7.868 | 11.997 | 9.995 | 7.610 |

Tabla 16. Errores del modelo en diferentes condiciones de desbalance, cargas y 0 SCT, valores estimados vs. valores reales.

| 0 SCT | | 0 % desbalance | 2.5 % desbalance | 5 % desbalance | 7.5 % desbalance | 10 % desbalance |
|------------------|-----------------|----------------|------------------|----------------|------------------|-----------------|
| 0 % desbalance | Sin carga | 3.331 | 27.009 | 29.594 | 25.637 | 35.155 |
| | Carga Lineal | 10.274 | 16.130 | 11.366 | 9.519 | 8.576 |
| | Carga No Lineal | 7.835 | 19.221 | 13.542 | 14.919 | 13.177 |
| 2.5 % desbalance | Sin carga | 29.193 | 7.997 | 9.959 | 6.613 | 9.367 |
| | Carga Lineal | 12.605 | 15.620 | 11.626 | 10.324 | 8.577 |
| | Carga No Lineal | 16.618 | 8.526 | 7.285 | 7.875 | 6.812 |
| 5 % desbalance | Sin carga | 36.863 | 12.083 | 11.012 | 8.181 | 12.849 |
| | Carga Lineal | 13.113 | 16.830 | 11.635 | 9.539 | 8.002 |
| | Carga No Lineal | 14.235 | 10.106 | 5.514 | 8.191 | 6.844 |
| 7.5 % desbalance | Sin carga | 42.060 | 12.896 | 13.385 | 10.566 | 13.437 |
| | Carga Lineal | 29.355 | 34.345 | 24.534 | 18.989 | 17.680 |
| | Carga No Lineal | 13.020 | 12.907 | 7.872 | 8.093 | 8.783 |
| 10 % desbalance | Sin carga | 36.508 | 9.411 | 11.853 | 8.484 | 9.505 |
| | Carga Lineal | 12.712 | 16.561 | 9.931 | 8.974 | 7.601 |
| | Carga No Lineal | 12.899 | 10.012 | 7.006 | 7.299 | 6.854 |

Tabla 17. Errores del modelo en diferentes condiciones de desbalance, cargas y 5 SCT, valores estimados vs. valores reales.

| 5 SCT | | 0 % desbalance | 2.5 % desbalance | 5 % desbalance | 7.5 % desbalance | 10 % desbalance |
|------------------|-----------------|----------------|------------------|----------------|------------------|-----------------|
| 0 % desbalance | Sin carga | 33.509 | 28.684 | 29.632 | 36.958 | 43.477 |
| | Carga Lineal | 170.503 | 157.509 | 133.124 | 206.848 | 190.654 |
| | Carga No Lineal | 20.748 | 42.732 | 34.946 | 42.428 | 36.408 |
| 2.5 % desbalance | Sin carga | 9.735 | 9.772 | 13.508 | 12.786 | 15.294 |
| | Carga Lineal | 38.170 | 24.666 | 26.796 | 51.966 | 40.607 |
| | Carga No Lineal | 26.053 | 17.477 | 15.336 | 23.662 | 17.925 |
| 5 % desbalance | Sin carga | 14.361 | 13.000 | 17.988 | 16.459 | 20.129 |
| | Carga Lineal | 23.898 | 11.831 | 16.811 | 28.455 | 25.720 |
| | Carga No Lineal | 26.657 | 14.220 | 11.354 | 19.110 | 15.156 |
| 7.5 % desbalance | Sin carga | 11.871 | 11.129 | 15.149 | 14.035 | 16.169 |
| | Carga Lineal | 14.132 | 7.489 | 9.763 | 14.975 | 15.932 |
| | Carga No Lineal | 30.825 | 17.303 | 11.762 | 16.261 | 16.204 |
| 10 % desbalance | Sin carga | 14.291 | 14.982 | 17.901 | 15.900 | 14.771 |
| | Carga Lineal | 35.976 | 33.293 | 21.399 | 53.311 | 42.140 |
| | Carga No Lineal | 58.897 | 18.975 | 15.375 | 21.285 | 21.197 |

Tabla 18. Errores del modelo en diferentes condiciones de desbalance, cargas y 10 SCT, valores estimados vs. valores reales.

| 10 SCT | | 0 % desbalance | 2.5 % desbalance | 5 % desbalance | 7.5 % desbalance | 10 % desbalance |
|---------------------|-----------------|-------------------|---------------------|-------------------|---------------------|--------------------|
| 0 % desbalance | Sin carga | 7.101 | 14.051 | 21.968 | 17.145 | 17.922 |
| | Carga Lineal | 7.617 | 12.809 | 17.014 | 10.452 | 8.015 |
| | Carga No Lineal | 9.412 | 35.726 | 37.255 | 30.302 | 27.991 |
| 2.5 % desbalance | Sin carga | 23.168 | 10.237 | 14.916 | 11.168 | 12.452 |
| | Carga Lineal | 15.881 | 10.188 | 17.541 | 19.559 | 16.645 |
| | Carga No Lineal | 27.476 | 8.743 | 10.072 | 9.229 | 7.264 |
| 5 % desbalance | Sin carga | 28.781 | 12.564 | 12.332 | 12.075 | 19.028 |
| | Carga Lineal | 12.846 | 9.287 | 14.722 | 16.922 | 14.349 |
| | Carga No Lineal | 30.536 | 10.788 | 8.262 | 9.160 | 8.504 |
| 7.5 % desbalance | Sin carga | 11.485 | 8.912 | 15.365 | 11.725 | 13.904 |
| | Carga Lineal | 12.918 | 23.452 | 23.903 | 16.936 | 13.969 |
| | Carga No Lineal | 21.169 | 12.651 | 13.041 | 10.852 | 8.964 |
| 10 % desbalance | Sin carga | 17.953 | 9.564 | 14.507 | 10.783 | 11.860 |
| | Carga Lineal | 7.063 | 15.216 | 17.983 | 9.274 | 7.379 |
| | Carga No Lineal | 24.492 | 10.267 | 10.914 | 9.720 | 7.610 |

4.4 Caso de estudio 4: Análisis de la metodología de diagnóstico temprano en el dominio del tiempo.

Una vez segmentadas las señales VA, estas se deben normalizar a la escala de grises, la cual debe llevarse a cabo para sólo considerar valores enteros, además ayuda a mantener un mismo nivel de referencia, minimizando y generalizando el impacto de las diferentes cargas, y cabe mencionar que esta transformación a la señal VA no modifica el comportamiento o información de esta. En la Figura 45 se muestra una señal VA de la primera sección y su versión normalizada en escala de grises; se debe recordar que la normalización se realizó para cada una de las secciones de la señal, en cada condición y en cada prueba. La estimación de contraste; para ambas definiciones, Unser y Tamura, de cada sección es el siguiente paso. Se utilizan con el propósito de determinar cuál de estos enfoques es el más adecuado para caracterizar las variaciones asociadas a una falla temprana de SCT. Para la estimación del contraste de Unser se necesita elegir una distancia d de separación entre dos datos de la señal VA. Después de diferentes pruebas, el valor de $d = 15$ es seleccionado, ya que presenta el mejor resultado (su estimación será explicada más adelante). La Tabla 19 y Figura 45 muestran los valores obtenidos. En la Tabla 19 se muestran los valores de la media (μ) y la desviación estándar (σ) para los valores de contraste que incluyen las 3 condiciones de falla (0,1 y 2 SCTs), también las cuatro condiciones de carga (S0, S1, S2 y S3) de las 20 pruebas de cada condición.

En los resultados de la Tabla 19 y Figura 45a, se observa que la media del contraste no presenta variaciones considerables en las diferentes condiciones de carga, es decir que, la carga no presenta influencia en la estimación del contraste.

De una manera similar, el índice de Tamura se estimado para las condiciones de falla y las diferentes condiciones de carga. Se observa tanto en la Tabla 19 uno como en la Figura 46, este índice también presenta un comportamiento similar para las diferentes combinaciones de carga. Sin embargo, los valores de contraste estimados tanto de Unser y Tamura no están en la misma escala, pero ambos gráficos son bastante similares, lo cual reafirma la baja influencia de la carga en la estimación del contraste.

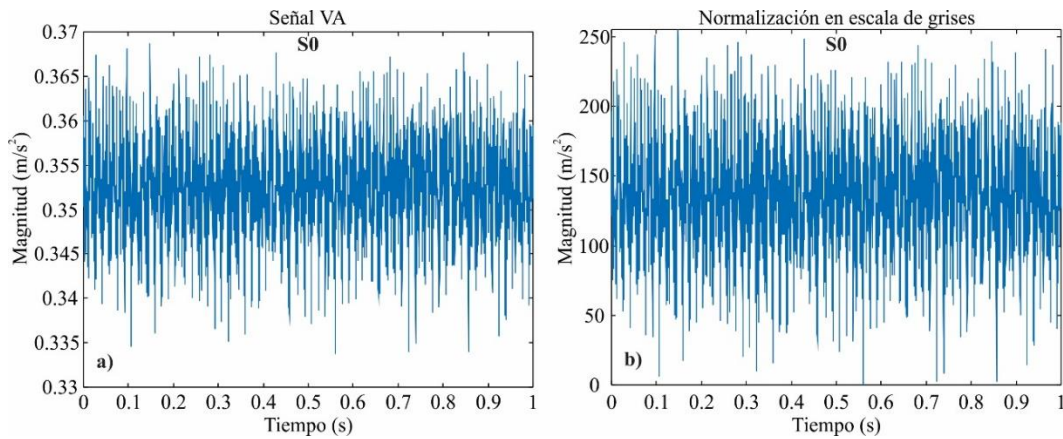


Figura 45. Ejemplo de señales: (a) señal VA y (b) su normalización en escala de grises.

Tabla 19. Media (μ) y desviación estándar (σ) de los valores de contraste en diferentes combinaciones de carga y diferentes condiciones de falla SCT.

| | | Contraste de Unser, $d = 15$ | | | | Contraste de Tamura | | | |
|---------------|----------|------------------------------|-----------|-----------|-----------|---------------------|---------|---------|---------|
| | | S0 | S1 | S2 | S3 | S0 | S1 | S2 | S3 |
| 0 SCTs | μ | 3862.5413 | 3426.7146 | 3597.4812 | 3511.6746 | 38.1231 | 35.4044 | 36.5590 | 36.0443 |
| | σ | 683.7739 | 690.3487 | 652.7069 | 848.0176 | 4.6503 | 4.6849 | 4.4967 | 5.4222 |
| 1 SCTs | μ | 6732.2393 | 6363.5508 | 6543.8623 | 6294.7972 | 53.8102 | 51.9030 | 53.0096 | 51.8991 |
| | σ | 1441.4742 | 1220.7590 | 1301.9952 | 1195.6256 | 7.5780 | 6.6916 | 6.9990 | 6.5757 |
| 2 SCTs | μ | 8699.9884 | 8304.6975 | 8529.3658 | 8147.1655 | 62.6589 | 60.8933 | 62.1086 | 60.5648 |
| | σ | 1084.0015 | 1022.1635 | 1049.8129 | 1016.2967 | 4.3483 | 4.1768 | 4.2930 | 4.2054 |

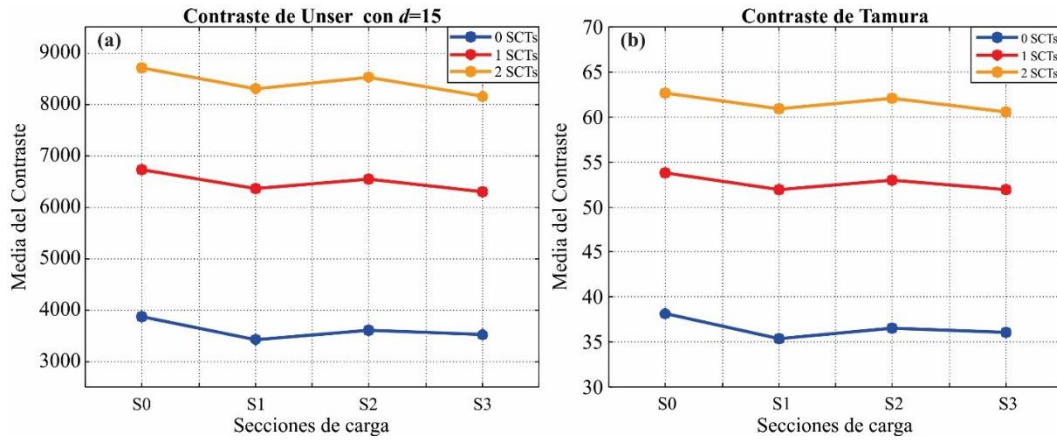


Figura 46. Media (μ) del contraste para diferentes cargas: (a) Contraste de Unser con $d=15$ y (b) contraste de Tamura.

Como los valores del contraste de Unser no cambian con la carga, los valores para cada sección (combinaciones de carga: S0, S1, S2 y S3) Pueden producir cúmulos más grandes de las condiciones de falla de SCTs, es decir, que las muestras pueden agruparse para describir el comportamiento de la falla SCTs. En la Figura 47 se muestran las distribuciones de los cúmulos para cada condición de SCTs. de esta figura puede ser observado que los índices de contraste son sensitivos a la severidad de la falla SCT ya que sus valores incrementan cuando la severidad de la falla SCT también incrementa. En la Tabla 20 se muestran los valores de la media (μ) y la desviación estándar (σ) de esos cúmulos. Todos esos resultados caracterizan de una forma numérica el comportamiento de cada condición SCT.

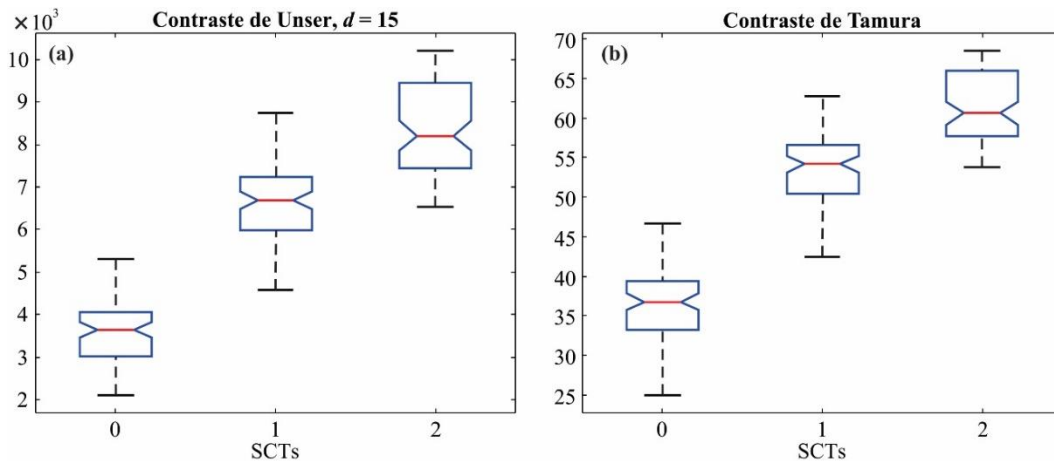


Figura 47. Distribución de los datos de los valores de contraste para las señales VA con diferentes condiciones de fallas SCT: (a) contraste de Unser y (b) contraste de Tamura.

Tabla 20. Media (μ) y desviación estándar (σ) para las diferentes distribuciones de contraste de las diferentes condiciones de falla.

| | Contraste de Unser, $d = 15$ | | | Contraste de Tamura | | |
|----------|------------------------------|-----------|-----------|---------------------|---------|---------|
| | 0 SCTs | 1 SCTs | 2 SCTs | 0 SCTs | 1 SCTs | 2 SCTs |
| μ | 3599.6029 | 6483.6124 | 8420.3043 | 36.5327 | 52.6555 | 61.5564 |
| σ | 740.9540 | 130.6383 | 1064.5340 | 4.9304 | 7.0183 | 4.3420 |

Una vez que ya se describió que los valores de contraste no cambian para diferentes condiciones de carga, por fines de claridad ahora se muestran los resultados para diferentes valores de la distancia d de la definición el contraste de Unser. En la Figura 48 se muestran los diferentes valores de la distancia d de las diferentes agrupaciones. Para $d = 5$, las agrupaciones no muestran separación entre ellas. La separación entre las agrupaciones comienza cuando $d = 10$, donde las agrupaciones mantienen una separación similar, pero en una diferente escala (eje y). A pesar de esto, el valor más adecuado es cuando $d=15$. Esto no es precisamente por la separación observada entre las agrupaciones, sino que también por la precisión obtenida cuando se aplica el algoritmo de clasificación.

Como se observó, el contraste es sensitivo a la falla, sin embargo, entre las diferentes condiciones se observan traslapes, lo cual puede producir incertidumbre al momento de la clasificación, que en consecuencia traerá errores de clasificación. Con el propósito de realizar un proceso de diagnóstico automático y mejorar la precisión de la clasificación, se propone el uso de un algoritmo de reconocimiento de patrones. Para esto se utilizan dos diferentes clasificadores; ANN y SVM, y ambos se aplican a ambas definiciones de contraste, es decir: Unser y Tamura. Aplicar ambos clasificadores ayuda a comparar su desempeño, para de esta manera seleccionar el mejor método en el que se obtenga la mayor precisión de clasificación. Los parámetros de los clasificadores se obtienen con un análisis exhaustivo de prueba y error, donde se selecciona el algoritmo con los mejores resultados. Además, del proceso de entrenamiento y validación en ambos clasificadores se utiliza haciendo la validación cruzada o k -fold, donde k se establece en 5 debido a que no se tienen demasiadas muestras, es decir, que el conjunto total de muestras se divide en 5, donde cuatro de estas partes se utilizan para entrenar y una para validar, esto se repite cambiando la parte con la que se válida para así validar con todos los datos. En la Tabla 21 se muestra el promedio de la precisión de las diferentes definiciones de contraste con los diferentes algoritmos de clasificación.

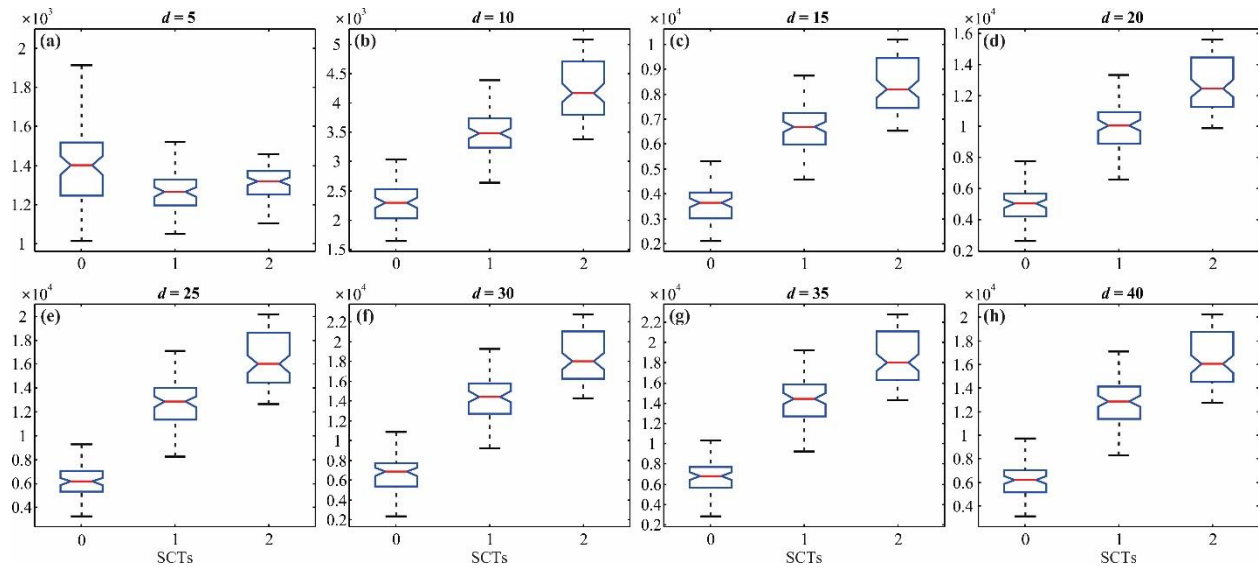


Figura 48. Agrupaciones del contraste de Unser para diferente valores d : (a) $d = 5$, (b) $d = 10$, (c) $d = 15$, (d) $d = 20$, (e) $d = 25$, (f) $d = 30$, (g) $d = 35$ y (h) $d = 40$.

Tabla 21. Promedio del porcentaje de precisión para los clasificadores ANN y SVM considerando las diferentes estimaciones del contraste.

| | Unser con $d = 15$ | Tamura |
|---------|--------------------|--------|
| ANN (%) | 89.78 | 86.38 |
| SVM (%) | 86.1 | 85.96 |

Como se observa en la Tabla 21, el mejor desempeño de los clasificadores es utilizando el contraste de Unser y una ANN, donde se obtiene el 89.78% de precisión. Los parámetros que proveen la precisión para la configuración de la ANN son: una neurona como entrada, 2 capas ocultas; una con cinco y la otra con 25 neuronas y tres neuronas en la capa de salida. La función de activación es una sigmoide para las capas de entrada y ocultas, mientras que es una función de activación lineal para la capa de salida. La diferencia con la ANN utilizada con el contraste de Tamura es que la primera capa oculta tiene 10 neuronas y la segunda que oculta las mismas 25 neuronas. Por otro lado, cuando se emplea un clasificador SVM, los parámetros que tienen la mayor influencia en la precisión de la calificación son la escala del kernel (δ) y la función de penalización, C. Consecuentemente, Los parámetros (δ, C) resultantes para la SVM utilizando el contraste de Unser son 0.03 y 25, respectivamente. El parámetro de distancia d del contraste de Unser también cambia cuando se utiliza una SVM, tomando el valor de 25. Para el contraste de Tamura los parámetros (δ, C) de la SVM también cambian y son 0.4 y 35, respectivamente.

En la Tabla 22 se muestra la matriz de confusión para la validación k -fold cuando $k = 1$, en la que se obtiene una efectividad de 91.7%. Debe notarse que se utilizan 16 datos de prueba; 1/5 parte o el 20% de los 80 datos disponibles. En estos resultados, la condición sana es claramente identificada de una no sana, sin embargo, diferenciar entre las condiciones de 1 y 2 SCTs presenta

un par de errores. A pesar de estos resultados la efectividad que se considera corresponde al promedio obtenido durante toda la validación *k-fold*, la cual es del 89.78%.

Después de diseñar y validar la propuesta usando los datos experimentales, se observaron dos grandes ventajas: (i) la sensibilidad a las fallas tempranas SCTs, es decir, puede reaccionar a ligeros cambios en los patrones de las vibraciones, y (ii) lo robusto al cambio de cargas, es decir, el índice de contraste apenas cambia cuando aparecen diferentes condiciones de carga.

Tabla 22. Matriz de confusión para la clasificación de SCTs.

| SCTs | 0 | 1 | 2 | |
|------------------|-------------|--------------|--------------|-------------------------|
| 0 | 16 | 0 | 0 | |
| 1 | 0 | 14 | 2 | |
| 2 | 0 | 2 | 14 | |
| Presición | 100% | 87.5% | 87.5% | Promedio = 91.7% |

Capítulo 5. Conclusiones.

En este trabajo de tesis se desarrollaron distintos diseños y equipos que ayudan para el análisis de la deformación estructural de los devanados de un transformador. Uno de ellos fue un banco de transformadores que pueden emular las deformaciones estructurales del núcleo y devanados. Además, se desarrolló un sistema de alimentación que permite emular el desbalance de una fuente de alimentación, que le permite tomar los valores bajo las normas de CFE. También se trabajó y desarrollo la instrumentación de un sistema de adquisición de datos para el análisis de estos transformadores utilizando varios sensores y micrófonos a la vez. En la exploración de distintas características y algoritmos que ayudaran a clasificar fallas en el transformador se logró realizar una publicación en un congreso internacional, dicho documento se presenta en el Anexo D (Huerta-Rosales et al., 2021). Finalmente, por cada caso de estudio se obtuvieron algunos puntos importantes bastante notables los cuales serán ahora mencionados.

En el primer caso de estudio se logran identificar diversas severidades de SCT (es decir 8 severidades), empleando diferentes índices estadísticos en el dominio del tiempo, donde resulta que siete índices característicos ayudan a obtener información de las señales de vibración para diagnosticar un transformador. Buscando realizar un diagnóstico de manera automática se emplea un algoritmo de clasificación (es decir un SVM) resultando una buena combinación para dicha tarea. Con el fin de aprovechar el éxito de la metodología propuesta, ésta fue implementada en una FPGA, que debido a sus características como el paralelismo y reconfigurabilidad permitirán su futura aplicación en tareas de tiempo real, otorgando la posibilidad de desarrollo de un sensor inteligente ya que el sensor (acelerómetro), el sistema de adquisición de datos y el procesador (FPGA) son los elementos básicos de uno de estos. Dicha implementación muestra un máximo error relativo del 2%, un tiempo de cálculo aproximado de 1.24 ms y una frecuencia de operación de 806 Hz. Además, utiliza una baja cantidad de recursos, dando la posibilidad de que este desarrollo pueda ser implementado en FPGAs comerciales y de bajo costo. De los resultados de este caso de estudio se logró realizar una publicación en una revista indizada la cual se anexa en el Anexo A (Huerta-Rosales et al., 2021).

Para el segundo caso de estudio se logra diagnosticar diferentes severidades de SCT empleando técnicas avanzadas de procesamiento de datos (NMD, HT, etc.). También se encontró que solo algunos modos (NM4 del eje x y NM1 del eje y) presentan información relevante acerca de la condición del transformador. La técnica NMD permite analizar señales con comportamiento

no estacionario y no lineal como los suelen ser las señales de vibración, aunado a esto por su transitorio de arranque. El valor RMS estimado de dichos modos resulta ser un excelente indicador de falla SCT. Sin embargo, el empleo de la NMD implica una gran carga computacional, lo que resulta una limitante para aplicaciones en tiempo real. De los resultados de este caso de estudio se logró realizar una publicación en una revista indizada la cual se anexa en el Anexo B (Huerta-Rosales et al., 2020).

En el tercer caso de estudio, el modelo implementado presenta buenos resultados para la estimación de las amplitudes, sin embargo, para la estimación de las fases resulta no ser adecuado. Los valores de estimación de las amplitudes indicando que en la metodología seguida es correcta, sin embargo, la estimación de las fases resulta no adecuado por la falta de sincronización en las señales de vibración, lo que provoca que los valores con los que se entrena la red neuronal sean muy variantes impidiendo que la red neuronal aprenda adecuadamente. En este orden, con el propósito de mejorar la sincronía de las fases, aplicar técnicas avanzadas de procesamiento que permitirá extraer las de manera más adecuada las fases de cada prueba, lo que la mejorará el modelo. Además, aunque las estimaciones de las amplitudes tienden a ser bastante parecidas a las amplitudes reales de las pruebas, resultan no ser suficientes para lograr diferenciar entre todas las diferentes condiciones (135), por lo que el uso del modelo junto con otros indicadores podría ser utilizado como clasificador.

En el cuarto caso de estudio se explora el contraste como un indicador de falla en transformadores, demostrando la gran capacidad para diagnosticar fallas tempranas de SCT. Además, de mostrar gran robustez ante diferentes condiciones de carga: sin carga, carga lineal, carga no lineal y cargas lineal más no lineal. Un punto bastante importante es la detección de fallas incipientes, esto es debido a que el ruido embebido en las señales, la poca variabilidad de estas dificulta la detección y diagnóstico de fallas incipientes. Algo importante de mencionar es que de los dos indicadores de contraste estudiados, Unser y Tamura, y los algoritmos de clasificación empleados (ANN y SVM), el contraste de Unser junto con una ANN se obtienen buenos resultados, lo que provee a la metodología de la capacidad de poder ser implementada para el diagnóstico en tiempo real. De los resultados de este caso de estudio se logró realizar una publicación en una revista indizada la cual se anexa en el Anexo C (Huerta-Rosales et al., 2022).

5.1 Prospectivas.

Un punto importante es que, a pesar de lograr la detección e identificación de la severidad de la falla, aún no se detecta la localización de la falla, es por lo que uno de los trabajos a futuro es la localizar la falla y detectar tanto localización como severidad. Además, se investigarán otros tipos de falla del transformador como la pérdida de sujeción en el núcleo y devanados, y otras condiciones de alimentación, explotando la inherente relación entre las propiedades mecánicas del transformador y las señales de vibración.

Exportar la metodología a distintos tipos de transformadores, ejemplo: monofásicos y trifásicos, de potencia mayor, además de extenderla a ambientes no controlados. También,

investigar otras variantes en la fuente de alimentación que estén relacionadas a la calidad de la energía, así con la variabilidad de las conexiones de cargas, tornando la metodología más robusta ante situaciones muy parecidas a la realidad.

Explorar distintas técnicas de procesamiento para realizar estimaciones de amplitud y fase adecuadamente para la mejora del modelo. Por otro lado, con el mismo propósito de mejorar el modelo, obtener más datos para un mejor análisis estadístico.

Finalmente, explorar la combinación de técnicas de procesamiento de señales, algoritmos de reconocimiento de patrones, así como la fusión de sensores, es decir, emplear diferentes tipos de señales, por ejemplo, corriente y voltaje, para incrementar la precisión de la detección y clasificación de las fallas.

Referencias

- Ahn, H. M., Lee, J. Y., Kim, J. K., Oh, Y. H., Jung, S. Y., & Hahn, S. C. (2011). Finite-element analysis of short-circuit electromagnetic force in power transformer. *IEEE Transactions on Industry Applications*, 47(3), 1267–1272. <https://doi.org/10.1109/TIA.2011.2126031>
- Aljibes L, G. (2015). *Discriminación entre las corrientes de Inrush y cortocircuito en transformadores de potencia usando transformada de Wavelet y máquinas de vectores de soporte*.
- Álvarez, Gustavo. (2017). *Análisis de corriente de energización en transformador basado en wavelets para detección de fallas de cortocircuito. s.l.: Protocolo de tesis de maestría*. UAQ.
- Amarnath, M., & Krishna, I. R. P. (2013). Detection and diagnosis of surface wear failure in a spur geared system using EEMD based vibration signalanalysis. *Tribology International*, 61, 224–234. <https://doi.org/10.1016/j.triboint.2013.01.001>
- Amezquita-Sanchez, J. P., & Adeli, H. (2015). A new music-empirical wavelet transform methodology for time-frequency analysis of noisy nonlinear and non-stationary signals. *Digital Signal Processing: A Review Journal*, 45, 55–68. <https://doi.org/10.1016/j.dsp.2015.06.013>
- Amezquita-Sanchez, J. P., Valtierra-Rodriguez, M., Camarena-Martinez, D., Granados-Lieberman, D., Romero-Troncoso, R. J., & Dominguez-Gonzalez, A. (2016). Fractal dimension-based approach for detection of multiple combined faults on induction motors. *Journal of Vibration and Control*, 22(17), 3638–3648. <https://doi.org/10.1177/1077546314565685>
- Arcila, José Daniel, I. S. A. (n.d.). *ARMÓNICOS EN SISTEMAS ELÉCTRICOS*. 1–26.
- Bagheri, M., Naderi, M., & Blackburn, T. (2012). Advanced transformer winding deformation diagnosis: Moving from off-line to on-line. *IEEE Transactions on Dielectrics and Electrical Insulation*, 19(6), 1860–1870. <https://doi.org/10.1109/TDEI.2012.6396941>
- Bagheri, M., Nezhivenko, S., Naderi, M. S., & Zollanvari, A. (2018). A new vibration analysis approach for transformer fault prognosis over cloud environment. *International Journal of Electrical Power and Energy Systems*, 100, 104–116. <https://doi.org/10.1016/j.ijepes.2018.02.026>

- Bagheri, M., Zollanvari, A., & Nezhivenko, S. (2018). Transformer Fault Condition Prognosis Using Vibration Signals over Cloud Environment. *IEEE Access*, 6, 9862–9874. <https://doi.org/10.1109/ACCESS.2018.2809436>
- Bartoletti, C., Desiderio, M., di Carlo, D., Fazio, G., Muzi, F., Sacerdoti, G., & Salvatori, F. (2004). Vibro-Acoustic Techniques to Diagnose Power Transformers. *IEEE Transactions on Power Delivery*, 19(1), 221–229. <https://doi.org/10.1109/TPWRD.2003.820177>
- Bigdeli, M., Vakilian, M., & Rahimpour, E. (2012). Transformer winding faults classification based on transfer function analysis by support vector machine. *IET Electric Power Applications*, 6(5), 268. <https://doi.org/10.1049/iet-epa.2011.0232>
- Bollen, M. H. J., Das, R., Djokic, S., Ciufu, P., Meyer, J., Rönnerberg, S. K., & Zavoda, F. (2017). Power Quality Concerns in Implementing Smart Distribution-Grid Applications. *IEEE Transactions on Smart Grid*, 8(1), 391–399. <https://doi.org/10.1109/TSG.2016.2596788>
- Borucki, S. (2012). Diagnosis of technical condition of power transformers based on the analysis of vibroacoustic signals measured in transient operating conditions. *IEEE Transactions on Power Delivery*, 27(2), 670–676. <https://doi.org/10.1109/TPWRD.2012.2185955>
- Borucki, S., Cichoń, A., Majchrzak, H., & Zmarzły, D. (2017). Evaluation of the Technical Condition of the Active Part of the High Power Transformer Based on Measurements and Analysis of Vibroacoustic Signals. *Archives of Acoustics*, 42(2), 313–320. <https://doi.org/10.1515/aoa-2017-0033>
- Caesarendra, W., & Tjahjowidodo, T. (2017). A review of feature extraction methods in vibration-based condition monitoring and its application for degradation trend estimation of low-speed slew bearing. *Machines*, 5(4). <https://doi.org/10.3390/machines5040021>
- Camarena-Martinez, D., Valtierra-Rodriguez, M., Perez-Ramirez, C. A., Amezcua-Sanchez, J. P., de Jesus Romero-Troncoso, R., & Garcia-Perez, A. (2016). Novel Downsampling Empirical Mode Decomposition Approach for Power Quality Analysis. *IEEE Transactions on Industrial Electronics*, 63(4), 2369–2378. <https://doi.org/10.1109/TIE.2015.2506619>
- Castro, A. R. G., & Miranda, V. (2005). Knowledge Discovery in Neural Networks With Application to Transformer Failure Diagnosis. *IEEE Transactions on Power Systems*, 20(2), 717–724. <https://doi.org/10.1109/TPWRS.2005.846074>
- Chapman, J. S. (2000). *Máquinas Eléctricas* (M. Hill, Ed.; 3rd ed.).
- Contreras, V. A. (2018). *Compresión y minería de datos para el diagnóstico de fallas incipientes de cortocircuito en transformadores monofásicos con carga eléctrica. s.l.: Protocolo de tesis de maestría. UAQ.*

- Contreras-Valdes, A., Amezcua-Sanchez, J. P., Granados-Lieberman, D., & Valtierra-Rodriguez, M. (2020). Predictive data mining techniques for fault diagnosis of electric equipment: A review. *Applied Sciences (Switzerland)*, *10*(3), 1–23. <https://doi.org/10.3390/app10030950>
- Duan, R., & Wang, F. (2016). Fault Diagnosis of On-Load Tap-Changer in Converter Transformer Based on Time – Frequency Vibration Analysis. *IEEE Transactions on Industrial Electronics*, *63*(6), 3815–3823. <https://doi.org/10.1109/TIE.2016.2524399>
- ECAMEC. (2009). *Desbalance de Tensiones es Sitemas Trifásicos*.
- García, B., Burgos, J. C., & Alonso, Á. (2005). Winding deformations detection in power transformers by tank vibrations monitoring. *Electric Power Systems Research*, *74*(1), 129–138. <https://doi.org/10.1016/j.epsr.2004.09.010>
- García, B., Burgos, J. C., & Alonso, Á. M. (2006). Transformer tank vibration modeling as a method of detecting winding deformations - Part I: Theoretical foundation. *IEEE Transactions on Power Delivery*, *21*(1), 157–163. <https://doi.org/10.1109/TPWRD.2005.852280>
- Garcia, B., Burgos, J. C., & Alonso, A. M. (2006). Transformer Tank Vibration Modeling as a Method of Detecting Winding Deformations—Part II: Experimental Verification. *IEEE Transactions on Power Delivery*, *21*(1), 164–169. <https://doi.org/10.1109/TPWRD.2005.852275>
- Geng, C., Wang, F., Zhang, J., & Jin, Z. (2014). Modal parameters identification of power transformer winding based on improved Empirical Mode Decomposition method. *Electric Power Systems Research*, *108*, 331–339. <https://doi.org/10.1016/j.epsr.2013.12.002>
- Golestan, S., Ramezani, M., Guerrero, J. M., Freijedo, F. D., & Monfared, M. (2014). Moving average filter based phase-locked loops: Performance analysis and design guidelines. *IEEE Transactions on Power Electronics*, *29*(6), 2750–2763. <https://doi.org/10.1109/TPEL.2013.2273461>
- Goyal, D., & Pabla, B. S. (2016). The Vibration Monitoring Methods and Signal Processing Techniques for Structural Health Monitoring: A Review. *Archives of Computational Methods in Engineering*, *23*(4), 585–594. <https://doi.org/10.1007/s11831-015-9145-0>
- Granados-Lieberman, D., Razo-Hernandez, J. R., Venegas-Rebollar, V., Olivares-Galvan, J. C., & Valtierra-Rodriguez, M. (2021). Harmonic PMU and Fuzzy Logic for Online Detection of Short-Circuited Turns in Transformers. *Electric Power Systems Research*, *190*(April), 106862. <https://doi.org/10.1016/j.epsr.2020.106862>
- Haijun, Z., Bin, Y., Weijie, X., Shuhong, W., Guolin, W., Youpeng, H., & JingYin, Z. (2014). Dynamic Deformation Analysis of Power Transformer Windings in Short-Circuit Fault by FEM. *Applied Superconductivity, IEEE Transactions On*, *24*(3), 1–4. <https://doi.org/10.1109/TASC.2013.2285335>

- Haralick, R. M., Shanmugam, K., & Dinstein, I. (1973). Textural Features for Image Classification. *IEEE Transactions on Systems, Man, and Cybernetics*, *SMC-3*(6), 610–621. <https://doi.org/10.1109/TSMC.1973.4309314>
- Harper, G. E. (2005). *El libro práctico de los generadores, transformadores y motores eléctricos*. (LIMUSA, Ed.).
- Hasan, M. J., & Kim, J. M. (2019). Fault detection of a spherical tank using a genetic algorithm-based hybrid feature pool and k-nearest neighbor algorithm. *Energies*, *12*(6). <https://doi.org/10.3390/en12060991>
- Ho, S. L., Li, Y., Wong, H. C., Wang, S. H., & Tang, R. Y. (2004). Numerical simulation of transient force and eddy current loss in a 720-MVA power transformer. *IEEE Transactions on Magnetics*, *40*(2 II), 687–690. <https://doi.org/10.1109/TMAG.2004.824801>
- Hong, K., Huang, H., Fu, Y., & Zhou, J. (2016). A vibration measurement system for health monitoring of power transformers. *Measurement: Journal of the International Measurement Confederation*, *93*, 135–147. <https://doi.org/10.1016/j.measurement.2016.07.002>
- Hong, K., Huang, H., & Zhou, J. (2015). Winding Condition Assessment of Power Transformers Based on Vibration Correlation. *IEEE Transactions on Power Delivery*, *30*(4), 1735–1742. <https://doi.org/10.1109/TPWRD.2014.2376033>
- Hong, K., Huang, H., Zhou, J., Shen, Y., & Li, Y. (2015). A method of real-time fault diagnosis for power transformers based on vibration analysis. *Measurement Science and Technology*, *26*(11), 115011. <https://doi.org/10.1088/0957-0233/26/11/115011>
- Hostetter, M., Ahmadzadeh, A., Aydin, B., Georgoulis, M. K., Kempton, D. J., & Angryk, R. A. (2019). Understanding the Impact of Statistical Time Series Features for Flare Prediction Analysis. *Proceedings - 2019 IEEE International Conference on Big Data, Big Data 2019*, 4960–4966. <https://doi.org/10.1109/BigData47090.2019.9006116>
- Hu, Y., Zheng, J., & Huang, H. (2019). Experimental Research on Power Transformer Vibration Distribution under Different Winding Defect Conditions. *Electronics*, *8*(8), 842. <https://doi.org/10.3390/electronics8080842>
- Huerta-Rosales, J. R., Valtierra-Rodriguez, M., Amezcua-Sanchez, J. P., & Granados-Lieberman, D. (2021). Detection of Short-Circuited Turns in Transformer Vibration Signals using MUSIC-Empirical Wavelet Transform and Fractal Dimension. *2021 IEEE International Autumn Meeting on Power, Electronics and Computing (ROPEC), Ropec*, 1–7. <https://doi.org/10.1109/ROPEC53248.2021.9667997>
- Huerta-Rosales, J. R., Granados-Lieberman, D., Garcia-Perez, A., Camarena-Martinez, D., Amezcua-Sanchez, J. P., & Valtierra-Rodriguez, M. (2021). Short-circuited turn fault diagnosis in transformers by using vibration signals, statistical time features, and support vector machines on fpga. *Sensors*, *21*(11). <https://doi.org/10.3390/s21113598>

