



UNIVERSIDAD DE GUANAJUATO

DIVISIÓN DE INGENIERÍAS
CAMPUS IRAPUATO-SALAMANCA

“Clasificación de disturbios simples y combinados en redes eléctricas empleando técnicas de análisis espectral avanzado”

TESIS PROFESIONAL

QUE PARA OBTENER EL GRADO DE:

MAESTRÍA EN INGENIERÍA ELÉCTRICA

(INSTRUMENTACIÓN Y SISTEMAS DIGITALES)

PRESENTA:

ING. ARMANDO MEDINA VILLA

ASESORES:

DR. ARTURO GARCÍA PÉREZ

M.I. OSCAR ALMANZA CONEJO

SALAMANCA, GUANAJUATO

MAYO 2024

DEDICATORIA

A mis padres, Sra. Vilma Villa Pereira y Sr. Armando Medina Cruz.

A mi esposa Madglenis Beato Domínguez.

A mis hijas Natali Medina Beato y Melisa Medina Beato.

A mis hermanas Vilma Yaquelin Medina Villa y Tania Medina Villa.

A toda mi familia y amigos cercanos.

En especial a mi madre y hermana Tania que hoy no se encuentran físicamente entre nosotros, las extraño y siempre estarán en mi corazón.

AGRADECIMIENTOS

Quiero expresar mi profunda gratitud a mis padres por su constante apoyo, cuidado y motivación. Aunque mi madre ya no está con nosotros, su impulso me ha traído hasta aquí. Este logro es tanto de ellos como mío, y estoy orgulloso de los excelentes padres que han sido. Siempre estaré agradecido y espero retribuir todo su esfuerzo. A mis hermanas, gracias por su ayuda incondicional y por siempre creer en mí. Los amo a todos.

A mi esposa Magui, por estar siempre presente a lo largo de todo este proceso, por ser mi compañera de vida y de aventuras. Gracias por brindarme tu confianza y apoyo incondicional, por motivarme cada día a seguir adelante en este camino que he elegido, por cuidarme y ayudarme a ser una mejor persona. Te amo profundamente.

A mis queridas hijas Natali y Melisa, gracias por estar siempre a mi lado y formar parte de este logro. Su amor, comprensión y paciencia han sido fundamentales para culminar esta maestría. Este logro también es de ustedes. Las amo con todo mi corazón.

A mi asesor, el Dr. Arturo García Pérez, por estar siempre disponible para ayudarme. Gracias por darme la confianza para trabajar bajo su supervisión, por compartir sus consejos, experiencias y, sobre todo, su tiempo. Gracias por creer en mí, estoy muy agradecido.

A mi co-asesor, el Msc. Oscar Almanza Conejo, por su conocimiento compartido, valiosos consejos y completo apoyo, fundamentales para este proyecto. Aprecio profundamente su enseñanza y la perspectiva única que me proporcionó.

A todos mis profesores en el periodo de maestría, por compartir sus conocimientos conmigo, además de su valioso tiempo, gracias a todos y cada uno de ellos. En especial al Dr. David Camarena Martínez, por su apoyo incondicional.

A todos mis compañeros de la maestría, gracias por su compañerismo y apoyo constante. Su colaboración y ánimo han sido invaluable en este camino. Agradezco las amistades y las experiencias compartidas que han enriquecido esta etapa. Gracias por todo.

AGRADECIMIENTOS INSTITUCIONALES

A la Universidad de Guanajuato, División de Ingenierías Campus Irapuato Salamanca, por cultivar en mí los valores que a caracterizan y por moldearme como una persona íntegra y profesional con aspiraciones de éxito.



Agradezco a la División de Ingenierías del Campus Irapuato Salamanca de la Universidad de Guanajuato por permitirme completar con éxito mi Maestría en Ingeniería Eléctrica. Valorando especialmente la calidad de sus profesores, laboratorios completamente equipados y la excelencia en sus servicios, los cuales siempre respondieron a mis necesidades de manera excepcional.



Al honorable Consejo Nacional de Humanidades Ciencia y Tecnología CONAHCYT por el apoyo brindado con el número de becario 148219 y CVU 1193491, durante los dos años de la maestría.

PREFACIO

En el presente trabajo de tesis, se ha diseñado y desarrollado una metodología que se fundamenta en el procesamiento de señales eléctricas a través de técnicas de tiempo-frecuencia. A partir de modelos matemáticos conocidos, se generan señales eléctricas sintéticas que incorporan disturbios eléctricos. Se emplean métodos de procesamiento digital de señales para identificar perturbaciones eléctricas simples y combinadas. Posteriormente, se realiza un análisis de tiempo-frecuencia para obtener un conjunto de características descriptivas que facilitan la identificación de dichas perturbaciones. Se emplean diversas métricas de evaluación de rendimiento para la clasificación de las perturbaciones en señales eléctricas, basándose en las metodologías de aprendizaje de máquina.

PALABRAS CLAVES: Señales eléctricas, disturbios, características descriptivas, clasificación.

ABSTRACT

In this thesis work, a methodology has been designed and developed that is based on the processing of electrical signals through time-frequency techniques. From known mathematical models, synthetic electrical signals that incorporate electrical disturbances are generated. Digital signal processing methods are used to identify single and combined electrical disturbances. Subsequently, a time-frequency analysis is carried out to obtain a set of descriptive characteristics that facilitate the identification of said disturbances. Various performance evaluation metrics are used for the classification of disturbances in electrical signals, based on machine learning methodologies.

KEYWORDS: Electrical signals, disturbances, descriptive characteristics, classification.

Contenido

1	Capítulo	1
1.1	Introducción.....	1
1.2	Antecedentes.....	2
1.3	Justificación.....	4
1.4	Objetivos	5
1.4.1	Objetivo general	5
1.4.2	Objetivos específicos	5
1.5	Organización de la tesis	6
2	Capítulo	8
2.1	Marco Teórico	8
2.2	Perturbaciones eléctricas	8
2.3	2.2 Características de las perturbaciones eléctricas	9
2.3.1	Señal normal sin perturbaciones.....	9
2.3.2	Interrupción	10
2.3.3	Hueco de tensión	11
2.3.4	Pico de tensión.....	12
2.3.5	Transitorio oscilatorio	13
2.3.6	Armónicos	14
2.3.7	Parpadeo.....	15
2.3.8	Muesca	16
2.3.9	Armónicos con hueco de tensión.....	17
2.3.10	Armónicos con pico de tensión.....	18

2.4	Señal sintética	19
2.5	Procesamiento digital de señales mediante técnicas de análisis espectral	19
2.5.1	Transformada Constante-Q	20
2.5.2	Transformada de Fourier.....	23
2.5.3	Transformada corta de Fourier	25
2.5.4	Transformada Wavelet.....	26
2.5.5	Transformada Wavelet Synchrosqueezing.....	30
2.6	Aprendizaje de máquina.....	31
2.6.1	Máquinas de Soporte Vectorial.	33
2.6.2	Redes Neuronales.	36
3	Capítulo 3.....	43
3.1	Metodología del Proyecto.	43
3.2	Creación de base de datos a partir de modelos matemáticos de las perturbaciones. .	43
3.3	Aplicación de las Técnicas de análisis espectral.	44
3.3.1	Aplicación de la Transformada Constante-Q.....	46
3.3.2	Aplicación de la Transformada de Fourier.....	47
3.3.3	Aplicación de la Transformada Corta de Fourier.	48
3.3.4	Aplicación de la Transformada Wavelet.....	49
3.3.5	Aplicación de la Transformada Wavelet Synchrosqueezing.....	53
3.4	Clasificación de las características obtenidas.....	54
3.4.1	Obtención de características.....	54
3.4.2	Preparación de datos	54
3.4.3	Clasificación con MATLAB	55

3.4.4	Exploración de datos.....	55
3.4.5	Selección de características	55
3.4.6	Esquemas de validación	56
3.4.7	Entrenamiento de modelos	56
3.4.8	Entrenamiento automatizado	56
3.4.9	Evaluación de resultados.....	56
3.4.10	Evaluación del rendimiento	57
3.4.11	Selección del mejor método.....	57
4	Capítulo 4	58
4.1	Pruebas y Resultados	58
4.2	Prueba 1. Técnica transformada constante-Q sin SNR.....	58
4.3	Prueba 2. Técnica transformada constante-Q con 40 dB.....	60
4.4	Prueba 3. Técnica transformada constante-Q con 20 dB.....	62
4.5	Prueba 4. Técnica transformada constante-Q con 10 dB.....	63
4.6	Prueba 5. Técnica transformada de Fourier sin SNR.....	65
4.7	Prueba 6. Técnica transformada de Fourier con 40 dB.....	66
4.8	Prueba 7. Técnica transformada de Fourier con 20 dB.....	68
4.9	Prueba 8. Técnica transformada de Fourier con 10 dB.....	69
4.10	Prueba 9. Técnica transformada corta de Fourier sin SNR	71
4.11	Prueba 10. Técnica transformada corta de Fourier con 40 dB.....	72
4.12	Prueba 11. Técnica transformada corta de Fourier con 20 dB.....	74
4.13	Prueba 12. Técnica transformada corta de Fourier con 10 dB.....	75
4.14	Prueba 13. Técnica transformada Wavelet sin SNR	77

4.15	Prueba 14. Técnica transformada Wavelet con 40 dB	78
4.16	Prueba 15. Técnica transformada Wavelet con 20 dB	80
4.17	Prueba 16. Técnica transformada Wavelet con 10 dB	81
4.18	Prueba 17. Técnica transformada Wavelet Synchrosqueezing sin SNR	83
4.19	Prueba 18. Técnica transformada Wavelet Synchrosqueezing con 40 dB	84
4.20	Prueba 19. Técnica transformada Wavelet Synchrosqueezing con 20 dB	86
4.21	Prueba 20. Técnica transformada Wavelet Synchrosqueezing con 10 dB	87
4.22	Discusión de resultados	93
4.23	Interpretación de los resultados.....	93
4.24	Comparación con otros estudios	94
4.25	Implicaciones de los resultados.....	94
4.26	Fortalezas y limitaciones	94
4.27	Análisis de clases afectadas	95
5	CONCLUSIONES	96
6	REFERENCIAS	98

ÍNDICE DE FIGURAS

Figura 2.1 Señal Normal	10
Figura 2.2 Interrupción.....	11
Figura 2.3 Hueco de tensión.....	12
Figura 2.4 Pico de tensión	13
Figura 2.5 Transitorio Oscilatorio	14
Figura 2.6 Armónicos	15
Figura 2.7 Parpadeo	16
Figura 2.8 Muesca.....	17
Figura 2.9 Armónicos con hueco de tensión	18
Figura 2.10 Armónicos con pico de tensión.....	19
Figura 2.11 Ejemplo de lectura de una señal de audio utilizando 12 bins por octava	23
Figura 2.12 Señal estacionaria y su FT con tres componentes de frecuencia 5Hz, 25 Hz y 50 Hz.....	24
Figura 2.13 Transformada corta de Fourier.....	26
Figura 2.14 Diferentes tipos de Wavelet Madres	27
Figura 2.15 Dominio del tiempo y dominio tiempo-frecuencia producido por la CWT.	29
Figura 2.16 Árbol de resolución de wavelets de tres niveles.	30
Figura 2.17 Dominio del tiempo y dominio tiempo-frecuencia generado por la WSST.	31
Figura 2.18 Máquina de Soporte Vectorial	35
Figura 2.19 Estructura básica de una red neuronal.....	36
Figura 2.20 Función de activación en una neurona artificial	37
Figura 2.21 Red recurrente Hopfield con tres neuronas	38
Figura 3.1 Plan de trabajo realizado	43
Figura 3.2 Obtención de la Transformada Constante-Q	47
Figura 3.3 Obtención de la Transformada Discreta de Fourier	48
Figura 3.4 Obtención de la STFT	49
Figura 3.5 Diagrama de descomposición nivel	50
Figura 3.6 Aplicación de la función wavedec	50
Figura 3.7 Aplicación de la Transformada Wavelet Synchrosqueezing	53