Huerta-Rosales, J. R., Granados-Lieberman, D., Amezcuita-Sanchez, J. P., Camarena-Martinez, D., & Valtierra-Rodriguez, M. (2020). Vibration Signal Processing-Based Detection of Short-Circuited Turns in Transformers: A Nonlinear Mode Decomposition Approach. *Mathematics*, 8(4), 575. <https://doi.org/10.3390/math8040575>

Huerta-Rosales, J. R., Granados-Lieberman, D., Amezcuita-Sanchez, J. P., Garcia-Perez, A., Bueno-Lopez, M., & Valtierra-Rodriguez, M. (2022). Contrast Estimation in Vibroacoustic Signals for Diagnosing Early Faults of Short-Circuited Turns in Transformers under Different Load Conditions. *Energies*, 15(22), 8508. <https://doi.org/10.3390/en15228508>

Iatsenko, D., McClintock, P. V. E., & Stefanovska, A. (2013). *Linear and synchrosqueezed time-frequency representations revisited. Part II: Resolution, reconstruction and concentration*. <http://arxiv.org/abs/1310.7274>

Iatsenko, D., McClintock, P. V. E., & Stefanovska, A. (2015a). Nonlinear mode decomposition: A noise-robust, adaptive decomposition method. *Physical Review E - Statistical, Nonlinear, and Soft Matter Physics*, 92(3), 1–25. <https://doi.org/10.1103/PhysRevE.92.032916>

Iatsenko, D., McClintock, P. V. E., & Stefanovska, A. (2015b). Linear and synchrosqueezed time–frequency representations revisited: Overview, standards of use, resolution, reconstruction, concentration, and algorithms. *Digital Signal Processing*, 42, 1–26. <https://doi.org/10.1016/j.dsp.2015.03.004>

Iatsenko, D., McClintock, P. V. E., & Stefanovska, A. (2016). Extraction of instantaneous frequencies from ridges in time–frequency representations of signals. *Signal Processing*, 125, 290–303. <https://doi.org/10.1016/j.sigpro.2016.01.024>

Islam, M. M., Lee, G., & Hettiwatte, S. N. (2018). A review of condition monitoring techniques and diagnostic tests for lifetime estimation of power transformers. *Electrical Engineering*, 100(2), 581–605. <https://doi.org/10.1007/s00202-017-0532-4>

Jan, S. U., Lee, Y. D., Shin, J., & Koo, I. (2017). Sensor Fault Classification Based on Support Vector Machine and Statistical Time-Domain Features. *IEEE Access*, 5(c), 8682–8690. <https://doi.org/10.1109/ACCESS.2017.2705644>

Jiang, X., & Adeli, H. (2007). Pseudospectra, MUSIC, and dynamic wavelet neural network for damage detection of highrise buildings. *International Journal for Numerical Methods in Engineering*, 71(5), 606–629. <https://doi.org/10.1002/nme.1964>

Jović, A., Brkić, K., & Bogunović, N. (2015). A review of feature selection methods with applications. *2015 38th International Convention on Information and Communication Technology, Electronics and Microelectronics, MIPRO 2015 - Proceedings*, 1200–1205. <https://doi.org/10.1109/MIPRO.2015.7160458>

- Kang, P., & Birtwhistle, D. (2001). Condition Assessment of Power Transformer On-Load Tap-Changers Using Wavelet Analysis. In *IEEE TRANSACTION ON POWER DELIVERY* (Vol. 16, Issue 3).
- Kari, T., Gao, W., Zhao, D., Abiderexiti, K., Mo, W., Wang, Y., & Luan, L. (2018). Hybrid feature selection approach for power transformer fault diagnosis based on support vector machine and genetic algorithm. *IET Generation, Transmission and Distribution*, 12(21), 5672–5680. <https://doi.org/10.1049/iet-gtd.2018.5482>
- Kim, M., & Lee, S. (2022). Power Transformer Voltages Classification with Acoustic Signal in Various Noisy Environments. *Sensors*, 22(3). <https://doi.org/10.3390/s22031248>
- Korn, F., Pagel, B., & Faloutsos, C. (2001). On the ^aDimensionality Curse^o and the ^aSelf-Similarity Blessing^o. *Knowledge Creation Diffusion Utilization*, 13(1), 96–111.
- Kuncheva, L. I. (2000). *Fuzzy Classifier Design* (Vol. 49). Physica-Verlag HD. <https://doi.org/10.1007/978-3-7908-1850-5>
- Lambert, M., Sirois, F., Martinez-Duro, M., & Mahseredjian, J. (2013). Analytical calculation of leakage inductance for low-frequency transformer modeling. *IEEE Transactions on Power Delivery*, 28(1), 507–515. <https://doi.org/10.1109/TPWRD.2012.2225451>
- Li, Y., Zhou, W., Jing, Y., & Sun, X. (2011). Axial vibration analysis of power transformer active part under short-circuit. *2011 International Conference on Electrical Machines and Systems, ICEMS 2011*, 1–4. <https://doi.org/10.1109/ICEMS.2011.6073998>
- Liu, C., Jiang, D., & Yang, W. (2014). Global geometric similarity scheme for feature selection in fault diagnosis. *Expert Systems with Applications*, 41(8), 3585–3595. <https://doi.org/10.1016/j.eswa.2013.11.037>
- Liu, J., Xu, Z., Zhou, L., Nian, Y., & Shao, Y. (2019). A statistical feature investigation of the spalling propagation assessment for a ball bearing. *Mechanism and Machine Theory*, 131, 336–350. <https://doi.org/10.1016/j.mechmachtheory.2018.10.007>
- Liu, J., Zhao, Z., Tang, C., Yao, C., Li, C., & Islam, S. (2019). Classifying Transformer Winding Deformation Fault Types and Degrees Using FRA Based on Support Vector Machine. *IEEE Access*, 7, 112494–112504. <https://doi.org/10.1109/access.2019.2932497>
- Liu, X., Yang, Y., & Huang, Y. (2018). Vibration analysis of transformer DC bias caused by HVDC based on EMD reconstruction. *Journal of Electrical Engineering and Technology*, 13(2), 781–789. <https://doi.org/10.5370/JEET.2018.13.2.781>
- Liu, Z., Xia, X., Ji, S., Shi, Y., Zhang, F., Fu, Y., & Jiang, Z. (2018). Fault Diagnosis of OLTC Based on Time-Frequency Image Analysis of Vibration Signal. *2018 Condition Monitoring and Diagnosis (CMD)*, 1–6. <https://doi.org/10.1109/CMD.2018.8535918>
- López, H. (2008). *Identificación de Sistemas. Aplicación al modelado de un motor de continua*. 64.

- Martinez-Figueroa, G. D. J., Morinigo-Sotelo, D., Zorita-Lamadrid, A. L., Morales-Velazquez, L., & Romero-Troncoso, R. D. J. (2017). FPGA-based smart sensor for detection and classification of power quality disturbances using higher order statistics. *IEEE Access*, 5, 14259–14274. <https://doi.org/10.1109/ACCESS.2017.2732726>
- Mboo, C. P., & Hameyer, K. (2016). Fault diagnosis of bearing damage by means of the linear discriminant analysis of stator current features from the frequency selection. *IEEE Transactions on Industry Applications*, 52(5), 3861–3868. <https://doi.org/10.1109/TIA.2016.2581139>
- Mejia-Barron, A., Tapia-Tinoco, G., Razo-Hernandez, J. R., Valtierra-Rodriguez, M., & Granados-Lieberman, D. (2021). A neural network-based model for MCSA of inter-turn short-circuit faults in induction motors and its power hardware in the loop simulation. *Computers and Electrical Engineering*, 93. <https://doi.org/10.1016/j.compeleceng.2021.107234>
- Mejia-Barron, A., Valtierra-Rodriguez, M., Granados-Lieberman, D., Olivares-Galvan, J. C., & Escarela-Perez, R. (2017). Experimental data-based transient-stationary current model for inter-turn fault diagnostics in a transformer. *Electric Power Systems Research*, 152, 306–315. <https://doi.org/10.1016/j.epsr.2017.07.020>
- Mejia-Barron, A., Valtierra-Rodriguez, M., Granados-Lieberman, D., Olivares-Galvan, J. C., & Escarela-Perez, R. (2018). The application of EMD-based methods for diagnosis of winding faults in a transformer using transient and steady state currents. *Measurement: Journal of the International Measurement Confederation*, 117(November 2017), 371–379. <https://doi.org/10.1016/j.measurement.2017.12.003>
- Mizokami, M., Yabumoto, M., & Okazaki, Y. (1997). Vibration Analysis of a 3-Phase Model Transformer Core. In *Electrical Engineering in Japan* (Vol. 119, Issue 1, pp. 1194–1203). [https://doi.org/10.1002/\(SICI\)1520-6416\(19970415\)119:1<1::AID-EEJ1>3.0.CO;2-C](https://doi.org/10.1002/(SICI)1520-6416(19970415)119:1<1::AID-EEJ1>3.0.CO;2-C)
- Moses, a. J., Anderson, P. I., Phophongviwat, T., & Tabrizi, S. (2010). Contribution of magnetostriction to transformer noise. *Universities Power Engineering Conference (UPEC), 2010 45th International, May 2014*, 1–5.
- Olivares-Galvan, J. C., Escarela-Perez, R., Gonzalez, J. A. A., Jacobo, J. C., Guillen, D., & Espino-Cortes, F. P. (2016). Detection of interturn faults during transformer energization using wavelet transform. *2016 IEEE International Autumn Meeting on Power, Electronics and Computing (ROPEC), Ropec*, 1–5. <https://doi.org/10.1109/ROPEC.2016.7830612>
- Oppenheim, A. V., Willsky, A. S., & Nawab, S. H. (1998). *Señales y Sistemas* (2nd ed.). Prentice Hall.
- Rao, S. S. (2012). Vibraciones Mecánicas. In PEARSON (Ed.), *Lecturas De Ingeniería 17 Vibraciones* (5th ed.).

- Rivas, E., Burgos, J. C., & García-Prada, J. C. (2010). Vibration analysis using envelope wavelet for detecting faults in the OLTC tap selector. *IEEE Transactions on Power Delivery*, 25(3), 1629–1636. <https://doi.org/10.1109/TPWRD.2010.2043746>
- Romero-Troncoso, R. D. J. (2017). Multirate Signal Processing to Improve FFT-Based Analysis for Detecting Faults in Induction Motors. *IEEE Transactions on Industrial Informatics*, 13(3), 1291–1300. <https://doi.org/10.1109/TII.2016.2603968>
- Rostaminia, R., Sanie, M., Vakilian, M., Mortazavi, S. S., & Parvin, V. (2016). Accurate power transformer PD pattern recognition via its model. *IET Science, Measurement and Technology*, 10(7), 745–753. <https://doi.org/10.1049/iet-smt.2016.0075>
- Santos-Hernandez, J. A., Valtierra-Rodriguez, M., Amezquita-Sanchez, J. P., Romero-Troncoso, R. D. J., & Camarena-Martinez, D. (2019). Hilbert filter based FPGA architecture for power quality monitoring. *Measurement: Journal of the International Measurement Confederation*, 147, 106819. <https://doi.org/10.1016/j.measurement.2019.07.047>
- Sanz-Bobi, M. A., Garcia-Cerrada, A., Palacios, R., Villar, J., Rolan, J., & Moran, B. (1997). Experiences learned from the on-line internal monitoring of the behaviour of a transformer. *Electric Machines and Drives Conference Record, 1997. IEEE International*, TC3/11.1-TC3/11.3. <https://doi.org/10.1109/IEMDC.1997.604272>
- Saucedo-Dorantes, J. J., Delgado-Prieto, M., Osornio-Rios, R. A., & de Jesus Romero-Troncoso, R. (2017). Multifault Diagnosis Method Applied to an Electric Machine Based on High-Dimensional Feature Reduction. *IEEE Transactions on Industry Applications*, 53(3), 3086–3097. <https://doi.org/10.1109/TIA.2016.2637307>
- Saucedo-Dorantes, J. J., Delgado-Prieto, M., Osornio-Rios, R. A., & Romero-Troncoso, R. de J. (2018). Diagnosis methodology for identifying gearbox wear based on statistical time feature reduction. *Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science*, 232(15), 2711–2722. <https://doi.org/10.1177/0954406217721727>
- Saxena, M. K., Raju, S. D. V. S. J., Arya, R., Pachori, R. B., Ravindranath, S. V. G., Kher, S., & Oak, S. M. (2016). Empirical Mode Decomposition-Based Detection of Bend-Induced Error and Its Correction in a Raman Optical Fiber Distributed Temperature Sensor. *IEEE Sensors Journal*, 16(5), 1243–1252. <https://doi.org/10.1109/JSEN.2015.2499242>
- Secic, A., Krpan, M., & Kuzle, I. (2019). Vibro-Acoustic Methods in the Condition Assessment of Power Transformers: A Survey. In *IEEE Access* (Vol. 7, pp. 83915–83931). Institute of Electrical and Electronics Engineers Inc. <https://doi.org/10.1109/ACCESS.2019.2923809>
- Shah, A. M., Bhalja, B. R., & Member, S. (2013). Discrimination Between Internal Faults and Other Disturbances in Transformer Using the Support Vector Machine-Based Protection Scheme. *IEEE Transactions on Power Delivery*, 28(3), 1508–1515. <https://doi.org/10.1109/TPWRD.2012.2227979>

- Shahdoosti, H. R., & Mirzapour, F. (2017). Spectral–spatial feature extraction using orthogonal linear discriminant analysis for classification of hyperspectral data. *European Journal of Remote Sensing*, 50(1), 111–124. <https://doi.org/10.1080/22797254.2017.1279821>
- Sharma, A., Amarnath, M., & Kankar, P. K. (2016). Feature extraction and fault severity classification in ball bearings. *JVC/Journal of Vibration and Control*, 22(1), 176–192. <https://doi.org/10.1177/1077546314528021>
- Sun, L., Fu, S., & Wang, F. (2019). Decision tree SVM model with Fisher feature selection for speech emotion recognition. *Eurasip Journal on Audio, Speech, and Music Processing*, 2019(1). <https://doi.org/10.1186/s13636-018-0145-5>
- Suwanasri, T., Chaidee, E., & Adsoongnoen, C. (2007). Failure statistics and power transformer condition evaluation by dissolved gas analysis technique. *Proceedings of 2008 International Conference on Condition Monitoring and Diagnosis, CMD 2008*, 492–496. <https://doi.org/10.1109/CMD.2008.4580333>
- Tamura, H., Mori, S., & Yamawaki, T. (1978). Textural Features Corresponding to Visual Perception. *IEEE Transactions on Systems, Man, and Cybernetics*, 8(6), 460–473. <https://doi.org/10.1109/TSMC.1978.4309999>
- Tarimoradi, H., Gharehpetian, G. B., & Member, S. (2017). A Novel Calculation Method of Indices to Improve Classification of Transformer Winding Fault Type , Location and Extent. 3203(c). <https://doi.org/10.1109/TII.2017.2651954>
- Téllez Ramírez, E. (n.d.). *Distorsión armónica*. 222.
- Unser, M. (1986). Sum and Difference Histograms for Texture Classification. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, PAMI-8(1), 118–125. <https://doi.org/10.1109/TPAMI.1986.4767760>
- Urbina-Salas, I., Razo-Hernandez, J. R., Granados-Lieberman, D., Valtierra-Rodriguez, M., & Torres-Fernandez, J. E. (2017). Instantaneous Power Quality Indices Based on Single-Sideband Modulation and Wavelet Packet-Hilbert Transform. *IEEE Transactions on Instrumentation and Measurement*, 66(5), 1021–1031. <https://doi.org/10.1109/TIM.2017.2663560>
- Valles-Novo, R., de Jesus Rangel-Magdaleno, J., Ramirez-Cortes, J. M., Peregrina-Barreto, H., & Morales-Caporal, R. (2015). Empirical Mode Decomposition Analysis for Broken-Bar Detection on Squirrel Cage Induction Motors. *IEEE Transactions on Instrumentation and Measurement*, 64(5), 1118–1128. <https://doi.org/10.1109/TIM.2014.2373513>
- Valles-Novo, R., Rangel-Magdaleno, J. D. J., Ramirez-Cortes, J. M., Peregrina-Barreto, H., & Morales-Caporal, R. (2015). *Empirical Mode Decomposition Analysis for Broken-Bar Detection on Squirrel Cage Induction Motors*. 64(5), 1118–1128. <https://doi.org/10.1109/TIM.2014.2373513>

- Valtierra-Rodriguez, M. (2020). Fractal dimension and data mining for detection of short-circuited turns in transformers from vibration signals. *Measurement Science and Technology*, 31(2), 025902. <https://doi.org/10.1088/1361-6501/ab48ac>
- Valtierra-Rodriguez, M., Granados-Lieberman, D., Torres-Fernandez, J. E., Rodriguez-Rodriguez, J. R., & Gomez-Aguilar, J. F. (2016). A new methodology for tracking and instantaneous characterization of voltage variations. *IEEE Transactions on Instrumentation and Measurement*, 65(7), 1596–1604. <https://doi.org/10.1109/TIM.2016.2540866>
- Valtierra-Rodriguez, M., Rivera-Guillen, J. R., Basurto-Hurtado, J. A., Jesus De-Santiago-Perez, J., Granados-Lieberman, D., & Amezcuita-Sanchez, J. P. (2020). Convolutional neural network and motor current signature analysis during the transient state for detection of broken rotor bars in induction motors. *Sensors (Switzerland)*, 20(13), 1–20. <https://doi.org/10.3390/s20133721>
- Van, M., & Kang, H. J. (2015). Wavelet Kernel Local Fisher Discriminant Analysis with Particle Swarm Optimization Algorithm for Bearing Defect Classification. *IEEE Transactions on Instrumentation and Measurement*, 64(12), 3588–3600. <https://doi.org/10.1109/TIM.2015.2450352>
- Wang, M., Vandermaar, A. J., & Srivastava, K. D. (2002). Review of condition assessment of power transformers in service. *IEEE Electrical Insulation Magazine*, 18(6), 12–25. <https://doi.org/10.1109/MEI.2002.1161455>
- Wang, X., Deck-Leger, Z.-L., Zou, L., Azana, J., & Caloz, C. (2019). Microwave Hilbert Transformer and Its Applications in Real-Time Analog Processing. *IEEE Transactions on Microwave Theory and Techniques*, 67(6), 2216–2226. <https://doi.org/10.1109/TMTT.2019.2905596>
- Wang, X., Zheng, Y., Zhao, Z., & Wang, J. (2015). Bearing fault diagnosis based on statistical locally linear embedding. *Sensors (Switzerland)*, 15(7), 16225–16247. <https://doi.org/10.3390/s150716225>
- Wen, J., Fang, X., Cui, J., Fei, L., Yan, K., Chen, Y., & Xu, Y. (2019). Robust Sparse Linear Discriminant Analysis. *IEEE Transactions on Circuits and Systems for Video Technology*, 29(2), 390–403. <https://doi.org/10.1109/TCSVT.2018.2799214>
- WU, S., HUANG, W., KONG, F., WU, Q., ZHOU, F., ZHANG, R., & WANG, Z. (2010a). Extracting Power Transformer Vibration Features by a Time-Scale-Frequency Analysis Method. *Journal of Electromagnetic Analysis and Applications*, 02(01), 31–38. <https://doi.org/10.4236/jemaa.2010.21005>
- WU, S., HUANG, W., KONG, F., WU, Q., ZHOU, F., ZHANG, R., & WANG, Z. (2010b). Extracting Power Transformer Vibration Features by a Time-Scale-Frequency Analysis Method. *Journal of Electromagnetic Analysis and Applications*, 02(01), 31–38. <https://doi.org/10.4236/jemaa.2010.21005>

- Wu, X., Li, L., Zhou, N., Lu, L., Hu, S., Cao, H., & He, Z. (2018). Diagnosis of DC Bias in Power Transformers Using Vibration Feature Extraction and a Pattern Recognition Method. *Energies*, *11*(7), 1775. <https://doi.org/10.3390/en11071775>
- Wu, Y., Zhang, Z., Xiao, R., Jiang, P., Dong, Z., & Deng, J. (2021). Operation state identification method for converter transformers based on vibration detection technology and deep belief network optimization algorithm. *Actuators*, *10*(3), 1–32. <https://doi.org/10.3390/act10030056>
- Wu, Z., & Huang, N. E. (2009). Ensemble Empirical Mode Decomposition: A Noise-Assisted Data Analysis Method. *Advances in Adaptive Data Analysis*, *01*(01), 1–41. <https://doi.org/10.1142/S1793536909000047>
- Xu, J. (2018). A weighted linear discriminant analysis framework for multi-label feature extraction. *Neurocomputing*, *275*, 107–120. <https://doi.org/10.1016/j.neucom.2017.05.008>
- Xue, X., & Zhou, J. (2017). A hybrid fault diagnosis approach based on mixed-domain state features for rotating machinery. *ISA Transactions*, *66*, 284–295. <https://doi.org/10.1016/j.isatra.2016.10.014>
- Yanez-borjas, J. J., Valtierra-rodriguez, M., Camarena-, D., & Amezquita-sanchez, J. P. (2020). Statistical time features for global corrosion assessment in a truss bridge from vibration signals. *Measurement*, *157*, 107858. <https://doi.org/10.1016/j.measurement.2020.107858>
- Yoon, J. T., Youn, B. D., Park, K. M., & Lee, W. R. (2013). Vibration-based robust health diagnostics for mechanical failure modes of power transformers. *PHM 2013 - 2013 IEEE International Conference on Prognostics and Health Management, Conference Proceedings*, 0–4. <https://doi.org/10.1109/ICPHM.2013.6621421>
- Zhang, L. L., Wu, Q. H., Ji, T. Y., & Zhang, A. Q. (2017). Identification of inrush currents in power transformers based on higher-order statistics. *Electric Power Systems Research*, *146*, 161–169. <https://doi.org/10.1016/j.epsr.2017.01.029>
- Zhang, Y., Wang, P., Ni, T., Cheng, P., & Lei, S. (2017). Wind power prediction based on LS-SVM model with error correction. *Advances in Electrical and Computer Engineering*, *17*(1), 3–8. <https://doi.org/10.4316/AECE.2017.01001>
- Zhang, Z., Wu, Y., Zhang, R., Jiang, P., Liu, G., Ahmed, S., & Dong, Z. (2019). Novel Transformer Fault Identification Optimization Method Based on Mathematical Statistics. *Mathematics*, *7*(3), 288. <https://doi.org/10.3390/math7030288>
- Zhao, M., & Xu, G. (2018). Feature extraction of power transformer vibration signals based on empirical wavelet transform and multiscale entropy. *IET Science, Measurement & Technology*, *12*(1), 63–71. <https://doi.org/10.1049/iet-smt.2017.0188>
- Zheng, J., Huang, H., & Pan, J. (2018). Detection of Winding Faults Based on a Characterization of the Nonlinear Dynamics of Transformers. *IEEE Transactions on*

Instrumentation and Measurement, 68(1), 206–214.
<https://doi.org/10.1109/TIM.2018.2838178>

Zheng, J., Pan, J., & Huang, H. (2015). An experimental study of winding vibration of a single-phase power transformer using a laser Doppler vibrometer. *Applied Acoustics*, 87, 30–37. <https://doi.org/10.1016/j.apacoust.2014.06.012>

Zhou, H., Hong, K., Huang, H., & Zhou, J. (2016). Transformer winding fault detection by vibration analysis methods. *Applied Acoustics*, 114(1–3), 136–146. <https://doi.org/10.1016/j.apacoust.2016.07.024>

Zhou, Y., & Wang, B. (2022). Acoustic Multi-Parameter Early Warning Method for Transformer DC Bias State. *Sensors*, 22(8), 2906. <https://doi.org/10.3390/s22082906>

ANEXOS

Anexo A: Artículo indizado (caso de estudio 1)

Article

Short-Circuited Turn Fault Diagnosis in Transformers by Using Vibration Signals, Statistical Time Features, and Support Vector Machines on FPGA

Jose R. Huerta-Rosales ¹, David Granados-Lieberman ², Arturo Garcia-Perez ³, David Camarena-Martinez ³, Juan P. Amezcuita-Sanchez ¹ and Martin Valtierra-Rodriguez ^{1,*}

- ¹ ENAP-Research Group, CA-Sistemas Dinámicos y Control, Laboratorio de Sistemas y Equipos Eléctricos (LaSEE), Facultad de Ingeniería, Universidad Autónoma de Querétaro (UAQ), Campus San Juan del Río, Río Moctezuma 249, Col. San Cayetano, San Juan del Río, CP 76807, Mexico; roberto.huerta@enap-rg.org (J.R.H.-R.); juan.amezcuita@enap-rg.org (J.P.A.-S.)
- ² ENAP-Research Group, CA-Fuentes Alternas y Calidad de la Energía Eléctrica, Departamento de Ingeniería Electromecánica, Tecnológico Nacional de México, Instituto Tecnológico Superior de Irapuato (ITESI), Carr. Irapuato-Silao km 12.5, Colonia El Copal, Irapuato, Guanajuato, CP 36821, Mexico; david.granados@enap-rg.org
- ³ ENAP-Research Group, División de Ingeniería, Universidad de Guanajuato, Campus Irapuato-Salamanca, Carretera Salamanca-Valle de Santiago km 3.5 + 1.8 km, Comunidad de Palo Blanco, Salamanca, Guanajuato, CP 36885, Mexico; arturo.garcia@enap-rg.org (A.G.-P.); david.camarena@enap-rg.org (D.C.-M.)
- * Correspondence: martin.valtierra@enap-rg.org



Citation: Huerta-Rosales, J.R.; Granados-Lieberman, D.; Garcia-Perez, A.; Camarena-Martinez, D.; Amezcuita-Sanchez, J.P.; Valtierra-Rodriguez, M. Short-Circuited Turn Fault Diagnosis in Transformers by Using Vibration Signals, Statistical Time Features, and Support Vector Machines on FPGA. *Sensors* **2021**, *21*, 3598. <https://doi.org/10.3390/s21113598>

Academic Editor: Giulio D'Emilia

Received: 6 April 2021
Accepted: 17 May 2021
Published: 21 May 2021

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

Abstract: One of the most critical devices in an electrical system is the transformer. It is continuously under different electrical and mechanical stresses that can produce failures in its components and other electrical network devices. The short-circuited turns (SCTs) are a common winding failure. This type of fault has been widely studied in literature employing the vibration signals produced in the transformer. Although promising results have been obtained, it is not a trivial task if different severity levels and a common high-level noise are considered. This paper presents a methodology based on statistical time features (STFs) and support vector machines (SVM) to diagnose a transformer under several SCTs conditions. As STFs, 19 indicators from the transformer vibration signals are computed; then, the most discriminant features are selected using the Fisher score analysis, and the linear discriminant analysis is used for dimension reduction. Finally, a support vector machine classifier is employed to carry out the diagnosis in an automatic way. Once the methodology has been developed, it is implemented on a field-programmable gate array (FPGA) to provide a system-on-a-chip solution. A modified transformer capable of emulating different SCTs severities is employed to validate and test the methodology and its FPGA implementation. Results demonstrate the effectiveness of the proposal for diagnosing the transformer condition as an accuracy of 96.82% is obtained.

Keywords: fault diagnosis; support vector machine; linear discriminant analysis; FPGA; short-circuit fault; transformer; vibration signals



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

1. Introduction

In an electrical network, the transformer is one of the most valuable pieces of equipment. Although the transformer is a robust machine, it is under different electrical and mechanical stresses for inherent operating conditions. As well as under different weather conditions, which can produce different types of failures [1] and, consequently interrupt the continuity of the power supply and will influence the stability and safety of power systems [2]. The most common fault occurs in windings since they are among the most vulnerable internal components in a transformer [3,4]. Besides, the high electrodynamic forces that appear during short-circuited turns (SCTs) provoke winding deformations and core

failures [5,6]. Hence, the development and successful application of monitoring systems and protection schemes for reducing the negative effects that the transformer faults produce on service and users represent a crucial task [7]. There are different techniques to diagnose a transformer, for instance: dissolved gas analysis (DGA), insulating quality, power factor testing, thermography, frequency response analysis (FRA), among others [4]. Although promising results have been obtained with these traditional methods, the vibration analysis (VA) method has received special interest in recent years because it represents an effective way to assess different applications as deterioration induction motors [8], bearing faults [9], civil structures [10], etc. In a transformer, principally because the vibration signals directly correlate with winding mechanical changes [11].

Several examples of VA techniques in literature can be separated into signal-based, model-based, and knowledge-based [12]. The signal-based algorithms extract information from vibration signals. The Fourier transform (FT) can extract information, which is a common tool for a frequency domain analysis. Bartoletti et al. [13] use FT to differentiate between a healthy transformer and an anomalous transformer. Meanwhile, Bagheri et al. [14] analyze the vibration spectra to detect short-circuit initiation. Even though the FT has presented good results, its performance decreases when the signal presents non-stationary events as monitored in the transformers [15]. In this regard, advanced signal processing has been introduced, specifically time-frequency domain techniques. Borucki [16] develops an assessment method for the mechanical structure of the core and windings transformer using the short-time Fourier Transform.

Meanwhile, Liu et al. [17] propose a methodology based on the wavelet transform (WT). Zhao and Xu [18] present a variation of WT. They use the empirical wavelet transform (EWT) to construct a time-frequency representation using the Hilbert transform. Finally, Wu et al. [19] present a time-scale-frequency analysis technique based on wavelet packet transform and Hilbert Huang transform. The major drawback to adopting WT-based approaches is the dependence on the adequate selection of the mother wavelet and decomposition level [20] because they change in each different application. On the other hand, model-based algorithms establish a direct relationship between the vibration and the input parameters. A model based on transformer tank vibration is developed by Garcia et al. [21]. Their analysis can detect winding deformation by measuring tank vibrations; besides, they obtain the most suitable place to acquire vibration signals from the transformer tank. Zheng et al. [11] present a model to diagnose mechanical faults in windings. The faults diagnosed are the winding clamping force and winding deformation. Other authors have investigated the winding deformation. For instance, Zhou et al. [22] develop a winding vibration model coupled with electromagnetic force. Their model distinguishes between faulty and normal windings. The major drawback of this approach is the incapability to diagnose in a transient state. On the other hand, works such as [23–26] have used knowledge-based algorithms to diagnose transformers, which are focused on pattern recognition and decision making. Hong et al. [23] present a probability-based classification model, which extracts two features from vibration signals, then a support vector machine (SVM) for classifying the transformer condition is used. However, the use of two features is sufficiently accurate to distinguish between some classes. Unfortunately, it is not suitable for applications where several fault levels are considered because the features are not always capable of maximizing the separation among classes. In [24], a new methodology for mapping an artificial neural network (ANN) into a rule-based fuzzy inference system (FIS) is proposed, i.e., they extract the rules for the FIS from a trained ANN. Another approach based on fractal dimension and data mining is presented in [25]. This method employs different fractal dimension algorithms as fault indicators and compares different classifiers. The best results are obtained by the K-nearest neighbor-based classifier, showing the capability to detect different fault severities of SCTs. In the work presented by Bigdeli et al. [26], an intelligent winding fault classification through transfer function analysis is developed. Their review of intelligent methods found that the SVM classifier is known as one of the best methods for solving classification problems.

They compare the performance of SVM and ANN classifiers and conclude that SVM has better performance than ANN. They highlighted that the most important factor required for a successful SVM-based fault recognition is the proper selection of input features.

The abovementioned works employ different features to carry out the diagnosis. For instance, in [26] they use mathematical indices from the frequency domain (i.e., frequency and amplitude variations), whereas in [23] they use features in both time and frequency domains (i.e., energy and frequency complexity). The work presented in [7] focuses on energies and entropies, obtaining good results in different transformer operations, i.e., in transient or steady states. On the other hand, the fractals indices presented in [25] demonstrated that can be an effective tool for the diagnosis of transformers. On the other hand, many other works have been focused on the use of statistical time features (STFs) and the proper selection of such input features. Consequently, efficient results have been obtained on applications related to rotatory machinery [27–29], sensor fault detection [30], civil structures [10], solar flare prediction [31], cardiac diseases [32], epileptic seizure detection [33], amputees limb motion [34], and neurodegenerative diseases [35], among others. In general, STFs are used to find and describe relevant signal properties and, at the same time, differentiate between different types of signals or classes, e.g., a healthy condition class and a fault condition class. Another advantage of the STFs is that they can be applied to non-stationary time signals [36], which are very common in real scenarios. The most common STFs are mean, standard deviation, variance, root mean square (RMS), skewness, and kurtosis [27,37]; in addition to them, other STFs such as square root mean (SRM), shape factor, log energy entropy (LEE), skewness factor, kurtosis factor, among others are prospective features to be considered in the diagnosis of different transformer winding conditions. Therefore, all of them will be explored to develop a tool based on certain STFs, which allows the proper analysis of vibration signals and, consequently, the diagnosis of SCTs conditions. On the other hand, it is worth noting that it is necessary to select appropriate features to maximize relevance and minimize redundancy into the available information to obtain a better performance, knowing that the construction of models from datasets with many features is more computationally demanding [38]. There are two processes to reduce the number of features: feature extraction and feature selection. For feature extraction, the classical methods include linear discriminant analysis (LDA), principal component analysis (PCA), and multidimensional scaling (MDS) [39]. On the other hand, a widely used feature reduction method is the Fisher score, which removes redundant features [40,41].

All the above-reviewed research works, and in this article, a methodology based on STFs, SVM, and its implementation on a field-programmable gate array (FPGA) to diagnose a transformer under different SCTs conditions using vibration signals is presented. The methodology emphasizes the feature selection to obtain the best features that properly describe the winding condition. These features should maximize the separation among classes. The study was carried out with real vibration signals acquired from a modified transformer with diverse conditions of SCTs. The range of SCTs is from 0 to 35 turns with steps of 5 turns, where the condition of 0 SCTs represents the healthy condition. The first step is to calculate the nineteen STFs from vibration signals; then, the set of features are examined by a feature set reduction approach to take the most representative subset of features. The reduction process consists of a feature selection by using the Fisher score analysis and the feature extraction by using the LDA. For these results, a classification algorithm based on SVM is proposed, which is compared with another common classification approach, i.e., ANN. Besides, the methodology implementation into an FPGA is presented to provide a system-on-a-chip solution for the future development of online monitoring systems. The selection of this technology is due to its parallelism, high speed, reconfigurability, and low cost [42], which make it a promising tool for the development of smart sensors [43]. The obtained results show the effectiveness of the proposal.

2. Theoretical Background

In this section, a brief description of the algorithms used in the proposed work is presented.

2.1. Transformer Vibration

The transformer vibrations are generated principally into the core and windings. The magnetostriction phenomenon produces the core vibrations, which change the shape of a ferromagnetic material under a magnetic field. The forces are induced into the core when the voltage is applied; it appears in a perpendicular direction to the core and occurs twice per cycle; hence, the fundamental frequency of core vibration is double of the transformer excitation voltage frequency [44]. The magnitude of the transformer core vibration (F_{core}) is proportional to the square of the excitation voltage (V) as seen in (1). Due to the non-linearity of magnetostriction, harmonics of high frequencies are induced with random magnitudes [45].

$$F_{core} \propto V^2 \quad (1)$$

On the other hand, winding vibration is caused by electromagnetic forces resulting from the interaction between the winding current and the magnetic leakage flux. These forces have components in axial and radial directions, which are proportional to the square of the current signal; consequently, the vibration acceleration ($F_{winding}$) is proportional to the square of the current (I) as shown in (2) [22]. Similar to the core, the main acceleration frequency is twice the fundamental frequency of the current. Also, some harmonics of the fundamental frequency source can appear due to the magnetizing current or some residual currents. Finally, the influence of other factors in transformer vibration has a relatively minor impact, e.g., the power factor exhibits a very small variation over time, and the temperature factor has very small fluctuations [46].

$$F_{winding} \propto I^2 \quad (2)$$

As can be seen, the vibration signals are directly related to the transformer performance; therefore, the application of STFs to characterize the properties of the vibration signal can help to determine the transformer condition.

2.2. Statistical Time Features

STFs extract information from a signal about the behavior of the system, i.e., a system with different operating conditions has signals with different statistical parameters. In this regard, the objective of feature extraction in fault detection is to obtain parameters that can correctly reflect the working condition of a system and, consequently, identify its fault patterns [36]. It is worth noting that these features have been satisfactorily applied to condition monitoring due to their simplicity, low computational burden, and, principally, the capability to estimate general trends [10,40].

In vibration signal analysis, some STFs such as mean, RMS, standard deviation, and variance to study differences between signals associated with a fault condition have been studied [36]; meanwhile, in not purely stationary signals, advanced statistical features such as skewness and kurtosis have been used to examine them, by measuring the deviation of a distribution from the normal distribution [47]. Despite obtaining promising results, many other features have to be investigated. Hence, in this work, the most representative STFs such as mean, maximum value, RMS, SRM, standard deviation, variance, shape factor with RMS and SRM, crest, latitude and impulse factor, skewness, skewness factor, kurtosis, kurtosis factor, normalized fifth and sixth moment, Shannon entropy, LEE (i.e., log energy entropy), which have been presented in different fields of research, are calculated and analyzed to properly describe the operating condition of the transformer with SCTs conditions. In Table 1, the mathematical formulation for the above-mentioned nineteen STFs are presented [29,39,48–51], where x_i is the time signal for $i = 1, 2, \dots, N$, and N is the number of data points.

Table 1. Statistical time features.

| Feature | Equation | Feature | Equation |
|----------------------|-----------------------------------------------------------------------|-------------------------------|--------------------------------------------------------------------------|
| Mean | $F_{mn} = \frac{1}{N} \sum_{i=1}^N x_i$ (3) | Impulse Factor | $F_{if} = \frac{F_{\max}}{\frac{1}{N} \sum_{i=1}^N x_i }$ (13) |
| Maximum Value | $F_{\max} = \max(x)$ (4) | Skewness | $F_{skw} = \frac{\sum_{i=1}^N (x_i - F_{mn})^3}{N \cdot F_{std}^3}$ (14) |
| RMS | $F_{rms} = \left(\frac{1}{N} \sum_{i=1}^N x_i^2 \right)^{1/2}$ (5) | Skewness Factor | $F_{skf} = \frac{F_{skw}}{F_{rms}^3}$ (15) |
| SRM | $F_{srm} = \left(\frac{1}{N} \sum_{i=1}^N x_i ^{1/2} \right)^2$ (6) | Kurtosis | $F_{kur} = \frac{\sum_{i=1}^N (x_i - F_{mn})^4}{N \cdot F_{std}^4}$ (16) |
| Variance | $F_{var} = \frac{1}{N} \sum_{i=1}^N (x_i - F_{mn})^2$ (7) | Kurtosis Factor | $F_{kf} = \frac{F_{kur}}{F_{rms}^4}$ (17) |
| Standard Deviation | $F_{std} = (F_{var})^{1/2}$ (8) | Normalized 5th central Moment | $F_{5m} = \frac{\sum_{i=1}^N (x_i - F_{mn})^5}{N \cdot F_{std}^5}$ (18) |
| Shape Factor for RMS | $F_{srms} = \frac{F_{rms}}{\frac{1}{N} \sum_{i=1}^N x_i }$ (9) | Normalized 6th central Moment | $F_{6m} = \frac{\sum_{i=1}^N (x_i - F_{mn})^6}{N \cdot F_{std}^6}$ (19) |
| Shape Factor for SRM | $F_{ssrm} = \frac{F_{srm}}{\frac{1}{N} \sum_{i=1}^N x_i }$ (10) | Shannon Entropy | $F_{se} = - \sum_{i=1}^N x_i^2 \log(x_i^2)$ (20) |
| Crest Factor | $F_{cf} = \frac{F_{\max}}{F_{rms}}$ (11) | Log Energy Entropy | $F_{lee} = - \sum_{i=1}^N \log(x_i^2)$ (21) |
| Latitude Factor | $F_{lf} = \frac{F_{\max}}{F_{srm}}$ (12) | | |

Although it is good to obtain as much information as possible about a system, the information provided by the STFs can be redundant to carry out a diagnostic; in this regard, the most relevant features for this particular goal have to be selected in a posterior processing step [52], as mentioned in next subsection.

2.3. Feature Reduction

The performance of a fault identification system depends on the input features. A small set of features does not ensure the complete description of the system, e.g., different transformer SCTs conditions, and they may drive misclassification. Meanwhile, many features may increase the capability of discrimination but do not ensure the addition of relevant information related to malfunctions, i.e., the information can be redundant. In addition, the construction of models from data sets with many features is more computationally demanding [53]. Hence, algorithms to discover significant information from features, avoid redundancy, and reduce the data sets must be applied. The feature reduction is performed through the process of feature extraction and feature selection [38].

2.3.1. Feature Selection

Feature selection aims to maximize relevance and minimize redundancy into the information, taking a small feature subset from the original feature set [41]. In general, it is considered an approach to setoff filtering. The most used filter approaches are based on information, distance, consistency, and statistical measures, among others [49]. An effective strategy that has been successfully employed for different applications because of its good results and easiness of computation is the Fisher score analysis [41,49,54,55]. The Fisher score (FS) finds a subset of features with the maximum distance between classes while the

distances between data points in the same class are as small as possible. The FS^j of the j feature is computed as [54]:

$$FS^j = \frac{\sum_{i=1}^c n_i (\mu_i^j - \mu^j)^2}{\sum_{i=1}^c n_i (\sigma_i^j)^2} \quad (22)$$

where μ_i^j , σ_i^j and n_i are the mean, standard deviation, and size of i th c -class of the j th feature, respectively, μ^j is the mean of the whole data set of the j th feature. After computing the FS, the top-ranked features have been selected and extracted.

2.3.2. Feature Extraction

The feature extraction procedure transforms the original features into a new set constructed by the combinations of the original set (dimension reduction). Its purpose is to discover meaningful information in the new set. The most commonly used methods are the PCA (i.e., principal component analysis), [37,50,52], and the LDA (i.e., linear discriminant analysis) [56–59].

LDA is a supervised feature extraction technique that consists of a linear combination of the features, reducing the feature space, and scaling the features according to their importance. Besides, it deals with multi-class problems, has an easy implementation, and a clear physical interpretation. In general, the objective of LDA is to find a new lower-dimension projection to maximize the distance of samples from different classes and minimize the distance of samples from the same class.

The optimal projection vector \mathbf{w} to obtain a well-separated class in a low-dimensional space must satisfy the separability maximization criterion among classes. It is given by the Fisher criterion [58]:

$$\mathbf{w} = \operatorname{argmax} \left| \frac{\mathbf{w}^T \mathbf{S}_b \mathbf{w}}{\mathbf{w}^T \mathbf{S}_w \mathbf{w}} \right| \quad (23)$$

where \mathbf{S}_b is the between-class scatter matrix, which evaluates the separability of different classes, while \mathbf{S}_w is the within-class scatter matrix that evaluates the compactness within each class and the between-class scatter matrix. They are defined as [56]:

$$\mathbf{S}_b = \sum_{i=1}^c n_i (\boldsymbol{\mu}_i - \boldsymbol{\mu})(\boldsymbol{\mu}_i - \boldsymbol{\mu})^T \quad (24)$$

$$\mathbf{S}_w = \sum_{i=1}^c \sum_{j=1}^{n_i} (x_j^i - \boldsymbol{\mu}_i)(x_j^i - \boldsymbol{\mu}_i)^T \quad (25)$$

where n_i is the number of samples in the j th c -class, $\boldsymbol{\mu}_i = \frac{1}{n_i} \sum_{j=1}^{n_i} x_j^i$ denotes the mean feature of samples of the i th c -class, and $\boldsymbol{\mu} = \frac{1}{n} \sum_{i=1}^c \sum_{j=1}^{n_i} x_j^i$ is the mean feature of all samples.

Solving Equation (23), the optimal projection vector \mathbf{w} is the eigenvector corresponding to the maximum eigenvalue λ of [57]:

$$\mathbf{S}_w \mathbf{w} = \lambda \mathbf{S}_b \mathbf{w} \quad (26)$$

For multi-class classification, the projection matrix \mathbf{W} is constructed as a set of eigenvectors corresponding to the largest k eigenvalues $\{\lambda_i | i = 1, 2, \dots, k\}$. Finally, the feature extracted \mathbf{Y} into a new low-dimensional space by the projection of the original data set \mathbf{x} can be obtained as follows [40]:

$$\mathbf{Y} = \mathbf{W}^T \mathbf{x} \quad (27)$$

This new set of features contains the best information, improving the accuracy of the classification method [38].

2.4. Support Vector Machine

The application of SVMs in fault diagnosis has attracted the attention of researchers around the world due to their excellent classification performance on small samples, high dimension, and nonlinear problems. The SVM can solve linear classification problems easily, and when the classification problem is nonlinear, the SVM turns the nonlinear and inseparable classification problem into a nonlinear and separable classification problem [60].

The SVM is a linear classifier whose objective is to find an optimal hyperplane between two different classes to obtain a decision function to classify the samples in a specific class. The decision function is constructed as [30,61]

$$g(x) = \boldsymbol{\omega}^T \mathbf{x} + \omega_0 = 0 \quad (28)$$

where $\boldsymbol{\omega}$ is the vector of weights, \mathbf{x} is the input vector, and ω_0 is the bias. The goal is to search the direction that gives the maximum possible margin between the support vectors and the hyperplane. The equations for the support vectors of each class are given as

$$\begin{aligned} \boldsymbol{\omega}^T \mathbf{x} + \omega_0 &\geq 1, \forall \mathbf{x} \in \omega_1 \\ \boldsymbol{\omega}^T \mathbf{x} + \omega_0 &\leq -1, \forall \mathbf{x} \in \omega_2 \end{aligned} \quad (29)$$

where ω_1 and ω_2 correspond to each class. Then, to find the optimal hyperplane (training), the quadratic problem minimizing presented in Equation (30) has to be solved:

$$J(\boldsymbol{\omega}) \equiv \frac{1}{2} \|\boldsymbol{\omega}\|^2 \quad (30)$$

subject to

$$y_i (\boldsymbol{\omega}^T \mathbf{x}_i + \omega_0) \geq 1, \quad (31)$$

then, the final decision function can be obtained as

$$\boldsymbol{\omega} = \sum_{i=1}^N y_i \alpha_i \mathbf{x}_i, \quad (32)$$

where α_i are the Lagrange multipliers, $y_i = \pm 1$ is a class indicator for each training data \mathbf{x}_i , which also are known as support vectors. In contrast, the optimal hyperplane classifier is known as a support vector machine. When nonlinear and non-separable patterns appear, the resulting linear classifier is

$$g(\mathbf{x}) = \sum_{i=1}^N y_i \alpha_i K(\mathbf{x}_i, \mathbf{x}) + \omega_0, \quad (33)$$

where \mathbf{x}_i is assigned to ω_1 if $g(\mathbf{x}) > 1$ or ω_2 if $g(\mathbf{x}) < 0$, and $K(\mathbf{x}_i, \mathbf{x})$ is a kernel function. The most used kernel function is the radial basis function (RBF) [2,60]; therefore, it is used in this study, and it is defined as

$$K(\mathbf{x}_i, \mathbf{x}) = \exp\left(-\frac{\|\mathbf{x} - \mathbf{x}_i\|^2}{\sigma^2}\right) \quad (34)$$

The parameter σ is called the kernel scale. To control the SVM generalization capability, a misclassification parameter C is also defined. This parameter controls the trade-off between the margin and the size of the slack variables. The selection of SVM parameters C and σ has an important influence on the classification accuracy. Both parameters are chosen by the user [26]. In Figure 1, the corresponding architecture of an SVM is shown.

The SVM is commonly employed for binary classification; yet, it can also be used for multiple-class classification. For this last task, the multiple one-against-other classifiers are adopted. There are two approaches to carry out the multiple one-against-others

classifications. The first approach is to put each classifier in series, whereas, in the second, the one-against-others SVMs are putting in parallel. In this work, the one-against-all approach is employed in a parallel way because the input sample can be evaluated by each classifier at the same time, saving processing time and exploiting the FPGA capabilities. The scheme for this approach is shown in Figure 2 [62].




Figure 1. SVM architecture.

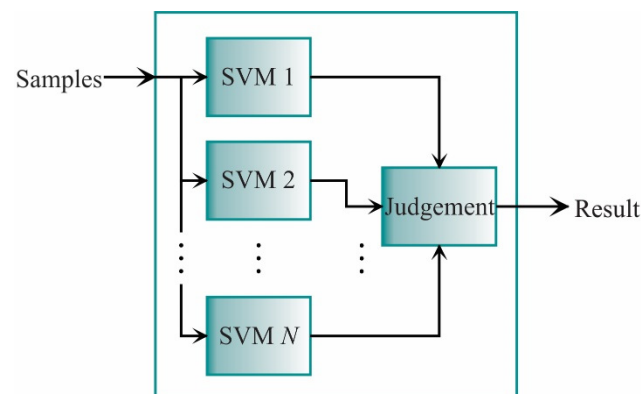


Figure 2. Scheme for the parallel SVM approach.

Each classifier in Figure 2 is designed to separate one class from the rest. As aforementioned, it is expected that all points from the class ω_i in the SVM_i classifier yields $g(\mathbf{x}) > 0$, while a negative value is obtained for the rest of the classes. Then, \mathbf{x} data is classified in ω_i if satisfy:

$$\omega_i^T \mathbf{x} + \omega_{i0} > \omega_j^T \mathbf{x} + \omega_{j0}, \forall i \neq j \quad (35)$$

To evaluate the performance of the SVM, the k -fold cross-validation is utilized. The experiments are separated into k groups. The i th group is left out, and the others $k-1$ groups are used to train the SVM. The group left out is used to carry out the validation process and measure the error. The process is repeated k times with the $(i-1)$ th validation data; where $i = 1, \dots, k$. Finally, the error of each k validation is averaged [33]. In this work, five-fold cross-validation is used because it allows one to train the classifier with a large number of samples by class (80%), maintaining the error estimation and its variance in low values [63].

3. Proposed Methodology

The proposed work is carried out as shown in Figure 3. In general, the vibration signals from the transformer under different SCT fault conditions are acquired. Then, these signals are analyzed during the design stage to obtain the best STFs and the SVM settings, which will be implemented into the FPGA for hardware computation. The result of both the design and implementation stages is the transformer diagnosis.

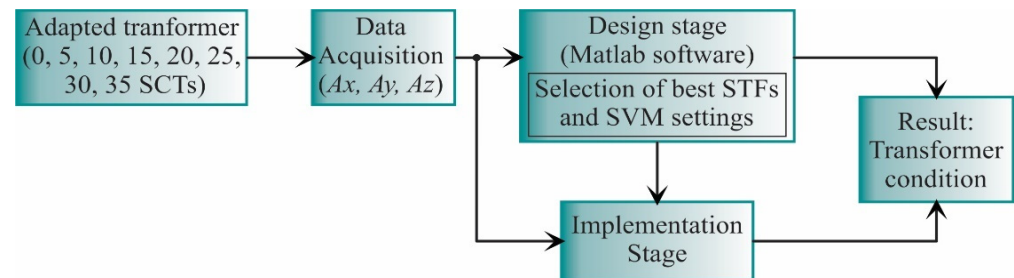


Figure 3. General block diagram for the proposed work.

3.1. Design Stage

In the design stage (see Figure 4), the vibration signals acquired are from the three axes (A_x , A_y , A_z). These signals are acquired from a single-phase transformer without load during its energization; therefore, the vibration signals include transient state and steady-state. The transformer can emulate diverse conditions of SCTs: 0, 5, 10, 15, 20, 25, 30, and 35, where 0 SCT is the healthy condition. The energization is carried out through a solid-state relay.

In the design stage, the 19 STFs are calculated for each axis to find properties that can describe the behavior of the vibration signal. The analyzed STFs are specified in Table 1, Section 2.2. When the STFs are calculated, they are also normalized to obtain a suitable measure to compare the extracted features. Then, the feature reduction, which consists of feature selection and feature extraction, is carried out. In the feature selection, a subset of features that maximize the distance between classes and minimize the distance between data points are selected. Meanwhile, the feature extraction uses a transformation matrix to decrease the n -dimensional space to a 2-dimensional space: feature 1 (f_1) and feature 2 (f_2). Once the data have been obtained, they are separated into two groups: a training set and a testing set. The training set is used to construct the SVM models, i.e., to train the SVM, and the testing set is used to evaluate the SVM models and validate the classification results.

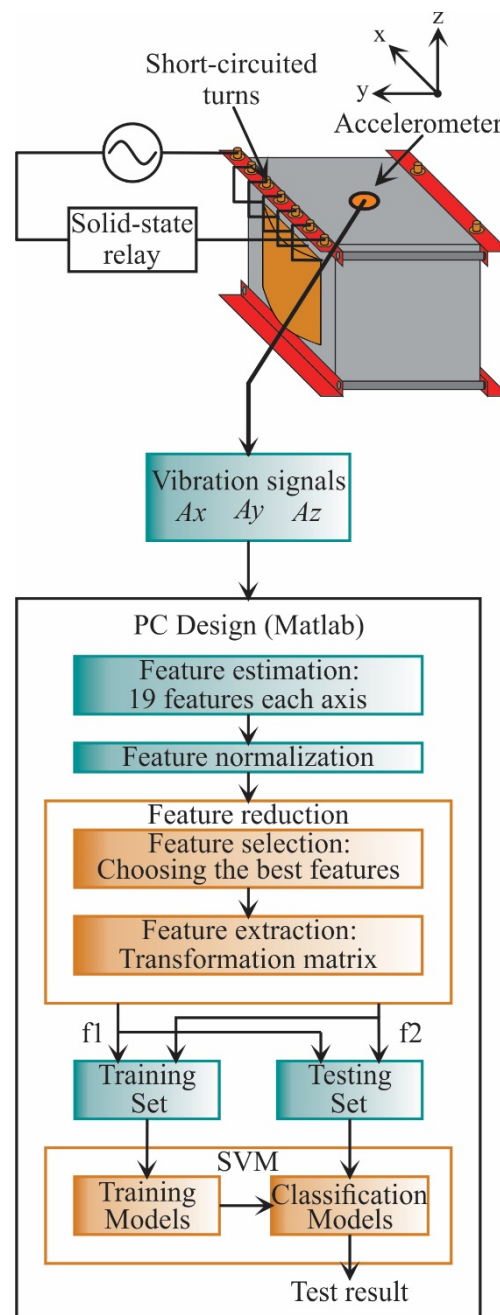


Figure 4. Flowchart for the proposed methodology during the design stage.

3.2. Implementation Stage

The implementation stage (see Figure 5) utilizes the best features found in the design stage. These features are only acquired from two axes (A_x , A_y); in the design stage, it was observed that the estimated features from the z-axis do not present relevant information and, therefore, are discarded. Then, the features are calculated as the first step, and then they are normalized. Next, the data is reduced to a 2-dimensional space using the transformation matrix calculated in the design stage. Finally, the classification unit based on SVM classifiers, which was constructed and validated in the design stage, diagnoses the transformer condition. It is worth noting that the implementation stage can be carried out in a personal computer, e.g., using Matlab software as was used in the design stage; yet, in this work, to provide a system-on-a-chip-solution for future equipment development, the FPGA implementation is developed. In this regard, the information used to normalize the features, the transformation matrix, and the values that describe the SVM models are

stored in a read-only memory (ROM), included in the FPGA. The SVM-based classification stage determines the SCTs condition, showing values of 0, 1, 2, 3, 4, 5, 6, and 7, where class 0 represents the healthy condition, class 1 represents 5 SCTs, and so on.

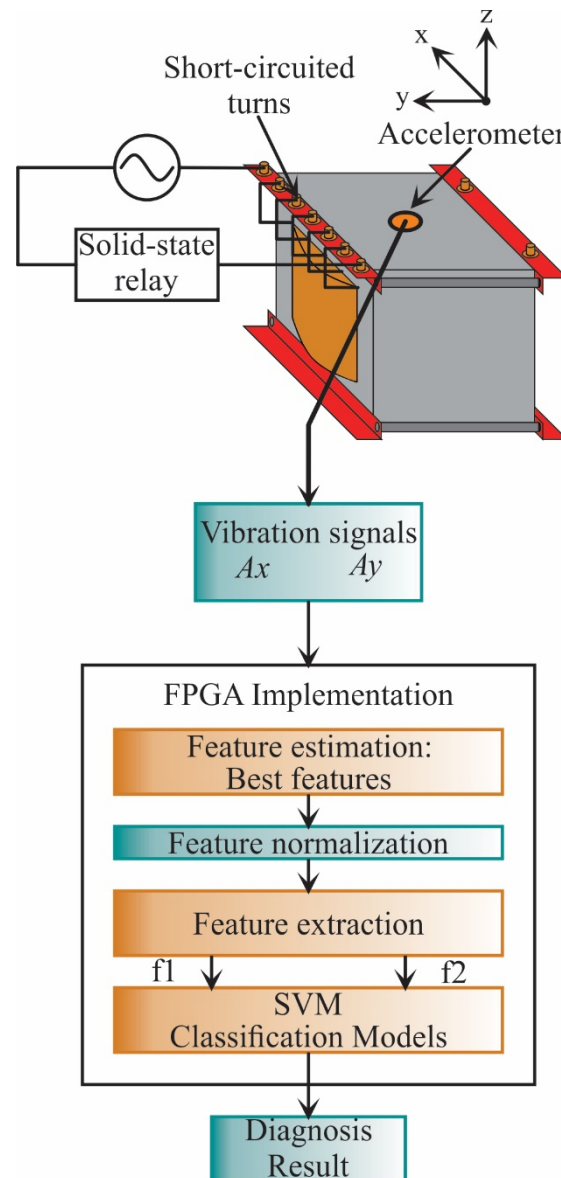


Figure 5. Flowchart for the proposed methodology during the implementation stage.

4. Experiments and Results

This section shows the experimental setup, PC results, and FPGA results.

4.1. Experimental Setup

The experimental setup to test and validate the proposal is shown in Figure 6. A single-phase transformer of 1.5 kVA operated to 120 V is used. The transformer has 135 turns in its primary winding, which was modified to emulate several SCTs faults. These conditions are 0, 5, 10, 15, 20, 25, 30, 35 SCTs, where 0 SCT is the healthy condition. The vibration signals are measured from the transformer employing a triaxial accelerometer model 8395A from KISTLER, which can measure ± 10 g with a resolution of 400 mV/g over a bandwidth of 1000 Hz. The accelerometer is located on the clamping frame of the transformer, where it can receive the vibrations from the core and the windings in a symmetrical way. The accelerometer data for the design stage (see Figure 4) are acquired employing a data ac-

quisition system (DAS) based on the National Instruments NI-USB6211 board, which has a 16-bit analog-to-digital converter configured with a sampling frequency of 6000 samples/s. A solid-state relay model SAP4050D is employed to energize the transformer and start the test. The acquisition time is 5 s, enough to include the transient state and steady-state for each test during the transformer energization. Figure 7 shows an example of vibration signals acquired from the transformer in a healthy condition and a damage condition, respectively. At the end of each test, the transformer is de-energized with the activation of the autotransformer to eliminate the remnant flux. For each condition, 20 tests were performed. The resulting data are processed on a PC by using Matlab software. The PC has Windows 10 with a processor i7-4510U at 2.6 GHz and 8 GB of RAM. On the other hand, during the implementation stage, the complete processing is carried out into the FPGA by considering that the proposed methodology was previously designed. The used FPGA is a Cyclone IV EP4CE115F29C7 into an Altera DE2-115 development board. In Figure 6, a zoomed area of the liquid crystal display from the development board to show the SCTs class during a 5 SCTs fault identification is shown. It is worth noting that the proposed system can be considered as a smart sensor since it contains an accelerometer as a primary sensor, a DAS, and processing capabilities with communication protocols. However, the development of a smart sensor will need both optimization and design stages to convert the proposed system into a portable smart sensor-based monitoring system.





Figure 6. Experimental setup.



(a)

Figure 7. Cont.

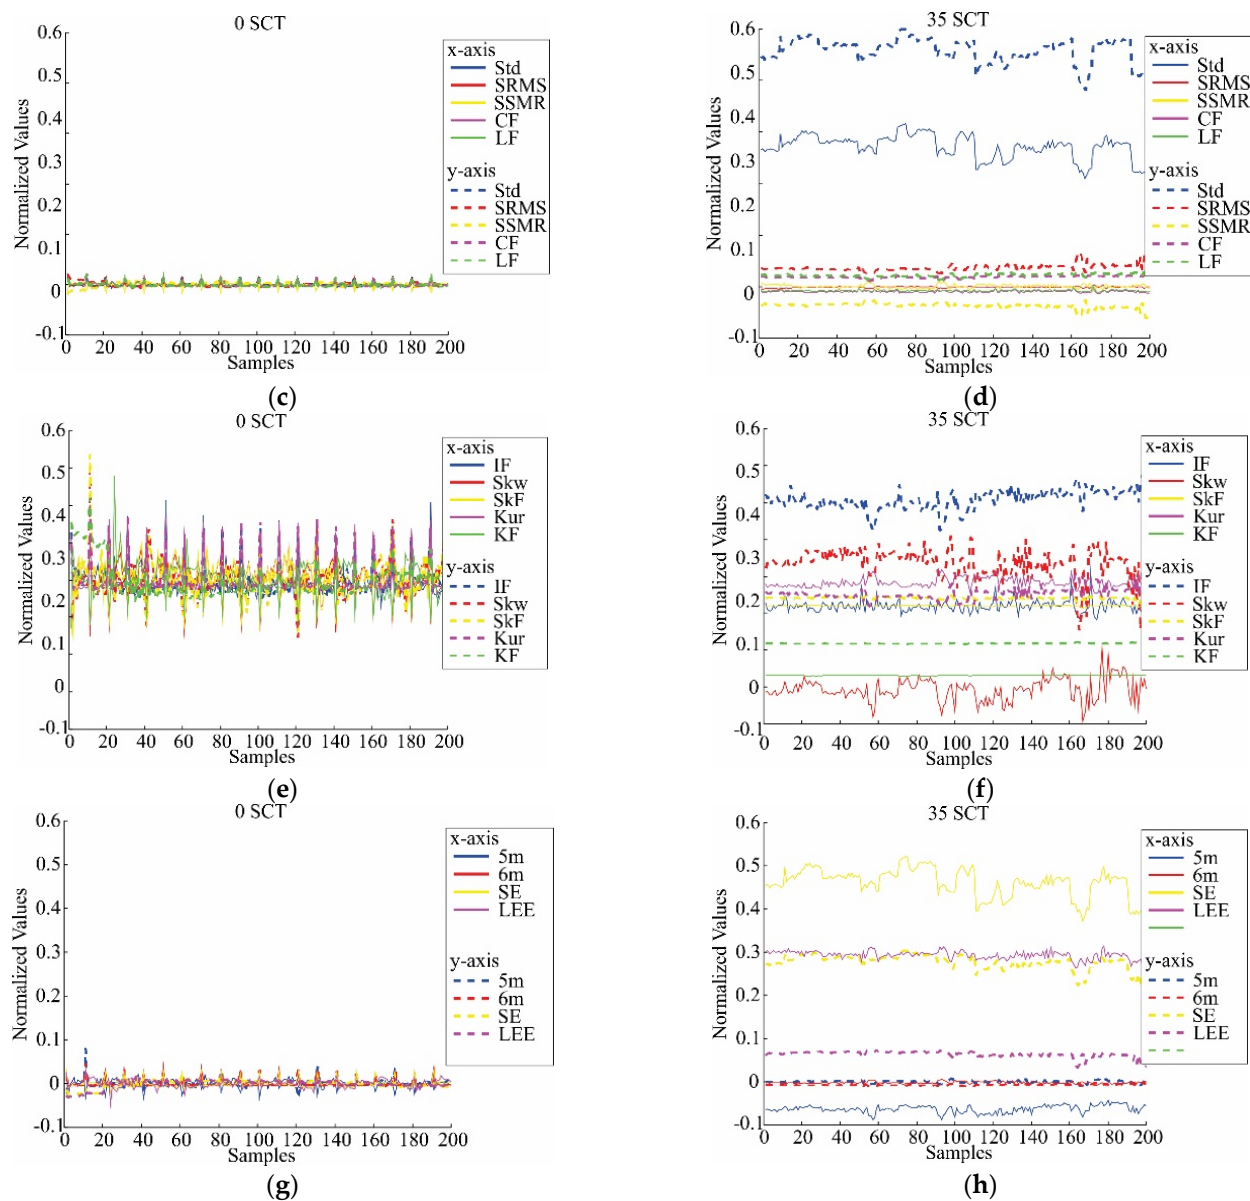


Figure 8. Estimated normalized features in healthy condition and 35 SCTs fault condition: (a) Mean, maximum value (Max), RMS, SRM, and variance (Var) for 0 SCT; (b) Mean, maximum value (Max), RMS, SRM, and variance (Var) for 35 SCT; (c) Standard deviation (Std), shape factor (RMS) (SRMS), shape factor (SRM) (SSRM), crest factor (CF), and latitude factor (LF) for 0 SCT; (d) Standard deviation (Std), shape factor (RMS) (SRMS), shape factor (SRM) (SSRM), crest factor (CF), and latitude factor (LF) for 35 SCT; (e) Impulse factor (IF), skewness (Skw), skewness factor (SkF), kurtosis (Kur), and kurtosis factor (KF) for 0 SCT; (f) Impulse factor (IF), skewness (Skw), skewness factor (SkF), kurtosis (Kur), and kurtosis factor (KF) for 35 SCT; (g) 5th Normalized moment (5m), 6th normalized moment (6m), Shannon entropy (SE), and log energy entropy (LEE) for 0 SCT; (h) 5th Normalized moment (5m), 6th normalized moment (6m), Shannon entropy (SE), and log energy entropy (LEE) for 35 SCT.

4.2.2. Feature Selection

A significant number of features do not mean that all of them provide representative information to describe the behavior of the system or, in this case, the SCTs conditions, as this information can be redundant or irrelevant. In this regard, feature selection aims to filter these features to obtain a more informative subset and, at the same time, minimize their redundancy. This process is carried out by computing the Fisher score, which is a relative measure in terms of distance between the data points from diverse classes. A large Fisher score value represents a considerable distance between features; hence, these

features are more relevant. However, the method must evaluate a total of $2^m - 1$ subsets, where m represents the total number of features in the data set. In this case, the number of features is 38, i.e., 19 for the x-axis and 19 for the y-axis. The evaluation of all these subsets is computationally infeasible; then, a heuristic method can be proposed to find a proper subset of features without an expensive computational burden [38]. A three-feature combination subset is generated in the first place, 8436 different subsets are created. Subsequently, these subsets are evaluated through the Fisher score, and the best 10 combinations are selected, i.e., the subsets with the 10 highest Fisher score values. This process must be replicated for all combinations of conditions to find the maximum separability between all classes. In this way, having eight conditions, the number of combinations is 28, implying 236,208 Fisher score calculations, which is negligible compared with $2^m - 1$. A histogram that shows the features that most maximize the separation between classes can be obtained (see Figure 9). There, the features with the biggest numbers of appearances and above a threshold value are adopted to be part of the new subset; in this work, the threshold value of 35 is selected by trial and error, looking for the best classification results, as will be shown in Section 4.2.4. In this regard, the new subset of features is selected. It contains the features: 4, 15, 19, 22, 24, 25, and 34, as shown in Figure 9. These features correspond to SRM, kurtosis factor, and LEE for x-axis and RMS, standard deviation, variance, and kurtosis factor for the y-axis.




Figure 9. Histogram for the best features.

4.2.3. Feature Extraction

In this process, a new feature subset of 2-dimensional transformation from the original subset is obtained. As abovementioned, LDA and PCA can offer a different transformation for the data set. In Figure 10, the results for the transformations using both techniques are shown. Figure 10a shows the transformation carried out by PCA, whereas Figure 10b shows the LDA transformation. Although good results are obtained in both transformations, a better grouping in terms of area is observed for LDA; therefore, it is selected as the transformation step.

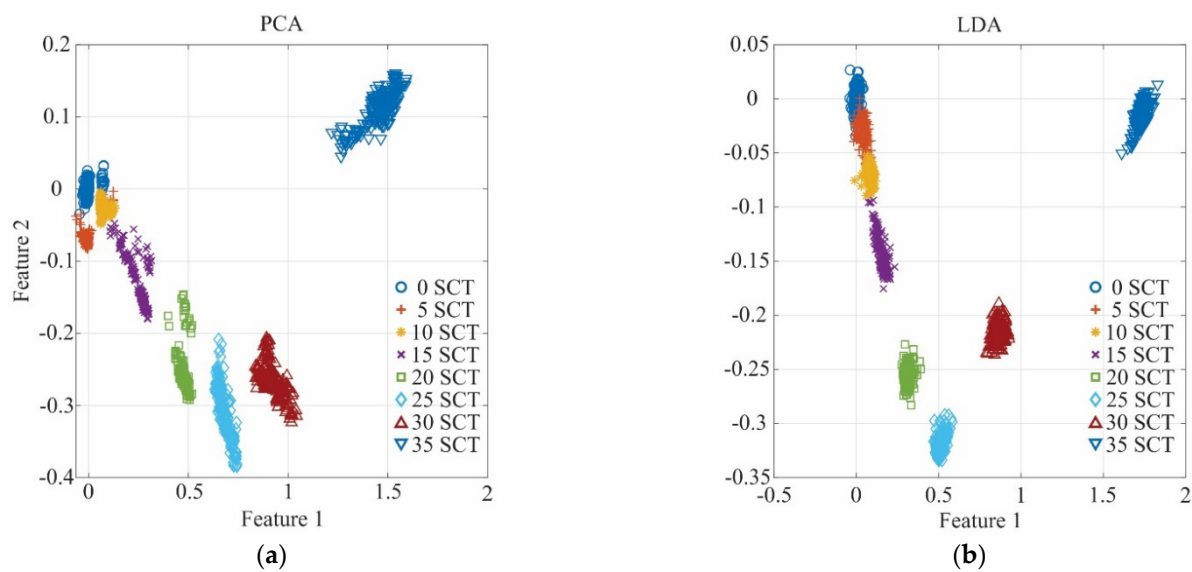


Figure 10. Performance comparison between (a) PCA transformation and (b) LDA transformation.

4.2.4. Classification Results

An SVM was trained to carry out the classification task by using MATLAB software. As σ and C parameters of the SVM have a significant influence on the classification accuracy, an exhaustive analysis in a trial-and-error process was carried out, resulting in values of 0.25 and 50, respectively. The training and validation steps were carried out using a k -fold validation with a k value of five. To compare the performance of the SVM, an ANN was used. The ANN parameters were also chosen in a trial-and-error process, resulting in an ANN with seven inputs (i.e., seven features), nine neurons in the hidden layer, and eight neurons (i.e., eight SCTs conditions) in the output layer. The activation functions are log-sigmoid for the input and hidden layers and linear for the output layer. The obtained results show that the SVM has a better performance than the ANN when the same number of features is used. The results of both classifiers are presented in Table 2.

Table 2. Accuracy percentage of SVM and ANN for different threshold values according to Figure 9.

| Threshold | Features | SVM (%) | ANN (%) |
|-----------|----------|---------|---------|
| 0 | 38 | 97.76 | 95.29 |
| 30 | 10 | 96.76 | 93.98 |
| 35 | 7 | 96.82 | 94.97 |
| 40 | 5 | 96.64 | 94.33 |

As can be seen in Table 2, the SVM has better performance than ANN in each subset of features chosen. The number of features in each subset is defined by the threshold value obtained in the feature selection (see Figure 9). For both classifiers, the best results are when all the features are used, i.e., a threshold of 0. To keep a balance between the number of features and the classification performance, the threshold of 35, i.e., 7 features, is chosen. This subset has better performance than the subset of 10 features and only decreases one percent compared to the subset of 38 features, which implies a noticeable reduction of the computational burden.

Figure 11 shows the clusters and their decision regions for the SVM results using a k -fold validation. In particular, Figure 11a shows the clusters produced for a threshold of 35, i.e., seven features, and the LDA transformation for these features. It can be noted that for the initial conditions: healthy (blue), 5 SCTs (yellow), 10 SCTs (red), and some data points of 15 SCTs (green), the clusters are close to each other, even some points are mixed; yet, it is possible to differentiate them and define the borders between their decision regions

as shown in Figure 11b. The remaining clusters (20, 25, 30, and 35 SCTs) do not present any complications. Figure 11c,d show the results for different k values in the five-fold validation. Figure 11c shows the results for $k = 4$, where some points misclassified can be observed, principally data points from the 5 SCTs and 10 SCTs conditions; yet, the accuracy percentage keeps above 90%. Figure 11d shows the results for $k = 3$, in which it can be seen that most of the validation data points were classified adequately. Table 3 shows the confusion matrix using five-fold validation when $k = 3$, where it can be observed that only one data is misclassified, obtaining 99.7 % of effectiveness. It is worth noting that for any condition that has not to be contemplated in the training step, the resulting class will follow the regions shown in Figure 11d, i.e., it can be No Class or be one of the two adjacent classes (e.g., for a 7 SCT condition, the resulting class can be either 5 SCT condition or 10 SCT condition according to the decision region). For a better resolution and accuracy in the classification of the fault severity, further research for interpolated and extrapolated conditions has to be carried out.

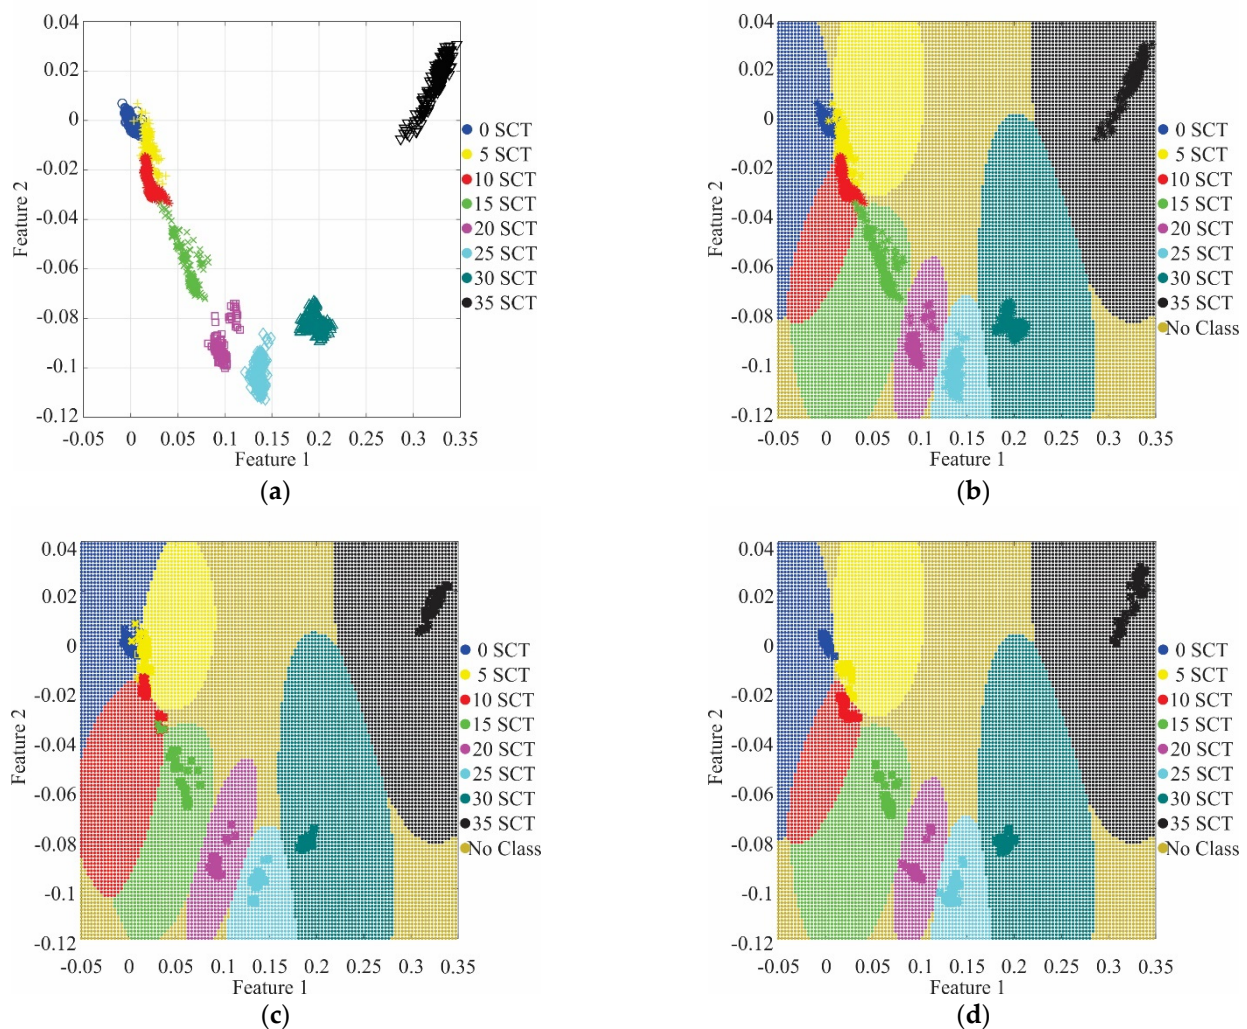


Figure 11. SVM classification: (a) dataset using 7 features; (b) projection of decision regions and his training data from a five-fold; (c) projection of decision regions and validation data from a $k = 4$; (d) projection of decision regions and validation data from $k = 3$.

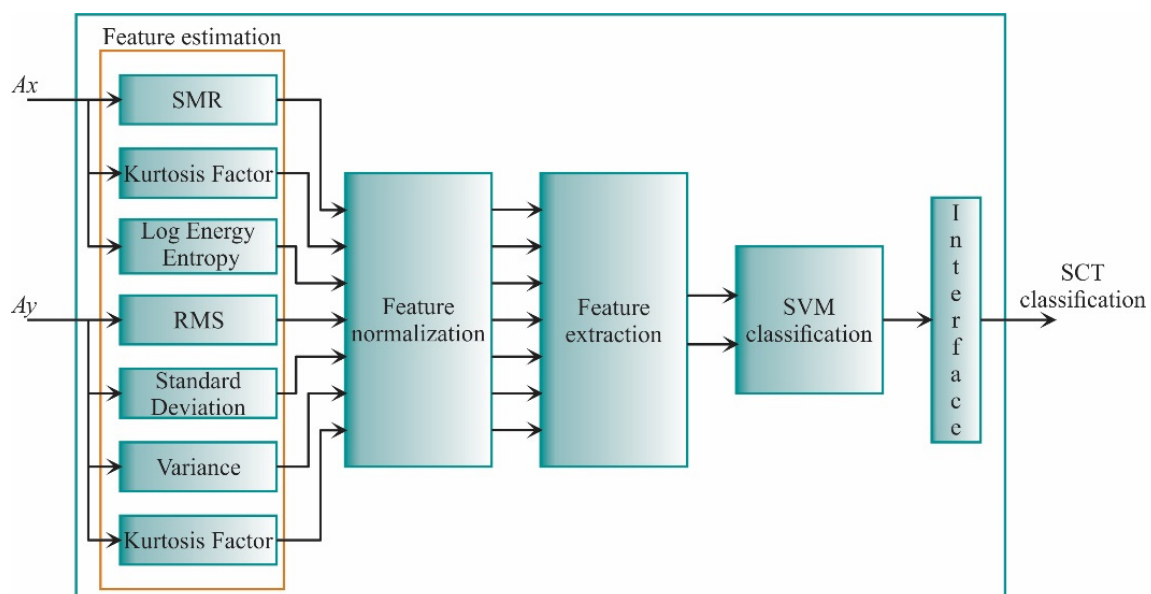
Table 3. Confusion matrix of SCTs classification using five-fold validation and $k = 3$.

| SCTs | 0 | 5 | 10 | 15 | 20 | 25 | 30 | 35 |
|------|----|----|----|----|----|----|----|----|
| 0 | 40 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| 5 | 0 | 40 | 1 | 0 | 0 | 0 | 0 | 0 |
| 10 | 0 | 0 | 39 | 0 | 0 | 0 | 0 | 0 |
| 15 | 0 | 0 | 0 | 40 | 0 | 0 | 0 | 0 |
| 20 | 0 | 0 | 0 | 0 | 40 | 0 | 0 | 0 |
| 25 | 0 | 0 | 0 | 0 | 0 | 40 | 0 | 0 |
| 30 | 0 | 0 | 0 | 0 | 0 | 0 | 40 | 0 |
| 35 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 40 |

4.3. FPGA Implementation

Once the methodology has been developed and validated, the FPGA-based hardware solution is also implemented for future equipment development such as smart sensors [43,64], flexible systems that include software [65,66], different sensors with real implementations [67], among others.

Figure 12 shows the principal architecture for the proposed FPGA processor. It follows the structure presented in Figure 5. In general, the FPGA-based processor consists of four main steps. The first step is the feature estimation in which the STFs are computed for the vibration signals of the x-axis and y-axis. The second and third stages are feature normalization and feature extraction. Finally, the SVM classification stage classifies the new sample into a particular SCTs condition. All these stages are described in detail in the next subsections.