Figura 3.8 Gráfica 3D de las diez perturbaciones al aplicar la STFT.....	55
Figura 3.9 Ambiente de la APP Classification Learner de Matlab.....	57
Figura 4.1 Gráfica de las características varianza vs media de la técnica transformada constante Q.....	59
Figura 4.2 Matriz de confusión del modelo Cubic SVM con la técnica transformada constante Q.....	60
Figura 4.3 Gráfica de las características varianza vs media de la técnica transformada constante Q con un SNR de 40 dB	61
Figura 4.4 Matriz de confusión del modelo Cubic SVM en la técnica transformada constante Q con un SNR de 40 dB.....	61
Figura 4.5 Gráfica de las características varianza vs media de la técnica transformada constante Q con un SNR de 20 dB	62
Figura 4.6 Matriz de confusión del modelo Cubic SVM en la técnica transformada constante Q con un SNR de 20 dB.....	63
Figura 4.7 Gráfica de las características varianza vs media de la técnica transformada constante Q con un SNR de 10 dB	64
Figura 4.8 Matriz de confusión del modelo Medium Neural Network en la técnica transformada constante Q con un SNR de 10 dB	64
Figura 4.9 Gráfica de las características varianza vs media de la técnica transformada de Fourier.....	65
Figura 4.10 Matriz de confusión del modelo Medium Neural Network con la técnica transformada de Fourier	66
Figura 4.11 Gráfica de las características varianza vs media de la técnica transformada de Fourier con SNR de 40 dB	67
Figura 4.12 Matriz de confusión de la transformada de Fourier con SNR de 40dB	67
Figura 4.13 Gráfica de las características varianza vs media de la técnica transformada de Fourier con SNR de 20 dB	68
Figura 4.14 Matriz de confusión del modelo Medium Neural Network en la técnica transformada de Fourier con SNR de 20 dB	69
Figura 4.15 Gráfica de las características varianza vs media de la técnica transformada de Fourier con SNR de 10 dB	70
Figura 4.16 Matriz de confusión del modelo Medium Neural Network en la técnica transformada de Fourier con SNR de 10 dB	70

Figura 4.17 Gráfica de las características varianza vs media de la técnica transformada corta de Fourier	71
Figura 4.18 Matriz de confusión del modelo Wide Neural Network en la técnica transformada corta de Fourier.....	72
Figura 4.19 Gráfica de las características varianza vs media de la técnica transformada corta de Fourier con SNR de 40 dB.....	73
Figura 4.20 Matriz de confusión del modelo Cubic SVM en la técnica transformada corta de Fourier con SNR de 40 dB	73
Figura 4.21 Gráfica de las características varianza vs media de la técnica transformada corta de Fourier con SNR de 20 dB.....	74
Figura 4.22 Matriz de confusión del modelo Medium Neural Network en la técnica transformada corta de Fourier con SNR de 20 dB.....	75
Figura 4.23 Gráfica de las características varianza vs media de la técnica transformada corta de Fourier con SNR de 10 dB.....	76
Figura 4.24 Matriz de confusión del modelo Narrow Neural Network en la técnica transformada corta de Fourier con SNR de 10 dB.....	76
Figura 4.25 Gráfica de las características varianza vs media de la técnica transformada Wavelet	77
Figura 4.26 Matriz de confusión del modelo Narrow Neural Network en la técnica transformada Wavelet	78
Figura 4.27 Gráfica de las características varianza vs media de la técnica transformada Wavelet con SNR de 40 dB.....	79
Figura 4.28 Matriz de confusión del modelo Bagged Trees en la técnica transformada Wavelet con SNR de 40 dB	79
Figura 4.29 Gráfica de las características varianza vs media de la técnica transformada Wavelet con SNR de 20 dB.....	80
Figura 4.30 Matriz de confusión del modelo Bagged Trees en la técnica transformada Wavelet con SNR de 20 dB	81
Figura 4.31 Gráfica de las características varianza vs media de la técnica transformada Wavelet con SNR de 10 dB.....	82
Figura 4.32 Matriz de confusión del modelo Quadratic Discriminant en la técnica transformada Wavelet con SNR de 10 dB	82
Figura 4.33 Gráfica de las características varianza vs media de la técnica transformada Wavelet Sychrosqueezing	83

Figura 4.34 Matriz de confusión del modelo Quadratic SVM en la técnica transformada Wavelet Synchrosqueezing	84
Figura 4.35 Gráfica de las características varianza vs media de la técnica transformada Wavelet Synchrosqueezing con SNR de 40 dB.....	85
Figura 4.36 Matriz de confusión del modelo Bagged Trees en la técnica transformada Wavelet Synchrosqueezing con SNR de 40 dB	85
Figura 4.37 Gráfica de las características varianza vs media de la técnica transformada Wavelet Synchrosqueezing con SNR de 20 dB.....	86
Figura 4.38 Matriz de confusión del modelo Bagged Trees en la técnica transformada Wavelet Synchrosqueezing con SNR de 20 dB	87
Figura 4.39 Gráfica de las características varianza vs media de la técnica transformada Wavelet Synchrosqueezing con SNR de 10 dB.....	88
Figura 4.40 Matriz de confusión del modelo Trilayered Neural Network en la técnica transformada Wavelet Synchrosqueezing con SNR de 10 dB	88

ÍNDICE DE TABLAS

Tabla 1 Funciones de activación más usuales	41
Tabla 2 Modelos matemáticos de las perturbaciones utilizadas	45
Tabla 3 Características estadísticas y de tiempo-frecuencia aplicadas a las señales.....	522
Tabla 4 Comparación entre las cinco técnicas de análisis espectral utilizadas	90
Tabla 5 Comparación del rendimiento del método propuesto con otras referencias	91

1 Capítulo

1.1 Introducción

En la actualidad, surge una preocupación crucial relacionada con la degradación y la insostenibilidad en el ámbito de la energía eléctrica. Este problema se ve agudizado por el crecimiento demográfico reciente, que ha conducido a un aumento en la demanda del suministro eléctrico, así como por el uso de redes y sistemas de generación [1]. Otros factores que contribuyen a este declive incluyen la integración de fuentes de energía renovable, la implementación de dispositivos de conmutación y cargas no lineales, además de consideraciones medioambientales [2].

Considerando la importancia de la calidad en el suministro de energía eléctrica y reconociendo que las interferencias electromagnéticas resultan en pérdidas significativas tanto para la industria como para los usuarios domésticos, es necesario llevar a cabo un análisis y una caracterización de estos fenómenos con el objetivo de implementar acciones correctivas o preventivas. En consecuencia, la supervisión de los sucesos relacionados con la calidad de la energía eléctrica es esencial para ofrecer soluciones al sector eléctrico en general.

El propósito fundamental de la gestión de la calidad de la energía radica en proponer y probar diversas técnicas y enfoques que posibiliten la detección, reconocimiento, caracterización o modelado de fallas y anomalías en el sistema de suministro eléctrico. En este contexto, la supervisión de la calidad de la energía resulta fundamental para garantizar un suministro eléctrico fiable, sin interrupciones, y en conformidad con los estándares internacionales establecidos por reconocidas instituciones, como se refiere en [3].

1.2 Antecedentes

La creciente necesidad de mejorar la calidad de la energía, impulsada por la presencia de diversas perturbaciones [14,15], ha generado un considerable número de investigaciones. Estos estudios se centran en la identificación y extracción de características, seguidas de una clasificación de estas.

Una de las técnicas de detección utilizadas es la Transformada Stockwell, ST (Stockwell Transform) por sus siglas en inglés, donde en [18] fue empleada para la detección de perturbaciones utilizando MATLAB. El algoritmo propuesto fue evaluado en distintos niveles de ruido, sin ruido, SNR de 30 dB y SNR de 45 dB, los resultados obtenidos fueron bastante satisfactorios. En la investigación [4], se emplea la ST con doble resolución para la extracción de características de señales anómalas debido a su mayor resistencia y menor carga computacional.

En [5] presentan un enfoque híbrido mediante la fusión de las características en tiempo-frecuencia de la Transformada Stockwell y la Transformada Hilbert, HT (Hilbert Transform) por sus siglas en inglés. Este algoritmo se propone para la detección y extracción de características, que luego se utilizan como entrada para un clasificador basado en un Árbol de Decisión. Los resultados revelaron una alta precisión en la clasificación de perturbaciones.

Se han planteado enfoques que integran distintas estrategias, como el presentado en la investigación [6], donde se realizó una aproximación que combina la Distribución de Wigner-Ville, WVD (Wigner-Ville Distribution) por sus siglas en inglés, y una Red Neuronal Convolutiva, CNN (Convolutional Neural Network) por sus siglas en inglés, para detectar y clasificar las perturbaciones. Su atributo distintivo radica en la capacidad de la WVD para convertir señales unidimensionales en imágenes bidimensionales, aprovechando así las propiedades inherentes al procesamiento de imágenes. En [7] sugieren combinar la Transformada Discreta Wavelet, DWT (Discrete Wavelet Transform) por sus siglas en inglés, con la Transformada Discreta de Fourier, DFT (Discrete Fourier Transform) por sus siglas en inglés, y la Máquina de Soporte Vectorial, SVM (Support Vector Machine) por sus siglas en inglés, con el objetivo de identificar la mayor cantidad de eventos anómalos en la calidad de la energía. El método propuesto logra la clasificación y detección de las

perturbaciones, arrojando que el método híbrido conduce a más resultados precisos que utilizando SVM solo.

En [16] se aplicó un método de análisis tiempo-frecuencia basado en la Transformada de Gabor-Wigner, GWT (Gabor Wigner Transform) por sus siglas en inglés, demostrando mejorar simultáneamente las resoluciones de tiempo y frecuencia. Además, se destaca la importancia del ancho de la ventana en el análisis tiempo-frecuencia, recomendando el uso de ventanas más amplias para detectar cambios lentos y ventanas más estrechas para cambios rápidos.

Los autores en [8], [9] y [10] indican que la Transformada Wavelet presenta, a altas frecuencias, una resolución notable en el dominio temporal pero baja resolución en el dominio frecuencial. En contraste, a bajas frecuencias, ocurre lo opuesto: una mala resolución en el tiempo, pero una buena resolución en la frecuencia. Esta propiedad hace que la Transformada Wavelet sea altamente eficaz para analizar señales que incluyan componentes de alta frecuencia de corta duración y componentes de baja frecuencia de larga duración, características que coinciden precisamente con las de las perturbaciones.

En el trabajo desarrollado en [11] presentaron un sistema en tiempo real para identificar eventos y perturbaciones vinculadas a la calidad de la energía, fundamentado en la utilización de la Transformada Wavelet. Para la clasificación, se empleó una adaptación de los clasificadores basados en Máquinas de Soporte Vectorial, denominada Máquinas de Soporte Vectorial de Mínimos Cuadrados, LSSVM (Least-Squares Support Vector Machines) por sus siglas en inglés. La implementación del sistema de reconocimiento se llevó a cabo en una FPGA (Field Programmable Gate Array) por sus siglas en inglés, los FPGA son dispositivos programables que permiten a los diseñadores configurar y personalizar la lógica digital dentro del chip según sus necesidades específicas. Los resultados indicaron que el algoritmo de detección y clasificación es aceptable para dicho propósito.

Los autores en [12] presentan una metodología para identificar perturbaciones mediante la extracción del Valor Cuadrático Medio, RMS (Root Mean Square) por sus siglas en inglés, y Distorsión Armónica Total, THD (Total Harmonic Distortion) por sus siglas en inglés. Las perturbaciones examinadas fueron creadas de manera sintética utilizando sus modelos

matemáticos [14], variando en duración y magnitud, con base a los resultados que se obtuvieron, se observó que la metodología propuesta pudo, de manera rápida y eficiente detectar doce tipos de perturbaciones.

Previamente, se han mostrado algunas metodologías existentes en la literatura que emplean múltiples enfoques de procesamiento digital de señales. No obstante, es necesario continuar proponiendo y desarrollando otros métodos para buscar una mejora en este campo, por otro lado, según [13], se menciona que algunas de las complicaciones para implementar varios de estos algoritmos en tiempo real se relacionan con los retrasos que presentan ciertos dispositivos digitales durante el procesamiento de los datos.

Es por lo que en este trabajo de tesis se propone desarrollar una metodología que permita una adecuada detección y clasificación de perturbaciones. Lo cual permitirá en un futuro realizar un buen acoplamiento con un dispositivo embebido y obtener una buena y rápida respuesta en tiempo real para minimizar o desaparecer por completo las perturbaciones que podrían aparecer.

1.3 Justificación

En la actualidad, el suministro de energía eléctrica es vital para el desarrollo socioeconómico, ya que el crecimiento de industrias, comercios y hogares depende directamente de este recurso [19]. Sin embargo, la calidad de la energía se ve amenazada por diversos disturbios en el sistema eléctrico, como cargas de arranque, transitorias, desequilibradas, de iluminación y de alta potencia [20]. La presencia de alta distorsión armónica en la red eléctrica puede causar fallas y calentamiento en equipos, afectando su funcionamiento y aumentando la probabilidad de malfuncionamientos [21]. Interrupciones del servicio, variaciones de voltaje y otros problemas degradan aún más la calidad de la red eléctrica [22]. Por ende, resulta esencial identificar y clasificar con precisión estos disturbios, ya sean simples o combinados [23]. Las redes eléctricas desempeñan un papel crucial en la distribución eficiente de energía, pero la presencia de disturbios puede comprometer su estabilidad y seguridad [20]. La detección y clasificación precisa de estos disturbios se vuelve fundamental para garantizar el

óptimo funcionamiento de las redes eléctricas [22]. A pesar de los avances en técnicas de análisis espectral avanzado, la complejidad de los disturbios eléctricos requiere nuevos y mejores enfoques a un alto rendimiento [23]. La generación de señales sintéticas a partir de modelos matemáticos brinda la oportunidad de simular escenarios realistas, pero la falta de un marco integral de clasificación representa una limitación en la gestión efectiva de los disturbios [21].