**Figure 12.** The principal architecture of the FPGA-based processor.

4.3.1. Statistical Time Features Estimation

For this stage, seven features have to be estimated, i.e., three for the x-axis and four for the y-axis. Nevertheless, one of these features appears in both axes, i.e., the kurtosis factor. Therefore, six processing cores will be only constructed. Figure 13 shows the core for the mean, which is given by Equation (1). This core is based on accumulator structure. The function of this structure is to compute successive sums using one adder and two registers. The adder output is connected to the inputs of the registers; the output of one of them is connected in feedback to the adder to contain the cumulative value of $N - 1$ successive sums of the input signal, x , where N is the number of samples; the word length

of each x data is $e = 2$ and $f = 16$. The other register will contain the total cumulative value until the count concludes. Each register has a load signal to maintain the respective values. From now on, the accumulator structure will be represented as a single block and will not have the load signals. The accumulator output goes to a divider to be divided by the number of samples N and obtain the mean. The divider is a digital structure based on a successive approximation register (SAR). Taking the division as $A/B = Y$, the SAR successively approximates the quotient Y by comparing the product of the quotient and the divisor ($Y \times B$) with the dividend A until the product is equal or very close to the dividend. Also, the divider includes the signal to initiate the process (STR) and the signal that indicates the process ending (RDY). For clarity, the load, start, and ready signals from registers, accumulators, and dividers will also be omitted in the next diagrams. For completing the structure, a counter is used to count from zero to $N-1$ when the control unit indicates it. The control unit synchronizes the start and the end of the complete process.

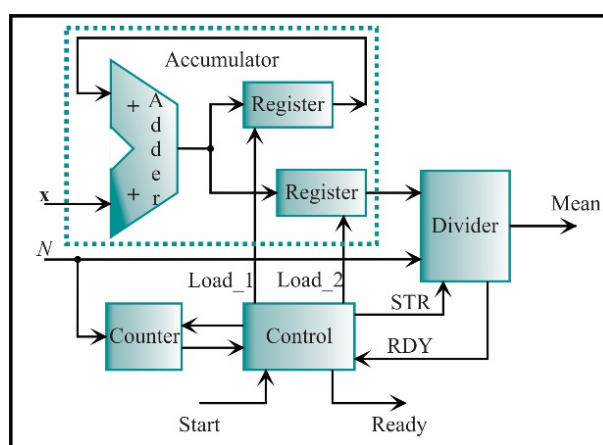


Figure 13. The architecture of the processing core for computing the mean.

The variance processing core is shown in Figure 14. Rearranging Equation (7), the variance can be computed as

$$F_{var} = \frac{1}{N} \sum_{i=1}^N x_i^2 - \left[\frac{1}{N} \sum_{i=1}^N x_i \right]^2 \tag{37}$$

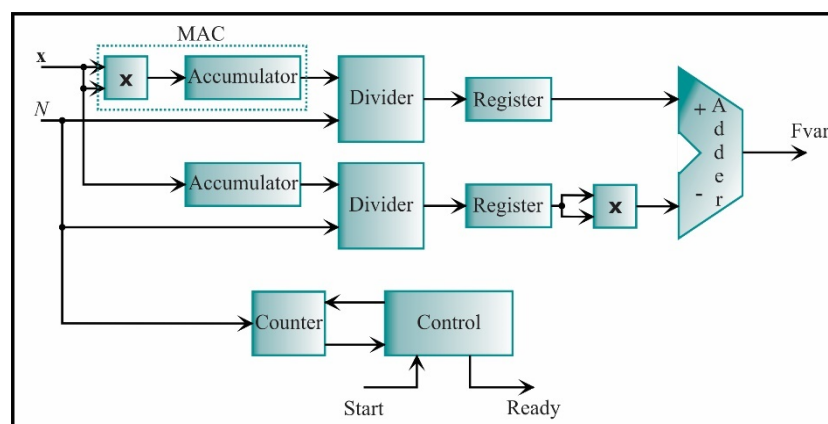


Figure 14. The architecture of the processing core for computing the variance.

With this equation, the variance processing core is constructed. This core is based on the digital structure called multiplier-accumulator (MAC). It computes a successive sum of products. Also, an accumulator is employed to cumulate the input values, x . The output signals of the accumulator are connected to a divider and, next to, a register for storage.

Then, a subtraction between the first term and the second term of Equation (37) is carried out, where the second term is squared.

In Figure 15, the RMS architecture, which is described by Equation (5), is shown. It consists of a MAC, a divider, and a square root unit. The square root is similar to the divider, i.e., it is based on a SAR, but they differ in the comparison. For the square root, the root square value is compared with the squared radicand until this value is equal or very close to the root value. The signals to control the square root are start and ready. These signals start and finish the process. For clarity, they will be omitted in the next diagrams. The output of the square root block is the RMS value.

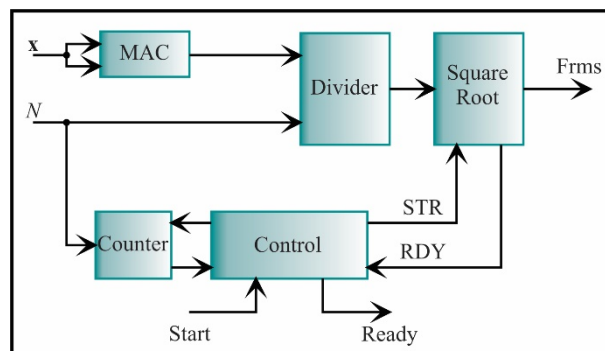


Figure 15. The architecture of the processing core for computing the RMS.

The SRM core is described by Equation (6) and shown in Figure 16. In the first place, the absolute value is computed. To always obtain a positive number, it is necessary to recognize the sign of the number; this is possible by comparing the most significant bit; if the most significant bit is one, the number is negative; otherwise, it is positive. If the number is negative, then the two's complement is applied to obtain a positive number. The next step is to compute the square root of this number and accumulate it. When all the values were accumulated, the output value is divided by the number of data, N . Finally, the result of the division is squared, giving the SRM value.

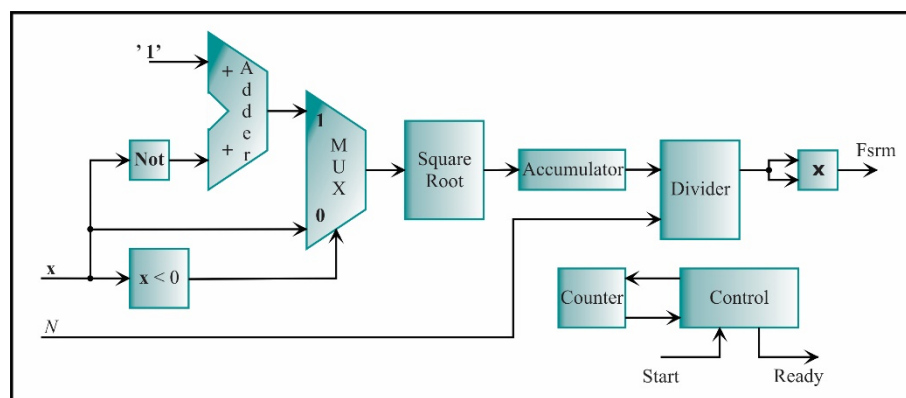


Figure 16. The architecture of the processing core for computing the SRM.

The next processing core is the kurtosis factor. It is described by Equation (17). However, it is necessary to first compute the kurtosis index. In this regard, Figure 17 shows the architecture of the kurtosis according to Equation (16) by using cores previously described, such as adders, multipliers, dividers, and accumulators. To compute the kurtosis, it is necessary to execute a subtraction between the input data and the mean of all the input data; therefore, the mean is first computed according to Equation (3) using the architecture presented in Figure 13. While the mean is computed, the input data is stored in a random access memory (RAM); additionally, the RAM has the input ADD to indicate the direction

in which the input data will be stored when the input WE enable the option of writing it. Then, the subtraction can be computed. The result goes to a serial multiplier, and the product goes to two accumulators. One accumulator accumulates the subtraction elevated to the fourth power, and the other one accumulates the square subtraction. The output of each accumulator is connected to a divider, dividing the accumulated values by N . Both results are connected to another divider, where the dividend goes direct; meanwhile, the divisor passes by a multiplier to be squared. Finally, as the kurtosis value of the normal distribution is three, it is necessary to subtract this value from the resulting value to obtain the kurtosis value of a zero-value normal distribution.

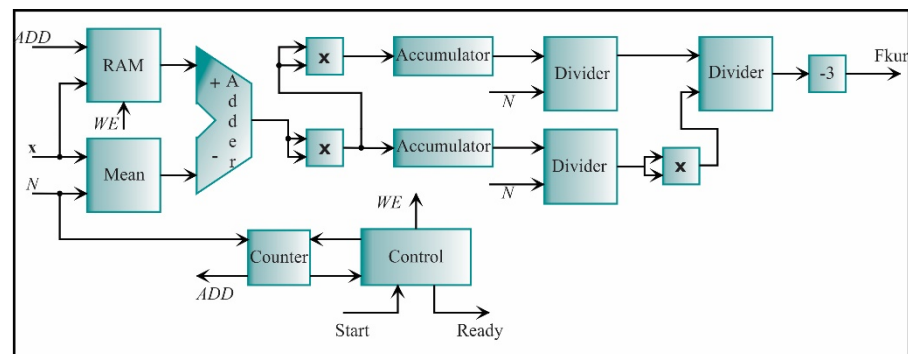


Figure 17. The architecture of the processing core for computing the kurtosis.

The architecture of the kurtosis factor is presented in Figure 18. It consists of two essential cores: the kurtosis and RMS, which were previously described. The signal to initiate both processes is STR and the signals that indicate the end of the process is RDY_K for the kurtosis and RDY_R for the RMS. The value of each core is stored in a register. The RMS value is elevated to the fourth power, becoming the divisor of the kurtosis value. The resulting value is the kurtosis factor value.

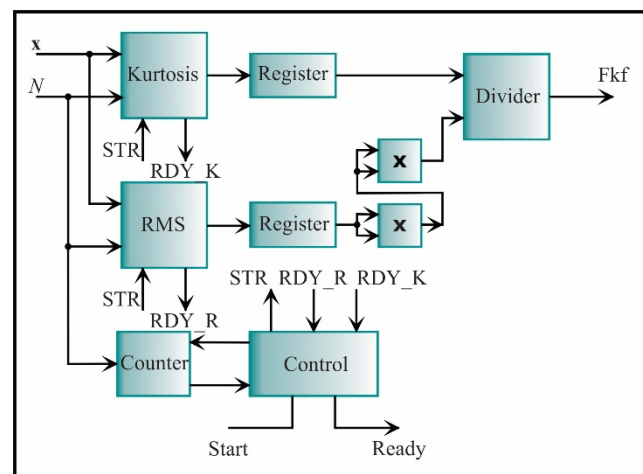


Figure 18. The architecture of the processing core for computing the kurtosis factor.

The latter feature is the LEE, which is described by Equation (21). The proposed core for its computing is shown in Figure 19. In general, the LEE corresponds to the successive accumulation of logarithms of a squared signal. To do so, a multiplier for obtaining the squared signal is used, while the logarithm is estimated using Mitchell's algorithm [68] and logarithm properties. The $-\text{Log}_2$ block initiates the process through the signal STR and the signal that indicates the end of the process is RDY. As the input signal cannot be zero or one, a comparator (Comp) is previously used. Finally, the control unit synchronizes the complete

process taking the value from the comparator (CMP) and starting the $-\text{Log}_2$ block, giving through the accumulator the LEE value.

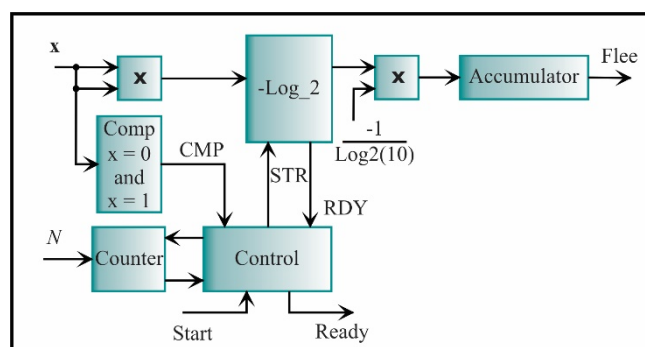


Figure 19. The architecture of the processing core for computing the log energy entropy.

4.3.2. Feature Normalization and Feature Extraction

The generic architecture for feature normalization is depicted in Figure 20. In general, the architecture is constituted by a multiplexor, an adder, a multiplier, two read only memories (ROMs), and one register for each feature. The mean and standard deviation values, which were previously computed during the design stage, are stored in the ROM Means and ROM STDs, respectively. In Equation (36), the subtraction is divided by the standard deviation; yet, in this work, a multiplier is used to obtain the product among the subtraction and the inverse of the standard deviation. The multiplexor allows selecting the feature that will be normalized. The multiplexor reduces the resources since one adder, and one multiplier are only used for all the features. The normalized features (FN1, FN4, FN5, and FN6) are cascaded through a set of registers.

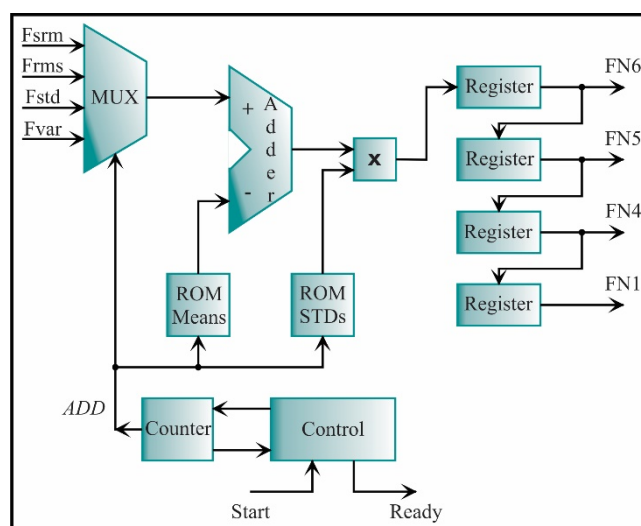


Figure 20. Architecture for computing the feature normalization of 4 features.

Because the seven estimated features have different length words, the architecture presented in Figure 20 has to be modified according to the number of features that have the same word length; then, the feature normalization can be computed for all features (FN1, FN2, FN3, FN4, FN5, FN6, FN7). For instance, the SRM from the x -axis, RMS, STD, and variance from the y -axis has the same length word, i.e., $e = 2$ and $f = 16$; therefore, the architecture for these features (see Figures 19 and 20) is considered as a single block. On the other hand, the kurtosis factor is estimated for both axes (Fkfx, Fkfy) with a word length of $e = 24$ and $f = 16$; therefore, two inputs, two registers, and the ROMs with two

respective values are needed. For the LEE feature estimated from the x-axis, a word length of $e = 16$ and $f = 16$ is needed; therefore, one input, one register, and one value in each ROM are needed. In summary, the feature normalization architecture for all the features is depicted in Figure 21. The seven estimated features are the inputs. The NORM 4F is the feature normalization from Figure 20, while the NORM 2F and NORM 1F are the same architectures but they are modified for different word lengths, i.e., $e = 24, f = 16$, and $e = 16, f = 16$, respectively. For the seven features, the output signals have the same word length, i.e., $e = 2$ and $f = 16$.

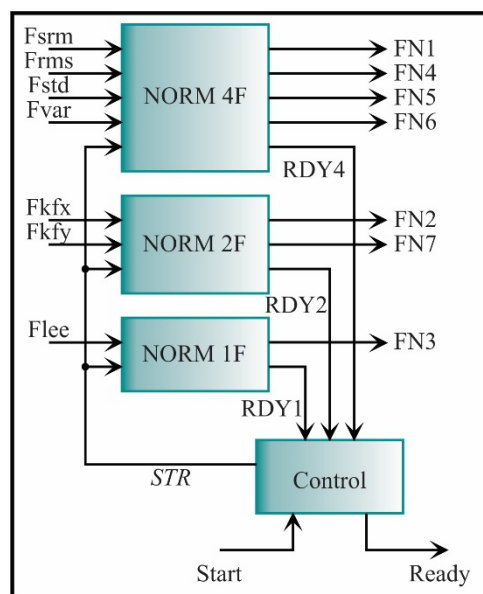


Figure 21. Architecture for computing the feature normalization.

The feature extraction is carried out with the architecture depicted in Figure 22. It is obtained through a simple multiplication between the seven-feature vector and the transformation matrix, which is a 7×2 matrix built by the LDA method. In the ROMs C1 and C2, the transformation matrix is stored. The ROM C1 contains the values of the first column, and the ROM C2 contains the values of the second column. Multiplying and accumulating the features and the matrix elements, the new feature set in a lower dimension, i.e., dimension 2, is obtained to ease the classification step.

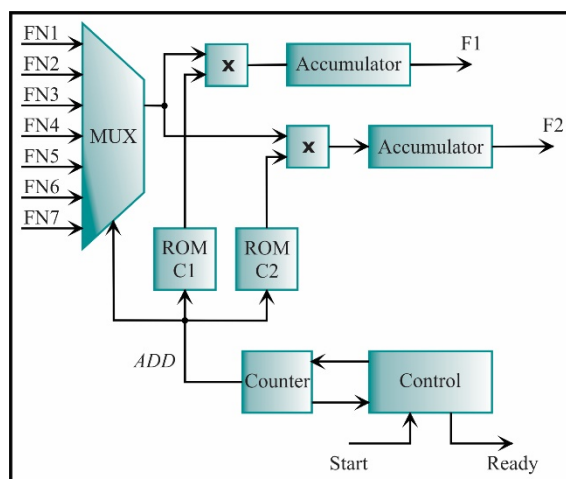


Figure 22. The architecture of the processing core for computing the feature extraction.

4.3.3. SVM Classifier

The multiple one-against-all structures are employed to classify a new data set. This structure allows separating one class from the others. The structure designed for this task is shown in Figure 23. It consists of eight SVM classifiers, i.e., one classifier for each condition. The inputs to each SVM core are the two features, i.e., the two features obtained in the feature extraction step. Then, each SVM core yields an output score (S_1, S_2, \dots, S_8) according to Equation (35). If the score is positive, the new data set belongs to that class. However, there are regions in the feature space where no training data lie; in this case, different hyperplanes can yield positive or negative values. A comparator is required to evade this problem, and compare these score values, being the highest one the corresponding class for the new data set. The signal to initiate each SVM is STR_S, the signals that indicate the each SVM process ending are: R1, R2, . . . , R8, and the signals to initiate and finish the COMPARATOR are STR_C and RDY_C, respectively.




Figure 23. The architecture of the processing core for one-against-all SVM classification.

The architecture of each SVM is constructed by following the Equation (33). The resulting processing core is shown in Figure 24. As abovementioned, the SVM core has three ROMs: two for the support vectors (ROM SV1 and ROM SV2) and one for the alpha values (ROM Alphas). The IDX signal indicates the address in each ROM. The block called EXP is an exponential function which is defined by the series:

$$EXP(x) = \sum_{i=0}^6 \frac{x^i}{i!}. \quad (38)$$

This series is used for its fast convergence and its easy implementation. The inverse of the dividends is used to avoid the divisions, into the multiplier since they are known in each iteration. This operation is implemented through a MAC. The blocks that complement the SVM core are adders, multipliers, an accumulator, and a register.

The kernel scale is taken as a constant value defined for each SVM core in the training step; thus, it can be utilized as a multiplication of a fractional number, avoiding the use of a divisor. The bias is represented by W_0 . Once the scores of the eight SVMs are obtained, the comparator of Figure 23 automatically determines the SCT condition.

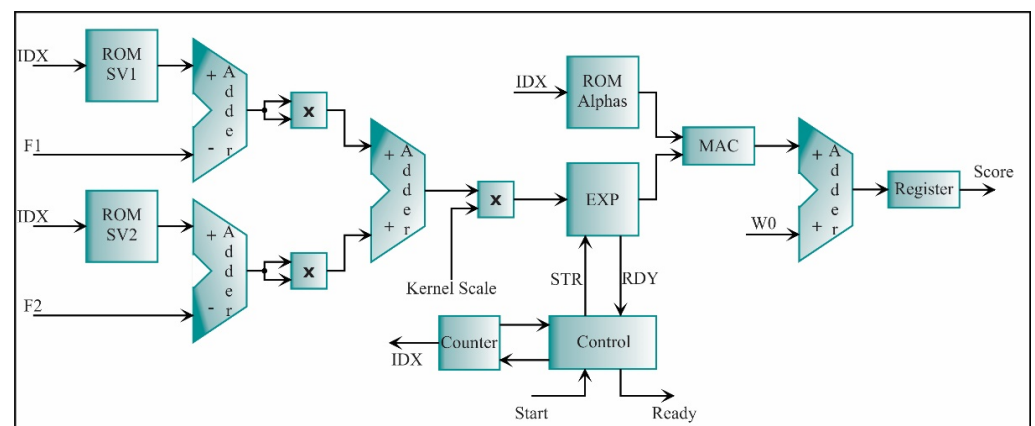


Figure 24. The architecture of the processing core for an SVM classifier.

4.3.4. Results

In Table 4, the processing time of each processing core and their relative errors are shown. It can be noted that the processing time in clock cycles depends on: the number of data N , the width of each data (i.e., e and f , which are the integer and fractional parts of each datum, respectively), and the number of maximum support vectors N_{sv} . For this work, $N = 3000$ and $N_{sv} = 192$. As the SRM feature has the longest processing time by considering all the seven features, this time will reference the feature estimation stage. Therefore, the total number of cycles corresponds to the sum of the clock cycles of the SRM feature, feature normalization, feature extraction, and SVMs stages. The total number of cycles of the SVM stage is from the SVM with the biggest number of support vectors.

Table 4. Time and relative error from each processing core.

| Digital Structure | Word Length | Time (Clock Cycles) | Relative Error (%) |
|---------------------------------------|------------------|---------------------------------------------------|--------------------|
| SVM | $e = 7, f = 20$ | $2 + 10N_{sv}$ | 0.33 |
| Feature Extraction | $e = 2, f = 16$ | 14 | 0.3 |
| Feature Normalization | $e = 2, f = 16$ | 10 | 1.67 |
| SRM | $e = 2, f = 16$ | $(N + 1)(e + f + 2) + 1$ | 2 |
| Kurtosis Factor | $e = 24, f = 16$ | $4(e + f) + 3N + 35$ | 0.05 |
| Log Energy Entropy | $e = 16, f = 16$ | $N(f + 2) + 2$ | 1.11 |
| RMS | $e = 2, f = 16$ | $2(e + f) + N + 5$ | 0.004 |
| Standard Deviation | $e = 2, f = 16$ | $2(e + f) + N + 6$ | 0.002 |
| Variance | $e = 2, f = 16$ | $e + f + N + 5$ | 0.0002 |
| Total time with a 50 MHz clock | | 61,967 clock cycles 1,239,340 ns | |

Consequently, the total time using a 50 MHz clock is around 1.24 ms. The relative error is obtained by comparing the estimated values in Matlab using floating-point and the ones estimated by the processing cores using fixed-point. On the other hand, although the maximum relative error is two percent, this result can be considered accurate enough since the difference between values is of an order of magnitude of 10^{-3} .

Table 5 summarizes the FPGA resources used for each processing core. As can be observed, most of them occupy less than 2% of the total available resources, except for the number of multipliers. These results indicate that the proposed FPGA-based processor can be implemented either in the FPGA used in this work or many other commercially

available FPGA devices with an equivalent number of multipliers but with much fewer elements, registers and, memory bits, which could reduce the implementation costs.

Table 5. FPGA resources usage.

| Digital Structure | Logic Elements (%) | Registers (%) | Multipliers 9-Bit (%) | Memory Bits (%) |
|------------------------|---------------------|------------------|-----------------------|--------------------|
| SVM | 6361 (6%) | 1564 (1%) | 256 (48%) | 0 (0%) |
| Feature Extraction | 178 (<1%) | 101 (<1%) | 4 (<1%) | 73,728 (2%) |
| Feature Normalization | 478 (<1%) | 144 (<1%) | 20 (4%) | 0 (0%) |
| SRM | 360 (<1%) | 166 (<1%) | 6 (1%) | 0 (0%) |
| Kurtosis Factor | 1818 (2%) | 870 (<1%) | 35 (7%) | 0 (0%) |
| Log Energy Entropy | 221 (<1%) | 121 (<1%) | 6 (1%) | 0 (0%) |
| RMS | 315 (<1%) | 184 (<1%) | 6 (1%) | 0 (0%) |
| Standard Deviation | 577 (<1%) | 336 (<1%) | 10 (2%) | 0 (0%) |
| Variance | 513 (<1%) | 300 (<1%) | 8 (2%) | 0 (0%) |
| Total Processor | 12,639 (12%) | 4656 (5%) | 386 (73%) | 73,728 (2%) |

5. Conclusions

In this paper, a new methodology and its implementation into an FPGA for assessing the transformer condition under different levels of SCT fault is presented. To test and validate the methodology and its FPGA implementation, vibration signals are acquired from a transformer that can emulate different SCT fault conditions. The obtained results show the potential of the methodology to carry out a transformer diagnosis. In this regard, the main findings are

- The methodology developed and implemented into the FPGA can diagnose eight severity levels of SCTs in a transformer by measuring the vibration signals from the top of the transformer core;
- The feature reduction allows obtaining the best set of features, selecting the features that present the most relevant information related to the transformer performance and then, reducing the dimensional space;
- The Fisher score implementation to select features allows reducing from an extensive number of features a set of only seven STFs, i.e., three for the x-axis: SRM, kurtosis factor, and LEE, and four for the y-axis: RMS, standard deviation, variance, and kurtosis factor;
- For reducing the dimensional space, the LDA method presents a more satisfactory performance than the PCA method, simplifying the classification process;
- The SVM classifier can classify among eight severities of SCT with an accuracy of 96.82%. The results also demonstrate that the SVM classifier performs better than an ANN under the same experimental setup;
- The processor core makes use of low FPGA resources, presents a maximum relative error of 2% if it is compared with its floating-point computation in Matlab software, and requires a small computing time (≈ 1.24 ms) to offer a diagnosis result;
- All these characteristics show the suitability of the FPGA technology for a future device development, e.g., a smart sensor since the accelerometer, the DAS, and the FPGA-based processor represents the basic elements that compose it;
- The proposed methodology and the individually developed cores could also be adaptable and calibrated to other applications such as assessment buildings, bridges, wind turbines, induction motors, and other types of equipment as demonstrated in the literature.

Future work will focus on employing the methodology to diagnose single-phase and three-phase transformers under different transformer operation conditions, e.g., with load unbalance and harmonic content in the power supply, among others. The impact of the fault location on the proposed methodology will be explored to assess its robustness and calibrate it if necessary, aiming at proposing a methodology that can detect, quantify, and locate a fault condition. Besides, different sets of features in time and frequency domains, fractals, and entropy-base indicators will be explored, as well as different optimization algorithms such as genetic algorithms [51] and boosting algorithms [69] will be used to improve the performance of the classifiers.

Author Contributions: Conceptualization, J.R.H.-R. and M.V.-R.; methodology, J.R.H.-R., M.V.-R., and A.G.-P.; software, validation, and formal analysis, all authors; investigation, resources, and visualization, J.R.H.-R., D.G.-L., and D.C.-M.; data curation, J.R.H.-R. and D.G.-L.; writing—original draft preparation, writing—review and editing, all authors; supervision and project administration, D.G.-L. and M.V.-R.; funding acquisition, A.G.-P., D.C.-M., J.P.A.-S., and M.V.-R. All authors have read and agreed to the published version of the manuscript.

Funding: This research received no external funding.

Institutional Review Board Statement: Not applicable.

Informed Consent Statement: Not applicable.

Data Availability Statement: The data presented in this study are not publicly available due to privacy issues.

Acknowledgments: This work was partially supported by the Mexican Council of Science and Technology (CONACyT) by the scholarship 734987.

Conflicts of Interest: The authors declare no conflict of interest.

References

1. Bagheri, M.; Naderi, M.; Blackburn, T. Advanced transformer winding deformation diagnosis: Moving from off-line to on-line. *IEEE Trans. Dielectr. Electr. Insul.* **2012**, *19*, 1860–1870. [[CrossRef](#)]
2. Liu, J.; Zhao, Z.; Tang, C.; Yao, C.; Li, C.; Islam, S. Classifying Transformer Winding Deformation Fault Types and Degrees Using FRA Based on Support Vector Machine. *IEEE Access* **2019**, *7*, 112494–112504. [[CrossRef](#)]
3. Hu, Y.; Zheng, J.; Huang, H. Experimental research on power transformer vibration distribution under different winding defect conditions. *Electronics* **2019**, *8*, 842. [[CrossRef](#)]
4. Islam, M.M.; Lee, G.; Hettiwatte, S.N. A review of condition monitoring techniques and diagnostic tests for lifetime estimation of power transformers. *Electr. Eng.* **2018**, *100*, 581–605. [[CrossRef](#)]
5. García, B.; Burgos, J.C.; Alonso, Á.M. Transformer tank vibration modeling as a method of detecting winding deformations—Part I: Theoretical foundation. *IEEE Trans. Power Deliv.* **2006**, *21*, 157–163. [[CrossRef](#)]
6. Zhang, Z.; Wu, Y.; Zhang, R.; Jiang, P.; Liu, G.; Ahmed, S.; Dong, Z. Novel Transformer Fault Identification Optimization Method Based on Mathematical Statistics. *Mathematics* **2019**, *7*, 288. [[CrossRef](#)]
7. Mejia-Barron, A.; Valtierra-Rodriguez, M.; Granados-Lieberman, D.; Olivares-Galvan, J.C.; Escarela-Perez, R. The application of EMD-based methods for diagnosis of winding faults in a transformer using transient and steady state currents. *Meas. J. Int. Meas. Confed.* **2018**, *117*, 371–379. [[CrossRef](#)]
8. Glowacz, A.; Glowacz, W.; Kozik, J.; Piech, K.; Gutten, M.; Caesarendra, W.; Liu, H.; Brumerick, F.; Irfan, M.; Faizal Khan, Z. Detection of Deterioration of Three-phase Induction Motor using Vibration Signals. *Meas. Sci. Rev.* **2019**, *19*, 241–249. [[CrossRef](#)]
9. Nayana, B.R.; Geethanjali, P. Analysis of Statistical Time-Domain Features Effectiveness in Identification of Bearing Faults from Vibration Signal. *IEEE Sens. J.* **2017**, *17*, 5618–5625. [[CrossRef](#)]
10. Yanez-borjas, J.J.; Valtierra-rodriguez, M.; Camarena, D.; Amezcua-sanchez, J.P. Statistical time features for global corrosion assessment in a truss bridge from vibration signals. *Measurement* **2020**, 107858. [[CrossRef](#)]
11. Zheng, J.; Huang, H.; Pan, J. Detection of Winding Faults Based on a Characterization of the Nonlinear Dynamics of Transformers. *IEEE Trans. Instrum. Meas.* **2018**, *68*, 206–214. [[CrossRef](#)]
12. Hong, K.; Huang, H.; Zhou, J. Winding Condition Assessment of Power Transformers Based on Vibration Correlation. *IEEE Trans. Power Deliv.* **2015**, *30*, 1735–1742. [[CrossRef](#)]
13. Bartoletti, C.; Desiderio, M.; Di Carlo, D.; Fazio, G.; Muzi, F.; Sacerdoti, G.; Salvatori, F. Vibro-Acoustic Techniques to Diagnose Power Transformers. *IEEE Trans. Power Deliv.* **2004**, *19*, 221–229. [[CrossRef](#)]
14. Bagheri, M.; Nezhivenko, S.; Naderi, M.S.; Zollanvari, A. A new vibration analysis approach for transformer fault prognosis over cloud environment. *Int. J. Electr. Power Energy Syst.* **2018**, *100*, 104–116. [[CrossRef](#)]

15. Huerta-Rosales, J.R.; Granados-Lieberman, D.; Amezcua-Sanchez, J.P.; Camarena-Martinez, D.; Valtierra-Rodriguez, M. Vibration Signal Processing-Based Detection of Short-Circuited Turns in Transformers: A Nonlinear Mode Decomposition Approach. *Mathematics* **2020**, *8*, 575. [[CrossRef](#)]
16. Borucki, S. Diagnosis of technical condition of power transformers based on the analysis of vibroacoustic signals measured in transient operating conditions. *IEEE Trans. Power Deliv.* **2012**, *27*, 670–676. [[CrossRef](#)]
17. Liu, Z.; Xia, X.; Ji, S.; Shi, Y.; Zhang, F.; Fu, Y.; Jiang, Z. Fault Diagnosis of OLTC Based on Time-Frequency Image Analysis of Vibration Signal. In Proceedings of the 2018 Condition Monitoring and Diagnosis (CMD), Perth, WA, Australia, 23–26 September 2018; pp. 1–6.
18. Zhao, M.; Xu, G. Feature extraction of power transformer vibration signals based on empirical wavelet transform and multiscale entropy. *IET Sci. Meas. Technol.* **2018**, *12*, 63–71. [[CrossRef](#)]
19. Wu, S.; Huang, W.; Kong, F.; Wu, Q.; Zhou, F.; Zhang, R.; Wang, Z. Extracting Power Transformer Vibration Features by a Time-Scale-Frequency Analysis Method. *J. Electromagn. Anal. Appl.* **2010**, *2*, 31–38. [[CrossRef](#)]
20. Amezcua-Sanchez, J.P.; Adeli, H. A new music-empirical wavelet transform methodology for time-frequency analysis of noisy nonlinear and non-stationary signals. *Digit. Signal Process. A Rev. J.* **2015**, *45*, 55–68. [[CrossRef](#)]
21. García, B.; Burgos, J.C.; Alonso, Á. Winding deformations detection in power transformers by tank vibrations monitoring. *Electr. Power Syst. Res.* **2005**, *74*, 129–138. [[CrossRef](#)]
22. Zhou, H.; Hong, K.; Huang, H.; Zhou, J. Transformer winding fault detection by vibration analysis methods. *Appl. Acoust.* **2016**, *114*, 136–146. [[CrossRef](#)]
23. Hong, K.; Huang, H.; Zhou, J.; Shen, Y.; Li, Y. A method of real-time fault diagnosis for power transformers based on vibration analysis. *Meas. Sci. Technol.* **2015**, *26*, 115011. [[CrossRef](#)]
24. Castro, A.R.G.; Miranda, V. Knowledge Discovery in Neural Networks With Application to Transformer Failure Diagnosis. *IEEE Trans. Power Syst.* **2005**, *20*, 717–724. [[CrossRef](#)]
25. Valtierra-Rodriguez, M. Fractal dimension and data mining for detection of short-circuited turns in transformers from vibration signals. *Meas. Sci. Technol.* **2020**, *31*, 025902. [[CrossRef](#)]
26. Bigdeli, M.; Vakilian, M.; Rahimpour, E. Transformer winding faults classification based on transfer function analysis by support vector machine. *IET Electr. Power Appl.* **2012**, *6*, 267–276. [[CrossRef](#)]
27. Liu, H.; Zhou, J.; Xu, Y.; Zheng, Y.; Peng, X.; Jiang, W. Unsupervised fault diagnosis of rolling bearings using a deep neural network based on generative adversarial networks. *Neurocomputing* **2018**, *315*, 412–424. [[CrossRef](#)]
28. Chen, G.; Lu, G.; Liu, J.; Yan, P. An integrated framework for statistical change detection in running status of industrial machinery under transient conditions. *ISA Trans.* **2019**, *94*, 294–306. [[CrossRef](#)]
29. Liu, J.; Xu, Z.; Zhou, L.; Nian, Y.; Shao, Y. A statistical feature investigation of the spalling propagation assessment for a ball bearing. *Mech. Mach. Theory* **2019**, *131*, 336–350. [[CrossRef](#)]
30. Jan, S.U.; Lee, Y.D.; Shin, J.; Koo, I. Sensor Fault Classification Based on Support Vector Machine and Statistical Time-Domain Features. *IEEE Access* **2017**, *5*, 8682–8690. [[CrossRef](#)]
31. Hostetter, M.; Ahmadzadeh, A.; Aydin, B.; Georgoulis, M.K.; Kempton, D.J.; Angryk, R.A. Understanding the Impact of Statistical Time Series Features for Flare Prediction Analysis. In Proceedings of the 2019 IEEE International Conference on Big Data (Big Data), Los Angeles, CA, USA, 9–12 December 2019; pp. 4960–4966. [[CrossRef](#)]
32. Devi, R.L.; Kalaivani, V. Machine learning and IoT-based cardiac arrhythmia diagnosis using statistical and dynamic features of ECG. *J. Supercomput.* **2019**, 1–12. [[CrossRef](#)]
33. Ong, P.; Zainuddin, Z.; Lai, K.H. A novel selection of optimal statistical features in the DWPT domain for discrimination of ictal and seizure-free electroencephalography signals. *Pattern Anal. Appl.* **2018**, *21*, 515–527. [[CrossRef](#)]
34. Samuel, O.W.; Zhou, H.; Li, X.; Wang, H.; Zhang, H.; Sangaiah, A.K.; Li, G. Pattern recognition of electromyography signals based on novel time domain features for amputees’ limb motion classification. *Comput. Electr. Eng.* **2018**, *67*, 646–655. [[CrossRef](#)]
35. Xia, Y.; Gao, Q.; Ye, Q. Classification of gait rhythm signals between patients with neuro-degenerative diseases and normal subjects: Experiments with statistical features and different classification models. *Biomed. Signal Process. Control* **2015**, *18*, 254–262. [[CrossRef](#)]
36. Caesarendra, W.; Tjahjowidodo, T. A review of feature extraction methods in vibration-based condition monitoring and its application for degradation trend estimation of low-speed slew bearing. *Machines* **2017**, *5*, 21. [[CrossRef](#)]
37. Xue, X.; Zhou, J. A hybrid fault diagnosis approach based on mixed-domain state features for rotating machinery. *ISA Trans.* **2017**, *66*, 284–295. [[CrossRef](#)] [[PubMed](#)]
38. Jović, A.; Brkić, K.; Bogunović, N. A review of feature selection methods with applications. In Proceedings of the 2015 38th international convention on information and communication technology, electronics and microelectronics (MIPRO), Opatija, Croatia, 25–29 May 2015; pp. 1200–1205. [[CrossRef](#)]
39. Wang, X.; Zheng, Y.; Zhao, Z.; Wang, J. Bearing fault diagnosis based on statistical locally linear embedding. *Sensors* **2015**, *15*, 16225–16247. [[CrossRef](#)] [[PubMed](#)]
40. Saucedo-Dorantes, J.J.; Delgado-Prieto, M.; Osornio-Rios, R.A.; Romero-Troncoso, R.D.J. Diagnosis methodology for identifying gearbox wear based on statistical time feature reduction. *Proc. Inst. Mech. Eng. Part C J. Mech. Eng. Sci.* **2018**, *232*, 2711–2722. [[CrossRef](#)]