Este trabajo busca abordar estas limitaciones mediante la implementación de técnicas avanzadas de análisis espectral para la clasificación de disturbios en redes eléctricas. Utilizando una base de datos de señales sintéticas generadas con MATLAB, se programarán diversas técnicas de análisis espectral para clasificar los disturbios, evaluando su desempeño con métricas diversas. La resolución de este problema contribuirá a mejorar la eficiencia y confiabilidad de las redes eléctricas, fortaleciendo la capacidad de detección y respuesta frente a disturbios eléctricos simples y combinados [19]. Además, sentará las bases para crear sistemas avanzados de monitoreo y gestión en entornos eléctricos complicados [23].

1.4 Objetivos

1.4.1 Objetivo general

Diseñar y desarrollar una metodología basada en el procesamiento de señales eléctricas mediante técnicas de tiempo-frecuencia empleando una clasificación de aprendizaje de máquina para detectar los disturbios simples o combinados en las redes eléctricas.

1.4.2 Objetivos específicos

- 1) Realizar una revisión bibliográfica sobre las perturbaciones en redes eléctricas.
- 2) Explorar el estado del arte en técnicas avanzadas para el procesamiento de señales eléctricas mediante análisis espectral.

- 3) Utilizar modelos matemáticos para generar de forma sintética señales eléctricas que reproduzcan disturbios específicos, permitiendo así simular todos los posibles disturbios que pueden aparecer, tanto simples como combinados.
- 4) Aplicar métodos de procesamiento digital de señales que permitan identificar perturbaciones eléctricas simples y combinadas.
- 5) Realizar análisis de tiempo-frecuencia para la obtención de un conjunto de características descriptivas que nos permitan modelar las perturbaciones eléctricas.
- 6) Realizar una clasificación de perturbaciones en señales eléctricas basada en metodologías de aprendizaje de máquina, utilizando diferentes métricas de evaluación de desempeño de clasificación.
- 7) Evaluar y comparar rigurosamente diversas metodologías con el objetivo de determinar la más efectiva para el reconocimiento y clasificación de perturbaciones eléctricas.

1.5 Organización de la tesis

Este trabajo de tesis de maestría está dividido en 5 capítulos y cuenta con apéndices que contienen información adicional. A continuación, se ofrece una breve descripción de cada uno de ellos:

En el Capítulo 1, se presentan los antecedentes, justificación y los objetivos de la presente investigación. Posteriormente en el capítulo 2, se abordan los principales conceptos que dan soporte a la tesis, una breve explicación de los principales disturbios eléctricos, métodos y técnicas utilizadas, estudio en tiempo-frecuencia de las señales, entre otros. Luego en el capítulo 3, se detalla la metodología empleada en el proyecto, abordando minuciosamente los pasos necesarios para la construcción de un clasificador de señales afectadas por perturbaciones eléctricas. Se cubren aspectos que van desde la adquisición de la base de datos hasta el desarrollo e implementación de cada una de las técnicas de análisis espectral utilizadas. Finalmente, se describe el proceso de clasificación de las señales mediante cada una de las diferentes técnicas. A continuación, en el capítulo 4, se presentan los resultados

obtenidos de las pruebas realizadas. Y por último en el capítulo 5, se exponen las conclusiones generales. Al final del documento se presenta la bibliografía utilizada en esta investigación.

2 Capítulo

2.1 Marco Teórico

Este estudio aborda el análisis de las perturbaciones eléctricas, que son aquellas interferencias que comprometen la calidad y estabilidad del suministro de energía eléctrica. Exploramos los conceptos teóricos esenciales para comprender estos fenómenos. Este capítulo se centra en los fundamentos teóricos que respaldan nuestro trabajo, presentados de manera clara para facilitar su comprensión y definir su alcance. Comenzamos describiendo los aspectos relacionados con la interpretación de las señales afectadas por perturbaciones eléctricas. Luego, se aplicaron diversas técnicas de análisis espectral utilizadas en el estudio realizado. Se concluyó este capítulo con la descripción de los algoritmos de clasificación, una tarea de alta relevancia para nuestro enfoque de estudio.

2.2 Perturbaciones eléctricas

Las perturbaciones eléctricas se refieren a cualquier cambio no deseado o anormal en las características normales de la corriente eléctrica que fluye a través de un sistema [40][41] [42]. Múltiples fenómenos pueden dar origen a perturbaciones particulares, originando perturbaciones atípicas y siendo generadas tanto por fenómenos internos como externos. Estas perturbaciones pueden ser generadas internamente por equipos eléctricos o externamente debido a eventos como tormentas, cortocircuitos, entre otros. La gestión de la calidad de la energía eléctrica implica la identificación y mitigación de estos eventos para garantizar un suministro eléctrico estable y seguro. Algunos de los tipos comunes de perturbaciones eléctricas [59] incluyen:

- **Variaciones de Tensión:** Cambios en el nivel de voltaje, como aumentos (sobretensiones) o disminuciones (subtensiones).
- **Fluctuaciones de Frecuencia:** Variaciones en la frecuencia de la corriente alterna, que pueden afectar el funcionamiento de equipos sensibles.
- **Armónicos:** Señales de frecuencia múltiple de la frecuencia fundamental, que pueden distorsionar la onda de la corriente eléctrica y afectar el rendimiento de dispositivos electrónicos.
- **Desviaciones Transitorias:** Cambios bruscos y temporales en la onda eléctrica, generalmente de corta duración.
- **Ruido Eléctrico:** Señales eléctricas no deseadas que pueden interferir con la operación normal de los equipos.
- **Desbalance de Carga:** Distribución desigual de la corriente eléctrica entre las fases de un sistema, lo que puede causar problemas en el equipo.
- **Hoyo de Tensión:** Caídas momentáneas en el voltaje por debajo del nivel nominal.

2.3 2.2 Características de las perturbaciones eléctricas

2.3.1 Señal normal sin perturbaciones

Una señal eléctrica normal [60] y estable, sin perturbaciones, exhibirá una forma de onda sinusoidal regular, con voltaje y frecuencia constantes, sin fluctuaciones notables ni distorsiones, como se aprecia en la Figura 2.1. Estas características son deseables para garantizar el funcionamiento adecuado de los dispositivos eléctricos y sistemas conectados a la red eléctrica.

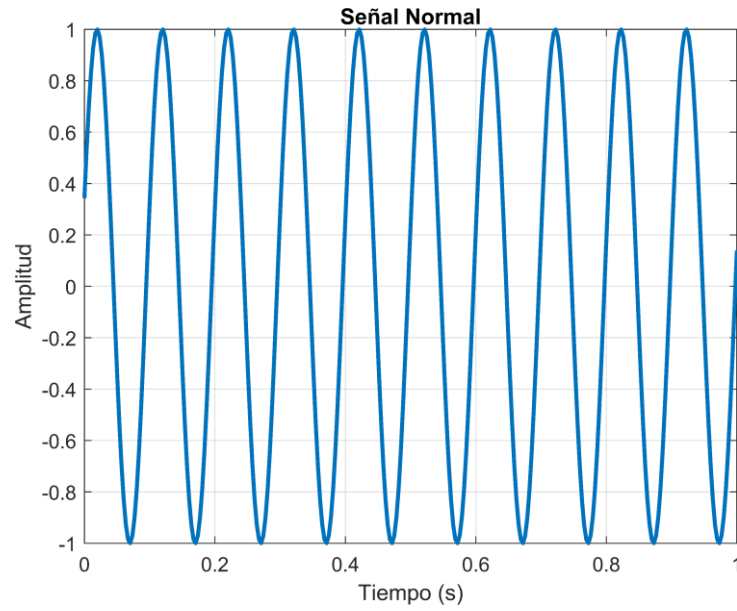


Figura 2.1 Señal Normal

2.3.2 Interrupción

La interrupción [61], [62] en las señales eléctricas es una perturbación que se caracteriza por la pérdida temporal o completa de la energía eléctrica en un sistema, Figura 2.2. Suelen ser eventos de corta duración, aunque su duración puede variar desde fracciones de segundo hasta minutos, horas o incluso más, dependiendo de la causa y las medidas de restauración. Pueden ser causadas por diversos factores, como fallas en el suministro, cortocircuitos, daños en la infraestructura eléctrica, mantenimiento programado o eventos externos como tormentas y desastres naturales.

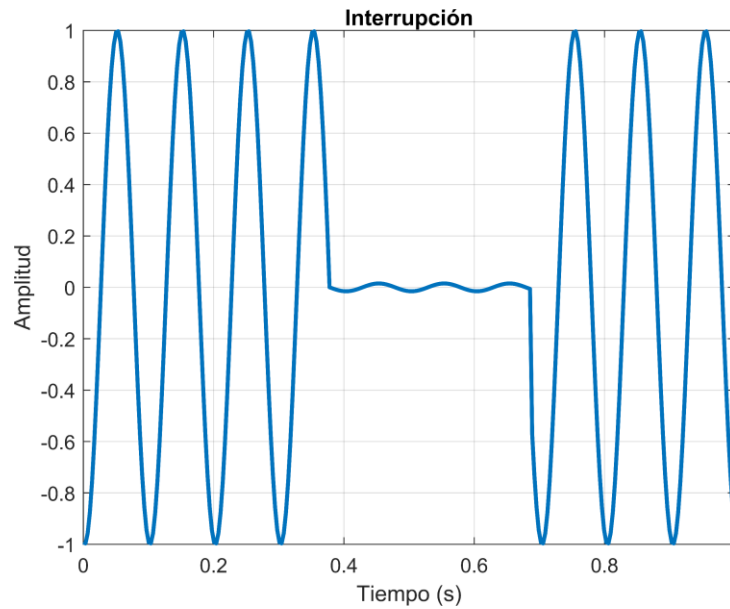


Figura 2.2 Interrupción

2.3.3 Hueco de tensión

Es una perturbación en la señal eléctrica caracterizada por una disminución momentánea y significativa del nivel de voltaje por debajo de su valor nominal, disminuye a un nivel inferior pero no se corta completamente, la amplitud de la onda eléctrica experimenta una reducción para después volver a su correcto comportamiento tiempo-frecuencia (Figura 2.3). Son eventos de corta duración, generalmente menos de un segundo [62][63]. Pueden variar en duración de unos ciclos de la onda, pero son más breves en comparación con otras perturbaciones más prolongadas. pueden ser causados por eventos como arranques de motores grandes, conexiones deficientes, variaciones repentinas en la carga, o incluso por fallas temporales en la red eléctrica.




Figura 2.3 Hueco de tensión

2.3.4 Pico de tensión

Es una perturbación en la señal eléctrica caracterizada por un aumento momentáneo y significativo del nivel de voltaje por encima de su valor nominal [62][64]. La amplitud de la onda eléctrica se incrementa, pero luego vuelve a su nivel normal (Figura 2.4). Suelen tener una duración variable, pero tienden a ser más breves en comparación con otras perturbaciones más prolongadas. Pueden ser causados por eventos como desconexiones rápidas de grandes cargas inductivas, variaciones repentinas en la carga o por ajustes en la regulación del voltaje en la red eléctrica.

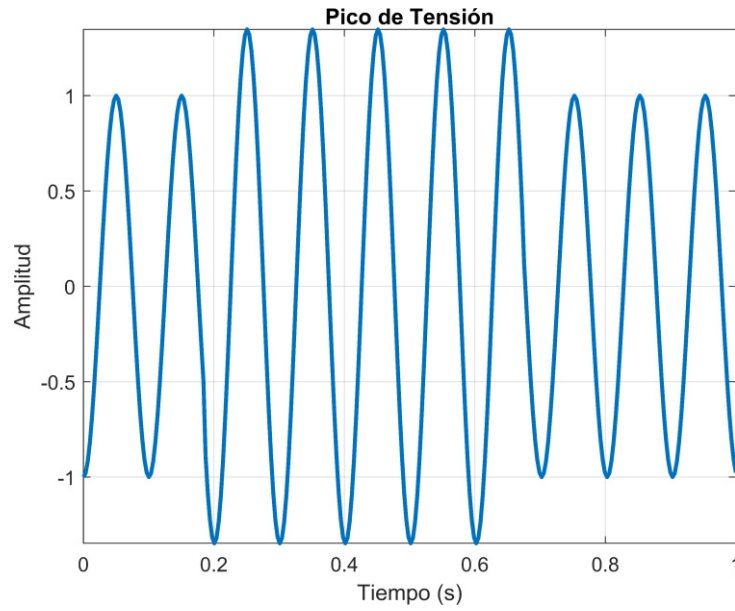


Figura 2.4 Pico de tensión

2.3.5 Transitorio oscilatorio

Se caracterizan por cambios rápidos y repetitivos en la amplitud o frecuencia de la señal, que pueden ocurrir de manera transitoria [62][65]. Al igual que otros transitorios, los oscilatorios transitorios son eventos de corta duración, generalmente en el rango de microsegundos a milisegundos Figura 2.5. A diferencia de otros transitorios, pueden tener componentes de frecuencia específicos y repetitivos, creando patrones oscilatorios en la señal. Pueden ser causados por diversas fuentes, como la conmutación rápida de cargas, cambios en la impedancia del sistema, eventos de conmutación no controlada o problemas de estabilidad en la red eléctrica.