41. Sun, L.; Fu, S.; Wang, F. Decision tree SVM model with Fisher feature selection for speech emotion recognition. *Eurasip J. Audio, Speech, Music Process.* **2019**, 2019. [[CrossRef](#)]
42. Santos-Hernandez, J.A.; Valtierra-Rodriguez, M.; Amezcua-Sanchez, J.P.; Romero-Troncoso, R.D.J.; Camarena-Martinez, D. Hilbert filter based FPGA architecture for power quality monitoring. *Measurement* **2019**, *147*, 106819. [[CrossRef](#)]
43. Martinez-Figueroa, G.D.J.; Morinigo-Sotelo, D.; Zorita-Lamadrid, A.L.; Morales-Velazquez, L.; Romero-Troncoso, R.D.J. FPGA-based smart sensor for detection and classification of power quality disturbances using higher order statistics. *IEEE Access* **2017**, *5*, 14259–14274. [[CrossRef](#)]
44. Hong, K.; Huang, H.; Fu, Y.; Zhou, J. A vibration measurement system for health monitoring of power transformers. *Meas. J. Int. Meas. Confed.* **2016**, *93*, 135–147. [[CrossRef](#)]
45. Bagheri, M.; Zollanvari, A.; Nezhivenko, S. Transformer Fault Condition Prognosis Using Vibration Signals Over Cloud Environment. *IEEE Access* **2018**, *6*, 9862–9874. [[CrossRef](#)]
46. Hu, C.; Wang, P.; Youn, B.D.; Lee, W.R.; Yoon, J.T. Copula-based statistical health grade system against mechanical faults of power transformers. *IEEE Trans. Power Deliv.* **2012**, *27*, 1809–1819. [[CrossRef](#)]
47. Zhang, L.L.; Wu, Q.H.; Ji, T.Y.; Zhang, A.Q. Identification of inrush currents in power transformers based on higher-order statistics. *Electr. Power Syst. Res.* **2017**, *146*, 161–169. [[CrossRef](#)]
48. Sharma, A.; Amarnath, M.; Kankar, P.K. Feature extraction and fault severity classification in ball bearings. *JVC/Journal Vib. Control* **2016**, *22*, 176–192. [[CrossRef](#)]
49. Saucedo-Dorantes, J.J.; Delgado-Prieto, M.; Osornio-Rios, R.A.; De Jesus Romero-Troncoso, R. Multifault Diagnosis Method Applied to an Electric Machine Based on High-Dimensional Feature Reduction. *IEEE Trans. Ind. Appl.* **2017**, *53*, 3086–3097. [[CrossRef](#)]
50. Rostaminia, R.; Sanie, M.; Vakilian, M.; Mortazavi, S.S.; Parvin, V. Accurate power transformer PD pattern recognition via its model. *IET Sci. Meas. Technol.* **2016**, *10*, 745–753. [[CrossRef](#)]
51. Hasan, M.J.; Kim, J.M. Fault detection of a spherical tank using a genetic algorithm-based hybrid feature pool and k-nearest neighbor algorithm. *Energies* **2019**, *12*, 991. [[CrossRef](#)]
52. Van, M.; Kang, H.J. Wavelet Kernel Local Fisher Discriminant Analysis with Particle Swarm Optimization Algorithm for Bearing Defect Classification. *IEEE Trans. Instrum. Meas.* **2015**, *64*, 3588–3600. [[CrossRef](#)]
53. Korn, F.; Pagel, B.; Faloutsos, C. On the “Dimensionality Curse” and the “Self-Similarity Blessing”. *Knowl. Creat. Diffus. Util.* **2001**, *13*, 96–111. [[CrossRef](#)]
54. Gu, Q.; Li, Z.; Han, J. Generalized fisher score for feature selection. *arXiv* **2012**, arXiv:1202.3725.
55. Liu, Y.; Nie, F.; Wu, J.; Chen, L. Efficient semi-supervised feature selection with noise insensitive trace ratio criterion. *Neurocomputing* **2013**, *105*, 12–18. [[CrossRef](#)]
56. Mbooi, C.P.; Hameyer, K. Fault diagnosis of bearing damage by means of the linear discriminant analysis of stator current features from the frequency selection. *IEEE Trans. Ind. Appl.* **2016**, *52*, 3861–3868. [[CrossRef](#)]
57. Wen, J.; Fang, X.; Cui, J.; Fei, L.; Yan, K.; Chen, Y.; Xu, Y. Robust Sparse Linear Discriminant Analysis. *IEEE Trans. Circuits Syst. Video Technol.* **2019**, *29*, 390–403. [[CrossRef](#)]
58. Shahdoosti, H.R.; Mirzapour, F. Spectral–spatial feature extraction using orthogonal linear discriminant analysis for classification of hyperspectral data. *Eur. J. Remote Sens.* **2017**, *50*, 111–124. [[CrossRef](#)]
59. Xu, J. A weighted linear discriminant analysis framework for multi-label feature extraction. *Neurocomputing* **2018**, *275*, 107–120. [[CrossRef](#)]
60. Kari, T.; Gao, W.; Zhao, D.; Abiderexiti, K.; Mo, W.; Wang, Y.; Luan, L. Hybrid feature selection approach for power transformer fault diagnosis based on support vector machine and genetic algorithm. *IET Gener. Transm. Distrib.* **2018**, *12*, 5672–5680. [[CrossRef](#)]
61. Zhang, Y.; Wang, P.; Ni, T.; Cheng, P.; Lei, S. Wind power prediction based on LS-SVM model with error correction. *Adv. Electr. Comput. Eng.* **2017**, *17*, 3–8. [[CrossRef](#)]
62. Liu, C.; Jiang, D.; Yang, W. Global geometric similarity scheme for feature selection in fault diagnosis. *Expert Syst. Appl.* **2014**, *41*, 3585–3595. [[CrossRef](#)]
63. Tarimoradi, H.; Gharehpetian, G.B.; Member, S. A Novel Calculation Method of Indices to Improve Classification of Transformer Winding Fault Type, Location and Extent. *IEEE Trans. Ind. Inform.* **2017**, *13*, 1531–1540. [[CrossRef](#)]
64. Zamudio-Ramirez, I.; Osornio-Rios, R.A.; Trejo-Hernandez, M.; Romero-Troncoso, R.d.J.; Antonino-Daviu, J.A. Smart-Sensors to Estimate Insulation Health in Induction Motors via Analysis of Stray Flux. *Energies* **2019**, *12*, 1658. [[CrossRef](#)]
65. Urbikain, G.; López de Lacalle, L.N. MoniThor: A complete monitoring tool for machining data acquisition based on FPGA programming. *SoftwareX* **2020**, *11*, 100387. [[CrossRef](#)]
66. Milton, M.; Benigni, A. ORTiS solver codegen: C++ code generation tools for high performance, FPGA-based, real-time simulation of power electronic systems. *SoftwareX* **2021**, *13*, 100660. [[CrossRef](#)]
67. Urbikain, G.; Olvera, D.; de Lacalle, L.N.L.; Elías-Zúñiga, A. Spindle speed variation technique in turning operations: Modeling and real implementation. *J. Sound Vib.* **2016**, *383*, 384–396. [[CrossRef](#)]
68. Yin, P.; Wang, C.; Waris, H.; Liu, W.; Han, Y.; Lombardi, F. Design and Analysis of Energy-Efficient Dynamic Range Approximate Logarithmic Multipliers for Machine Learning. *IEEE Trans. Sustain. Comput.* **2020**, 1–13. [[CrossRef](#)]
69. Bustillo, A.; Urbikain, G.; Perez, J.M.; Pereira, O.M.; Lopez de Lacalle, L.N. Smart optimization of a friction-drilling process based on boosting ensembles. *J. Manuf. Syst.* **2018**, *48*, 108–121. [[CrossRef](#)]

Anexo B: Artículo indizado (caso de estudio 2)

Article

Vibration Signal Processing-Based Detection of Short-Circuited Turns in Transformers: A Nonlinear Mode Decomposition Approach

Jose R. Huerta-Rosales ¹, David Granados-Lieberman ², Juan P. Amezcua-Sanchez ¹,
David Camarena-Martinez ³ and Martin Valtierra-Rodriguez ^{1,*}

- ¹ ENAP-Research Group, CA-Sistemas Dinámicos, Facultad de Ingeniería, Universidad Autónoma de Querétaro (UAQ), Campus San Juan del Río, Río Moctezuma 249, Col. San Cayetano, San Juan del Río C. P. 76807, Mexico; roberto.huerta@enap-rg.org (J.R.H.-R.); juan.amezcua@enap-rg.org (J.P.A.-S.)
 - ² ENAP-Research Group, CA-Fuentes Alternas y Calidad de la Energía Eléctrica, Departamento de Ingeniería Electromecánica, Tecnológico Nacional de México, Instituto Tecnológico Superior de Irapuato (ITESI), Carr. Irapuato-Silao km 12.5, Colonia El Copal, Irapuato, Guanajuato C. P. 36821, Mexico; david.granados@enap-rg.org
 - ³ ENAP-Research Group, CA Procesamiento Digital de Señales, Departamento de Electrónica, División de Ingenierías Campus Irapuato-Salamanca (DICIS), Salamanca, Guanajuato C. P. 36885, Mexico; david.camarena@enap-rg.org
- * Correspondence: martin.valtierra@enap-rg.org

Received: 23 March 2020; Accepted: 10 April 2020; Published: 13 April 2020

Abstract: Transformers are vital and indispensable elements in electrical systems, and therefore, their correct operation is fundamental; despite being robust electrical machines, they are susceptible to present different types of faults during their service life. Although there are different faults, the fault of short-circuited turns (SCTs) has attracted the interest of many researchers around the world since the windings in a transformer are one of the most vulnerable parts. In this regard, several works in literature have analyzed the vibration signals that generate a transformer as a source of information to carry out fault diagnosis; however this analysis is not an easy task since the information associated with the fault is embedded in high level noise. This problem becomes more difficult when low levels of fault severity are considered. In this work, as the main contribution, the nonlinear mode decomposition (NMD) method is investigated as a potential signal processing technique to extract features from vibration signals, and thus, detect SCTs in transformers, even in early stages, i.e., low levels of fault severity. Also, the instantaneous root mean square (RMS) value computed using the Hilbert transform is proposed as a fault indicator, demonstrating to be sensitive to fault severity. Finally, a fuzzy logic system is developed for automatic fault diagnosis. To test the proposal, a modified transformer representing diverse levels of SCTs is used. These levels consist of 0 (healthy condition), 5, 10, 15, 20, and 25 SCTs. Results demonstrate the capability of the proposal to extract features from vibration signals and perform automatic fault diagnosis.

Keywords: fault diagnosis; fuzzy logic; nonlinear mode decomposition; short-circuit fault; transformers; vibration signals

1. Introduction

Transformers represent one of the most expensive and significant elements of a power network [1]. Therefore, their correct operation is fundamental for both utilities and consumers. In general, they are robust and reliable machines; however, because of inherent operating conditions, they are subject

to different power quality problems and harsh operating conditions that can lead to different faults such as winding and core deformations, broken clamping structures, and short-circuited turns, among others [2,3]. Among these faults, winding faults have attracted the interest of many researchers around the world since they represent around 30%–50% of the total faults in a transformer [4].

To perform fault diagnosis in transformers, different methods have been proposed, e.g., dissolved gas analysis, power factor testing, thermography, frequency response analysis, insulating oil quality, energization current, and vibration analysis, among others [5–8]. Although promising results have been obtained, some issues still remain unsolved in several diagnostic methods. For instance, the analysis of energization currents requires further research in order to properly differentiate between an energization current and a short-circuit fault current; on the other hand, temperature measurement-based diagnosis methods require long observation times. In recent years, vibration analysis has demonstrated, on one hand, to overcome some drawbacks of the aforementioned methods [5] and, on the other hand, to improve the diagnosis results through its combination with other methods [9], becoming a very attractive topic for many researchers around the world. Another advantage is that the vibration signals maintain a direct relation with the mechanical performance of the winding [4,5,10]; from this point of view, changes or alterations in the windings will modify the vibration patterns. In this regard, the diagnosis task relies on extracting and characterizing such patterns; yet, it is not an easy task since the vibration signals have nonstationary and nonlinear properties and are embedded in high level noise, compromising the performance of many signal processing techniques. Furthermore, the problem becomes more difficult when faults of low severity are considered.

In this work, a new methodology to diagnose short-circuit faults in transformers is presented. As the main contribution, the nonlinear mode decomposition (NMD) method is investigated as potential signal processing technique to detect short-circuited turns (SCTs) in transformers from vibration signals, which to the best of authors' knowledge, has not been reported yet, mainly on early fault stages. Furthermore, the root mean square (RMS) index computed from the Hilbert transform is proposed as fault severity indicator and a fuzzy logic (FL) system is developed to perform automatic diagnosis. To test the proposal in a real scenario, a transformer adapted with different fault severity levels, ranging from 0 to 25 SCTs with steps of 5 turns, where 0 turns represent the healthy condition, is used. Results demonstrate the effectiveness and usefulness of the proposal to assess the transformer condition as the proposal can detect different fault severities in an automatic way.

2. Related literature

In the literature, the diagnosis techniques for vibration analysis can be separated in signal processing-based and model-based techniques [11]. Model-based techniques implement relations between the measured vibration signal and certain input parameters to assess the transformer condition through the comparison of a reference value and the measured value. For instance, Garcia et al. in [12,13] propose a model based on the tank vibration of a transformer using the fundamental frequency component to determine winding deformations. Hong et al. [1] acquire signals from several sensors and perform a vibration correlation analysis in order to propose a model and assess the winding condition. A model coupled with and electromagnetic force analysis to detect winding faults is also presented by Zhou et al. [14]. On the other hand, the signal processing-based techniques extract features directly from vibration signals in order to perform a fault detection. The most common technique to extract frequency information is the Fourier transform (FT) [10,15,16]. Bartoletti et al. [10] propose a set of parameters based on the FT to diagnose the transformer. Two metrics, the root mean square (RMS) and the RMS deviation, both obtained from the FT are used to detect mechanical faults in power transformers [15]. Hong et al. [16] introduce the frequency complexity analysis using entropy as a measure of frequency uncertainty. Although promising results have been presented, the performance of FT can be compromised when the analyzed signal presents nonstationary events. For these types of events, a variant of the FT called short-time FT (STFT) is preferred. This method offers the evolution overtime of nonstationary properties of a signal. The

STFT is used by Borucki [17] to identify differences between diverse conditions of a transformer under transient operating conditions. In general, STFT is a powerful and low-complex tool for the analysis of nonstationary signals; yet, a compromise between frequency resolution and time resolution has to be properly established, which is not an easy task for signals with unknown properties. Another technique for the analysis of nonstationary signals is the Wavelet transform (WT), which decomposes a nonstationary signal in a set of frequency bands overtime. In [18–20], the WT is used to decompose vibrations signals, and thus, extract features that allow the fault detection in transformers. Some variations of the WT, i.e., wavelet package transform [21] and empirical wavelet transform [22], are also reported to extract features and diagnose different fault conditions in transformers. It is worth noting that the success of the WT-based methods depends on the proper selection of the mother wavelet and decomposition level [23], which change for different applications. In this regard, adaptive techniques become attractive solutions, where the empirical mode decomposition (EMD)-based methods have been the most widely used [24–28]. In [25], the EMD is used to process vibration signals in a transformer under DC bias. A comparison of three EMD-based methods to detect SCTs in transformers is presented in [26]. In [27,28], an improved version of the EMD is presented for fault diagnosis and modal parameter estimation, respectively. The EMD-based analysis for vibrations signals in other fields has been also reported in literature [29–32]. Despite the adaptive advantages of the EMD-based methods, some issues such as mode mixing, noise, and the lack of physical meaning for the decomposed modes can compromise their effectiveness [33]. A recent technique developed by Iatsenko et al. [33], the nonlinear mode decomposition (NMD), solves the drawbacks previously mentioned since it decomposes a complex waveform signal into a set of modes with physical meaning and, simultaneously, removes noise, making it a potential solution to analyze noisy vibrations signals with nonlinear and nonstationary properties as the ones presented in transformers.

3. Theoretical Background

This section provides the theoretical background for the topics employed in this research.

3.1. Transformer Vibrations

Transformer vibrations are generated principally by the forces that appear in the core and the winding during the transformer operation [34]. The forces into the core are produced by the magnetostriction phenomenon. This phenomenon occurs on ferromagnetic materials when they are subject to a magnetic field [11]. In this regard, the applied voltage and its relation with the magnetic induction makes the magnetostriction forces (F_{core}) proportional to the voltage (V) squared as follows [34]:

$$F_{core} \propto V^2 \quad (1)$$

On the other hand, the winding vibrations are generated by the electrodynamic forces that occur in the windings because of the interaction of the consumed current and the magnetic leakage flux [34]. Similar to Equation (1), these forces ($F_{winding}$) are proportional to the current (I) squared as follows:

$$F_{winding} \propto I^2 \quad (2)$$

It is worth noting that the magnetostriction is a nonlinear phenomenon that induces harmonic components into the vibration signal [11]; also, some harmonic components appear because of the magnetizing current or some residual currents [34], which affects negatively the vibration analysis.

3.2. Nonlinear Mode Decomposition (NMD) Method

Complex systems as transformers generate signals composed of different oscillation modes, including the unavoidable background noise [33]; for a correct analysis of these signals, these modes should be correctly separated from each other. The NMD method is presented as an adaptive decomposition tool for nonlinear and nonstationary signals, which decomposes a given signal into a

set of modes with physical meaning modes, and at the same time, removes the background noise. This method is based on the following steps [33,35–37]:

- *Preprocessing.* To obtain a suitable time frequency representation (TFR), a preprocessing of the input signal can be carried out. An essential step is to eliminate trends using a third order polynomial and extracting the bandwidth of interest by means of a bandpass filter.
- *Time-Frequency Representation (TFR).* A TFR allows simultaneously studying the properties, i.e., amplitude, frequency, and phase, from a signal in both time domain and frequency domain. The NMD uses the STFT, i.e., the Fourier transform of a windowed input signal. It is typically constructed as:

$$G(\omega, t) = \int s^+(u)g(u - t)e^{-i\omega(u-t)} du = e^{-i\omega t} \frac{1}{2\pi} \int_0^\infty e^{-i\xi t} \hat{s}(\xi) \hat{g}(\omega - \xi) d\xi \tag{3}$$

where $s^+(u)$ represents the use of positive frequencies, $g(u)$ is a specific window function (positive part) and $\hat{g}(\xi)$ its FT. The window used is the Gaussian window given by:

$$g(u) = \frac{B_{f_0}}{f_0 \sqrt{2\pi}} e^{-u^2/2f_0^2} \Leftrightarrow \hat{g}(\xi) = B_{f_0} e^{-f_0^2 \xi^2/2} \tag{4}$$

where f_0 is the resolution parameter which controls the spread of a Gaussian window in time and frequency, i.e., it controls the time and frequency resolution that are inversely proportional to each other, and B_{f_0} is a normalization factor. The window parameters and their selection are discussed in [36].

- *Component extraction and reconstruction.* The following step is carried out to obtain the component with the highest energy, i.e., the fundamental component, from the TFR. To extract components from a TFR, it is necessary to find its ridge curve as:

$$S[\omega_p(t)] = \sum_{n=1}^N \left[\log |G_s(\omega_p(t_n), t_n)| - \frac{1}{2} \left(\frac{|\Delta\omega_p(t_n) - \langle \Delta\omega_p \rangle|}{std[\Delta\omega_p]} \right)^2 - \frac{1}{2} \left(\frac{\omega_p(t_n) - \langle \omega_p \rangle}{std[\omega_p]} \right)^2 \right] \tag{5}$$

where $\omega_p(t)$ is a ridge point, which is an exclusive sequence for the TFR amplitude peaks, $\Delta\omega_p$ is equal to $\omega_p(t_n) - \omega_p(t_{n-1})$, $\langle f(t) \rangle$ is the mean value of $f(t)$, and $std[f(t)]$ represents the standard deviation of $f(t)$. From the ridge curve, the instantaneous amplitude $A(t)$, phase $\phi(t)$, and frequency $v(t)$ can be reconstructed using two different methods: ridge method and direct method. The former is given by:

$$v(t) = \omega_p(t) + \delta v_a(t), \quad A(t)e^{i\phi(t)} = \frac{2G_s(\omega_p(t), t)}{\hat{g}(\omega_p(t) - v(t))} \tag{6}$$

where $\delta v_a(t)$ is a correction for the discretization effects through a quadratic interpolation. On the other hand, the direct method uses a region in the TFR called time-frequency support $[\omega_-(t), \omega_+(t)]$. The parameters can be reconstructed as:

$$A(t)e^{i\phi(t)} = C_g^{-1} \int_{\omega_-(t)}^{\omega_+(t)} G_s(\omega, t) d\omega, \quad C_g \equiv \frac{1}{2} \int_{-\infty}^{\infty} \hat{g}(\xi) d\xi = \pi g(0), \tag{7}$$

$$v(t) = Re \left[\frac{\int_{\omega_-(t)}^{\omega_+(t)} \omega G_s(\omega, t) d\omega}{\int_{\omega_-(t)}^{\omega_+(t)} G_s(\omega, t) d\omega} \right]$$

The choice between the two methods depends on the amount of noise and the amplitude/frequency variation of the component to be extracted. The criteria used for an adaptive choice are shown in [36].

- *Test the parameters against noise.* After extraction of each NM, the extracted parameters must be tested against noise to decide if the decomposition continues or not, i.e., if the residual signal is composed by noise then the decomposition ends. To do so, the surrogate test is used. This test takes the inverse FT of the resulting FT of the in-test signal but with random phases. The

discriminant statistics, D , for the surrogate test are calculated as a combination of the spectral entropies, Q , of the values obtained for amplitude and frequency as follows:

$$D(\alpha_A, \alpha_f) = \alpha_A Q[\hat{A}(\omega)] + \alpha_f Q[\hat{f}(\omega)] \tag{8}$$

where $Q|f(x)|$ is the spectral entropy and is defined as follows:

$$Q[f(x)] = - \int \frac{|f(x)|^2}{\int |f(x)|^2 dx} \ln \frac{|f(x)|^2}{\int |f(x)|^2 dx} \tag{9}$$

In [32], it is recommended to carry out three tests and select the maximum value. These tests use $D(1,0)$, $D(0,1)$, and $D(1,1)$. If the null hypothesis is rejected for one of them, the component is not noise and the decomposition has to continue.

- *Extraction of harmonics.* The component extracted and identified as genuine will represent a harmonic of some NM. Assuming that the extracted harmonic is the fundamental component with instantaneous frequency $v^{(1)}(t)$, then the harmonics $h=2, 3, \dots, N$ and their instantaneous frequencies $hv^{(1)}(t)$ can be also obtained; hence, the ridge curve $\omega_p^h(t)$ from the h harmonic can be extracted. N is set according to the Nyquist theorem. Nevertheless, if the assumption is not correct, it is necessary to find the fundamental component by applying the same procedure but in inverse direction, i.e., using $h = 1/2, 1/3, \dots$. To identify a harmonic component as genuine, the method of surrogate data is used [33]. The following parameters are used to quantify the consistency degree between two harmonics, i.e., the first extracted harmonic and the last extracted harmonic, using amplitude, phase, and frequency information.

$$\begin{aligned} q_A^h &\equiv \exp \left[- \frac{\sqrt{\langle [A^h(t)\langle A^1(t) \rangle - A^1(t)\langle A^h(t) \rangle]^2}}{\langle A^1(t)A^h(t) \rangle} \right] \\ q_\phi^h &\equiv |\langle \exp[i(\phi^h(t) - h\phi^1(t))] \rangle| \\ q_v^h &\equiv \exp \left[- \frac{\sqrt{\langle [v^h(t) - hv^1(t)]^2}}{\langle v^h(t) \rangle} \right] \end{aligned} \tag{10}$$

A general measure of interdependence between harmonics is constructed by:

$$\rho^h(w_A, w_\phi, w_v) = (q_A^h)^{w_A} (q_\phi^h)^{w_\phi} (q_v^h)^{w_v} \tag{11}$$

where $w_{A,\phi,v}$ represents the weights to each value of consistency $q_{A,\phi,v}^h$. The $\rho^h(1,1,0)$ can be used by default [33].

- *Reconstruct the NM.* After extracting all the genuine harmonics, the full NM can be constructed. In addition, it is expected that components with higher amplitudes have less noise; nevertheless, the harmonic parameters of each component are refined through a weighted average over all the harmonic parameters as follows:

$$\begin{aligned} \tilde{A}^{(h)}(t) &= \langle A^{(h)}(t) \rangle \frac{\sum h' A^{(h')}(t)}{\sum h' \langle A^{(h')}(t) \rangle} \\ \tilde{\phi}^{(h)}(t) &= \arg \left(\sum_{h'} \min \left(1, \frac{h'}{h} \right) \langle A^{(h')}(t) \rangle \exp \left[j \frac{h\phi^{(h')}(t) - \Delta\phi_{h',h}}{h'} \right] \right) \\ &\quad \times \exp \left\{ -j \frac{2\pi}{h'} \text{round} \left[\frac{h\phi^{(h')}(t) - h'\phi^{(h)}(t) - \Delta\phi_{h',h}}{2\pi} \right] \right\} \\ \tilde{v}^{(h)}(t) &= \frac{\sum h' \min \left(1, \frac{h'}{h} \right) \langle A^{(h')}(t) \rangle h v^{(h')}(t) / h'}{\sum h' \min \left(1, \frac{h'}{h} \right) \langle A^{(h')}(t) \rangle} \end{aligned} \tag{12}$$

where $\Delta\phi_{h',h} = \arg(\exp\{j[h\phi^{(h')}(t) - h'\phi^{(h)}(t)]\})$.

- Finally, subtract the NM of the signal. The found NM must be extracted from the input signal before repeating the process to extract the next NM from the residual signal. Further information about the overall NMD method can be found in [33,35–37].

3.3. Hilbert Transform

For decomposition methods, further processing is required in many cases in order to extract and quantify different features or patterns. The Hilbert Transform (HT) is a lineal operation employed to compute instantaneous amplitude, phase, and frequency of a time series signal. In general, HT converts an input signal $x(t)$ into a signal $y(t)$ applying a convolution between $x(t)$ and the impulse response $h(t) = 1/\pi t$, which is defined as [38]:

$$y(t) = H[x(t)] = \frac{1}{\pi} P \int \frac{x(t')}{t-t'} dt' \quad (13)$$

where P denotes the Cauchy principal value. Thus, $x(t)$ and $y(t)$ form a complex conjugate pair, also called analytic signal [39], given by:

$$z(t) = x(t) + y(t) = A(t)e^{i\phi(t)} \quad (14)$$

where $A(t) = [x^2(t) + y^2(t)]^{1/2}$ is the amplitude, $\phi(t) = \arctan [y(t)/x(t)]$ is the phase, and $v(t) = d\phi(t)/dt$ is the frequency. From the amplitude or envelope of a signal, the RMS index can be computed using:

$$\text{RMS}(t) = A(t)/\sqrt{2} \quad (15)$$

When a signal presents unwanted variations overtime, a moving average filter (MAF) can be used to smooth or cancel out such variations. This type of filter is implemented as a finite-impulse-response (FIR) filter by using Equation (15) [40]. The window length has N samples and defines the filter order, while x is the signal input. In the filter, the present sample, n , and the previous sample, k , are considered.

$$y(n) = \frac{1}{N} \sum_{k=1}^N x(n-k) \quad (16)$$

3.4. Fuzzy Logic Systems

Among different classification algorithms, FL systems can be designed from a priori knowledge [41], i.e., when some features about the input data are known. In general, this knowledge is established through a set of if-then-else classification rules. To implement an FL system, four steps are required [41,42]: (i) fuzzification to convert the inputs into information that can be recognized by the inference mechanism, (ii) inference mechanism to process the information and take the decisions, (iii) rule-based structure to assign the inputs to a specific class using the stated set of rules, and (iv) defuzzification to map the inference mechanism conclusion into data that the user can understand. In the fuzzification, different membership functions such as Gaussian, triangular, trapezoidal, and other shapes can be used.

4. Methodology

The proposed methodology to analyze vibration signals and detect SCT faults is shown in Figure 1. Firstly, a single-phase transformer with no load is used to obtain vibration signals under different conditions. The transformer used has been modified to simulate in a controlled way different conditions of fault. These conditions are: 0 (healthy), 5, 10, 15, 20, and 25 SCTs. The energization of the transformer is through a solid-state relay and the transformer is always operating at rated conditions. Then, the vibration signals for the three axes (A_x , A_y , A_z) are acquired. These signals contain both transient state and steady state due to the energization current.

After the acquisition and by considering that the acquired vibration signals have nonstationary and nonlinear properties, the NMD method is used to extract their nonlinear modes. Once the modes

have been extracted, the HT is used to compute the instantaneous amplitude of each mode. With this value and inspired from other works, the RMS index is computed in order to provide a fault indicator according to its severity. Due to the inherent nature of the vibration signals, some variations in the RMS values are expected overtime; in order to smooth and allow a better discrimination between different transformer conditions, an MAF is applied. Finally, an FL system is proposed to automatically determine the fault condition.




Figure 1. Flowchart for the proposed methodology.

5. Experimentation and Results

5.1. Experimental Setup

To test and validate the proposed methodology, the experimental setup shown in Figure 2 is used. The single-phase transformer used is a 1.5 kVA with 135 turns in its primary winding and is operated at 120 V. This transformer is modified to simulate different severities of fault in a controlled way, i.e., 0, 5, 10, 15, 20, and 25 SCTs. A 3-axial accelerometer is used to measure the vibration from the transformer. It is an 8395A model from KISTLER, measuring ± 10 g with a resolution of 400 mV/g over a bandwidth of 1000 Hz. To perform the acquisition of vibration signals, the accelerometer is located at the center of the core in order to receive the core and winding vibrations in a symmetrical way, and a data acquisition system (DAS) using a 16-bit analog-to-digital converter with a sampling frequency of 6000 samples/s is configured. This sampling frequency satisfies the Nyquist theorem for the accelerometer bandwidth. The DAS is based on the NI-USB 6211 board from National Instruments. Two solid-state relays, SAP4050D models, are used. The first one is used to activate the transformer and start the test, and the second one is used to activate an autotransformer and de-energize the transformer after each test, cancelling out the remnant flux. For statistical purposes, 20 tests for each condition are performed, where the acquisition time in each test is 5s, i.e., 30,000 samples. All the vibration signal processing is carried out in a personal computer (PC) using the Matlab software.




Figure 2. Experimental setup.

5.2. Results

The vibration signals, A_x , A_y , A_z , for 0 and 25 SCTs are shown in Figure 3a. For space reasons, these two extreme conditions are only shown. As can be observed, the transient state is shorter for a fault condition. It is worth noting that the transient state in the vibration signals is due to the energization current as shown in Figure 4.

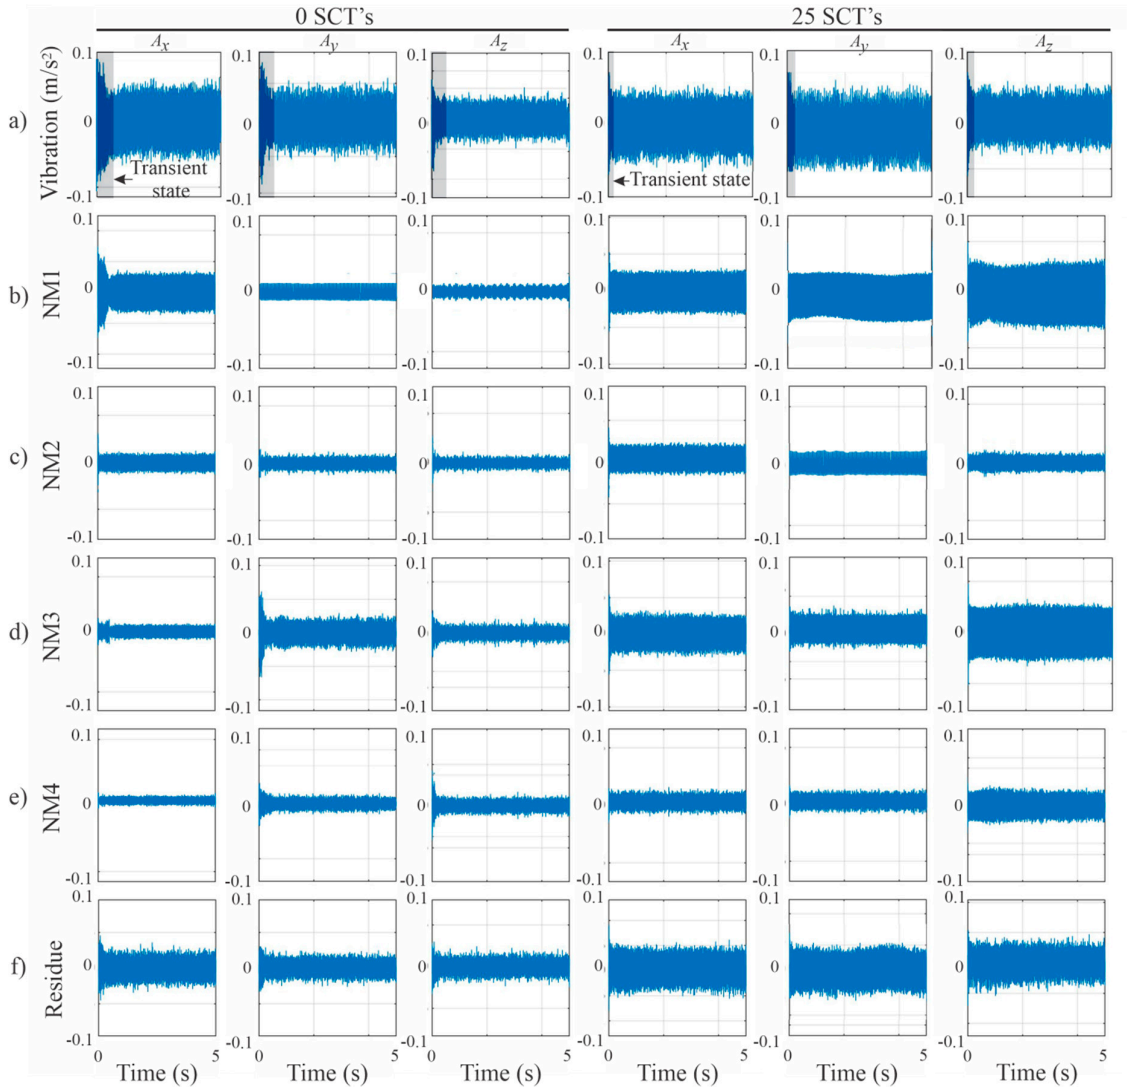


Figure 3. (a) Vibration signals, (b) nonlinear mode 1 (NM1), (c) nonlinear mode 2 (NM2), (d) nonlinear mode 3 (NM3), (e) nonlinear mode 4 (NM4), (f) Residues.




Figure 4. Current and vibration signals.

These transient states and the noise contained in the vibration signals generate negative effects in conventional signal processing techniques. Figure 5 shows the FT-based spectra obtained for two SCT conditions, where it can be observed that there are different changes (denoted by dotted red circles) in the frequency content; however, these components are not reliable due to the inherent drawbacks of FT to analyze nonstationary signals; in fact, these components change from test to test due to the noise, leakage effect, and transient conditions.

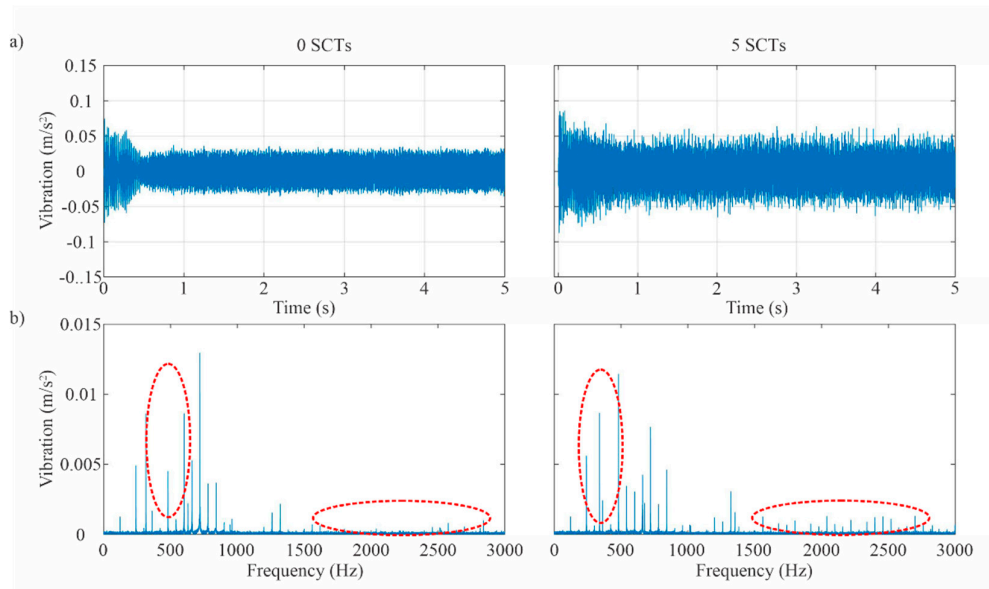


Figure 5. Vibration signals in (a) time domain and (b) frequency domain.

For the signals shown in Figure 3a, the NMD is then applied. Figures 3b–f show the obtained results, i.e., four modes and their residue. From all these plots, it is possible to observe an amplitude

level difference between conditions, which can be useful to identify the severity of the fault. In this regard, the HT is applied to each NM to obtain amplitude-related parameters, i.e., the RMS index. Figure 6 shows the RMS results using Equation (15). In order to reduce the number of analyzed modes, the most useful modes must be selected. From a visual inspection, the NM1 for A_y (plots shaded in gray) shows the maximum separation between conditions; therefore, it is selected to carry out the classification task by including other fault severities.

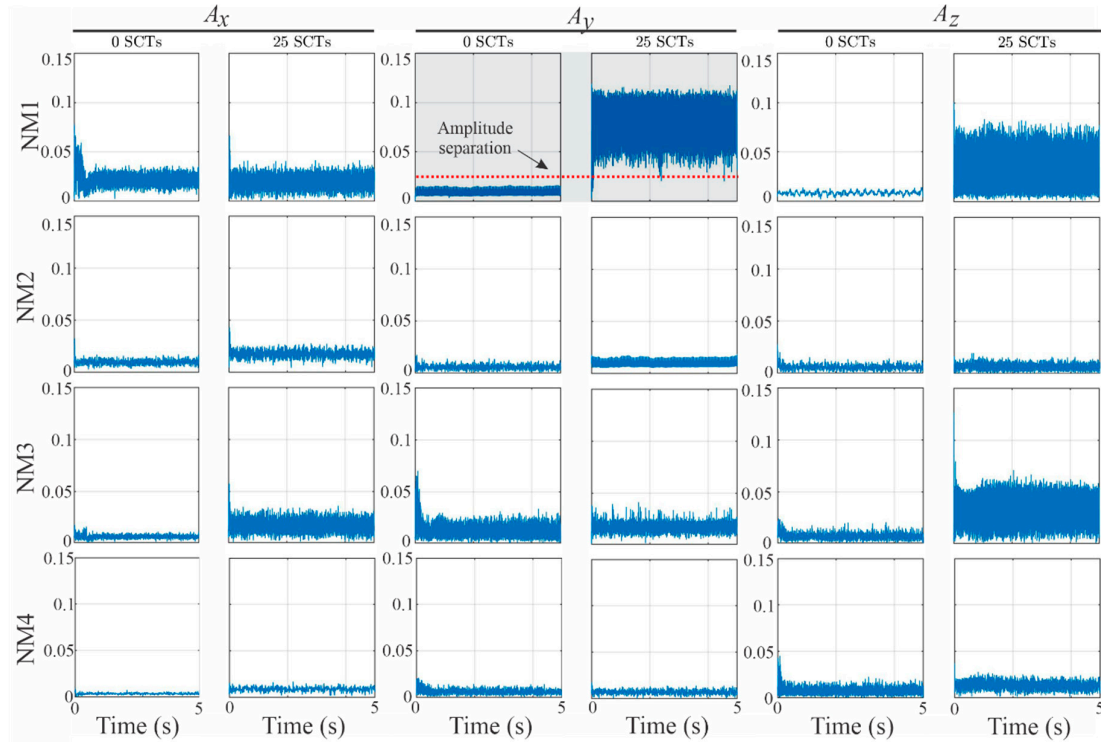


Figure 6. Root mean square (RMS) values for the NMs.

In order to improve the amplitude separation by smoothing the unwanted variations, an MAF with an order of 100 is applied. The order is selected by means of a trade-off between the converge time and the signal smoothness; at this stage, the frequency content is not that important since the NMD has been already applied. The obtained results for the selected mode, i.e., NM1 in A_y , are shown in Figure 7; as can be observed, the amplitude separation is higher and has a smoother behavior. This improvement is also observed in other modes of Figure 6. After an exhaustive analysis, it is found that the best results are obtained in two modes: NM4 in A_x and NM1 in A_y . Figure 8 shows the results for all the SCT fault conditions; in general, a proportional trend due to the fault severity is observed, indicating that the RMS index is sensitive to the fault severity in both transient and steady states, which is possible because the NMD method can deal with nonstationary signals. In particular, the proportional trend for 20 SCTs and 15 SCTs conditions in the NM4 for A_x does not continue; yet, the existing separation allows their correct identification.




Figure 7. Instantaneous RMS vs. filtered RMS of Ay: (a) 0 SCTs and (b) 25 SCTs.




Figure 8. RMS values for all conditions: (a) NM4 Ax and (b) NM1 Ay.

Finally, for automatic classification, an FL system is proposed. To obtain information about the input data, the mean and the standard deviation of the RMS values obtained for the 20 tests of each condition are computed. Table 1 presents the obtained results. With this information, the Gaussian distribution functions for the modes of interest (NM4 of A_x and NM1 of A_y in Table 1) can be plotted as shown in Figure 9. From these results, it is evident that the fuzzification process can be carried out through Gaussian membership functions. In this regard, a Mamdani-type fuzzy inference system is used. It has two inputs, 36 rules, and one output. Figure 8 shows the proposed membership functions for two inputs, NM1 A_y and NM4 A_x , and one output, i.e., the transformer condition. The membership functions in Figure 10a are labeled as: very small value (VS), small value (S), normal value (N), high value (H), very high values (VH), very much high value (VMH). On the other hand, the crisp output in Figure 10b can have values ranging from 0.5 to 6.5, where 0 SCTs = 1, 5 SCTs = 2, 10 SCTs = 3, 15 SCTs = 4, 20 SCTs = 5, 25 SCTs = 6. Table 2 shows the used rules in the inference mechanism, where each rule is read as follows if NM4 is N and NM1 is N then output is 10 SCTs. The inference mechanism performs minimum composition to quantify the output value and the defuzzification uses center of gravity [41].