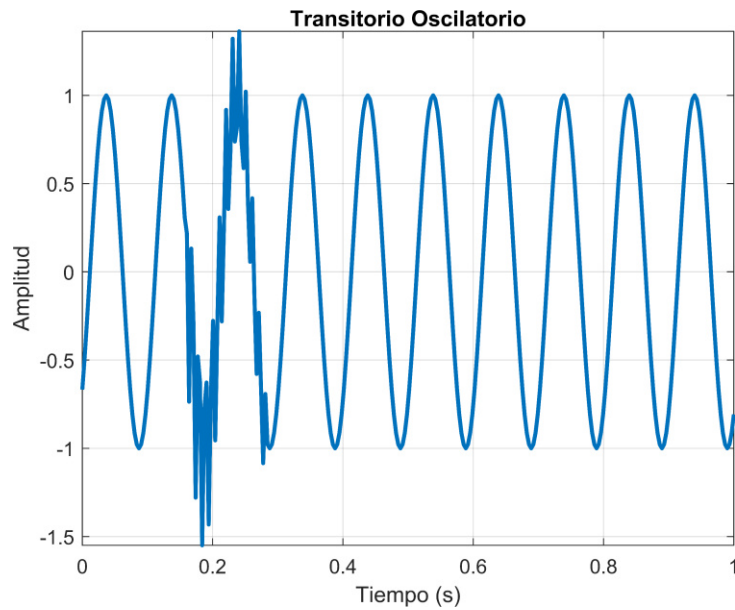


Figura 2.5 Transitorio Oscilatorio

2.3.6 Armónicos

Son perturbaciones que resultan en componentes de frecuencia múltiple de la frecuencia fundamental de la onda de voltaje o corriente [62][66]. Los armónicos son componentes de frecuencia que son múltiplos enteros de la frecuencia fundamental. Por ejemplo, el segundo armónico sería el doble de la frecuencia fundamental, el tercer armónico sería el triple, y así consecutivamente. La presencia de armónicos puede distorsionar la forma de onda de la señal eléctrica. En lugar de ser una onda sinusoidal pura, la forma de onda se vuelve más compleja debido a la presencia de estos componentes adicionales Figura 2.6. Pueden ser causados por la presencia de equipos no lineales en la red eléctrica, como convertidores de frecuencia variable, dispositivos electrónicos no lineales y cargas con rectificadores.

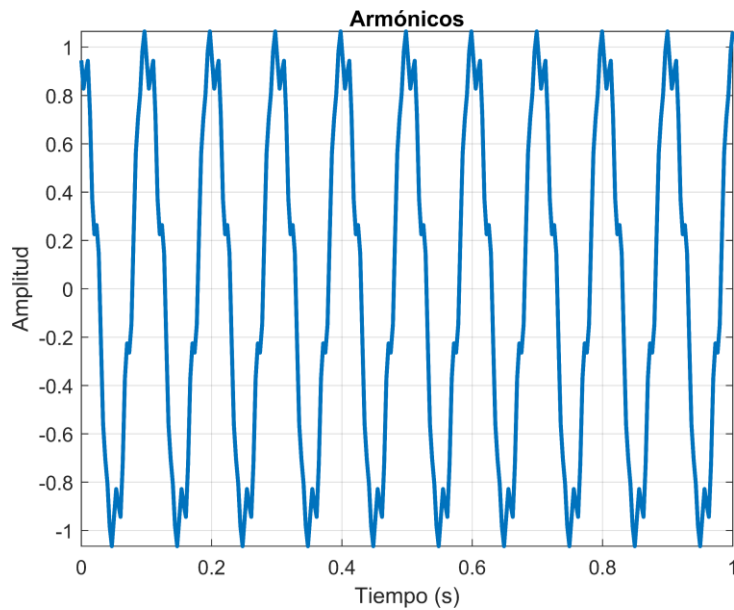


Figura 2.6 Armónicos

2.3.7 Parpadeo

Se manifiesta como fluctuaciones perceptibles en la iluminación de las lámparas incandescentes o en el brillo de los dispositivos luminosos [62][67]. Se percibe como variaciones perceptibles en la luminosidad de las fuentes de luz, como bombillas incandescentes o dispositivos LED. Estas variaciones pueden ser visibles a simple vista. El parpadeo o flicker puede tener una frecuencia de modulación específica, lo que significa que las fluctuaciones en la luminosidad pueden ocurrir a una tasa regular (Figura 2.7). La frecuencia típica es de varios Hertz. Las causas pueden incluir fluctuaciones en la carga eléctrica de la red, arranque de grandes motores, operación de equipos no lineales y otras variaciones en la carga de la red eléctrica.

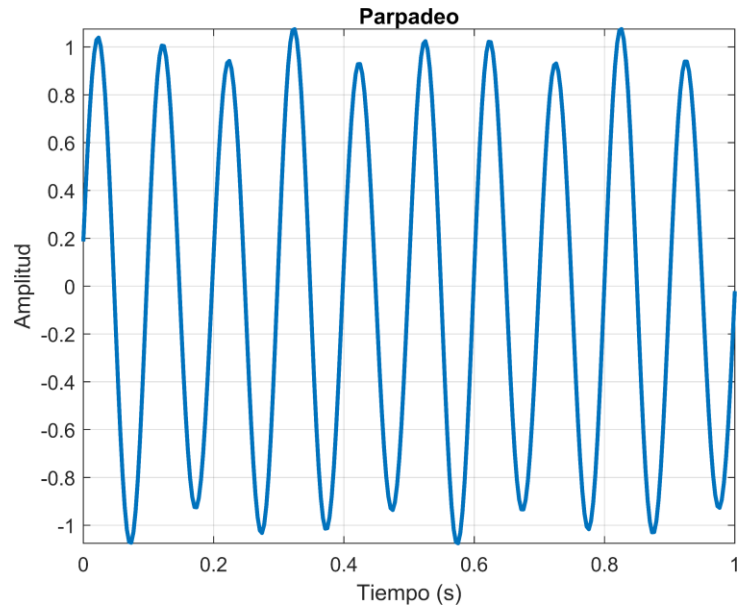


Figura 2.7 Parpadeo

2.3.8 Muesca

Se refiere a la presencia de una frecuencia específica que ha sido atenuada o filtrada, creando una "muesca" o "notch" en la forma de onda de la señal (Figura 2.8). A diferencia de los armónicos, que son múltiplos de la frecuencia fundamental, el notch se manifiesta en una frecuencia específica y puede ser causado por la presencia de ciertos equipos o cargas en la red eléctrica [62][68]. Pueden ser causados por equipos electrónicos no lineales, cargas específicas que generan interferencias selectivas, o por la operación de ciertos dispositivos de conmutación.




Figura 2.8 Muesca

2.3.9 Armónicos con hueco de tensión

La perturbación armónica con caída de voltaje implica la presencia de armónicos en la forma de onda del voltaje junto con una disminución temporal en su nivel [62][69], conocida como "sag", como podemos apreciar en la Figura 2.9. Los armónicos, que son múltiplos de la frecuencia fundamental de la red eléctrica, se generan principalmente por cargas no lineales en la red, como equipos electrónicos, convertidores de energía, rectificadores, entre otros. Estos armónicos pueden distorsionar la forma de onda del voltaje y afectar el funcionamiento de los equipos eléctricos, lo que puede resultar en fallas o daños en su operación cuando se combinan con una caída de voltaje. La presencia de esta perturbación puede tener impactos negativos en la eficiencia y el rendimiento de los equipos conectados a la red eléctrica.

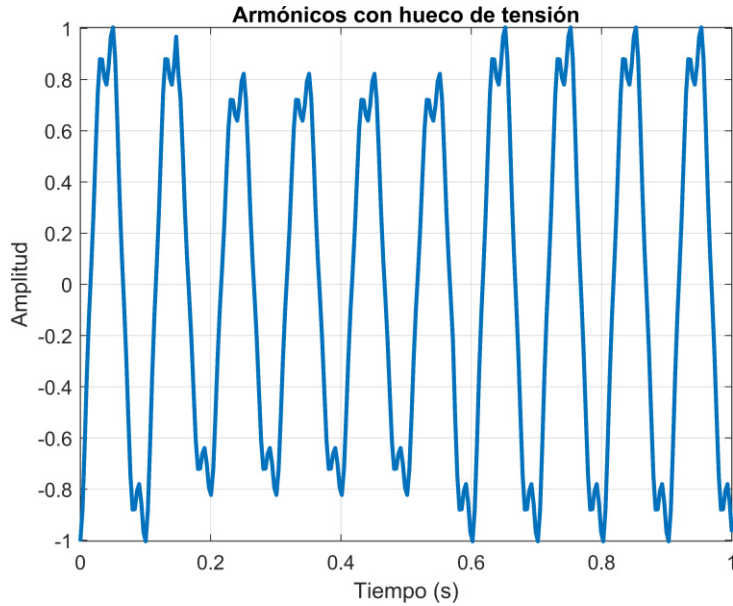
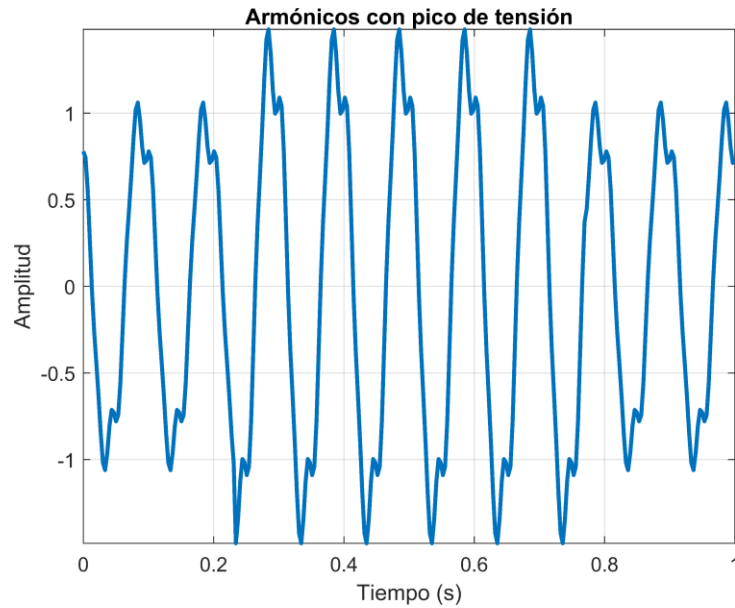


Figura 2.9 Armónicos con hueco de tensión

2.3.10 Armónicos con pico de tensión

La perturbación armónica con aumento de voltaje, conocida como "Harmonics with Swell" en inglés, implica la presencia simultánea de armónicos en la forma de onda del voltaje junto con un aumento temporal en su nivel [62], también llamado "swell", como se aprecia en la Figura 2.10. Los armónicos son componentes de frecuencia que son múltiplos enteros de la frecuencia fundamental de la red eléctrica, generados principalmente por cargas no lineales como equipos electrónicos, convertidores de energía y rectificadores. Cuando ocurre esta perturbación, se combina una serie de armónicos con un incremento momentáneo en el voltaje, lo cual puede afectar negativamente el rendimiento de los equipos eléctricos y electrónicos conectados a la red, incluso causando fallas o daños en su funcionamiento.



2.4 Señal sintética

Una señal sintética es una señal que se crea artificialmente, en contraposición a una señal obtenida directamente de una fuente física o de la naturaleza. Estas señales se generan mediante modelos matemáticos o algoritmos para simular ciertos comportamientos o características específicas. En el contexto de nuestra investigación, las señales sintéticas se utilizan para representar disturbios eléctricos controlados y predefinidos [14,17], permitiendo realizar experimentos y pruebas en un entorno controlado y reproducible. Estas señales son esenciales para el análisis y desarrollo de metodologías de detección y clasificación de perturbaciones en redes eléctricas.

2.5 Procesamiento digital de señales mediante técnicas de análisis espectral

Las técnicas de análisis espectral son métodos utilizados para examinar y entender la composición de señales o fenómenos en términos de sus componentes de frecuencia [70]. Estas técnicas son comúnmente aplicadas en el campo de procesamiento de señales y análisis

de datos. Algunas de las técnicas de análisis espectral incluyen:

- **Transformada Constante-Q**

- **Transformada de Fourier (FFT)**

- **Transformada corta de Fourier**

- **Transformada Wavelet**

- **Transformada Wavelet Synchrosqueezing**

Estas técnicas son esenciales en disciplinas como telecomunicaciones, procesamiento de señales, acústica, geofísica y otras áreas donde es crucial entender la composición frecuencial de las señales para el análisis y la toma de decisiones.

2.5.1 Transformada Constante-Q

La Transformada Constante-Q, CQT (Constant Q Transform, por sus siglas en inglés) también se puede utilizar para convertir una señal discreta del dominio del tiempo al dominio tiempo-frecuencia [34, 35]. Inicialmente diseñada para el análisis musical, esta transformada realiza una transformación en relación con el logaritmo de la frecuencia para lograr un patrón constante en el dominio de la frecuencia. Esta transformación puede describirse como una serie de filtros espaciados de forma logarítmica. En la CQT, los bins de frecuencia están distribuidos de manera geométrica, y su factor Q, que representa el número de ciclos enteros

procesados, se mantiene constante. La complejidad computacional excesiva ha sido tradicionalmente una de las razones de la falta de popularidad de esta transformada [36], aunque este problema se ha mitigado parcialmente gracias al aumento de la capacidad de cómputo de las computadoras modernas. La CQT puede ser utilizada para analizar señales con perturbaciones eléctricas. Es una herramienta poderosa para el análisis de señales en el dominio tiempo-frecuencia y ha demostrado ser eficaz en diversas aplicaciones. Las perturbaciones eléctricas a menudo generan cambios rápidos y abruptos en la forma de onda de las señales eléctricas, lo que se refleja en componentes de alta frecuencia. Dado que la CQT tiene una resolución no uniforme en frecuencia, con una mayor resolución en las frecuencias más altas, es particularmente adecuada para capturar y analizar estas características de alta frecuencia.

Esta técnica transforma una señal en el dominio del tiempo $x(n)$ en el dominio tiempo-frecuencia, de modo que las frecuencias centrales de los intervalos de frecuencia están espaciadas de manera geométrica y sus factores Q son todos iguales. En efecto, esto significa que la resolución de frecuencia es mejor para las bajas frecuencias y la resolución temporal es mejor para las altas frecuencias.

La CQT de una señal discreta en el dominio del tiempo $x(n)$ esta defina por:

$$\chi^{CQ}(k, n) = \sum_{j=n-\lfloor N_k/2 \rfloor}^{n+\lfloor N_k/2 \rfloor} x(j) a_k^*(j - n + N_k / 2) \quad (2.1)$$

Donde $k=1, 2, \dots, K$ indexa los intervalos de frecuencia de la CQT, $[\cdot]$ denota el redondeo hacia menos infinito, y $a_k^*(n)$ denota el conjugado complejo de $a_k(n)$. Las funciones de base $a_k(n)$ son formas de onda complejas, también llamadas átomos tiempo-frecuencia, y se definen por:

$$a_k(n) = \frac{1}{N_k} \omega\left(\frac{n}{N_k}\right) \exp\left[-i2\pi n \frac{f_k}{f_s}\right] \quad (2.2)$$

donde f_k es la frecuencia central del intervalo k , f_s denota la tasa de muestreo, y $\omega(t)$ es una función de ventana continua (por ejemplo, una ventana de Hann o Blackman), muestreada en puntos determinados por t . La función de ventana es cero fuera del rango $t \in [0,1]$. Las longitudes de ventana $N_k \in \mathbb{R}$ en 2.5 y 2.6, son valores reales e inversamente proporcionales a f_k para tener el mismo factor Q para todos los intervalos k [37].

La CQT propone establecer el tamaño de la ventana N_k de acuerdo con la ecuación 2.7 [38].

$$N_k = \left\lceil \frac{f_s}{f_k} Q \right\rceil \quad (2.3)$$

$\frac{f_s}{f_k}$ Es el número de muestras procesadas por ciclo a una frecuencia central f_k , las frecuencias centrales muestreadas obedecen la ecuación 2.8 [35].

$$f_k = f_1 \cdot 2^{\frac{k-1}{B}} \quad (2.4)$$

Donde f_1 es la frecuencia central del intervalo de frecuencia más bajo y B es el número de intervalos por octava. En la CQT, el número de intervalos por octava está relacionado con el factor de fidelidad Q mediante la ecuación 2.9 [39].

$$Q = \frac{1}{2^{\frac{1}{B}} - 1} \quad (2.5)$$

El número de bins está fijo para un Q dado y no puede aumentarse arbitrariamente, ya que también determina el número de ciclos dentro de la función de ventana. La CQT se obtiene con un barrido en $\log(\text{frecuencia})$, y generalmente se explica como una serie de filtros espaciados logarítmicamente. Esto hace que sea más complicado trabajar con la estructura de datos de la CQT que con la matriz tiempo-frecuencia de la STFT.




Figura 2.11 Ejemplo de lectura de una señal de audio utilizando 12 bins por octava

2.5.2 Transformada de Fourier

Es una herramienta matemática fundamental utilizada en el análisis de señales y sistemas. Su propósito principal es descomponer una señal en sus componentes de frecuencia, revelando la contribución de cada frecuencia presente en la señal original [71].

Dominio del Tiempo y Dominio de la Frecuencia:

- En el dominio del tiempo, una señal se representa como una función de amplitud en función del tiempo.
- La Transformada de Fourier convierte esta representación del dominio del tiempo a una representación en el dominio de la frecuencia.

Frecuencias y Componentes Armónicas:

- Cada señal en el dominio del tiempo puede descomponerse en una suma de componentes armónicas o sinusoidales con diferentes frecuencias.

- La Transformada de Fourier proporciona información sobre la amplitud y la fase de cada componente armónica.

Función de Transformación:

- La Transformada de Fourier de una señal $x(t)$ se denota como $X(f)$ o $X(\omega)$, donde f es la frecuencia en Hertz y ω es la frecuencia angular medida en radianes por segundo.
- La relación entre $X(f)$ y $x(t)$ está dada por la siguiente fórmula integral:

$$X(f) = \int_{-\infty}^{\infty} x(t) \cdot e^{-j2\pi ft} dt \quad (2.6)$$

Espectro de Frecuencia:

- El resultado de la Transformada de Fourier es el espectro de frecuencia de la señal original. Este espectro muestra las frecuencias presentes y sus respectivas amplitudes en la señal, figura 2.12.




Figura 2.12 Señal estacionaria y su FT con tres componentes de frecuencia 5Hz, 25 Hz y 50 Hz

Inversa de la Transformada de Fourier:

Esta inversa se utiliza para recuperar la función original $x(t)$ a partir de su representación en el dominio de la frecuencia $X(f)$ y se denota como $x(t) = F^{-1}[X(f)]$. La inversa de la Transformada de Fourier está definida como:

$$x(t) = \frac{1}{2\pi} \int_{-\infty}^{\infty} X(f) \cdot e^{-j\omega t} dt \quad (2.7)$$

Donde:

- $X(f)$ es la función en el dominio de la frecuencia,
- t es la variable de tiempo.

La inversa de la Transformada de Fourier permite reconstruir la señal original a partir de su representación en el dominio de la frecuencia [72]. Es una herramienta importante en el análisis y procesamiento de señales en áreas como la comunicación, la ingeniería eléctrica, la acústica, entre otras.

2.5.3 Transformada corta de Fourier

Para analizar las frecuencias locales de una señal, se requiere, en primer lugar, delimitar la región de interés de la señal y luego aplicar la transformada de Fourier. Un enfoque frecuentemente empleado consiste en aplicar una ventana a la señal en intervalos sucesivos, donde cada ventana tiene un tamaño suficientemente pequeño para aproximarse a una señal estacionaria (o cuasi estacionaria). Esta técnica de análisis en tiempo-frecuencia se conoce como la Transformada Corta de Fourier [27], STFT (Short-Time Fourier Transform) por sus siglas en inglés (Figura 2.13).

Esto se consigue al multiplicar la señal de entrada $f(t)$ por una función ventana $W(t)$, cuya posición se modifica a lo largo del tiempo, dividiendo así la señal en pequeños segmentos temporales. De esta manera, cada espectro de frecuencia refleja el contenido de frecuencia durante un breve lapso. La colección de estos espectros representa la evolución del contenido de frecuencia a lo largo del tiempo para toda la señal analizada.




Figura 2.13 Transformada corta de Fourier

La STFT permite analizar señales, proporcionando información de tiempo y frecuencia, pero enfrenta limitaciones debido al principio de incertidumbre, que establece que no se puede tener una localización exacta simultánea en tiempo y frecuencia. Esta limitación implica una relación intrínseca entre la resolución en tiempo y la resolución en frecuencia: al mejorar una, se reduce la otra y viceversa. La elección de Δt y $\Delta \omega$ no puede hacerse de forma independiente debido al principio de incertidumbre, que establece que el producto Δt y $\Delta \omega$ debe satisfacer una desigualdad. En resumen, la STFT busca un equilibrio entre resolución temporal y frecuencial, pero la mejora en uno conlleva una disminución en el otro, según el principio de incertidumbre de la transformada de Fourier.

2.5.4 Transformada Wavelet

La Transformada Wavelet de una función $f(t)$ es la descomposición de $f(t)$ en un conjunto de funciones $\psi_{a,b}(t)$, que forman una base y son llamadas las “Wavelets” [43]. La Transformada Wavelet se define como:

$$W_f(a,b) = \int f(t)\psi_{a,b}^*(t) dt \quad (2.8)$$

Las Wavelets son generadas a partir de la traslación y cambio de escala de una misma función wavelet $\psi(t)$, llamada la “Wavelet madre” (Figura 2.14), y se define como:

$$\psi_{a,b}(t) = \int \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \cdot f(t) dt \quad (2.9)$$

donde a es el factor de escala (controla el ancho de la wavelet en el dominio de la frecuencia y el tiempo), y b es el factor de desplazamiento (controla la posición de la wavelet en el dominio del tiempo).

Las wavelets $\psi_{a,b}(t)$ generadas de la misma función wavelet madre $\psi(t)$ tienen diferente escala a y desplazamiento b , pero todas tienen la misma forma. Se utilizan siempre factores de escala $a > 0$. Las Wavelets son dilatadas cuando la escala $a > 1$, y son contraídas cuando $a < 1$. Así, cambiando el valor de s se cubren rangos diferentes de frecuencias. Valores grandes del parámetro a corresponden a frecuencias de menor rango, o una escala grande de $\psi_{a,b}(t)$. Valores pequeños de a corresponden a frecuencias de mayor rango o una escala muy pequeña de $\psi_{a,b}(t)$ como se puede apreciar en [24].

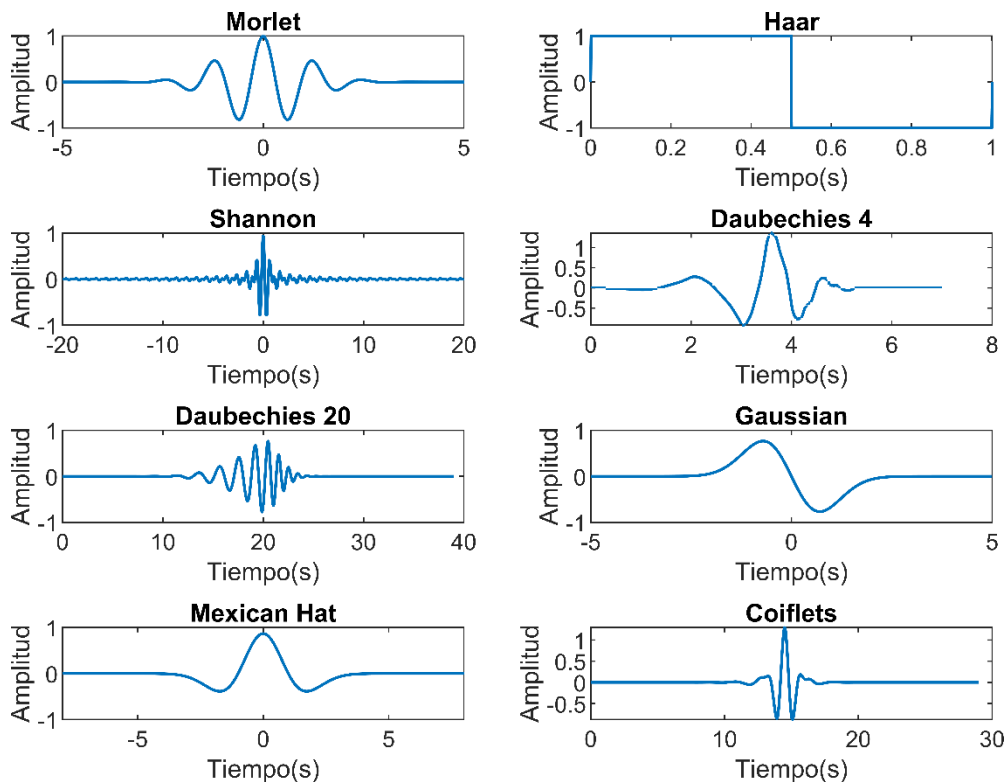


Figura 2.14 Diferentes tipos de Wavelet Madres

Existen dos enfoques fundamentales para llevar a cabo el análisis con wavelets [26]: el análisis de multiresolución (DWT) y el análisis de wavelets continuas (CWT). Además, se pueden clasificar las wavelets madre en dos categorías principales, cada una diseñada para uno de estos tipos de análisis. Aquellas wavelets madre no analíticas se emplean tanto en el análisis de multiresolución como en el análisis wavelet continuo, y se caracterizan por poseer valores reales en los coeficientes. Por otro lado, las wavelets madre analíticas, se utilizan específicamente en el análisis wavelet continuo, destacándose por presentar valores complejos en los coeficientes y, de esta manera, preservar la información de fase.