Table 1. Mean (\bar{x}) and standard deviation (σ) for the RMS values.

| | | A_x | | | | A_y | | | |
|-----|-----------|--------|----------|----------|----------|----------|----------|----------|----------|
| SCT | | NM1 | NM2 | NM3 | NM4 | NM1 | NM2 | NM3 | NM4 |
| 0 | \bar{x} | 0.0186 | 0.0125 | 0.0103 | 0.0037 | 0.0103 | 0.0059 | 0.0098 | 0.0024 |
| | σ | 0.0021 | 0.0012 | 0.000669 | 0.000544 | 0.000734 | 0.000711 | 0.0025 | 0.00028 |
| 5 | \bar{x} | 0.0124 | 0.012 | 0.0075 | 0.0044 | 0.0118 | 0.0115 | 0.0116 | 0.0057 |
| | σ | 0.0019 | 0.0021 | 0.000657 | 0.000411 | 0.000992 | 0.000914 | 0.0013 | 0.000652 |
| 10 | \bar{x} | 0.0194 | 0.0106 | 0.0092 | 0.0074 | 0.0167 | 0.0156 | 0.0102 | 0.0052 |
| | σ | 0.0016 | 0.0012 | 0.000789 | 0.000536 | 0.001 | 0.0014 | 0.000627 | 0.000537 |
| 15 | \bar{x} | 0.0215 | 0.0114 | 0.0113 | 0.0096 | 0.0376 | 0.0191 | 0.0104 | 0.0114 |
| | σ | 0.0024 | 0.000659 | 0.000934 | 0.000781 | 0.0023 | 0.001 | 0.000744 | 0.000971 |
| 20 | \bar{x} | 0.0151 | 0.0152 | 0.0116 | 0.0092 | 0.0611 | 0.0195 | 0.0104 | 0.0115 |
| | σ | 0.0021 | 0.0018 | 0.000997 | 0.000841 | 0.004 | 0.0011 | 0.000796 | 0.000709 |
| 25 | \bar{x} | 0.0219 | 0.0179 | 0.0097 | 0.0178 | 0.0753 | 0.0107 | 0.0165 | 0.0092 |
| | σ | 0.0019 | 0.0013 | 0.0011 | 0.0013 | 0.0044 | 0.000566 | 0.000888 | 0.000585 |

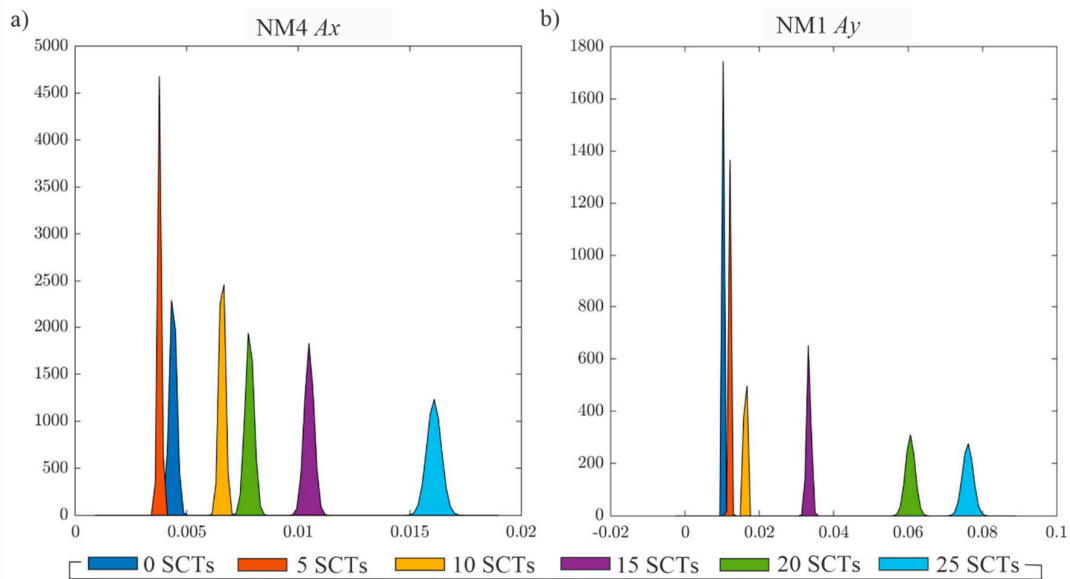


Figure 9. Density functions for (a) NM4 of A_x and (b) NM1 of A_y .

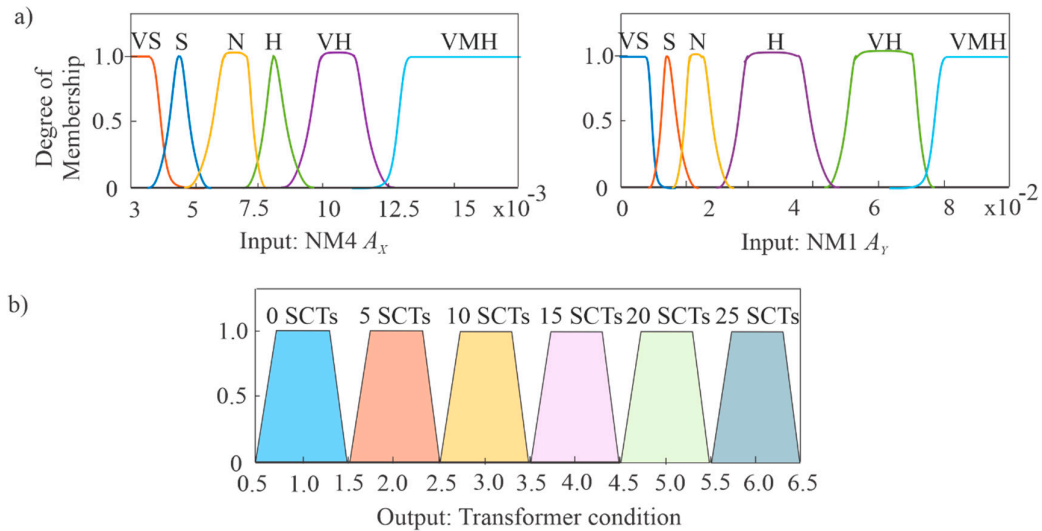


Figure 10. Membership functions for (a) inputs and (b) output.

Table 2. Rules for the proposed fuzzy logic (FL) system.

| Inputs | | NM1 | | | | |
|--------|----|-----|----|----|----|-----|
| NM4 | VS | S | N | H | VH | VMH |
| VS | 0 | 5 | 10 | 15 | 20 | 25 |
| S | 0 | 5 | 10 | 15 | 20 | 25 |
| N | 0 | 5 | 10 | 15 | 20 | 25 |
| H | 0 | 10 | 10 | 15 | 20 | 25 |
| VH | 0 | 10 | 10 | 15 | 20 | 25 |
| VMH | 5 | 10 | 15 | 20 | 25 | 25 |

All the numerical values are SCTs.

Finally, to test the overall methodology, 20 tests for each condition (0, 5, 10, 15, 20, 25, and 30 SCTs) are assessed. Table 3 shows the obtained results as a confusion matrix. In the diagonal, the number of tests that have been correctly classified is presented. As can be observed, an effectiveness of 100% is obtained from 10 SCTs, which is expected since the higher the fault severity, the easier the way to detect it. Yet, for 5 SCTs, an effectiveness of 90% is obtained which is somehow good enough, mainly considering that a low fault severity can generate imperceptible vibration changes. It is important to mention that the most of the fault severities could be identified using the information provided by the NM1 *Ay* only, as shown the results in Figure 8b; yet, in the cases where the Gaussian functions are overlapped, other source of information is required to facilitate the decision-making process. In this case, the proposed FL system and the information provided by the two inputs allow addressing in a better way with the uncertainty generated by the overlap of classes.

Table 3. Confusion matrix.

| | 0 SCTs | 5 SCTs | 10 SCTs | 15 SCTs | 20 SCTs | 25 SCTs | Effectiveness (%) |
|---------|--------|--------|---------|---------|---------|---------|-------------------|
| 0 SCTs | 19 | 1 | 0 | 0 | 0 | 0 | 95 |
| 5 SCTs | 1 | 18 | 1 | 0 | 0 | 0 | 90 |
| 10 SCTs | 0 | 0 | 20 | 0 | 0 | 0 | 100 |
| 15 SCTs | 0 | 0 | 0 | 20 | 0 | 0 | 100 |
| 20 SCTs | 0 | 0 | 0 | 0 | 20 | 0 | 100 |
| 25 SCTs | 0 | 0 | 0 | 0 | 0 | 20 | 100 |

5.3. Discussions

Table 4 shows some relevant methodologies related to fault diagnosis of transformer windings. In particular, the proposal presents some advantages that have to be highlighted. For instance, the proposal identifies the winding short-circuit fault under different severity levels, unlike other approaches that only present the difference between a healthy transformer or a damaged transformer [11,21]. Also, the proposal can detect a fault considering transient and steady states, which is not addressed in other works [11,17,21]. On the other hand, unlike the works presented in [17,21,22,26], the proposal offers an automatic diagnosis that is very important in order to avoid the need of expert users. Finally, the proposal can be considered as a low-complex solution since only three steps are required to (i) process the signal (NMD method), (ii) offer a fault indicator (HT-RMS), and (iii) automate the diagnosis (FLS) by considering different fault severities in transient and steady conditions.

Table 4. Comparison of the proposed methodology against other relevant methodologies.

| Reference | Techniques | Analyzed State | Signal | Sensors by Winding or Phase | Detected Fault in Windings | Types or Severity Levels | Automatic Classification |
|-----------|--------------------------------------------------------------------------------------------------------------------------------|----------------------|------------|-----------------------------|-------------------------------------------|--------------------------|--------------------------|
| Proposal | NMD, HT-based RMS | Transient and steady | Vibrations | 1 | SCTs | 6 | FLS |
| [11] | Frequency complexity analysis, Vibration stationary analysis, energy distribution analysis, and vibration correlation analysis | Steady | Vibrations | 2 | Aged transformer and winding deformations | 0 | Support vector machine |
| [17] | Short time Fourier transform and RMS | Transient | Vibrations | 2 | Winding loosening | 4 | -- |
| [21] | Wavelet packet transform, correlation degree threshold, Hilbert Huang transform and energy | Steady | Vibrations | 2 | Improvement in the fault detection | 0 | -- |
| [22] | Empirical wavelet transform, HT, and collection of sample entropies | Transient and steady | Vibrations | 2 | Winding deformation | 3 | -- |
| [26] | Complete ensemble empirical mode decomposition, Shannon entropy, RMS and energy index | Transient and steady | Current | 1 | SCTs | 6 | -- |

--no reported.

6. Conclusions

Winding faults represent the most severe problem in a transformer; therefore, it is fundamental to develop methodologies that allow their detection on early stages and, thus, implement proper solutions. In this work, a new methodology for detection of SCTs in transformers from vibrations signals is proposed, where different fault severities, i.e., 0, 5, 10, 15, 20, and 25 SCTs, are studied. As a signal processing technique, the NMD method is investigated. Results demonstrate that this method can deal with the nonstationary and nonlinear properties of vibration signals generated during the transformer energization. In particular, the NM1 in y-axis and the NM4 in x-axis provide the most useful information to perform the fault detection. As fault indicator, the RMS index computed through the HT showed a proportional trend according to the fault severity. By combining the RMS values of the selected modes, the proposed FL system achieved an effectiveness superior to 90% in all the cases, including the 5 SCTs fault condition. Although promising results have been obtained, further research has to be carried out in larger transformers in order to increase the proposal applicability, even the fusion with other methods has to be considered with the aim of making more robust and reliable diagnosis systems. In fact, the potential of vibration signals to provide information that allows carrying out the fault detection makes necessary the application and research of other advanced signal processing techniques, e.g., the variational mode decomposition [43], the nonlinear chirp mode decomposition [44], and improvements in Gabor frames [45], among others.

In a future work, other types of fault such as loosening in core and windings, and other transformer operating conditions will be investigated, exploiting the inherent relationship between the transformer's mechanical properties and the vibration signals. Also, different fault indicators will be evaluated to determine their sensitive to the fault severity, exploiting the modes extracted by the NMD method and improving the fault detection capability, mainly in early stages.

Author Contributions: Conceptualization, J.R.H.-R. and M.V.-R.; investigation, resources, and visualization, J.R.H.-R., D.G.-L., and D.C.-M.; funding acquisition, J.P.A.-S. and M.V.-R.; Writing—original draft, review, and editing, all authors. All authors have read and agreed to the published version of the manuscript.

Funding: This research was funded by the “Consejo Nacional de Ciencia y Tecnología (CONACYT)” under the scholarship 734987.

Conflicts of Interest: The authors declare no conflicts of interest.

References

1. Hong, K.; Huang, H.; Zhou, J. Winding Condition Assessment of Power Transformers Based on Vibration Correlation. *IEEE Trans. Power Deliv.* **2015**, *30*, 1735–1742.
2. Bagheri, M.; Naderi, M.; Blackburn, T. Advanced Transformer Winding Deformation Diagnosis: Moving from off-Line to on-Line. *IEEE Trans. Dielectr. Electr. Insul.* **2012**, *19*, 1860–1870.
3. Valtierra-Rodriguez, M. Fractal dimension and data mining for detection of short-circuited turns in transformers from vibration signals. *Meas. Sci. Technol.* **2019**, *31*, 025902.
4. Zheng, J.; Huang, H.; Pan, J. Detection of Winding Faults Based on a Characterization of the Nonlinear Dynamics of Transformers. *IEEE Trans. Instrum. Meas.* **2018**, *68*, 206–214.
5. Zhang, Z.; Wu, Y.; Zhang, R.; Jiang, P.; Liu, G.; Ahmed, S.; Dong, Z. Novel Transformer Fault Identification Optimization Method Based on Mathematical Statistics. *Mathematics* **2019**, *7*, 288.
6. Wang, M.; Vandermaar, A.J.; Srivastava, K.D. Review of Condition Assessment of Power Transformers in Service. *IEEE Electr. Insul. Mag.* **2002**, *18*, 12–25.
7. Islam, M.M.; Lee, G.; Hettiwatte, S.N. A Review of Condition Monitoring Techniques and Diagnostic Tests for Lifetime Estimation of Power Transformers. *Electr. Eng.* **2018**, *100*, 581–605.
8. Mejia-Barron, A.; Valtierra-Rodriguez, M.; Granados-Lieberman, D.; Olivares-Galvan, J.C.; Escarela-Perez, R. Experimental data-based transient-stationary current model for inter-turn fault diagnostics in a transformer. *Electr. Power Syst. Res.* **2017**, *152*, 306–315.
9. Banaszak, S.; Kornatowski, E. Evaluation of FRA and VM measurements complementarity in the field conditions. *IEEE Trans. Power Deliv.* **2016**, *31*, 2123–2130.

10. Bartoletti, C.; Desiderio, M.; Di Carlo, D.; Fazio, G.; Muzi, F.; Sacerdoti, G.; Salvatori, F. Vibro-Acoustic Techniques to Diagnose Power Transformers. *IEEE Trans. Power Deliv.* **2004**, *19*, 221–229.
11. Hong, K.; Huang, H.; Fu, Y.; Zhou, J. A Vibration Measurement System for Health Monitoring of Power Transformers. *Meas. J. Int. Meas. Confed.* **2016**, *93*, 135–147.
12. Garcia, B.; Burgos, J.C.; Alonso, A.M. Transformer Tank Vibration Modeling as a Method of Detecting Winding Deformations—Part II: Experimental Verification. *IEEE Trans. Power Deliv.* **2006**, *21*, 164–169.
13. García, B.; Burgos, J.C.; Alonso, Á.M. Transformer Tank Vibration Modeling as a Method of Detecting Winding Deformations—Part I: Theoretical Foundation. *IEEE Trans. Power Deliv.* **2006**, *21*, 157–163.
14. Zhou, H.; Hong, K.; Huang, H.; Zhou, J. Transformer Winding Fault Detection by Vibration Analysis Methods. *Appl. Acoust.* **2016**, *114*, 136–146.
15. Hu, C.; Wang, P.; Youn, B.D.; Lee, W.R.; Yoon, J.T. Copula-Based Statistical Health Grade System against Mechanical Faults of Power Transformers. *IEEE Trans. Power Deliv.* **2012**, *27*, 1809–1819.
16. Hong, K.; Huang, H.; Zhou, J.; Shen, Y.; Li, Y. A Method of Real-Time Fault Diagnosis for Power Transformers Based on Vibration Analysis. *Meas. Sci. Technol.* **2015**, *26*, 115011.
17. Borucki, S. Diagnosis of Technical Condition of Power Transformers Based on the Analysis of Vibroacoustic Signals Measured in Transient Operating Conditions. *IEEE Trans. Power Deliv.* **2012**, *27*, 670–676.
18. Liu, Z.; Xia, X.; Ji, S.; Shi, Y.; Zhang, F.; Fu, Y.; Jiang, Z. Fault Diagnosis of OLTC Based on Time-Frequency Image Analysis of Vibration Signal. In Proceedings of the 2018 Condition Monitoring and Diagnosis (CMD), Perth, Australia, 23–26 September 2018.
19. Rivas, E.; Burgos, J.C.; García-Prada, J.C. Vibration Analysis Using Envelope Wavelet for Detecting Faults in the OLTC Tap Selector. *IEEE Trans. Power Deliv.* **2010**, *25*, 1629–1636.
20. Kang, P.; Birtwhistle, D. Condition Assessment of Power Transformer On-Load Tap-Changers Using Wavelet Analysis. *IEEE Trans. Power Deliv.* **2001**, *16*, 394–400.
21. Wu, S.; Huang, W.; Kong, F.; Wu, Q.; Zhou, F.; Zhang, R.; Wang, Z. Extracting Power Transformer Vibration Features by a Time-Scale-Frequency Analysis Method. *J. Electromagn. Anal. Appl.* **2010**, *2*, 31–38.
22. Zhao, M.; Xu, G. Feature Extraction of Power Transformer Vibration Signals Based on Empirical Wavelet Transform and Multiscale Entropy. *IET Sci. Meas. Technol.* **2018**, *12*, 63–71.
23. Shah, A.M.; Bhalja, B.R.; Member, S. Discrimination Between Internal Faults and Other Disturbances in Transformer Using the Support Vector Machine-Based Protection Scheme. *IEEE Trans. Power Deliv.* **2013**, *28*, 1508–1515.
24. Valtierra-Rodriguez, M.; Amezcua-Sanchez, J.P.; Garcia-Perez, A.; Camarena-Martinez, D. Complete ensemble empirical mode decomposition on FPGA for condition monitoring of broken bars in induction motors. *Mathematics* **2019**, *7*, 783.
25. Liu, X.; Yang, Y.; Huang, Y. Vibration Analysis of Transformer DC Bias Caused by HVDC Based on EMD Reconstruction. *J. Electr. Eng. Technol.* **2018**, *13*, 781–789.
26. Mejia-Barron, A.; Valtierra-Rodriguez, M.; Granados-Lieberman, D.; Olivares-Galvan, J.C.; Escarela-Perez, R. The Application of EMD-Based Methods for Diagnosis of Winding Faults in a Transformer Using Transient and Steady State Currents. *Meas. J. Int. Meas. Confed.* **2018**, *117*, 371–379.
27. Duan, R.; Wang, F. Fault Diagnosis of On-Load Tap-Changer in Converter Transformer Based on Time–Frequency Vibration Analysis. *IEEE Trans. Ind. Electron.* **2016**, *63*, 3815–3823.
28. Geng, C.; Wang, F.; Zhang, J.; Jin, Z. Modal Parameters Identification of Power Transformer Winding Based on Improved Empirical Mode Decomposition Method. *Electr. Power Syst. Res.* **2014**, *108*, 331–339.
29. Camarena-Martinez, D.; Valtierra-Rodriguez, M.; Perez-Ramirez, C.A.; Amezcua-Sanchez, J.P.; de Jesus Romero-Troncoso, R.; Garcia-Perez, A. Novel Downsampling Empirical Mode Decomposition Approach for Power Quality Analysis. *IEEE Trans. Ind. Electron.* **2016**, *63*, 2369–2378.
30. Saxena, M.K.; Raju, S.D.V.S.J.; Arya, R.; Pachori, R.B.; Ravindranath, S.V.G.; Kher, S.; Oak, S.M. Empirical Mode Decomposition-Based Detection of Bend-Induced Error and Its Correction in a Raman Optical Fiber Distributed Temperature Sensor. *IEEE Sens. J.* **2016**, *16*, 1243–1252.
31. Amarnath, M.; Krishna, I.R.P. Detection and Diagnosis of Surface Wear Failure in a Spur Geared System Using EEMD Based Vibration Signalanalysis. *Tribol. Int.* **2013**, *61*, 224–234.
32. Valles-Novo, R.; de Jesus Rangel-Magdaleno, J.; Ramirez-Cortes, J.M.; Peregrina-Barreto, H.; Morales-Caporal, R. Empirical Mode Decomposition Analysis for Broken-Bar Detection on Squirrel Cage Induction Motors. *IEEE Trans. Instrum. Meas.* **2015**, *64*, 1118–1128.

33. Iatsenko, D.; McClintock, P.V.E.; Stefanovska, A. Nonlinear Mode Decomposition: A Noise-Robust, Adaptive Decomposition Method. *Phys. Rev. E* **2015**, *92*, 032916.
34. García, B.; Burgos, J.C.; Alonso, Á. Winding Deformations Detection in Power Transformers by Tank Vibrations Monitoring. *Electr. Power Syst. Res.* **2005**, *74*, 129–138.
35. Iatsenko, D.; McClintock, P.V.E.; Stefanovska, A. Linear and Synchrosqueezed Time-Frequency Representations Revisited: Overview, Standards of Use, Resolution, Reconstruction, Concentration, and Algorithms. *Digit. Signal Process.* **2015**, *42*, 1–26.
36. Iatsenko, D.; McClintock, P.V.E.; Stefanovska, A. Extraction of Instantaneous Frequencies from Ridges in Time-Frequency Representations of Signals. *Signal Process.* **2016**, *125*, 290–303.
37. Iatsenko, D.; McClintock, P.V.; Stefanovska, A. Linear and synchrosqueezed time-frequency representations revisited. Part ii: Resolution, reconstruction and concentration. *arXiv* **2013**, arXiv:1310.7274.
38. Wang, X.; Deck-Leger, Z.-L.; Zou, L.; Azana, J.; Caloz, C. Microwave Hilbert Transformer and Its Applications in Real-Time Analog Processing. *IEEE Trans. Microw. Theory Tech.* **2019**, *67*, 2216–2226.
39. Urbina-Salas, I.; Razo-Hernandez, J.R.; Granados-Lieberman, D.; Valtierra-Rodriguez, M.; Torres-Fernandez, J.E. Instantaneous power quality indices based on single-sideband modulation and wavelet packet-Hilbert transform. *IEEE Trans. Instrum. Meas.* **2017**, *66*, 1021–1031.
40. Golestan, S.; Ramezani, M.; Guerrero, J.M.; Freijedo, F.D.; Monfared, M. Moving Average Filter Based Phase-Locked Loops: Performance Analysis and Design Guidelines. *IEEE Trans. Power Electron.* **2014**, *29*, 2750–2763.
41. Kuncheva, L. *Fuzzy Classifier Design*; Springer Science & Business Media: Berlin, Germany, 2000; Volume 49.
42. Valtierra-Rodriguez, M.; Granados-Lieberman, D.; Torres-Fernandez, J.E.; Rodríguez-Rodríguez, J.R.; Gómez-Aguilar, J.F. A new methodology for tracking and instantaneous characterization of voltage variations. *IEEE Trans. Instrum. Meas.* **2016**, *65*, 1596–1604.
43. Dragomiretskiy, K.; Zosso, D. Variational Mode Decomposition. *IEEE Trans. Signal Process.* **2014**, *62*, 531–544.
44. Chen, S.; Dong, X.; Peng, Z.; Zhang, W.; Meng, G. Nonlinear Chirp Mode Decomposition: A Variational Method. *IEEE Trans. Signal Process.* **2017**, *65*, 6024–6037.
45. De Carli, L.; Vellucci, P. Stability results for Gabor frames and the p-order hold models. *Linear Algebra Appl.* **2018**, *536*, 186–200.



© 2020 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<http://creativecommons.org/licenses/by/4.0/>).

Anexo C: Artículo indizado (caso de estudio 4)

Article

Contrast Estimation in Vibroacoustic Signals for Diagnosing Early Faults of Short-Circuited Turns in Transformers under Different Load Conditions

Jose R. Huerta-Rosales ¹, David Granados-Lieberman ², Juan P. Amezcua-Sanchez ¹, Arturo Garcia-Perez ³, Maximiliano Bueno-Lopez ⁴ and Martin Valtierra-Rodriguez ^{1,*}

¹ ENAP-Research Group, CA-Sistemas Dinámicos y Control, Laboratorio de Sistemas y Equipos Eléctricos (LaSEE), Facultad de Ingeniería, Universidad Autónoma de Querétaro (UAQ), Campus San Juan del Río, Río Moctezuma 249, Col. San Cayetano, San Juan del Río 76807, Querétaro, Mexico

² ENAP-Research Group, CA-Fuentes Alternas y Calidad de la Energía Eléctrica, Departamento de Ingeniería Electromecánica, Tecnológico Nacional de México, Instituto Tecnológico Superior de Irapuato (ITESI), Carretera Irapuato-Silao km 12.5, Colonia El Copal, Irapuato 36821, Guanajuato, Mexico

³ ENAP-Research Group, División de Ingenierías, Universidad de Guanajuato, Campus Irapuato-Salamanca, Carretera Salamanca-Valle de Santiago km 3.5 + 1.8 km, Comunidad de Palo Blanco, Salamanca 36885, Guanajuato, Mexico

⁴ Department of Electronics, Instrumentation, and Control, Universidad del Cauca, Popayán 190002, Cauca, Colombia

* Correspondence: martin.valtierra@enap-rg.org

Citation: Huerta-Rosales, J.R.; Granados-Lieberman, D.; Amezcua-Sanchez, J.P.; Garcia-Perez, A.; Bueno-Lopez, M.; Valtierra-Rodriguez, M. Contrast Estimation in Vibroacoustic Signals for Diagnosing Early Faults of Short-Circuited Turns in Transformers under Different Load Conditions. *Energies* **2022**, *15*, 8508. <https://doi.org/10.3390/en15228508>

Academic Editors: Yuling He, David Gerada, Conggan Ma and Haisen Zhao

Received: 7 October 2022

Accepted: 11 November 2022

Published: 14 November 2022

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



Copyright: © 2022 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

Abstract: The transformer is one of the most important electrical machines in electrical systems. Its proper operation is fundamental for the distribution and transmission of electrical energy. During its service life, it is under continuous electrical and mechanical stresses that can produce diverse types of damage. Among them, short-circuited turns (SCTs) in the windings are one of the main causes of the transformer fault; therefore, their detection in an early stage can help to increase the transformer life and reduce the maintenance costs. In this regard, this paper proposes a signal processing-based methodology to detect early SCTs (i.e., damage of low severity) through the analysis of vibroacoustic signals in steady state under different load conditions, i.e., no load, linear load, nonlinear load, and both linear and nonlinear loads, where the transformer is adapted to emulate different conditions, i.e., healthy (0 SCTs) and with damage of low severity (1 and 2 SCTs). In the signal processing stage, the contrast index is analyzed as a fault indicator, where the Unser and Tamura definitions are tested. For the automatic classification of the obtained indices, an artificial neural network is used. It showed better results than the ones provided by a support vector machine. Results demonstrate that the contrast estimation is suitable as a fault indicator for all the load conditions since 89.78% of accuracy is obtained if the Unser definition is used.

Keywords: artificial neural networks; contrast estimation; fault diagnosis; short-circuited turns; transformer fault; vibroacoustic signals

1. Introduction

The condition monitoring and fault diagnosis of electrical machines have become essential tools for industrial processes since their reliability and safety can be improved [1]. Among the electric machines, the transformer can suffer various internal faults such as winding and core deformations, broken clamping structures, short-circuit turns (SCT), bending, and others [2]. For this machine, the winding is an essential operating component and, at the same time, it is one of the most vulnerable components; in fact, the associated faults to windings are nearly 40% [3], whereas in the most cases the initial damage can lead to the complete fault of the transformer, increasing repairment costs and people

risks. In this regard, the development and application of early fault detection methods are of paramount importance [4,5].

In literature, different techniques to carry out the monitoring and diagnosis of transformer windings by analyzing different types of signals have been proposed [6–9]. However, the vibration signal analysis has proven to be an effective tool for monitoring and diagnosing internal faults in transformers [6], since the vibrational response changes if the winding mechanical properties are modified [7], e.g., when a fault condition appears. Some studies measure acoustic signals instead of vibration signals [8,9]. It is observed that acoustic signals are produced by the vibration of a source, thus, they contain the same information about the source behavior. In this way, the vibration and acoustic signals are interrelated and homologous [8,9].

The machinery diagnosis that employs vibroacoustic (VA) signals typically consists of three essential steps: acquisition and preprocessing of data, feature extraction from the data, and classification based on the extracted features. Successful methods have shown that feature extraction is the most crucial step in machinery monitoring and diagnosis [7,10]. In literature, several techniques extract features from VA signals in distinct domains (e.g., time, frequency, or time-frequency) for assessing the transformer condition [11–22]. A widely employed tool to change from time-domain to frequency-domain is the Fourier Transform (FT). The FT allows extracting frequential information related to the system condition. In [11], they employ the FT in VA signals and estimate the total harmonic distortion (THD) to assess the transformer healthy condition. Meanwhile, in [9], the THD, dominant frequencies, and the ratio of frequencies from the spectrum of acoustic signals are estimated. They establish a warning threshold that allows identifying a direct current bias state. Although the FT presents promising results, it has some limitations. These limitations compromise the detection of changes in frequency over time, mainly due to the nonstationary nature of the signal and its high-level noise, among others [12]. To overcome these limitations, the short-time Fourier Transform (STFT) is introduced. This technique provides a two-dimensional representation of the analyzed signal in time, i.e., a time-frequency representation (TFR) in the time-frequency domain. In [13], the STFT is used to analyze a VA signal, where the changes in frequency are associated to the anomalous behavior in the transformer. Nevertheless, the STFT has the resolution trade-off issue, i.e., it can gain frequency resolution but, at the same time, loss resolution in time, and vice versa, which can compromise the accuracy of the results; in addition, if the signal presents a severe level of noise, the performance decreases due to the spectral leakage problem, compromising the diagnosis as well [14]. Another effective way to construct a TFR is using the Wavelet transform (WT) and its variations. The WT has better time and frequency localization, making it more effective than STFT for some applications [15]. The work presented in [16] uses the WT to analyze the transient state of the transformer from its vibration signals. Also, a WT-based work called Empirical WT is used in [17], in which it is employed to build a TFR and estimate the multiscale entropy as a fault feature. On the other hand, in [18], the Wavelet packet is applied to detect DC bias in transformers, obtaining very effective results. Yet, the success of a WT-based approach depends on the proper selection of both the mother wavelet and the decomposition level [19], which is different in each application.

As mentioned above, the changing of domain (i.e., time or frequency) always requires the application of a transformation technique, implying a computational cost. In this regard, feature extraction in the time domain has been explored. The work presented in [20] diagnoses a transformer under a SCT fault by employing different fractal algorithms. They extract information from the vibration signals to detect diverse SCT fault severities. In [21], several statistical features are extracted from the vibration signals, then, the most representative ones are selected to diagnose the transformer under different SCT fault severities. Also, a mathematical statistics-based method for the analysis of vibration signals is presented in [22], where the probability distribution is used to identify the SCT fault. Although promising results have been obtained, there are still some issues that have not

been completely addressed, e.g., damage detection of low severity (i.e., 1 or 2 SCTs) under different load conditions, which is of paramount importance since online condition monitoring systems for predictive maintenance can be developed. It is worth noting that the detection of early faults is a challenging task since the behavior of the transformer slightly changes. The challenge increases if both the high-level noise in the VA signals and the electrical stresses associated to the different load conditions are considered. Therefore, the development and application of new methods are still current needs.

Recently, the contrast index used in image processing for analyzing texture [23,24] has been used for diagnosing broken rotor bars in induction motors through the analysis of electric current signals [25], showing that it can provide information about variations into a signal waveform, which is congruent as it detects variations in color and brightness in an image. In this regard, as the main contribution, this work explores the application of the contrast index to diagnose early SCT faults, where a complete methodology (i.e., signal processing and automatic pattern recognition) is proposed. Also, unlike other works, the proposal is assessed when the transformer is under different load conditions, increasing its applicability in real operating scenarios; besides, it is worth noting that the detection of early SCT faults is not an easy task due to imperceptible changes in the transformer and the high noise into the VA signals. In order to develop and validate the proposed method, the VA signals from a transformer capable to emulate different early SCT severities, i.e., 0, 1, and 2 SCTs, where 0 SCTs represents the healthy condition, are firstly acquired. At this stage, four different load conditions, i.e., (1) no load, (2) linear load, (3) nonlinear load, and (4) both linear and nonlinear loads, are considered. In general, these loads represent real life operating conditions [5]. Once the signals have been acquired, two contrast definitions, i.e., Unser and Tamura, are computed and compared in order to observe which one provides the best sensibility to the fault. Finally, the different values of contrast for the different SCT conditions are processed by an artificial neural network (ANN) for automatic pattern recognition, where the performance of a support vector machine (SVM) is also compared. Results demonstrate the effectiveness of the proposal. The rest of the paper is organized as follows. Section 2 presents the theoretical background for transformer vibrations, contrast index, and ANNs. The proposed methodology is described in Section 3. Section 4 shows the experimental setup and the obtained results. A discussion of works is presented in Section 5. Finally, Section 6 draws the obtained conclusions.

2. Theoretical Background

2.1. Transformer Vibration

Transformer vibration is from two principal sources: windings and core. Although the vibration components of each source are distinct, the winding component is smaller than the component from the core [9].

The winding vibration is principally caused by the electric force, which is generated by the current that circulates through the windings and its interaction with the magnetic leakage flux [26]. The forces created by winding vibration have two components: axial and radial, where the force is proportional to the square of the current as shown in Equation (1) and its fundamental frequency is twice the fundamental frequency of the current signal [27].

$$F_{winding} \propto I^2 \quad (1)$$

On the other hand, the main cause of core vibration is the magnetostriction phenomenon. This phenomenon changes the shape of a ferromagnetic material when it is under the influence of a magnetic field. Then, in Equation (2), the force magnitude from core vibration is proportional to the square of the voltage [28]. The fundamental frequency due to the magnetostriction is twice the fundamental frequency of the voltage signal, but high

frequency harmonics can appear due to the nonlinear magnetostriction behavior. Also, the force direction is perpendicular to the core plane [29].

$$F_{core} \propto V^2 \quad (2)$$

As mentioned above, the vibration signals and acoustic signals are homologous. In this regard, any change in the VA signal is directly related to the transformer performance. Therefore, the characterization of these changes through time-domain indicators (e.g., the contrast index) can help to determine the transformer condition.

2.2. Contrast

The contrast index is a textural feature that measures the variations present in an image [30]. In a simple way, it is the difference between a pair of black and white dots. The contrast value can be maximum when two pair of dots have opposite values in the gray scale, e.g., 0 and 255, and be minimum when their values are similar. Although this index is intended for images, it can also be applied to 1D signals. Two simple ways to estimate the contrast are presented by Unser [31] and Tamura et al. [32].

2.2.1. Unser Contrast

Unser employs the sum and difference of histograms to estimate the contrast [31]. In order to do so, firstly, the variation between two points separated by d samples in a signal $L(n)$ is computed as follows:

$$D_{n,d} = L(n) - L(n+d) \quad (3)$$

where $n \in \{0, 1, \dots, N-1\}$. With this value, the histogram of differences is computed as:

$$h_d(j) = \text{card}\{n \in N, D_{n,d} = j\} \quad (4)$$

where $j = -N_g + 1, -N_g + 2, \dots, N_g - 2, N_g - 1$ for at least N_g levels of gray. $\text{card}\{\}$ refers to the number of elements of a set.

The normalized difference histogram is then given by:

$$P_D = \frac{h_d(j)}{T} \quad (5)$$

where T is the total number of counts. It is computed by:

$$T = \sum_j h(j) \quad (6)$$

Finally, the contrast can be computed as:

$$C = \sum_j j^2 P_D(j) \quad (7)$$

2.2.2. Tamura Contrast

Tamura et al. propose the contrast in function of [32]:

1. Dynamic range of gray levels;
2. Polarization of the distribution of black and white on the histogram of gray levels or the ratio between the black and white areas.

In this regard, the kurtosis provides the polarization factor as:

$$\alpha_4 = \frac{\mu_4}{\sigma^4}, \tag{8}$$

where μ_4 is the fourth moment around the mean and σ^2 is the variance that represents the distribution of the gray levels. Therefore, the Tamura contrast is defined as:

$$C = \frac{\sigma}{(\alpha_4)^n} \tag{9}$$

where n is a positive number, which is experimentally defined as $n = 1/4$.

2.3. Artificial Neural Networks

ANNs are a computational structure designed to emulate a neurological structure of a human brain, which are constructed by individual elements with similar behavior to the biologic neuron also called neurons, having the capability to learn and solve problems [33]. One of the most employed ANN architectures is the feed-forward neural network due to its reduced computational load and its simplicity to be used as a classifier [33]. Figure 1a shows the ANN architecture. This architecture includes an input layer, hidden layers, and an output layer. The information moves from the input layer the output layer. In each layer, it can have a single or multiple neurons. In Equation (10), the mathematical function of a neuron is shown, whereas its structure appears in Figure 1b. The neuron consists of a summation of multiplications between the inputs x_i and weights w_i , which emulates the synapsis process, and a bias b . The result of the summation is evaluated by a function called the activation function $f(\cdot)$, which is a nonlinear function that provides the capability of modeling nonlinear relationships. Finally, a training data stage is carried out to characterize the ANN weights, i.e., a set of inputs and the desired outputs are presented to the ANN. Consequently, comparing the desired outputs and the computed outputs, the error can be estimated. Employing a training rule, the weights can be adjusted to minimize the error in a subsequent iteration. This process is repeated until the error is acceptable.

$$O_1 = f\left(\sum_{i=1}^l w_i x_i + b\right), \tag{10}$$




Figure 1. ANN architecture: (a) ANN with hidden layers and (b) a single neuron.

3. Proposed Methodology

Figure 2 shows the flowchart for the proposed methodology. In general, as depicted by the red dashed rectangle, it is a three-step process: (1) signal processing which consists of the signal segmentation and the gray-scale normalization, (2) estimation of contrast as fault index, and (3) design and validation of a classification algorithm. To test the proposal, VA signals from a transformer under early SCT fault conditions and different load conditions are analyzed. In order to do so, firstly, VA signals are acquired from a single-phase transformer which can emulate different early SCT fault conditions: 0, 1, and 2 SCTs, where 0 SCTs is the healthy condition. To select the SCT condition, a conductor cable is connected to different taps with a resistor R . This resistor helps to limit the short-circuit current. For carrying out the transformer energization and connecting/disconnecting the different loads, three solid-state relays are used (see the switches in Figure 2). Once the VA signals are acquired, they are segmented, taking 1s of the signal in each different load case: (1) no load, (2) linear load, (3) linear and nonlinear loads, and (4) nonlinear load. This process is repeated for all the SCT conditions previously mentioned. Then, as part of the proposed methodology, the VA signals are normalized into a gray-scale, i.e., the VA signal takes values from 0 to 255. For each new signal, two different contrast indicators, i.e., Tamura and Unser, are computed to obtain the best fault indicator. Finally, in the automatic classification step, two different algorithms, i.e., ANN and SVM, are evaluated to detect and classify the SCT transformer condition under different load conditions. Results demonstrates that the Unser contrast and the ANN algorithm present the best results for detection and classification of SCT fault conditions regardless the load type.