2.5.4.1 Transformada Wavelet Continua

La Transformada Wavelet Continua [73][74] se ha desarrollado como una alternativa a la Transformada de Fourier de Tiempo Corto (STFT) para superar las limitaciones de resolución. Su propósito principal es lograr una representación lineal tiempo-frecuencia que conserve tanto los cambios temporales como las escalas temporales.

$$CWT(a, b) = - \int_{-\infty}^{\infty} f(t) \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) dt, \quad (2.10)$$

donde $f(t)$ es la señal y ψ es la wavelet madre respectivamente; a y b son los parámetros de escala y traslación.

El espectrograma generado mediante la Transformada Wavelet Continua (CWT), como se muestra en la Figura 2.15, exhibe una resolución superior en comparación con el espectrograma derivado de la Transformada de Fourier de Tiempo Corto (STFT). La CWT posee la propiedad de ser invertible cuando se emplean wavelets que cumplen con la condición de tener energía finita, una característica altamente beneficiosa para el análisis llevado a cabo.




Figura 2.15 Dominio del tiempo y dominio tiempo-frecuencia producido por la CWT.

2.5.4.2 Transformada Wavelet Discreta

La cantidad de información utilizada por la transformada wavelet continua para garantizar la carga de cálculo y la transformación es bastante grande. Un método más eficaz es la transformada wavelet discreta (DWT) que trata la señal solo en ciertas expansiones de la wavelet principal [73].

$$DWT(m, n) = 2^{-m/2} \sum_k f(k) \psi \left(\frac{n - k\tau_0 s_0^m}{s_0^m} \right) \quad (2.11)$$

Donde m y n son los parámetros de escala y traslación, respectivamente; s_0 y τ_0 son la escala discreta y el factor de traslación, respectivamente. Mallat desarrolló una forma eficaz de realizar este proceso en 1989 utilizando filtros [25]. El algoritmo Mallat es una forma clásica conocida como codificador de subbanda de 2 canales entre los métodos de procesamiento de señales. Las aproximaciones en este algoritmo de la WT muestran los componentes de alta escala y baja frecuencia. Los detalles por otro lado representan componentes de baja escala y alta frecuencia. En la figura 2.16 se aprecia como una señal $x(n)$ es descompuesta en aproximaciones $a_j(n)$ y detalles $d_j(n)$ por efecto de los filtros pasa-altos $h_j(n)$ y pasa-bajos $g_j(n)$. El símbolo $\downarrow 2$ significa el proceso de decimación, n es un número entero y $j=1, 2, 3 \dots k$ es el nivel de descomposición.

Este método no pierde la información de tiempo-frecuencia, a diferencia de la FT. Sin embargo, la resolución del análisis depende del nivel de descomposición en que uno se encuentre, por lo que se puede realizar un análisis en diferentes resoluciones (Análisis Multi-Resolución o MRA) y su complejidad computacional es de $O(n)$. La DWT es al igual que la CoWT un proceso reversible y la reconstrucción es realizada tomando los valores en la salida de los filtros y multiplicándolas por la respuesta al impulso considerando un proceso de undecimado debido a la decimación realizada en el análisis.

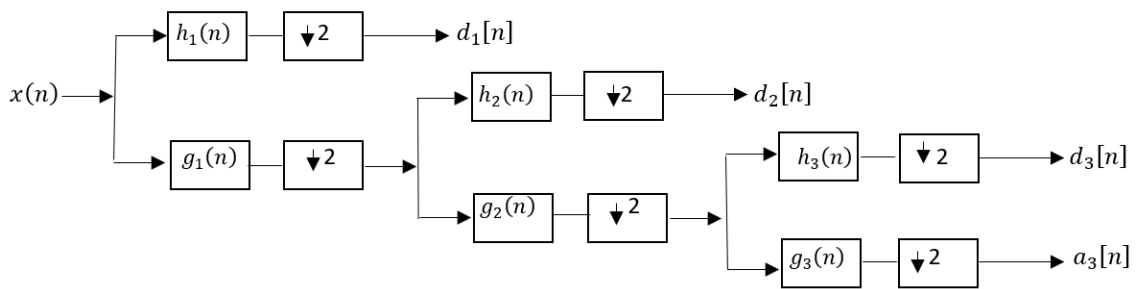


Figura 2.16 Árbol de resolución de wavelets de tres niveles.

2.5.5 Transformada Wavelet Synchrosqueezing

El diseño del algoritmo de la transformada Synchrosqueezing se orienta hacia la obtención de una representación tiempo-frecuencia apropiada para analizar señales multicomponentes con comportamiento no estacionario. Este enfoque analítico permite identificar componentes oscilatorios cuya amplitud y frecuencia experimentan cambios a lo largo del tiempo.

$$f(t) = \sum_{k=1}^k S_k(t) + \eta(t) \quad (2.12)$$

El modelo de modulación describe señales multicomponentes mediante la combinación de diversas funciones que presentan modulación en amplitud y frecuencia. Cada modo $S_k(t) = A_k(t)e^{2i\pi\phi_k(t)}$ incluye una amplitud instantánea $A_k(t)$ y una componente de frecuencia

asociada $\phi_k(t)$ que experimentan cambios a lo largo del tiempo. Además, se suma a cada función el error de muestreo o ruido $\eta(t)$.

Para mejorar la resolución en la representación de la CWT, es necesario reducir las dispersiones espectrales. Para lograr esto, se requiere comprimir las frecuencias alrededor de las obtenidas con la CWT, con el objetivo de transferir la información del dominio tiempo-escala al dominio tiempo-frecuencia. Este proceso transforma cada punto (τ, s) en $(\omega_f(\tau, s))$, y se conoce como "Synchrosqueezing" [75].

La utilización de la WSST proporciona una representación tiempo-frecuencia más precisa en comparación con la CWT, permitiendo la obtención de valores de frecuencia instantánea a lo largo del tiempo. Esta representación concentra las componentes oscilatorias en regiones estrechas del plano, lo que facilita la extracción individual de cada una de ellas. Aplicar la inversa de la WSST posibilita obtener cada componente en el dominio del tiempo. Esta herramienta facilita el aislamiento y análisis individual de cada componente, brindando información más detallada sobre su comportamiento en comparación con las técnicas tradicionales.




Figura 2.17 Dominio del tiempo y dominio tiempo-frecuencia generado por la WSST.

2.6 Aprendizaje de máquina.

El aprendizaje de máquina (también conocido como machine learning en inglés) es una rama de la inteligencia artificial que se enfoca en el desarrollo de algoritmos y modelos que permiten a las computadoras aprender patrones y realizar tareas sin ser explícitamente programadas [76]. En lugar de depender de reglas programadas manualmente, los sistemas

de aprendizaje de máquina utilizan datos y experiencias previas para mejorar su rendimiento en una tarea específica.

El proceso de aprendizaje de máquina generalmente implica los siguientes pasos:

- **Recopilación de Datos:** Se recopilan datos relevantes para la tarea que se desea abordar. Estos datos pueden incluir ejemplos, características y resultados deseados.
- **Entrenamiento del Modelo:** Se utiliza un algoritmo de aprendizaje de máquina para entrenar un modelo utilizando los datos recopilados. Durante el entrenamiento, el modelo ajusta sus parámetros para realizar la tarea específica.
- **Validación y Evaluación:** El modelo se valida y evalúa utilizando conjuntos de datos separados que no se utilizaron durante el entrenamiento. Esto ayuda a asegurar que el modelo pueda generalizar bien a nuevos datos.
- **Predicciones y Desempeño en Tiempo Real:** Una vez entrenado y validado, el modelo puede realizar predicciones o tomar decisiones en tiempo real basándose en nuevos datos.

Existen varios tipos de aprendizaje de máquina, incluyendo:

- **Aprendizaje Supervisado:** El modelo se entrena utilizando un conjunto de datos que incluye entradas y las respuestas correspondientes. El objetivo es aprender una función que mapee las entradas a las respuestas.
- **Aprendizaje No Supervisado:** El modelo se entrena con datos que no tienen respuestas etiquetadas. El objetivo es descubrir patrones, relaciones o estructuras en los datos.
- **Aprendizaje por Reforzamiento:** El modelo aprende tomando decisiones en un entorno y recibiendo retroalimentación en forma de recompensas o castigos. El objetivo es aprender a tomar acciones que maximicen las recompensas a lo largo del tiempo.

2.6.1 Máquinas de Soporte Vectorial.

Máquinas de Soporte Vectorial, SVM (Support Vector Machines) por sus siglas en inglés, es un algoritmo de aprendizaje supervisado utilizado para tareas de clasificación y regresión [30, 31]. La principal idea detrás de las SVM es encontrar un hiperplano en un espacio de alta dimensión que pueda separar eficientemente los datos de diferentes clases.

Algunos conceptos clave asociados con las SVM:

Hiperplano: En un espacio de dos dimensiones, un hiperplano es una línea que separa dos clases. En espacios de dimensiones superiores, es un subconjunto lineal que maximiza la separación entre clases.

Vectores de Soporte: Son los puntos de datos que están más cercanos al hiperplano y tienen una influencia significativa en la determinación del hiperplano óptimo.

Margen: Es la distancia perpendicular desde el hiperplano a los vectores de soporte más cercanos. El objetivo es maximizar este margen, lo que se traduce en una mejor generalización del modelo.

Función de Pérdida: En problemas de clasificación, se utiliza una función de pérdida que penaliza las clasificaciones incorrectas. El objetivo es minimizar esta función de pérdida.

Kernel: Las SVM pueden utilizar funciones de kernel para transformar el espacio de características y manejar relaciones no lineales entre las variables de entrada.

SVM es eficaz en espacios de alta dimensión y es particularmente útil cuando el número de dimensiones es mayor que el número de muestras. Además, debido a la capacidad de las SVM para manejar no linealidades mediante kernels [30, 31], son versátiles y pueden aplicarse a una variedad de problemas.

En situaciones del mundo real, es común necesitar espacios de hipótesis más intrincados que aquellos empleados por los discriminantes lineales. Las SVM tienen la capacidad de

identificar límites no lineales cuando las clases no son separables de manera lineal.

La principal motivación al emplear SVM en tareas de clasificación se centra en la eficacia de generalización y en la complejidad del clasificador, especialmente en lo que respecta a su aplicabilidad práctica.

Específicamente, al diseñar un sistema de clasificación, es natural buscar un rendimiento óptimo en el conjunto de prueba en lugar del conjunto de entrenamiento. El objetivo es que el clasificador converja hacia un óptimo global en lugar de quedarse en una posición óptima local. En este contexto, también es crucial abordar el problema de sobreajuste. Surge un dilema en cuanto a la cantidad de muestras de entrenamiento: el uso excesivo podría resultar en un sobreajuste del clasificador, mientras que muy pocas muestras podrían no proporcionar suficiente cobertura estadística para diversas situaciones. Ambas situaciones conducen a un rendimiento deficiente en la generalización, es decir, malos resultados al evaluar el modelo con el conjunto de prueba.

Además, se plantea una preocupación respecto a la complejidad computacional. Aunque los clasificadores bayesianos son métodos elegantes que emplean distribuciones de probabilidad a posteriori, el costo computacional se vuelve prohibitivamente alto cuando la dimensión de las características es considerable. Esta dificultad a menudo limita la viabilidad práctica de los clasificadores bayesianos.

Una SVM ofrece una solución adecuada a estos problemas al minimizar el error de generalización en la prueba. La creación de una SVM puede entenderse como la resolución de un problema de optimización con restricciones.

Cuando aplicamos una SVM, hace falta calcular el hiperplano óptimo. Cuando hablamos del hiperplano óptimo, nos estamos refiriendo al hiperplano que maximiza la distancia entre los datos que estamos intentando clasificar. En nuestro ejemplo, el cálculo de este hiperplano se realizará como una recta, como se muestra a continuación:

$$h(x) = wx + b = 0 \quad (2.13)$$

Donde:

$h(x)$ = hiperplano

w = vector de peso

x = vector de entrada

b = sesgo

Es evidente que esta función debería devolver un valor de 0 en todos los casos que recibe con esos parámetros, ya que el 0 indica que esos puntos están ubicados en el hiperplano. Si el resultado es positivo o negativo, significa que los puntos no se encuentran en el hiperplano, sino en la región de una de las dos clases que estamos tratando de clasificar. Sin embargo, trazar simplemente una recta para separar nuestros datos no es suficiente para encontrar nuestro hiperplano óptimo. Es en este punto donde los vectores de soporte desempeñarán un papel crucial en la consecución de este objetivo. La función de los vectores de soporte consiste en delimitar tres áreas: el área positiva, el área negativa y la región conocida como la frontera de decisión, como se puede apreciar en la Figura 2.18.

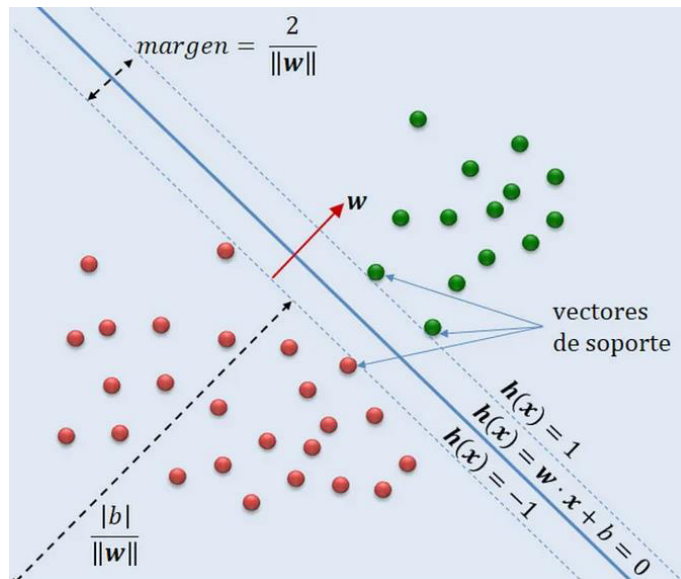


Figura 2.18 Máquina de Soporte Vectorial

2.6.2 Redes Neuronales.

Una red neuronal [77], según la descripción de Hecht-Nielsen [32], se define como una "estructura de procesamiento de información paralela y distribuida", compuesta por elementos de procesamiento conectados entre sí mediante canales unidireccionales de información. Cada elemento de procesamiento establece conexiones de salida con diversas ramificaciones que llevan la misma señal. Esta señal de salida se presenta en una forma matemática específica. Todo el procesamiento realizado en un elemento es completamente local, lo que significa que depende únicamente de los valores actuales de las entradas al elemento y de posibles valores almacenados en su memoria local.

2.6.2.1 Definición y Estructura:

- **Definición:** Una red neuronal es un modelo computacional inspirado en la estructura y funcionamiento del cerebro humano.
- **Estructura Básica:** Está compuesta por nodos (neuronas) interconectados, organizados en capas (entrada, oculta, salida) como se observa en la Figura 2.19.

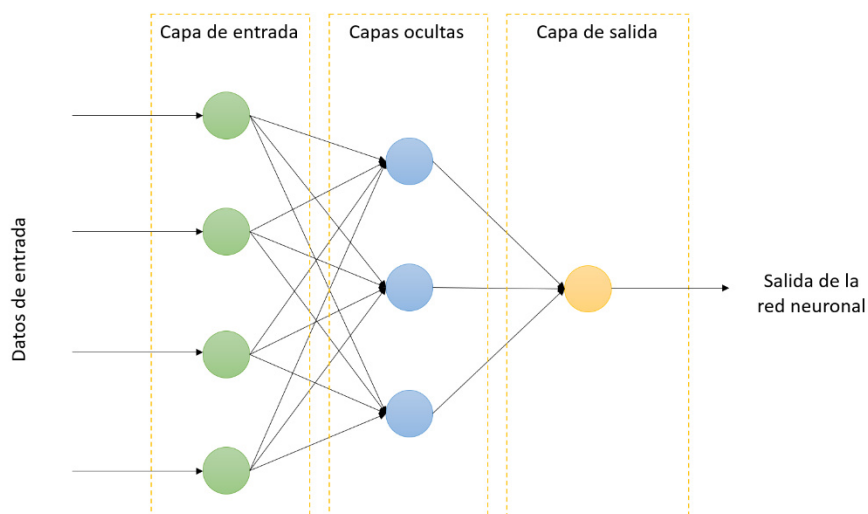


Figura 2.19 Estructura básica de una red neuronal

- **Conexiones Ponderadas:** Cada conexión entre neuronas tiene un peso que determina su influencia.

2.6.2.2 Neurona Artificial:

- **Función de Activación:** Las neuronas realizan una combinación lineal de sus entradas, seguida de una función de activación no lineal (como la función sigmoide o tangente hiperbólica). En el caso de las neuronas artificiales [78], la suma de las entradas multiplicadas por sus pesos asociados determina el “impulso nervioso” que recibe la neurona. Este valor, se procesa en el interior de la célula mediante una función de activación que devuelve un valor que se envía como salida de la neurona, Figura 2.20.




Figura 2.20 Función de activación en una neurona artificial

2.6.2.3 Capas y Tipos de Redes:

- **Capa de Entrada:** Recibe las señales de entrada.

- **Capa Oculta:** Procesa información interna.
- **Capa de Salida:** Produce las predicciones o resultados.
- **Redes Feedforward (Estáticas):** La información se mueve en una dirección, sin ciclos, propagación hacia adelante. Figura 2.19. Ejemplos de este tipo son: Perceptrón multicapa, Redes neuronales convolucionales [77], Redes RBF
- **Redes Recurrentes:** Permiten conexiones retroactivas, útiles para secuencias temporales. Parte de salida se retroalimenta a la entrada, son redes neuronales dinámicas [79]. Figura 2.20. Ejemplos de este tipo son: Memoria asociativa de Hopfield Figura 2.21, Boltzman machine, Red recurrente de Elman, LSTM (Memoria a largo-corto plazo).

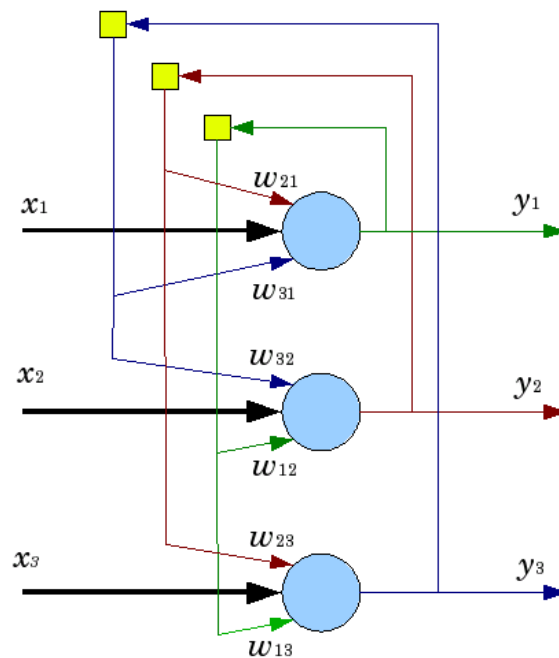


Figura 2.21 Red recurrente Hopfield con tres neuronas

2.6.2.4 Aprendizaje:

- **Aprendizaje Supervisado:** Se entrena con ejemplos etiquetados.
- **Aprendizaje No Supervisado:** Encuentra patrones sin etiquetas externas.

- **Aprendizaje Reforzado:** Aprende mediante la retroalimentación de recompensas o penalizaciones [80].

2.6.2.5 Entrenamiento y Retropropagación del Error:

- **Algoritmo de Retropropagación:** Entrenar una red neuronal consiste en ajustar cada uno de los pesos de las entradas de todas las neuronas que forman parte de la red neuronal, para que las respuestas de la capa de salida se ajusten lo más posible a los datos que conocemos [81][82].

2.6.2.6 Funciones de Pérdida y Optimización:

- **Función de Pérdida:** También conocidas como funciones de costo o error, evalúan la discrepancia entre las predicciones del modelo y las salidas deseadas (etiquetas) durante el entrenamiento. El objetivo es minimizar esta pérdida para mejorar la capacidad predictiva del modelo [83].
- **Optimización:** Son algoritmos que ajustan los pesos y sesgos de las conexiones en la red para minimizar la función de pérdida. Estos algoritmos controlan cómo se actualizan los pesos durante el entrenamiento [84].

2.6.2.7 Funciones de Activación:

Se aplican a la salida de cada neurona en la red y son responsables de introducir no linealidades en el modelo. Esto permite a la red aprender patrones más complejos y realizar tareas más allá de la capacidad de una combinación lineal simple. Las funciones de activación [85] (o funciones de transferencia para sistemas lineales) son usualmente funciones no lineales. Para una función de activación lineal, una neurona sólo puede hacer regresión o clasificación lineales. En cambio, para una función de activación no lineal, una neurona puede hacer regresión no lineal y clasificación de patrones no linealmente separables. Cuando se usa una función de activación sigmoide, la salida se puede interpretar como probabilidad o como una respuesta SI/NO o decisión binaria. Sin embargo, la saturación de la sigmoide

puede causar el problema del desvanecimiento del gradiente en redes deep (redes profundas). Reemplazando la sigmoide por funciones de activación como ReLU fue lo que permitió en 2012 entrenar por primera vez redes deep.

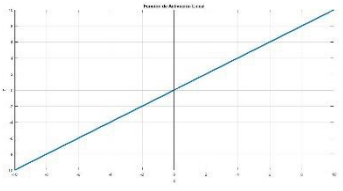
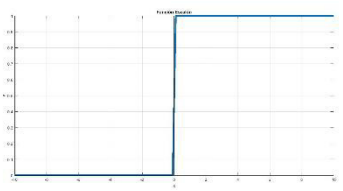
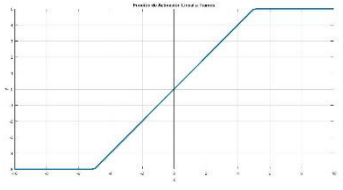
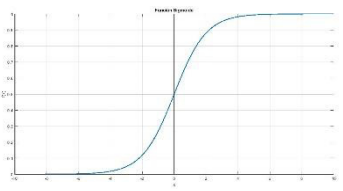
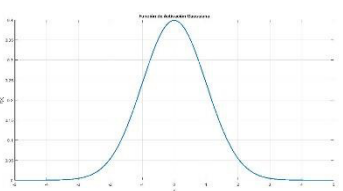
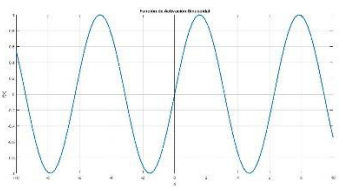
	Función	Rango	Gráfica
Lineal	$y = x$	$[-\infty, +\infty]$	
Escalón	$y = \text{sign}(x)$ $y = H(x)$	$\{-1, +1\}$ $\{0, +1\}$	
Lineal a tramos	$y = \begin{cases} -1, & \text{si } x < -l \\ x, & \text{si } -l \leq x \leq l \\ +1, & \text{si } x > l \end{cases}$	$[-1, +1]$	
Sigmoidea	$y = \frac{1}{1 + e^{-x}}$ $y = \text{tgh}(x)$	$[0, +1]$ $[-1, +1]$	
Gaussiana	$y = Ae^{-Bx^2}$	$[0, +1]$	
Sinusoidal	$y = A \text{sen}(\omega x + \varphi)$	$[-1, +1]$	

Tabla 1 Funciones de activación más usuales

2.6.2.8 Regularización y Generalización:

- **Regularización:** Evita el sobreajuste mediante penalizaciones en los pesos [86].
- **Generalización:** Busca que el modelo se desempeñe bien en datos no vistos.

2.6.2.9 Arquitecturas Específicas:

- **Redes Neuronales Convolucionales (CNN):** Diseñadas para datos con estructura de cuadrícula, como imágenes [87].
- **Redes Neuronales Recurrentes (RNN):** Adecuadas para datos secuenciales o de series temporales [79].

3 Capítulo 3.

3.1 Metodología del Proyecto.

En este capítulo se describe la evolución del proyecto, como se puede apreciar en la Figura 3.1, que implica la implementación y fusión de los principios abordados previamente. Se inicia con una exposición detallada del proceso de preprocesamiento de las señales, con el propósito de identificar atributos específicos en aquellas señales afectadas por perturbaciones. Este paso es crucial para clasificar cada señal y facilitar un diagnóstico.



Figura 3.1 Plan de trabajo realizado

3.2 Creación de base de datos a partir de modelos matemáticos de las perturbaciones.

Las perturbaciones en la calidad de energía (PQ por sus siglas en inglés), que conllevan problemas significativos en industrias y redes eléctricas, abarcan una amplia gama de fenómenos electromagnéticos que definen el comportamiento del voltaje y la corriente en momentos y lugares específicos dentro del sistema eléctrico [33]. La detección precisa y la clasificación efectiva de estas perturbaciones son fundamentales para mitigar los desafíos asociados. En este contexto, el primer paso de investigación en este estudio implica la obtención de diversas señales distorsionadas para evaluar los sistemas de clasificación. En este proyecto, se llevó a cabo la generación de señales mediante la implementación de

modelos matemáticos previamente establecidos [14] utilizando MATLAB. En la Tabla 2 se detallan los modelos matemáticos de las perturbaciones empleadas en nuestro proyecto, seleccionadas como referencia para comparación con investigaciones previas. Dada la flexibilidad de la programación, se logra ajustar diversos parámetros, como la frecuencia de muestreo, ciclos capturados y amplitud básica, entre otros. Esto facilita la generación de señales bajo diversas condiciones, proporcionando un enfoque integral para evaluar los sistemas de clasificación en diferentes situaciones operativas. Adicionalmente, se incorporaron niveles variables de ruido a las señales, aumentando así la robustez de las pruebas realizadas.