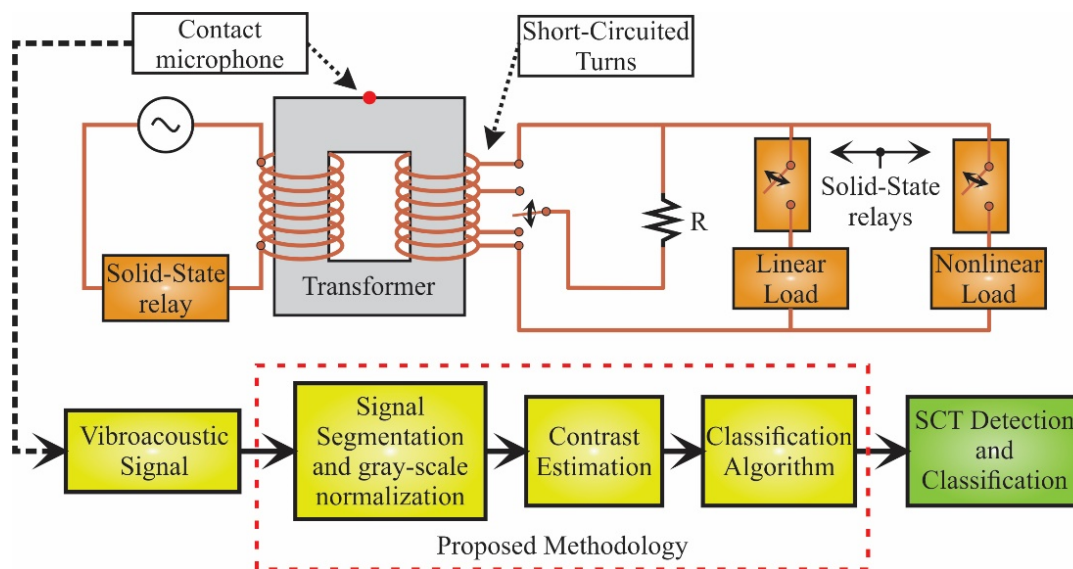


Figure 2. Flowchart for the proposed methodology.

4. Experimental Setup and Results

This section shows the experimental setup and the obtained results

4.1. Experimental Setup

The experimental setup for the proposed work is shown in Figure 3. For the tests, a single-phase transformer of 1.5 kVA operated to 220V with a relation 2:1 is employed. The transformer is modified to emulate early SCT fault conditions in the secondary winding. In order to do so, the transformer winding is unwound and, then, various taps are pulled out while rewinding. To protect the winding during the SCT fault, a resistor, R , of 2 ohms is used.

For the transformer energization and the connection/disconnection of the linear and nonlinear loads, three solid-state relays, model SAP4050D, are used. The linear and nonlinear loads represent approximately the 93% of the total load of the transformer, i.e., 900 W and 500 W, respectively. The linear load is a resistive array of 15 ohms and the nonlinear load is the combination of a resistive array of 24 ohms and a rectifier. The rectifier is composed by an array of diodes of 800 V and 8 A with a capacitor filter of 210 μF and 450 V. To measure the VA signals from the transformer and provide a low-cost, easy-to-use, and commercial solution, a contact microphone piezoelectric pickup (TP-6 model from RECK-LESS) is used. Its operating principle is based on a piezoelectric diaphragm that measures the vibrations (i.e., acceleration in m/s^2) from the contact zone with 6.4 kHz of maximum bandwidth which is good enough to capture the frequency range of interest, i.e., 1 kHz. It is located at the top center of the transformer core; in this location, the core and winding vibrations as well as the generated noise can be received in a similar way from a geometrical point of view. The data are acquired by using a data acquisition system (DAS) based on the National Instruments NI-USB-6211 board which is configured with a sampling frequency of 7812.5 samples/s. For each condition, i.e., 0, 1, and 2 SCTs, and the different combinations of load, 20 tests are carried out. All the data acquisition and their processing are on MATLAB software by using a personal computer (PC), featuring Windows 10, a processor 17-4510U at 2.6 GHz, and 8GB of RAM.

Figure 4 shows an example of the acquired signals. The acquisition time is of 10 s; thus, the transient and steady states can be captured. Current signals (bottom images) show clearly the changes associated to load condition. There are four load conditions: (1) no load (S0), (2) linear load (S1), (3) both linear and nonlinear loads (S2), and (4) nonlinear load (S4), where the activation/deactivation times are 2, 4, 6, and 8 s, respectively. From these time-windows, sections of 1 s are selected. This time-window contains enough information about the steady state and avoids overlaps with other load scenarios (see the red dashed rectangles in Figure 4). Once the signals are segmented, the data processing (i.e., the contrast index estimation and the classification based on a pattern recognition algorithm) is carried out.

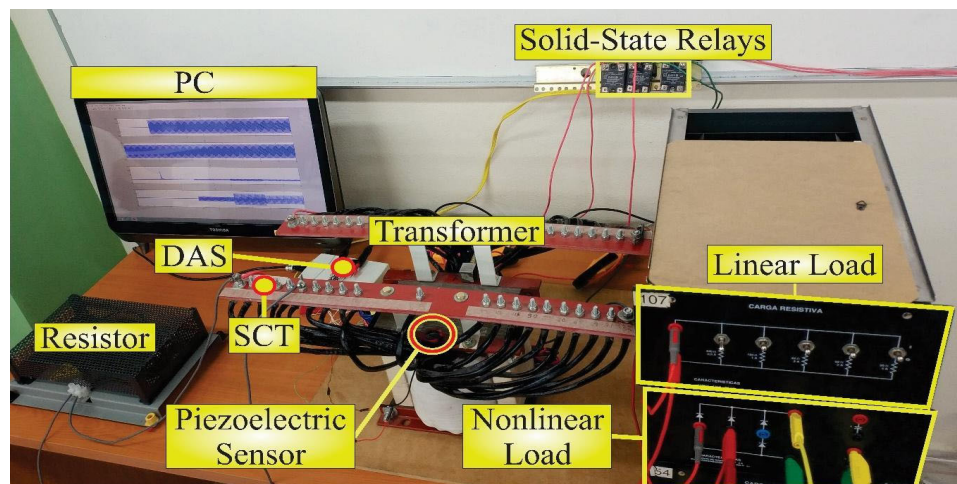


Figure 3. Experimental setup.

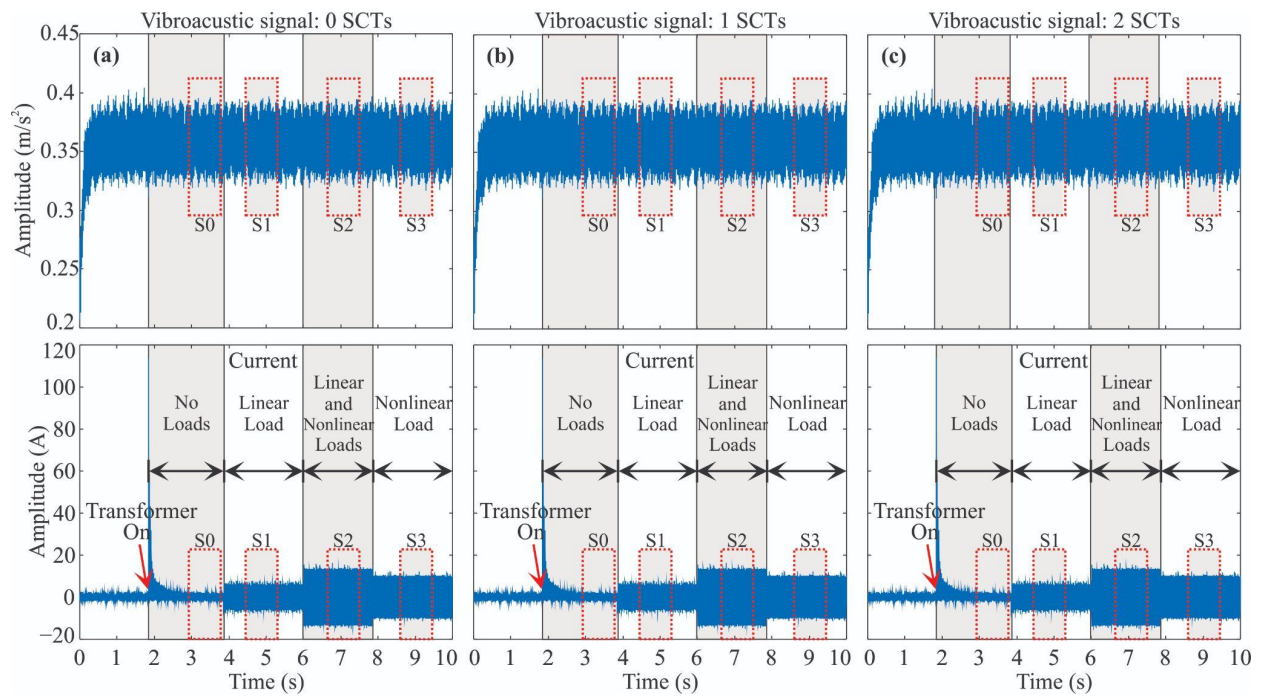


Figure 4. Signals acquired from the transformer: VA signals for: (a) 0 SCTs, (b) 1 SCTs, and (c) 2 SCTs.

4.2. Results

4.2.1. Gray-Scale Normalization

For the contrast estimation, the signals have to be normalized to a grayscale, i.e., to values from 0 to 255. Through this linear conversion, the minimum value of the VA signal is mapped to zero, whereas the maximum value is mapped to 255. Also, rounding down is carried out only to consider integer numbers (see Figure 5e–h). In general, this change in the VA signal values does not modify its behavior but it helps to maintain the same reference level, minimizing and generalizing the impact of different load levels.

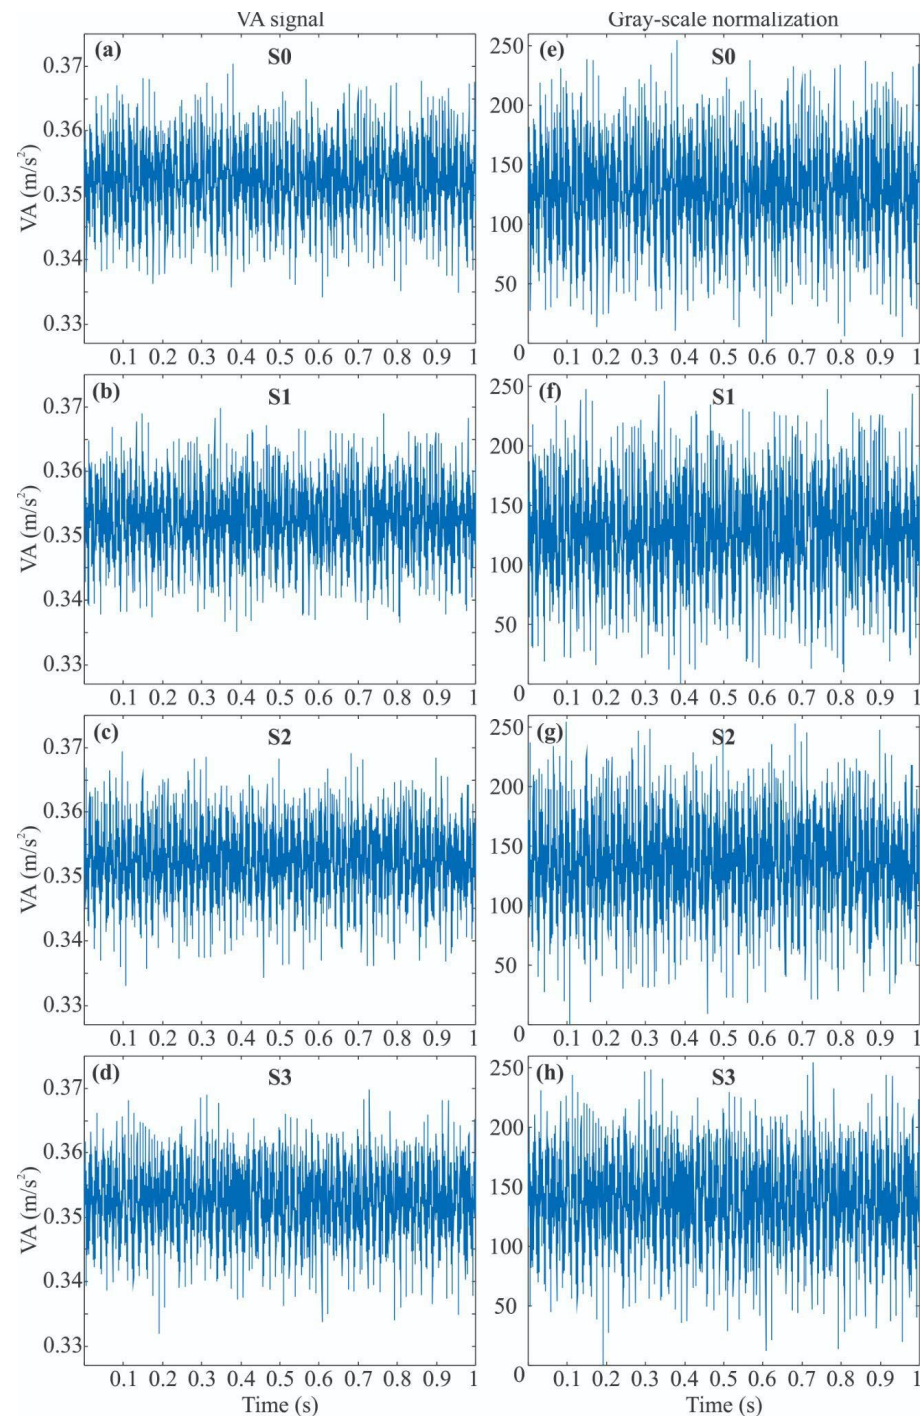


Figure 5. Example of a VA acquired signal and its gray-scale normalization: (a) section S0, (b) section S1, (c) section S2, (d) section S3, and gray-scale normalization for sections (e) S0, (f) S1, (g) S2, and (h) S3.

4.2.2. Unser and Tamura Contrast Estimations

Two contrast definitions, i.e., Unser and Tamura, are used with the purpose of determining which approach is the most adequate to characterize variations associated to an early SCT fault condition in VA signals from a transformer.

The Unser [31] definition uses the normalized differences histograms, i.e., Equation (7), to compute the contrast. In order to do so, a distance of separation between two data

points from the VA signal, i.e., d , has to be selected. After different trial-and-error tests, a value of $d = 15$ is selected since it presented the best results as will be discussed at the end of this section. Table 1 and Figure 6 show the obtained results. Table 1 presents the mean (μ) and the standard deviation (σ) for the values of contrast by including the three SCT conditions (i.e., 0, 1, and 2 SCTs), the four load conditions (i.e., S0, S1, S2, and S3), and the 20 tests carried out for each condition. From the results (Table 1 or Figure 6a), it can be observed that the mean of the contrast value does not exhibit considerable variations for the different load combinations, i.e., the load does not influence the contrast index estimation.

In a similar way, the Tamura contrast index is estimated for the SCT fault conditions and their different load conditions, but with the difference that the Tamura contrast is a statistical-based calculation, i.e., Equation (9). As can be observed in both Table 1 and Figure 6, this index also presents a similar behavior for the different load combinations. Although the estimated contrast values for both Unser and Tamura indexes are not on the same scale, both graphs are quite similar, which reaffirms the low influence of the load in the contrast estimation.

Table 1. Mean (μ) and standard deviation (σ) for the contrast values, different load combinations, and different SCT fault conditions.

| | | Unser Contrast, $d = 15$ | | | | Tamura Contrast | | | |
|--------|----------|--------------------------|-----------|-----------|-----------|-----------------|---------|---------|---------|
| | | S0 | S1 | S2 | S3 | S0 | S1 | S2 | S3 |
| 0 SCTs | μ | 3862.5413 | 3426.7146 | 3597.4812 | 3511.6746 | 38.1231 | 35.4044 | 36.5590 | 36.0443 |
| | σ | 683.7739 | 690.3487 | 652.7069 | 848.0176 | 4.6503 | 4.6849 | 4.4967 | 5.4222 |
| 1 SCTs | μ | 6732.2393 | 6363.5508 | 6543.8623 | 6294.7972 | 53.8102 | 51.9030 | 53.0096 | 51.8991 |
| | σ | 1441.4742 | 1220.7590 | 1301.9952 | 1195.6256 | 7.5780 | 6.6916 | 6.9990 | 6.5757 |
| 2 SCTs | μ | 8699.9884 | 8304.6975 | 8529.3658 | 8147.1655 | 62.6589 | 60.8933 | 62.1086 | 60.5648 |
| | σ | 1084.0015 | 1022.1635 | 1049.8129 | 1016.2967 | 4.3483 | 4.1768 | 4.2930 | 4.2054 |

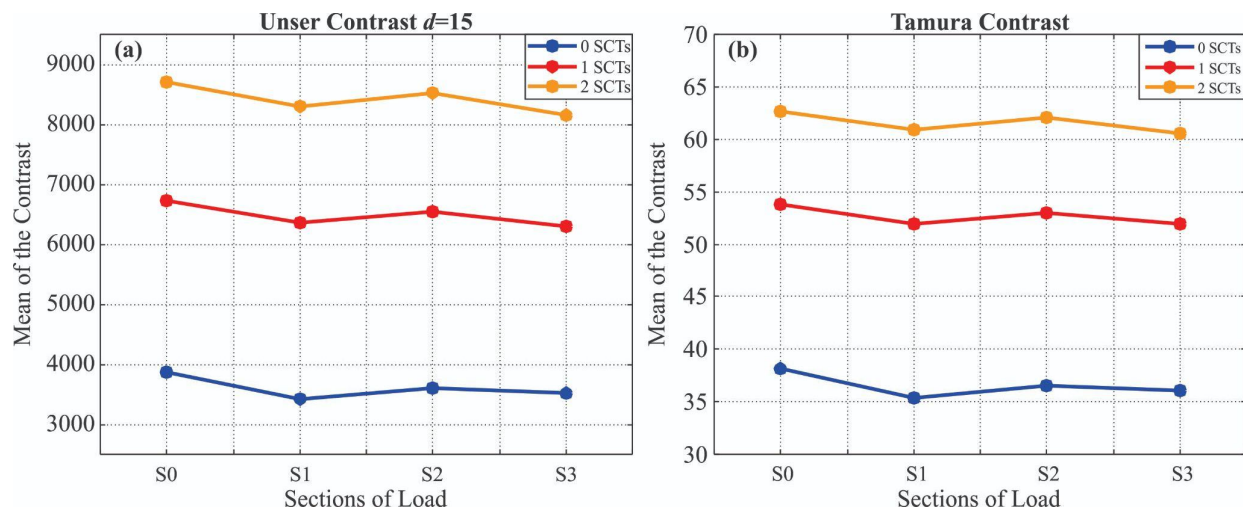


Figure 6. Mean (μ) of the contrast values for different loads: (a) Unser contrast with $d = 15$ and (b) Tamura contrast.

As the values of the Unser contrast does not change with the load, the values for each section (load combinations: S0, S1, S2, and S3) can produce a bigger cluster of SCT conditions.

Figure 7 shows the distributions of the clusters for each SCT condition. From this figure, it is also observed that the contrast indices are sensitive to the SCT severity since their value increases when the SCT fault severity increases. In Table 2, the values of the

mean (μ) and the deviation standard (σ) for these clusters are shown. All these results characterize in a numerical way the behavior of each SCT condition. It is worth noting that some conventional time features (e.g., peak factor, kurtosis, standard deviation, among others) have also been analyzed. However, although some of them present a certain degree of separation, their clusters are overlapped due to their more significant variances which are also affected by the load condition, resulting in lower classification accuracy.

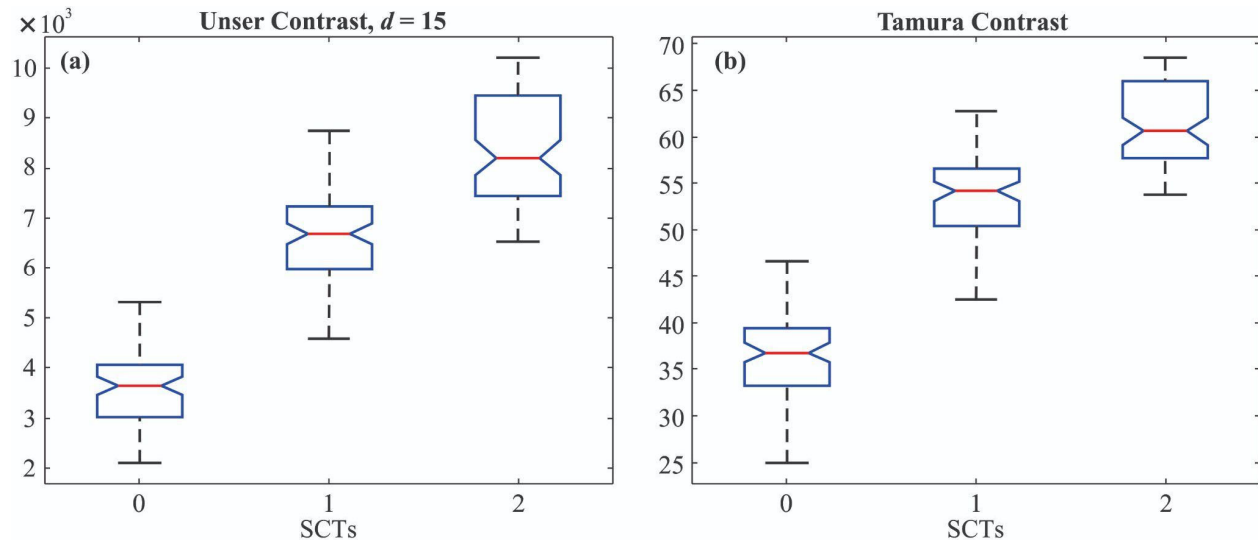


Figure 7. Data distributions of the contrast values for the VA signals with different SCT fault conditions: (a) Unser contrast and (b) Tamura contrast.

Table 2. Mean (μ) and standard deviation (σ) for the different contrast distributions of the different SCT fault conditions.

| | Unser Contrast, $d = 15$ | | | Tamura Contrast | | |
|----------|--------------------------|-----------|-----------|-----------------|---------|---------|
| | 0 SCTs | 1 SCTs | 2 SCTs | 0 SCTs | 1 SCTs | 2 SCTs |
| μ | 3599.6029 | 6483.6124 | 8420.3043 | 36.5327 | 52.6555 | 61.5564 |
| σ | 740.9540 | 130.6383 | 1064.5340 | 4.9304 | 7.0183 | 4.3420 |

Once the concept of grouping the contrast values for different load conditions (i.e., the contrast index does not change with the load as was shown in Figure 7) is described, the results for different values of d in the Unser contrast definition are shown for clarity purposes (see Figure 8).

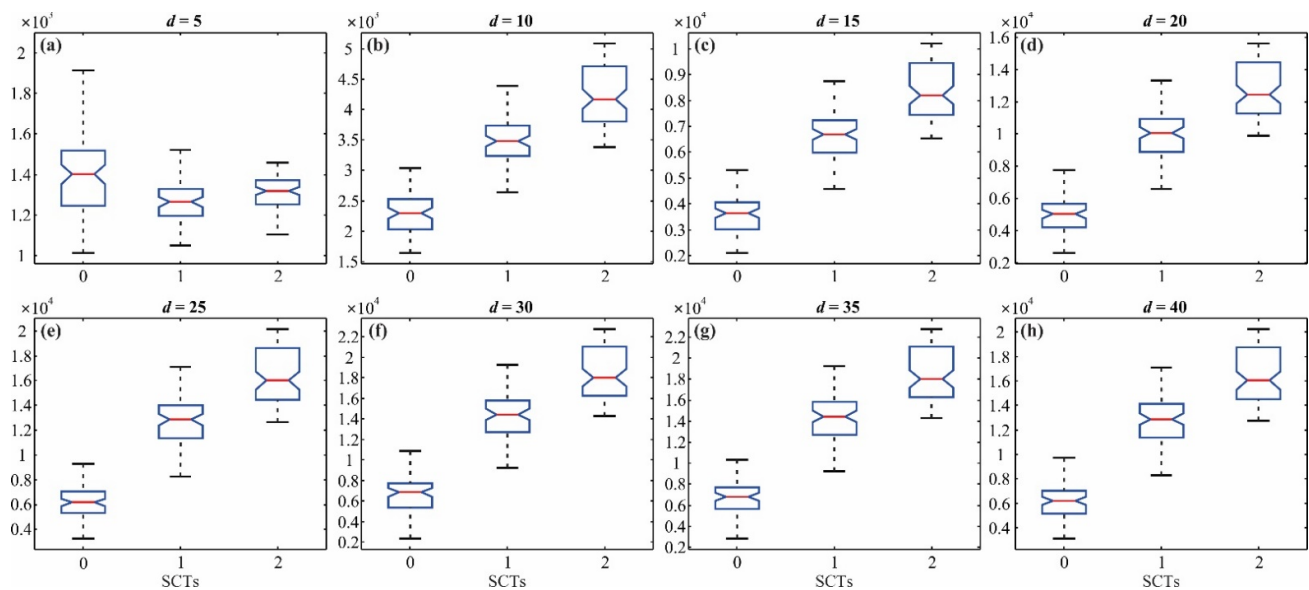


Figure 8. User contrast clusters for different values of d : (a) $d = 5$, (b) $d = 10$, (c) $d = 15$; (d) $d = 20$, (e) $d = 25$, (f) $d = 30$, (g) $d = 35$, and (h) $d = 40$.

In Figure 8, the clusters for different values of d are shown. For $d = 5$, the clusters do not show separation among them. The separation can be observed from $d = 10$, where the clusters maintain a similar separation but in a different scale (y -axis). Despite this fact, as mentioned above, the most suitable value for d is 15. This is not merely for the separation observed between the clusters but also for the accuracy obtained when the classification algorithm is applied.

4.2.3. Classification Results

As shown in Figure 7, the contrast index is sensitive to the fault; however, there are some overlaps between the different conditions, which can produce uncertainty and, consequently, misclassification. In order to automate the diagnosis process and improve the classification accuracy, a pattern recognition algorithm is proposed. In this regard, two different classifiers, i.e., ANN and SVM, are tested to detect and classify the early SCT fault. These classifiers are applied to both contrast definitions: Unser and Tamura. The application of both classifiers helps to compare their performance, selecting the best method and obtaining the highest classification accuracy. To obtain the parameters of the classifiers that achieve more accurate results, an exhaustive analysis in a trial-and-error process is carried out, i.e., the algorithms with different parameters are applied and the parameters with the best results are selected. In addition, for both classifiers, the training and validation processes are carried out using the k -fold validation, where k is set to 5 due to the number of samples. Figure 9 shows the accuracy percentage for each k -fold iteration and Table 3 shows their mean (μ).




Figure 9. Accuracy results for the ANN and SVM methods during the k-fold validation.

Table 3. Accuracy percentage mean (μ) for the ANN and SVM classifiers by considering different contrast estimation methods.

| | Unser with $d = 15$ | Tamura |
|---------|---------------------|--------|
| ANN (%) | 89.78 | 86.38 |
| SVM (%) | 86.1 | 85.96 |

As can be seen in Table 3, the ANN for Unser contrast has the best performance among the classifiers, i.e., 89.78%. The parameters that provide the accuracy previously mentioned in the ANN configuration are: one neuron as input, two hidden layers with 5 and 25 neurons, respectively, and three neurons in the output layer. The activation functions are log-sigmoid for all the layers. The difference with the ANN used for the Tamura contrast is that in its first hidden layer there are ten neurons, i.e., the hidden layers are of 10 and 25 neurons. On the other hand, when a SVM classifier is employed, the parameters with the most significant influence on the classification accuracy are the kernel scale, δ , and the penalty function, C , [34]. Consequently, the resulting SVM parameters (δ , C) for the Unser contrast are 0.03 and 25, respectively. The parameter d for the Unser contrast definition also changes for the SVM, taking the value of 25. For the Tamura contrast, the SVM parameters (δ , C) are 0.4 and 35, respectively.

Table 4 shows the confusion matrix for the k-fold validation when $k = 1$ (see Figure 9), in which 91.7% of effectiveness is obtained. It is worth noting that 16 tests, i.e., 20%, from the 80 available tests are used for the testing. In these results, the healthy condition is clearly identified; however, the 1 and 2 SCTs conditions present two errors. These values represent for the healthy condition (0 SCTs) a recall and a specificity of 1, which is a perfect score to diagnose the healthy condition. Despite these results, the effectiveness that is considered corresponds to the average obtained during the k-fold validation, i.e., 89.78%.

Table 4. Confusion matrix for SCTs classification.

| SCTs | 0 | 1 | 2 | |
|----------|------|-------|-------|-----------------|
| 0 | 16 | 0 | 0 | |
| 1 | 0 | 14 | 2 | |
| 2 | 0 | 2 | 14 | |
| Accuracy | 100% | 87.5% | 87.5% | Average = 91.7% |

5. Discussion

After designing and validating the proposal by using experimental data, two major advantages are observed: (i) its sensitivity to early SCT faults (i.e., it can react to little changes in the vibration patterns) and (ii) its robustness to the load changes (i.e., the contrast index barely changes when different load conditions appear).

Table 5 shows a comparison between the proposal and other works reported in the literature. Although in [28] an early fault condition is presented, it does not report a pattern recognition algorithm for automatic diagnosis unlike the proposed work that implements a neural network with 89.78% of effectiveness. In [20,35], different severity levels of SCT fault are analyzed; however, the impact of the load in the transformer is not taken into account, which compromises and limits their practical application. On the contrary, the proposal is tested under four load conditions: (i) no load, (ii) linear load, (iii) nonlinear load, and (iv) both linear and nonlinear loads. On the other hand, the works presented in [17,36] also demonstrate that vibration signals can provide information to detect faults in windings; however, the analysis of different fault severities and their automatic detection are not presented. Finally, from the works presented in Table 5, the proposal can be considered as the lowest complex method since the contrast index in the time domain is only required to process the VA signal.

Although promising results have been obtained, some opportunities of research still remain. For instance, in this work, the tests are carried out in a controlled environment; therefore, real operating conditions such as load intermittences, power quality issues, vibrations generated by other faults, and vibrations from external sources, among others, can negatively affect the performance of the proposal. In this regard, the obtained results can be considered as preliminary.

Table 5. Comparison of the proposed work and other methods.

| Work | Method | Signal | Fault Detected in Windings | Early Detection/Severities (SCTs) | Load Conditions | Automatic Classification |
|---------------|----------------------------------------------------------------------------------------|------------|----------------------------|-----------------------------------|-----------------|-------------------------------------------------|
| Proposed Work | Contrast index | Vibrations | SCTs | Yes 1,2 | 4 | ANN |
| [17] | Empirical Wavelet transform, HT, and entropies | Vibrations | Winding deformation | No | - | - |
| [20] | Fractal algorithms, ANOVA, Data mining | Vibrations | SCTs | No 5, 10, ..., 35 | No load | Decision trees, Naïve Bayes, k-nearest neighbor |
| [28] | FFT and total harmonic distortion | Vibrations | SCTs | Yes Initiation | 1 | - |
| [35] | Complete ensemble empirical mode decomposition, Shannon entropy, RMS, and energy index | Current | SCTs | No 5, 10, ..., 40 | - | - |
| [36] | Short time Fourier transform and RMS | Vibrations | Winding loosening | No | 1 | - |

- Not mentioned.

6. Conclusions

This paper presents a methodology for detecting and classifying the transformer condition under different early SCT fault conditions (i.e., 1 and 2 SCTs) from its VA signals. To develop, validate, and test the methodology, a transformer capable of emulating the conditions previously mentioned is used, where different load conditions (no load, linear

load, nonlinear load, and both loads) are considered to represent a more realistic scenario and open the possibility to offer an online fault detection method.

In this regard, the main findings are:

- The proposed method can diagnose early SCT fault conditions, i.e., 0, 1, and 2 SCTs. Detection of early SCT faults helps to increase the transformer life, reduce the break-down maintenance, and avoid possible catastrophic failures.
- One image processing feature used for the texture analysis, i.e., the contrast, allows characterizing the variations in a VA signal to detect early SCTs in a transformer.
- Two contrast definitions, i.e., Unser and Tamura, are tested, where the Unser definition with $d = 15$ demonstrated to provide the best results.
- The contrast measure is unaffected by the different load combinations connected to the transformer, when early SCTs are present.
- The classification effectiveness from both the Unser contrast definition and the ANN as classifier (i.e., 89.78%) is higher than the one obtained by the SVM (i.e., 86.1%). The Tamura contrast definition with an ANN obtained 86.38% of effectiveness and with a SVM 85.96% of effectiveness.

Forthcoming work will focus on employing the methodology to diagnose three-phase transformers under different operation conditions, e.g., under unbalance and harmonic content in the power supply, including different types of loads and other faults such as core faults, partial discharges, and winding loosening, among others. In addition, the combination of other signal preprocessing techniques, statistical time features, and pattern recognition algorithms, as well as the fusion of sensors, i.e., the information provided by different types of signals, e.g., current and voltage signals, to improve the fault detection and classification accuracy will be also explored.

Author Contributions: Conceptualization, J.R.H.-R. and M.V.-R.; methodology and software, J.R.H.-R. and M.V.-R.; investigation, validation, and formal analysis, all authors; data curation, J.R.H.-R., D.G.-L. and M.B.-L.; writing—original draft preparation, J.R.H.-R. and M.V.-R.; writing—review and editing, all authors; visualization, A.G.-P. and M.V.-R.; supervision, D.G.-L., J.P.A.-S. and M.V.-R.; project administration, D.G.-L., M.B.-L. and M.V.-R.; resources, funding acquisition, A.G.-P., J.P.A.-S., M.B.-L. and M.V.-R. All authors have read and agreed to the published version of the manuscript.

Funding: This research received no external funding.

Data Availability Statement: The data presented in this study are not publicly available due to privacy issues.

Acknowledgments: This work was partially supported by the Mexican Council of Science and Technology (CONACyT) by the scholarship 734987.

Conflicts of Interest: The authors declare no conflict of interest.

References

1. Kudelina, K.; Asad, B.; Vaimann, T.; Rassõlkin, A.; Kallaste, A.; Van Khang, H. Methods of Condition Monitoring and Fault Detection for Electrical Machines. *Energies* **2021**, *14*, 7459. <https://doi.org/10.3390/en14227459>.
2. Huerta-Rosales, J.R.; Granados-Lieberman, D.; Amezcua-Sanchez, J.P.; Camarena-Martinez, D.; Valtierra-Rodriguez, M. Vibration Signal Processing-Based Detection of Short-Circuited Turns in Transformers: A Nonlinear Mode Decomposition Approach. *Mathematics* **2020**, *8*, 575. <https://doi.org/10.3390/math8040575>.
3. Secic, A.; Krpan, M.; Kuzle, I. Vibro-Acoustic Methods in the Condition Assessment of Power Transformers: A Survey. *IEEE Access* **2019**, *7*, 83915–83931. <https://doi.org/10.1109/ACCESS.2019.2923809>.
4. Zhao, Z.; Tang, C.; Chen, Y.; Zhou, Q.; Yao, C.; Islam, S. Interpretation of Transformer Winding Deformation Fault by the Spectral Clustering of FRA Signature. *Int. J. Electr. Power Energy Syst.* **2021**, *130*, 106933. <https://doi.org/10.1016/j.ijepes.2021.106933>.
5. Granados-Lieberman, D.; Razo-Hernandez, J.R.; Venegas-Rebollar, V.; Olivares-Galvan, J.C.; Valtierra-Rodriguez, M. Harmonic PMU and Fuzzy Logic for Online Detection of Short-Circuited Turns in Transformers. *Electr. Power Syst. Res.* **2021**, *190*, 106862. <https://doi.org/10.1016/j.epsr.2020.106862>.

6. Hu, Y.; Zheng, J.; Huang, H. Experimental Research on Power Transformer Vibration Distribution under Different Winding Defect Conditions. *Electronics* **2019**, *8*, 842. <https://doi.org/10.3390/electronics8080842>.
7. Zheng, J.; Huang, H.; Pan, J. Detection of Winding Faults Based on a Characterization of the Nonlinear Dynamics of Transformers. *IEEE Trans. Instrum. Meas.* **2018**, *68*, 206–214. <https://doi.org/10.1109/TIM.2018.2838178>.
8. Kim, M.; Lee, S. Power Transformer Voltages Classification with Acoustic Signal in Various Noisy Environments. *Sensors* **2022**, *22*, 1248. <https://doi.org/10.3390/s22031248>.
9. Zhou, Y.; Wang, B. Acoustic Multi-Parameter Early Warning Method for Transformer DC Bias State. *Sensors* **2022**, *22*, 2906. <https://doi.org/10.3390/s22082906>.
10. Contreras-Valdes, A.; Amezcua-Sanchez, J.P.; Granados-Lieberman, D.; Valtierra-Rodriguez, M. Predictive Data Mining Techniques for Fault Diagnosis of Electric Equipment: A Review. *Appl. Sci.* **2020**, *10*, 950. <https://doi.org/10.3390/app10030950>.
11. Bartoletti, C.; Desiderio, M.; Di Carlo, D.; Fazio, G.; Muzi, F.; Sacerdoti, G.; Salvatori, F. Vibro-Acoustic Techniques to Diagnose Power Transformers. *IEEE Trans. Power Deliv.* **2004**, *19*, 221–229. <https://doi.org/10.1109/TPWRD.2003.820177>.
12. Romero-Troncoso, R.D.J. Multirate Signal Processing to Improve FFT-Based Analysis for Detecting Faults in Induction Motors. *IEEE Trans. Ind. Inform.* **2017**, *13*, 1291–1300. <https://doi.org/10.1109/TII.2016.2603968>.
13. Borucki, S.; Cichoń, A.; Majchrzak, H.; Zmarzły, D. Evaluation of the Technical Condition of the Active Part of the High Power Transformer Based on Measurements and Analysis of Vibroacoustic Signals. *Arch. Acoust.* **2017**, *42*, 313–320. <https://doi.org/10.1515/aoa-2017-0033>.
14. Valtierra-Rodriguez, M.; Rivera-Guillen, J.R.; Basurto-Hurtado, J.A.; Jesus De-Santiago-Perez, J.; Granados-Lieberman, D.; Amezcua-Sanchez, J.P. Convolutional Neural Network and Motor Current Signature Analysis during the Transient State for Detection of Broken Rotor Bars in Induction Motors. *Sensors* **2020**, *20*, 3721. <https://doi.org/10.3390/s20133721>.
15. Goyal, D.; Pabla, B.S. The Vibration Monitoring Methods and Signal Processing Techniques for Structural Health Monitoring: A Review. *Arch. Comput. Methods Eng.* **2016**, *23*, 585–594. <https://doi.org/10.1007/s11831-015-9145-0>.
16. Borucki, S.; Cichon, A. Wavelet Analysis of Vibroacoustic Signals Registered during the Transformer Start-Up. In Proceedings of the IEEE 2012 International Conference on High Voltage Engineering and Application, Shanghai, China, 17–20 September 2012; pp. 579–582.
17. Zhao, M.; Xu, G. Feature Extraction of Power Transformer Vibration Signals Based on Empirical Wavelet Transform and Multiscale Entropy. *IET Sci. Meas. Technol.* **2018**, *12*, 63–71. <https://doi.org/10.1049/iet-smt.2017.0188>.
18. Wu, X.; Li, L.; Zhou, N.; Lu, L.; Hu, S.; Cao, H.; He, Z. Diagnosis of DC Bias in Power Transformers Using Vibration Feature Extraction and a Pattern Recognition Method. *Energies* **2018**, *11*, 1775. <https://doi.org/10.3390/en11071775>.
19. Amezcua-Sanchez, J.P.; Adeli, H. A New Music-Empirical Wavelet Transform Methodology for Time-Frequency Analysis of Noisy Nonlinear and Non-Stationary Signals. *Digit. Signal Process. A Rev. J.* **2015**, *45*, 55–68. <https://doi.org/10.1016/j.dsp.2015.06.013>.
20. Valtierra-Rodriguez, M. Fractal Dimension and Data Mining for Detection of Short-Circuited Turns in Transformers from Vibration Signals. *Meas. Sci. Technol.* **2020**, *31*, 025902. <https://doi.org/10.1088/1361-6501/ab48ac>.
21. Huerta-Rosales, J.R.; Granados-Lieberman, D.; Garcia-Perez, A.; Camarena-Martinez, D.; Amezcua-Sanchez, J.P.; Valtierra-Rodriguez, M. Short-Circuited Turn Fault Diagnosis in Transformers by Using Vibration Signals, Statistical Time Features, and Support Vector Machines on Fpga. *Sensors* **2021**, *21*, 3958. <https://doi.org/10.3390/s21113598>.
22. Zhang, Z.; Wu, Y.; Zhang, R.; Jiang, P.; Liu, G.; Ahmed, S.; Dong, Z. Novel Transformer Fault Identification Optimization Method Based on Mathematical Statistics. *Mathematics* **2019**, *7*, 288. <https://doi.org/10.3390/math7030288>.
23. Chen, J.; Yu, W.; Tian, J.; Chen, L.; Zhou, Z. Image Contrast Enhancement Using an Artificial Bee Colony Algorithm. *Swarm Evol. Comput.* **2018**, *38*, 287–294. <https://doi.org/10.1016/j.swevo.2017.09.002>.
24. Cai, J.; Gu, S.; Zhang, L. Learning a Deep Single Image Contrast Enhancer from Multi-Exposure Images. *IEEE Trans. Image Process.* **2018**, *27*, 2049–2062. <https://doi.org/10.1109/TIP.2018.2794218>.
25. Ferrucho-Alvarez, E.R.; Martinez-Herrera, A.L.; Cabal-Yepez, E.; Rodriguez-Donate, C.; Lopez-Ramirez, M.; Mata-Chavez, R.I. Broken Rotor Bar Detection in Induction Motors through Contrast Estimation. *Sensors* **2021**, *21*, 7446. <https://doi.org/10.3390/s21227446>.
26. Wu, Y.; Zhang, Z.; Xiao, R.; Jiang, P.; Dong, Z.; Deng, J. Operation State Identification Method for Converter Transformers Based on Vibration Detection Technology and Deep Belief Network Optimization Algorithm. *Actuators* **2021**, *10*, 1–32. <https://doi.org/10.3390/act10030056>.
27. Zhang, F.; Ji, S.; Shi, Y.; Zhan, C.; Zhu, L. Investigation on Vibration Source and Transmission Characteristics in Power Transformers. *Appl. Acoust.* **2019**, *151*, 99–112. <https://doi.org/10.1016/j.apacoust.2019.03.011>.
28. Bagheri, M.; Nezhivenko, S.; Naderi, M.S.; Zollanvari, A. A New Vibration Analysis Approach for Transformer Fault Prognosis over Cloud Environment. *Int. J. Electr. Power Energy Syst.* **2018**, *100*, 104–116. <https://doi.org/10.1016/j.ijepes.2018.02.026>.
29. García, B.; Burgos, J.C.; Alonso, Á.M. Transformer Tank Vibration Modeling as a Method of Detecting Winding Deformations—Part I: Theoretical Foundation. *IEEE Trans. Power Deliv.* **2006**, *21*, 157–163. <https://doi.org/10.1109/TPWRD.2005.852280>.
30. Haralick, R.M.; Shanmugam, K.; Dinstein, I. Textural Features for Image Classification. *IEEE Trans. Syst. Man. Cybern.* **1973**, *SMC-3*, 610–621. <https://doi.org/10.1109/TSMC.1973.4309314>.
31. Unser, M. Sum and Difference Histograms for Texture Classification. *IEEE Trans. Pattern Anal. Mach. Intell.* **1986**, *PAMI-8*, 118–125. <https://doi.org/10.1109/TPAMI.1986.4767760>.

32. Tamura, H.; Mori, S.; Yamawaki, T. Textural Features Corresponding to Visual Perception. *IEEE Trans. Syst. Man. Cybern.* **1978**, *8*, 460–473. <https://doi.org/10.1109/TSMC.1978.4309999>.
33. Amezcua-Sanchez, J.P.; Valtierra-Rodriguez, M.; Camarena-Martinez, D.; Granados-Lieberman, D.; Romero-Troncoso, R.J.; Dominguez-Gonzalez, A. Fractal Dimension-Based Approach for Detection of Multiple Combined Faults on Induction Motors. *J. Vib. Control* **2016**, *22*, 3638–3648. <https://doi.org/10.1177/1077546314565685>.
34. Yang, Z.; Zhou, Q.; Wu, X.; Zhao, Z. A Novel Measuring Method of Interfacial Tension of Transformer Oil Combined PSO Optimized SVM and Multi Frequency Ultrasonic Technology. *IEEE Access* **2019**, *7*, 182624–182631. <https://doi.org/10.1109/ACCESS.2019.2954899>.
35. Mejia-Barron, A.; Valtierra-Rodriguez, M.; Granados-Lieberman, D.; Olivares-Galvan, J.C.; Escarela-Perez, R. The Application of EMD-Based Methods for Diagnosis of Winding Faults in a Transformer Using Transient and Steady State Currents. *Meas. J. Int. Meas. Confed.* **2018**, *117*, 371–379.
36. Borucki, S. Diagnosis of Technical Condition of Power Transformers Based on the Analysis of Vibroacoustic Signals Measured in Transient Operating Conditions. *IEEE Trans. Power Deliv.* **2012**, *27*, 670–676.

Anexo D: Artículo de congreso internacional

Detection of Short-Circuited Turns in Transformer Vibration Signals using MUSIC-Empirical Wavelet Transform and Fractal Dimension

Jose R. Huerta-Rosales, Martin Valtierra-Rodriguez*, Juan P. Amezcua-Sanchez.

ENAP-Research Group, CA-Sistemas Dinámicos y Control.

Facultad de Ingeniería, Universidad Autónoma de Querétaro (UAQ), Campus San Juan de Río. San Juan del Río, Querétaro, México.

*martin.valtierra@enap-rg.org

David Granados-Lieberman.

ENAP-Research Group, CA-Fuentes Alternas y Calidad de la Energía Eléctrica, Departamento de Ingeniería Electromecánica.

Tecnológico Nacional de México, Instituto Tecnológico Superior de Irapuato (ITESI). Irapuato, Guanajuato, México.

Abstract—In electrical systems, the transformers have an important role; therefore, their correct operation is fundamental. However, they can present malfunctions due to different types of faults. The short-circuited turns (SCTs) are one of the main causes of transformer damages, which can scale into most serious faults. In this regard, there are several works in literature to diagnose this type of fault through the analysis of vibration signals. In this work, the vibration signals are analyzed to diagnose the transformer condition; however, the analysis of a vibration signal with no relevant information and a high level of noise is not a simple task. In this work, the problem is addressed using the MUSIC-empirical wavelet transform (MEWT). This technique allows extracting the relevant features from vibration signals. Additionally, three fractal dimension algorithms (FDAs): Katz, Sevcik, and Petrosian, are proposed and investigated as potential fault indicators. To test the proposed methodology, a modified transformer to emulate different SCTs fault conditions is used. These conditions are healthy, 5, 10, and 15 SCTs. The results show that MEWT removes properly noise and irrelevant information, allowing the identification of the fault condition using the FDAs as indicators.

Keywords—vibration signals; transformer; short-circuit; MUSIC; empirical wavelet transform.

I. INTRODUCTION

The transformer is a key element in an electrical network. Although the transformer is a robust machine that can keep working even when they suffer a failure, it is not exempt from breakdowns and severe failures. The failure in a transformer could be catastrophic and could have a significant economic impact. Hence, it is necessary to keep it active and in a continuous monitoring. There are different types of faults such as winding and core deformations, broken clamping structures, short-circuited turns, among others [1]. The fault type of most considerable interest for researchers has been the winding fault because this represents around 30%–50% of the combined faults in a transformer [2]. The early detection allows minimizing the negative effects in the transformer windings. There are several techniques to perform the transformer

monitoring such as: dissolved gas analysis (DGA), power factor, frequency response analysis (FRA), vibration analysis (VA), among others [3]. The use of VA has become an effective technique to obtain excellent results in terms of accuracy, where the major benefit is the direct relation among vibration signals and the winding mechanical performance [4].

The feature extraction from vibration signals has been a common technique to observe the behavior of the transformer. The features can be in the time, frequency, or time-frequency domains. They can be linear or non-linear. In time-domain, the use of statistical features and fractal dimension algorithms (FDA) can be a promising tool. Meanwhile, in frequency domain, the conventional tool to extract features is the Fourier transform (FT), but its principal drawback is the analysis from signals with nonstationary behavior. The short time Fourier transform (STFT) and wavelet transform (WT) are widely employed for analyzing signals in the time-frequency domain. Nevertheless, accurately computing of the STFT is not an ordinary function because there is a trade-off between frequency and time resolution, this must be adequately determined, which represents a complex labor for signals with unknowing behavior. In addition, due to the fixed window size, the STFT is unable for describing the instantaneous frequencies. These limitations are addressed by the WT which uses a time-frequency representation (TFR) to describe signals with a non-linear and non-stationary behavior. A WT disadvantage is the dependence of the selection of the mother wavelet and the decomposition level, consequently, it cannot estimate the instantaneous frequencies effectively. Over the past few years, Gilles [5] introduced the empirical wavelet transform (EWT), which provides a TFR from nonlinear and non-stationary signals, decomposing the time signal according to frequency information contained in the signal. Unfortunately, the EWT provides inaccurate estimations of the signal when it presents high noise levels. To overcome this disadvantage, Amezcua and Adeli [6] proposes the MUSIC-Empirical Wavelet Transform (MEWT) which improves the methodology to select the band boundaries and thus avoid noise and irrelevant information.

In this work, a methodology to detect different SCTs levels in a transformer is presented. As the first step, the MEWT is implemented as filter in vibration signals to eliminate the irrelevant information and preserve the frequential content in time domain. Furthermore, the FDAs such as: Katz, Sevcik, and Petrosian algorithms are used as fault indicators to describe the behavior of the vibration signal and, consequently, differentiate between a healthy and anomalous transformer. At that point, the variance analysis (ANOVA) is applied to the FDAs to select the most adequate features that allows distinguishing between diverse conditions of failure. To examine the approach proposed in a real situation, an adapted transformer able to emulate several SCT fault conditions is used. The range of fault is zero, five, 10, and 15 SCTs, where 0 SCTs is the healthy condition. The results demonstrate the capability of MEWT to extract unwanted information allowing getting better measures in FDAs than the one obtained from pure vibration signals, showing the possibility of classifying a transformer under fault conditions.

II. THEORETICAL BACKGROUND

A. Vibration Signals

The vibration signals are generated in the windings and core of a transformer. The core vibrations are principally created by the magnetostriction phenomenon. The magnetostriction occurs when a magnetic field changes the dimensions of ferromagnetic materials. The forces of the phenomenon are proportional to voltage squared and perpendicular to the core [7] as:

$$F_{core} \propto V^2 \quad (1)$$

On the other hand, the vibration in windings is by the electrodynamic forces due to the interaction of the current with the remnant flux. These forces are proportional to current squared and produce components in axial and radial directions [8].

$$F_{winding} \propto I^2 \quad (2)$$

B. MUSIC-Empirical Wavelet Transform

The MEWT is based on the (EWT) but has the advantage to be adaptive and capable to extracting the frequential content of a time series signal by avoiding noise [6]. The main idea is to divide in N segments the frequency domain to build a filter bank of low-pass (LPF) and band-pass filters (BPF) as shown in Fig 1. Next, take the segments in which the frequential content is relevant, avoiding noise and unwanted frequency content. The complete MEWT algorithm is described as:

1. Use the MUSIC algorithm for analyzing the signal and obtain the contained frequencies.
2. The pseudospectrum is plotted in the frequency range from 0 to π to be compatible with EWT.




Fig 1. EWT basis construction.

3. Determine all local maxima of the MUSIC pseudospectrum and determine the lowest minima m_n back and forth of each maximum.
4. To avoid frequency bands with no relevant information, two neighboring minima or two consecutive minima are averaged to obtain new minima, nm_n . If the distance d between the two consecutive minima is less or equal to a predefined fixed value ν , the neighboring minima are averaged:

$$nm_n = \frac{m_n + m_{n+1}}{2} \Rightarrow \text{if } d \leq \nu \quad (3)$$

$$(d = m_{n+1} - m_n) \text{ for } 2 \leq n+2 \leq N-2$$

where n is the segment of N total segments that divide the pseudospectrum.

5. Using the estimated boundaries, build the empirical wavelet filter bank, which consist of one low-pass $\phi_n(\omega)$ and $N-1$ band-pass $\psi_n(\omega)$ filters as follows:

$$\phi_n(\omega) = \begin{cases} 1 & \text{if } |\omega| \leq \omega_n - \tau_n \\ \cos \left[\frac{\pi}{2} \beta \left(\frac{1}{2\tau_n} (|\omega| - \omega_n + \tau_n) \right) \right] & \text{if } \omega_n - \tau_n \leq |\omega| \\ 0 & \text{otherwise} \end{cases} \quad (4)$$

$$\psi_n(\omega) = \begin{cases} 1 & \text{if } \omega_n + \tau_n \leq |\omega| \leq \omega_{n+1} - \tau_{n+1} \\ \cos \left[\frac{\pi}{2} \beta \left(\frac{1}{2\tau_{n+1}} (|\omega| - \omega_{n+1} + \tau_{n+1}) \right) \right] & \text{if } \omega_{n+1} - \tau_{n+1} \leq |\omega| \leq \omega_{n+1} + \tau_{n+1} \\ \sin \left[\frac{\pi}{2} \beta \left(\frac{1}{2\tau_n} (|\omega| - \omega_n + \tau_n) \right) \right] & \text{if } \omega_n - \tau_n \leq |\omega| \leq \omega_n + \tau_n \\ 0 & \text{otherwise} \end{cases} \quad (5)$$

where $\beta(x)$ represents an arbitrary polynomial function with values in the range $[0,1]$ with the properties of Equation (4).

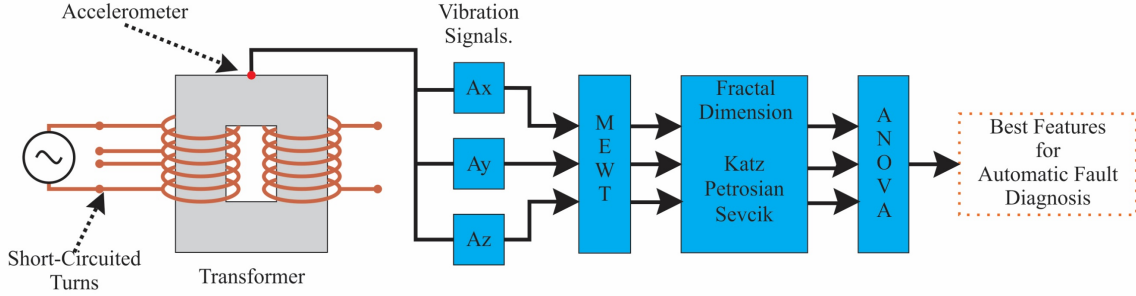


Fig 2. Proposed diagnosis methodology.

- Decompose the signal into different frequency bands using EWT with the polynomial of equation (5) which is proposed by Amezcua and Adeli [6].

$$\beta(x) = \begin{cases} 0 & \text{if } x < 0 \\ \text{and } \beta(x) + \beta(x-1) = 1 & x \in [0, 1] \\ 1 & \text{if } x \geq 1 \end{cases} \quad (6)$$

$$\beta(x) = x^4 (35 - 85x + 70x^2 - 20x^3) \quad (7)$$

- Apply the Hilbert transform to obtain a TFR from the calculated bands.

$$W_f^e(0, t) = F^{-1}(x(\omega)\varphi_n(\omega)) \quad (8)$$

$$W_f^e(n, t) = F^{-1}(x(\omega)\psi_n(\omega))$$

C. Fractal Dimension

The fractal dimension (FD) provides a self-similarity measure of a time series, which denotes to how many times a pattern in the signal is repeated [9]. In this regard, the FD can be employed to observe and quantify changes in waveforms. Applying FDAs to vibration signals from a transformer under SCT, it is possible detect changes in the FD values. These changes can be detected due to the alteration in the frequency content, principally in the harmonic content. At the time, the obtained FD values can be used as indicators to determine the operating condition of the source [10]. The proposed FD algorithms to use as indicators are Katz, Sevcik, and Petrosian algorithms, described as follows [11]:

1) *Katz Algorithm*: For a signal ordered as a set of (x_i, y_i) of N point pairs, the FD algorithm is computed as:

$$D = \frac{\log(N)}{\log(N) + \log\left(\frac{d}{L}\right)} \quad (9)$$

where L is the length of the waveform and d is the maximum distance between the initial point and the other ones and it is defined as:

$$L = \sum_{i=0}^{N-2} \sqrt{(y_{i+1} - y_i)^2 + (x_{i+1} - x_i)^2} \quad (10)$$

$$d = \max(\sqrt{x_i^2 - x_1^2})$$

2) *Sevcik Algorithm*: In the same way, supposing the signal is composed of a series of points (x_i, y_i) , the length of the signal is N . First the signal must be normalized:

$$x_i^* = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}}, y_i^* = \frac{y_i - y_{\min}}{y_{\max} - y_{\min}} \quad (11)$$

where x_{\min} and y_{\min} are the minimum values of the series x_i, y_i and x_{\max} and y_{\max} its maximum values. Then, the FD is computed as:

$$D = 1 + \frac{\ln(l) + \ln(2)}{\ln[2 \times (N - 1)]} \quad (12)$$

and

$$L = \sum_{i=0}^{N-2} \sqrt{(y_{i+1}^* - y_i^*)^2 + (x_{i+1}^* - x_i^*)^2} \quad (13)$$

3) *Petrosian Algorithm*: Supposing the signal is composed of a serie of points $\{y_1, y_2, \dots, y_N\}$, binarize the sequence first, and the set binary matrix z_i is

$$z_i = \begin{cases} 1, & x_i > \text{mean}(y) \\ -1, & x_i \leq \text{mean}(y) \end{cases} \quad (14)$$

Then, find the total number of adjacent symbol changes in the sequence:

$$N_{\Delta} = \sum_{i=1}^{N-2} \left| \frac{z_{i+1} - z_i}{2} \right| \quad (15)$$

The Petrosian FD is computed as follows:

$$D = \frac{\log_{10}(N)}{\log_{10}(N) + \log_{10}\left(\frac{N}{N + 0.4N_{\Delta}}\right)} \quad (16)$$

III. METHODOLOGY

The Fig. 2 shows methodology proposed in this work. A single-phase transformer operates in rated conditions and can emulate diverse fault configurations: healthy, 5, 10, and 15 SCTs. Vibration signals in steady state are acquired from the transformer with no load using a triaxial accelerometer. 20 signals are acquired for each fault configuration in all axes, resulting in 80 signals by axis. Subsequently, the vibration signals (V_x, V_y, V_z) are processed using the MEWT to filter the noise and irrelevant information. The FDAs are applied to the three axes yielding three features by axis and resulting in a

total data set of 80×9 . Finally, the data points are analyzed, employing the analysis of variance (ANOVA) to observe the separability of them. This allows selecting the FDAs capable to describe and distinguish between the different transformer operating conditions.

IV. EXPERIMENTATION AND RESULTS

A. Experimental Setup

The proposal is assessed with the experimental setup shown in Fig. 3. A single-phase transformer operated at 120 V is used. The transformer was modified to emulate different SCTs faults in its the secondary winding. To measure the vibration signals from the transformer a 3-axial accelerometer is used.

For receiving the core and winding vibrations, the accelerometer is located upper on the center of the core. The accelerometer is an 8395A model from KISTLER, measuring $\pm 10g$ with a resolution of 400 mV/g over a bandwidth of 1000 Hz. To acquire the vibrations a data acquisition system (DAS) based on the NI-USB 6211 board for National Instruments is used. The DAS uses a 16-bit analog-to-digital converter with a sampling frequency of 7.8 ksamples/s. This sampling frequency satisfies the Nyquist theorem for the accelerometer bandwidth and due to the maximum sampling frequency of DAS is 250 ksamples/s the sampling frequency is divided in a power of two for hardware exploiting properties. To start the test and activate the short-circuit fault, two solid-state relays (SAP4050D model) are used.

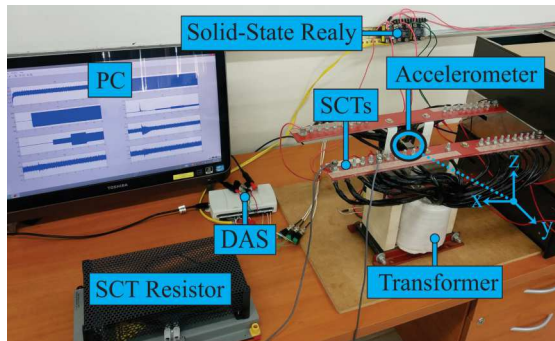


Fig. 3. Experimental Setup.




Fig. 4. Healthy transformer vibration signals.

For each SCT fault condition 20 tests were performed with an acquisition time of 5s, i.e., 39 ksamples acquired in each test. In addition, all the vibration signals are processing in a personal computer employing the Matlab software.

B. Results

The vibration signal acquired from a transformer is shown in Fig. 4. The vibration signal corresponds to the healthy condition for five seconds in steady state. There are regions in the band where the information is not entirely relevant or is simply noise. This information shall be excluded from the analysis.

The frequencies of interest are the harmonics which are the double of the source frequency (60 Hz). The application of MEWT to each vibration signal allows selecting the distinct bands in order to accept or reject them. In Fig. 5, the diverse bands, and their limits around of each harmonic are shown.

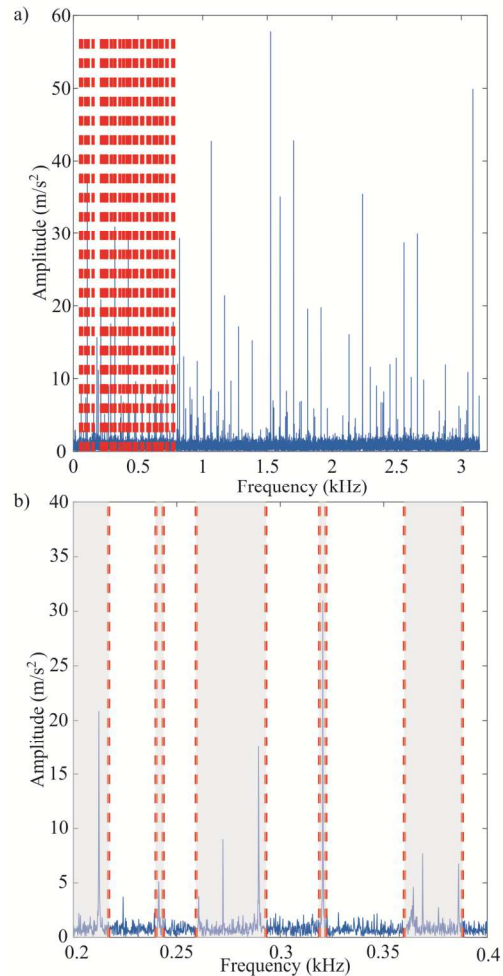


Fig. 5. Boundaries and bands in frequency domain.

In the left side of the Fig. 5a, the boundaries (red-plotted lines) can be defined because the analysis was carried out for values under 1000 Hz. Fig. 5b presents a zoom of Fig. 5a, where the reader can note how the boundaries were selected. They are very close to the principal harmonics. Meanwhile, in

other cases, the band is broader than other ones due to the frequential content. To reconstruct the signal, the selected bands are shaded in gray. In this manner, it can neglect the effects of the noise, focusing on the harmonics exclusively. For each axis, different bands with different boundaries values were selected because the amplitude and vibration components are different in each direction. For x-axis, 31 bands were selected, and 15 bands were used to reconstruct the signal. This procedure was replicated for the y-axis. Meanwhile, z-axis was divided in 33 bands and 16 bands (even bands) were selected to reconstruct the signal. Once the bands have been chosen, the vibration signal without the irrelevant content is reconstructed and the fractal dimension is calculated.

The results of applying the MEWT technique to the vibration signals are shown in Fig. 6. The Fig. 6a shows the comparison of the vibration signal from y-axis before and after to processing it with the MEWT. The difference in the amplitude among the two signals is significative and it can see how the amplitude of the signal is now smoother than the original vibration signal. To observe how the noise and unwanted frequency bands were removed, the spectrum of each signal was computed and plotted in Fig. 7b. The spectrum of the vibration signal from y-axis after to be processed with the MEWT technique (plotted in red) remains its frequential content almost with no change. In addition, it can be seen how the frequencies are isolated and the unwanted regions and noise were eliminated. As abovementioned, the content upper 1000 Hz does not present relevant information; therefore, it was removed for the next step.

For the calculation of the FD, the abovementioned algorithms, i. e., Katz (F1), Sevcik (F2), and Petrosian (F3), are employed. Subsequently, the different values of FD computed are analyzed using the ANOVA analysis. The Fig. 7 shows the ANOVA analysis of the vibration signals with not a processing technique applied to them. The Fig. 7a-c shows the different FD algorithms applied to vibration signals from x-axis, in they can be observed that there is not significant variance between them, i. e., they obtain similar values in vertical axis which avoids classifying them. For y-axis (Fig. 7d-f) and z-axis (Fig. 7g-i) the same phenomena from x-axis occur, i.e., they cannot be identified or differentiated among them due to similar values.

For this reason, the MEWT is applied to reduce the noise and irrelevant information from vibration signals as can be seen in Fig. 6. After MEWT application to the vibration signals, the FD algorithms are computed, and they present better results that previous FD computed. The mean and standard deviation values of each FD computed from all axes and SCT conditions are shown in Table I. The values shaded in gray from Table I show a slight trend that allows separate or differentiate because they do not overlap between them. This equally can be perceived in the ANOVA analysis from Fig. 8, in which can clearly observe the upward trends due to the presence of harmonics in the signal.

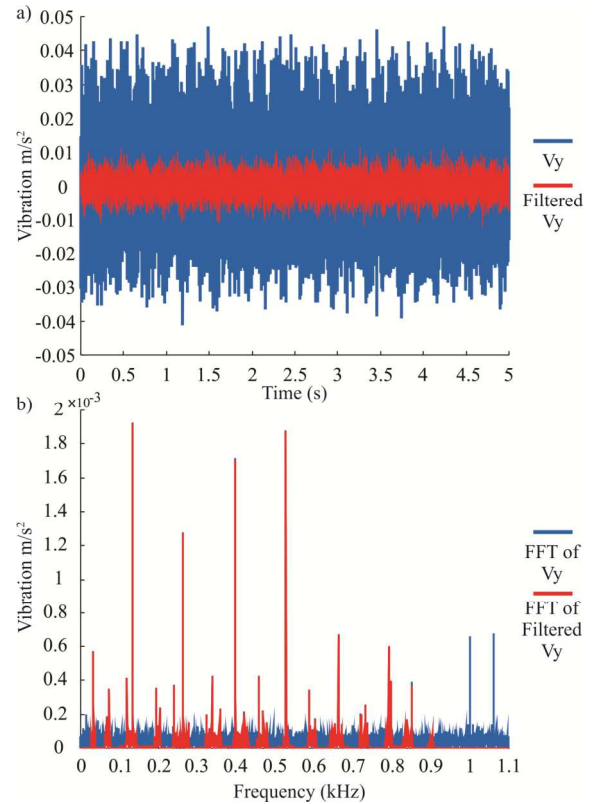


Fig. 6. Vibration signal and its spectrum before and after the MEWT processing a) Vibration from y-axis before MEWT vs. after MEWT, and b) Spectrum from y-axis vibration before MEWT vs. after MEWT.

I. TABLE OF MEANS AND STANDARD DEVIATIONS FROM DIFFERENT FDS FOR DIFFERENT AXIS AND SCTs CONDITIONS.

| Axis and SCT's | | F1 | | F2 | | F3 | |
|----------------|----|--------|----------|--------|----------|--------|----------|
| | | μ | σ | μ | σ | μ | σ |
| Ax | 0 | 1.1582 | 0.0039 | 1.0061 | 0.0004 | 1.7163 | 0.0064 |
| | 5 | 1.1611 | 0.0045 | 1.0059 | 0.00018 | 1.7396 | 0.0049 |
| | 10 | 1.1634 | 0.0020 | 1.0062 | 0.00019 | 1.7374 | 0.0049 |
| | 15 | 1.1638 | 0.0052 | 1.0062 | 0.00015 | 1.7294 | 0.0057 |
| Ay | 0 | 1.1129 | 0.0116 | 1.0045 | 0.00018 | 1.7067 | 0.0056 |
| | 5 | 1.1258 | 0.0102 | 1.0045 | 0.00015 | 1.7044 | 0.0029 |
| | 10 | 1.1062 | 0.0061 | 1.0045 | 0.00028 | 1.7058 | 0.0088 |
| | 15 | 1.1162 | 0.0153 | 1.0047 | 0.00032 | 1.7085 | 0.0061 |
| Az | 0 | 1.1395 | 0.0081 | 1.0052 | 0.00023 | 1.7119 | 0.0052 |
| | 5 | 1.1475 | 0.0066 | 1.0049 | 0.00020 | 1.7156 | 0.0053 |
| | 10 | 1.1430 | 0.0030 | 1.0051 | 0.00008 | 1.7160 | 0.0037 |
| | 15 | 1.1425 | 0.0094 | 1.0053 | 0.00011 | 1.7157 | 0.0052 |

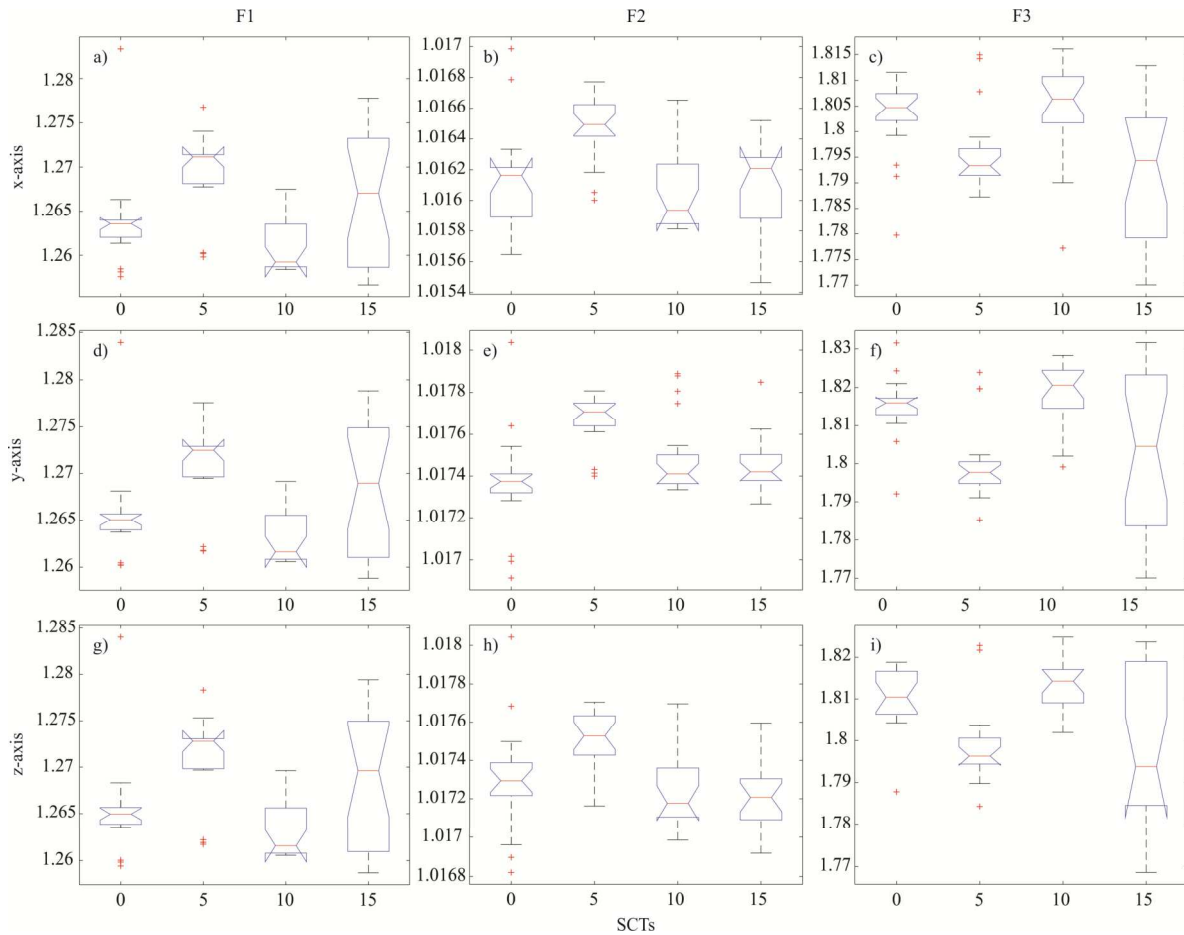


Fig. 7. Variance analysis of fractal dimension applied to vibration signals, a) x-axis with feature F1, b) x-axis with feature F2, c) x-axis with feature F3, d) y-axis with feature F1, e) y-axis with feature F2, f) y-axis with feature F3, g) z-axis with feature F1, h) z-axis with feature F2, and i) z-axis with feature F3.

In the Fig. 8a and Fig. 8c for x-axis, Fig. 8d for y-axis and Fig. 8i for z-axis, the trend is clearly rising unlike vibration signals without preprocessing. Although a practical classification between each condition is not totally clear, the identification between the healthy and fault conditions can be carried out. For instance, a simple if-else-then rule can be applied to determine a fault condition through the set of a threshold value (see the red dot lines in Fig. 8) or a more sophisticated classifier (e.g., neural networks, fuzzy logic systems, support vector machines, among others) can be implemented.

V. CONCLUSION

To carry out the electrical machine monitoring, the development and application of techniques that properly allow diagnosing the machine are needed. In this regard, a VA-based methodology to detect SCTs in a transformer is presented.

In the first place, the MEWT has a filter behavior, allowing an appropriate selection of the region of interest in the frequency bandwidth. In addition, the MEWT allows taking the cut frequencies close of the interest frequencies and at the same time cancelling the noise. Consequently, the fractal dimension can achieve a more satisfactory performance, as the properties of interest are unobscured by

the unwanted frequency content. It is observed that the measure of fractal indices presents an upward tendency because the harmonic content increase with the fault severity. This allows differentiate between fault conditions.

Finally, the results show the possibility to use the fractal dimension-based algorithms as fault indicators in a transformer. Consequently, the application of a classifier to perform the diagnosis fault in an automatic can be a straightforward process. However, the testing of different classifiers is always needed to obtain the best classification performance.

In a future work, diverse classifiers such as artificial neural networks, support vector machine, fuzzy logic, among others will be explored, allowing to identify and classify the fault condition and its severity. In addition, other indicators will be explored to determine their sensitive to the fault severity. Also, experimenting with a transformer under different operation conditions as various load levels, unbalance in the power supply, among others. This with the continuous employing of vibration signals to exploit its relationship with the mechanical properties of the transformer.

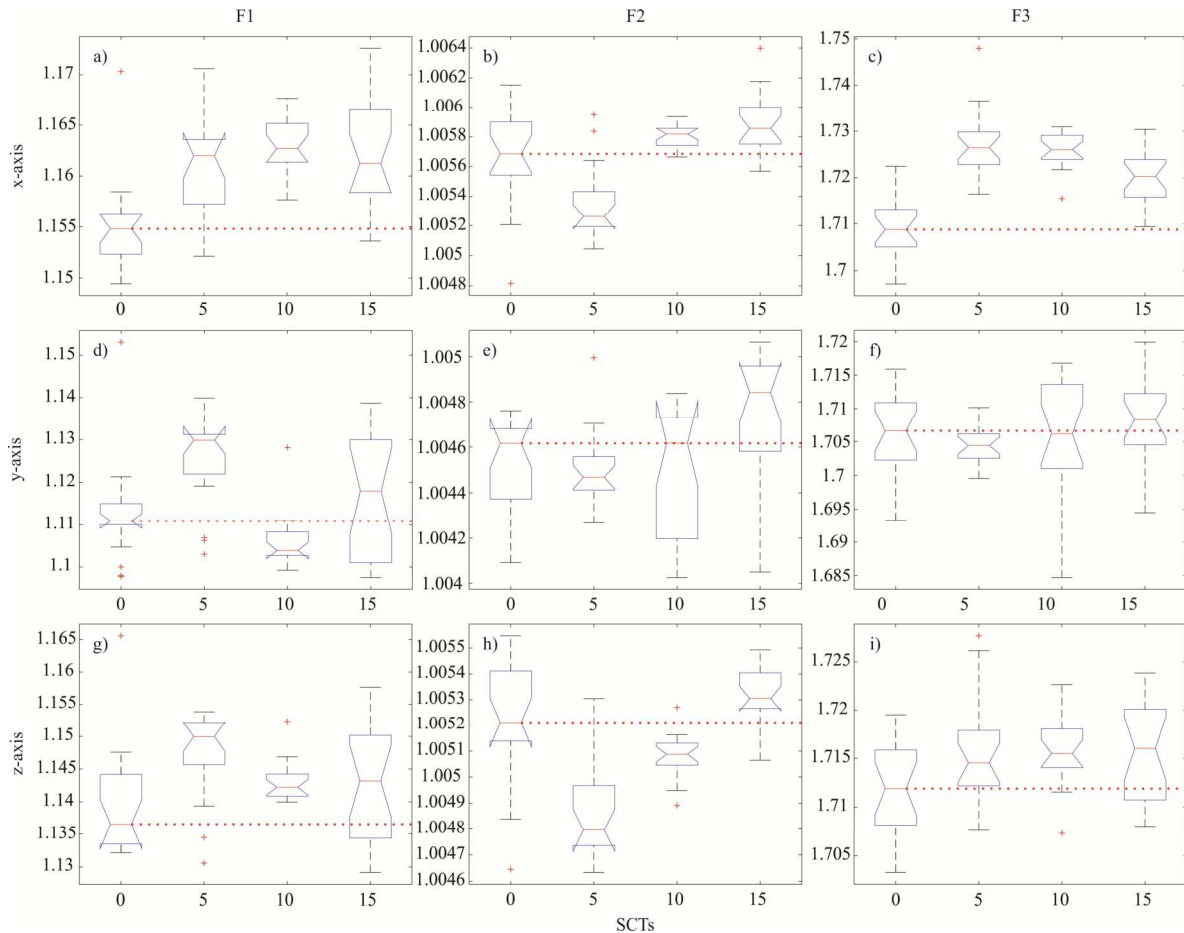


Fig. 8. Variance analysis of fractal dimension applied to vibration signals preprocessed by EWT: a) x-axis with feature F1, b) x-axis with feature F2, c) x-axis with feature F3, d) y-axis with feature F1, e) y-axis with feature F2, f) y-axis with feature F3, g) z-axis with feature F1, h) z-axis with feature F2, and i) z-axis with feature F3.

ACKNOWLEDGMENT

This work was partially supported by the Mexican Council of Science and Technology (CONACyT) through the scholarship 734987.

REFERENCES

- [1] M. Bagheri, M. Naderi, and T. Blackburn, "Advanced transformer winding deformation diagnosis: Moving from off-line to on-line," *IEEE Trans. Dielectr. Electr. Insul.*, vol. 19, no. 6, pp. 1860–1870, 2012.
- [2] J. Zheng, H. Huang, and J. Pan, "Detection of Winding Faults Based on a Characterization of the Nonlinear Dynamics of Transformers," *IEEE Trans. Instrum. Meas.*, vol. 68, no. 1, pp. 206–214, Jan. 2018.
- [3] J. R. Huerta-Rosales, D. Granados-Lieberman, J. P. Amezcua-Sanchez, D. Camarena Martinez, and M. Valtierra-Rodriguez, "Vibration Signal Processing-Based Detection of Short-Circuited Turns in Transformers: A Nonlinear Mode Decomposition Approach," *Mathematics*, vol. 8, no. 4, p. 575, 2020.
- [4] Z. Zhang *et al.*, "Novel Transformer Fault Identification Optimization Method Based on Mathematical Statistics," *Mathematics*, vol. 7, no. 3, p. 288, Mar. 2019.
- [5] J. Gilles, "Empirical wavelet transform," *IEEE Trans. Signal Process.*, vol. 61, no. 16, pp. 3999–4010, 2013.
- [6] J. P. Amezcua-Sanchez and H. Adeli, "A new music-empirical wavelet transform methodology for time-frequency analysis of noisy nonlinear and non-stationary signals," *Digit. Signal Process. A Rev. J.*, vol. 45, pp. 55–68, 2015.
- [7] Hong, K.; Huang, H.; Fu, Y.; Zhou, J. A vibration measurement system for health monitoring of power transformers. *Meas. J. Int. Meas. Confed.* 2016, 93, 135–147, doi:10.1016/j.measurement.2016.07.002.
- [8] B. García, J. C. Burgos, and Á. M. Alonso, "Transformer tank vibration modeling as a method of detecting winding deformations - Part I: Theoretical foundation," *IEEE Trans. Power Deliv.*, vol. 21, no. 1, pp. 157–163, 2006.
- [9] J. P. Amezcua-Sanchez, M. Valtierra-Rodriguez, D. Camarena-Martinez, D. Granados-Lieberman, R. J. Romero-Troncoso, and A. Dominguez-Gonzalez, "Fractal dimension-based approach for detection of multiple combined faults on induction motors," *J. Vib. Control*, vol. 22, no. 17, pp. 3638–3648, Oct. 2016.
- [10] M. Valtierra-Rodriguez, "Fractal dimension and data mining for detection of short-circuited turns in transformers from vibration signals," *Meas. Sci. Technol.*, vol. 31, no. 2, p. 025902, Feb. 2020.
- [11] C. T. Shi, "Signal pattern recognition based on fractal features and machine learning," *Appl. Sci.*, vol. 8, no. 8, 2018.