3.3 Aplicación de las Técnicas de análisis espectral.

La aplicación de diversas técnicas de análisis espectral a la base de datos de perturbaciones eléctricas generada cumple múltiples propósitos fundamentales. En primer lugar, estas técnicas tienen como objetivo principal caracterizar las señales, desentrañando la distribución de frecuencias y su evolución temporal. Este proceso permite revelar patrones espectrales únicos asociados con diferentes tipos de perturbaciones eléctricas presentes en la base de datos. Además, el análisis espectral busca extraer características significativas de las señales, proporcionando información valiosa para un entendimiento más profundo de las perturbaciones. En términos de clasificación, estas técnicas ofrecen una representación en el dominio de la frecuencia que sirve como entrada clave para los algoritmos de clasificación. Esto facilita la diferenciación precisa entre diversos tipos de perturbaciones eléctricas, contribuyendo así a la mejora del rendimiento de los sistemas de clasificación implementados. Cabe destacar que, tras la obtención de la base de datos, se procedió a aplicar específicamente las técnicas de análisis espectral de la transformada wavelet, transformada constante-Q, transformada de Fourier, transformada corta de Fourier y la transformada wavelet Synchrosqueezing. Estas técnicas se seleccionaron con el fin de aprovechar sus capacidades particulares en la revelación y caracterización de patrones espectrales, proporcionando así una evaluación exhaustiva y detallada de las perturbaciones eléctricas presentes en la base de datos.

Perturbación	Ecuación	
Señal normal	$y(t) = A \sin(\omega t - \varphi)$	
Sag	$y(t) = A \left(1 - \alpha(u(t - t_1) - u(t - t_2))\right) \sin(\omega t - \varphi)$	
Swell	$y(t) = A \left(1 + \beta(u(t - t_1) - u(t - t_2))\right) \sin(\omega t - \varphi)$	
Interrupción	$y(t) = A \left(1 + \rho(u(t - t_1) - u(t - t_2))\right) \sin(\omega t - \varphi)$	
Oscillatory transient	$y(t) = A[\sin(\omega t - \varphi) + \beta e^{-(t-t_I)/\tau} \sin(\omega_n(t - t_I) - \vartheta) ((u(t - t_{II}) - u(t - t_I)))]$	
Harmónicos	$y(t) = A[\sin(\omega t - \varphi) + \sum_{n=3}^7 \alpha_n \sin(n\omega t - \vartheta_n)]$	
Harmonics with sag	$y(t) = A \left(1 - \alpha(u(t - t_1) - u(t - t_2))\right) \left[\sin(\omega t - \varphi) + \sum_{n'=3}^5 \alpha_{n'} \sin(n'\omega t - \vartheta_{n'})\right]$	
Harmonics with swell	$y(t) = A \left(1 + \beta(u(t - t_1) - u(t - t_2))\right) \left[\sin(\omega t - \varphi) + \sum_{n'=3}^5 \alpha_{n'} \sin(n'\omega t - \vartheta_{n'})\right]$	
Flicker	$y(t) = A[1 + \lambda \sin(\omega_f t)] \sin(\omega t - \varphi)$	
Notch	$y(t) = A[\sin(\omega t - \varphi) - \text{sign}(\sin(\omega t - \varphi)) \sum_{n=0}^{N \cdot c - 1} k(u(t - (tc + s \cdot n)) - u(t - (td + s \cdot n)))]$	
Parámetros de los modelos utilizados		
<p>General:</p> $w = 2\pi f, -\pi \leq \varphi \leq \pi$	<p>Sag/Swell/Interrupción:</p> $T \leq t_2 - t_1 \leq (N - 1)T$ $0.1 \leq \alpha \leq 0.9$ $0.1 \leq \beta \leq 0.8$ $0.9 \leq \rho \leq 1.0$	<p>Flicker:</p> $0.05 \leq \lambda \leq 0.1$ $8 \leq f_f \leq 25\text{Hz}; \omega_f = 2\pi f_f$
$u(t) = \begin{cases} 0 & t < 0 \\ 1 & t \geq 0 \end{cases}$ N: número de ciclos A: amplitud normal fs: frecuencia de muestreo f: frecuencia fundamental	<p>Oscillatory transient:</p> $300 \leq f_n \leq 900\text{Hz}; \omega_n = 2\pi f_n; 8\text{ms} \leq \tau \leq 40\text{ms}$ $-\pi \leq \vartheta \leq \pi; 0.5T \leq t_{II} - t_I \leq \frac{N}{3.33}T$	<p>Harmonics:</p> $n = \{3, 5, 7\}; 0.05 \leq \alpha_n \leq 0.15$ $-\pi \leq \vartheta_n, \vartheta_{n'} \leq \pi$ $n' = \{3, 5\}; 0.05 \leq \alpha_{n'} \leq 0.15$
Notch: $0.01T \leq t_d - t_c \leq 0.05T; t_d \leq s; t_c \geq 0; 0.1 \leq k \leq 0.4; c = \{1, 2, 4, 6\}; s = \frac{T}{c}$		

Tabla 2 Modelos matemáticos de las perturbaciones utilizadas.

3.3.1 Aplicación de la Transformada Constante-Q.

Le aplicamos a nuestra base de datos un análisis espectral, implementando la Transformada Constante-Q, utilizando la función "cqt" en MATLAB. Previamente a la aplicación de esta función, configuramos diversos parámetros como la frecuencia de muestreo y los límites de frecuencia. La función generó la CQT de la señal de entrada. Como la señal de entrada fue un vector, la función devolvió una matriz que representó la CQT. Ya que, en el caso de ser una matriz como señal de entrada, se debería obtener la CQT para cada columna (canal independiente). El resultado fue un conjunto de datos multidimensional que representó la versión máximamente redundante de la CQT.

Cada fila en las páginas de esta representación corresponde a bandas de paso con frecuencias centrales normalizadas (ciclos/muestra) dispuestas de manera logarítmica entre 0 y 1. Una frecuencia normalizada de 1/2 se alinea con la frecuencia de Nyquist. La cantidad de columnas, o pasos, está asociada a la frecuencia central de ancho de banda más elevada, generalmente ubicada una frecuencia binaria antes o después de la frecuencia de Nyquist.

Después de aplicar la función en el algoritmo descrito en la Figura 3.2, se generaron matrices que representan la Transformada de Constante-Q (CQT) para cada señal en la base de datos. Estas matrices resultantes fueron posteriormente analizadas para extraer características estadísticas y de tiempo-frecuencia, las cuales se detallan en la Tabla 3. Este análisis se llevó a cabo con el propósito de clasificar las señales afectadas por perturbaciones, utilizando las herramientas de clasificación proporcionadas por el software de Matlab.

```

for x = 1:N
    % Acceder a la i-ésima tabla y realizar alguna operación en ella
    all_signal = data(x).tabla;
for i = 1:ns
    c=c+1;

    CQT=(cqt(all_signal(i,:))); %Uso de la funcion cqt
    CQT_signal = abs(CQT);

    % Características estadísticas

    Media(i,1)= mean(CQT_signal(:));
    Varianza(i,1)= var(CQT_signal(:));
    Sesgo(i,1)=skewness(CQT_signal(:));
    Kurt(i,1)= kurtosis(CQT_signal(:));

```

Figura 3.2 Obtención de la Transformada Constante-Q

3.3.2 Aplicación de la Transformada de Fourier.

En la realización de este estudio, se empleó la técnica de análisis espectral conocida como la Transformada de Fourier para identificar y caracterizar perturbaciones eléctricas en nuestra base de datos de señales. Esta transformada nos permitió descomponer las señales en sus componentes de frecuencia. La aplicación práctica de la Transformada de Fourier se llevó a cabo mediante el uso del software MATLAB, donde se empleó específicamente la función “fft”, como se puede apreciar en la porción de algoritmo de la Figura 3.3. Esta función realiza la Transformada de Fourier de Tiempo Discreto (DFT), permitiendo analizar la distribución espectral de las señales eléctricas. Tras la aplicación de la técnica y la obtención de los resultados, se derivaron una serie de características estadísticas y de tiempo-frecuencia, las cuales se detallan en la Tabla 3. Estas características fueron utilizadas en el proceso de clasificación de las señales, posibilitando la identificación y caracterización de las perturbaciones eléctricas bajo investigación.

```

    % Usar un ciclo para acceder a cada tabla en la matriz de la base de datos

for x = 1:N
    % Acceder a la i-ésima tabla y realizar alguna operación en ella
    all_signal = data(x).tabla;

for i = 1:ns
    c=c+1;

    FT_signal = abs(fft(all_signal(i,:))); % Aplicacion de la funcion fft para
                                           % obtener la Transformada Discreta
                                           % de Fourier

    % Características estadísticas

    Media(i,1)= mean(FT_signal(:));
    Varianza(i,1)= var(FT_signal(:));

```

Figura 3.3 Obtención de la Transformada Discreta de Fourier

3.3.3 Aplicación de la Transformada Corta de Fourier.

En nuestro trabajo de tesis, también empleamos la técnica de análisis espectral conocida como Transformada Corta de Fourier (STFT) para investigar las señales de la base de datos afectadas por perturbaciones eléctricas. La aplicación de la STFT, realizada de manera práctica a través del software MATLAB mediante la función “stft” como se puede observar en la porción de código de la Figura 3.4, nos permitió llevar a cabo un análisis detallado de la variación de frecuencia a lo largo del tiempo en estas señales. Posteriormente, extrajimos un conjunto de características estadísticas y de tiempo-frecuencia de los resultados obtenidos, las cuales se detallan en la Tabla 3. Estas resultaron fundamentales para el proceso de identificación de las perturbaciones eléctricas presentes en las señales analizadas, para realizar su clasificación.

```

% Usar un ciclo para acceder a cada tabla en la matriz de la base de datos

for x = 1:N

    % Acceder a la i-ésima tabla y realizar alguna operación en ella
    all_signal = data(x).tabla;

for i = 1:ns

    c=c+1;

    % Calcula la STFT a cada señal
    S=stft(all_signal(i,:),fs,'Window',kaiser(256,5),'OverlapLength',220,'FFTLenght',512);

    magnitud_S = abs(S);

    % Características estadísticas

    Media(i,1)= mean(magnitud_S(:));

```

Figura 3.4 Obtención de la STFT

3.3.4 Aplicación de la Transformada Wavelet.

Para la aplicación de la transformada wavelet, como una técnica de análisis espectral a nuestra base de datos se utilizó la función “wavedec”. Esta función en MATLAB devuelve la descomposición wavelet de la señal unidimensional x (señal de entrada) en el nivel n (número de niveles de descomposición) utilizando una de las wavelets conocidas. La estructura de descomposición de salida consta del vector de descomposición wavelet C y el vector de registro L , que contiene el número de coeficientes por nivel. El vector de registro L se utiliza para analizar los coeficientes en el vector de descomposición wavelet C por nivel. El vector de descomposición y el vector de registro están organizados como se muestra en la Figura 3.5 en un diagrama de descomposición de nivel 3.

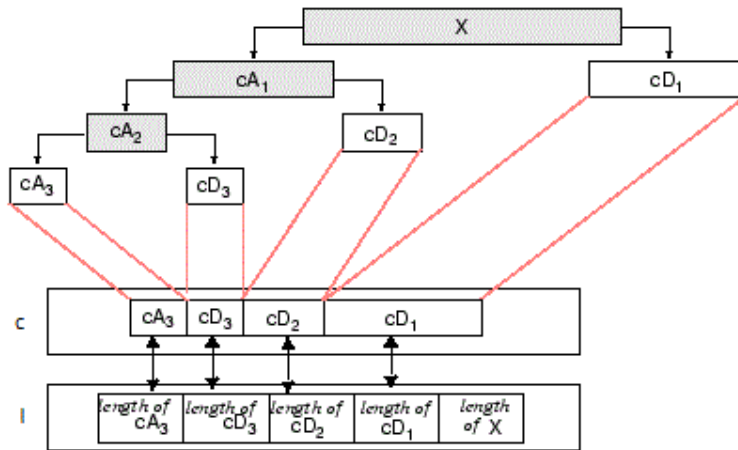


Figura 3.5 Diagrama de descomposición nivel

Luego de aplicar dicha función en el algoritmo que se presenta en la Figura 3.6 se obtienen los coeficientes de aproximación y detalle [25].

```

for x = 1:Nc          % Para iterar en todas las clases, que son las diferentes perturbaciones

    % Acceder a la i-ésima tabla y realizar alguna operación en ella
    all_signal = data(x).tabla;

for k = 1:ns        % Para iterar en todas las senales de cada clase

    c=c+1;

    % Seleccionar que Wavelet se le aplicara las senales

    wavelet='db1';   % Con esta wavelet se obtuvieron los mejores resultados
    %wavelet='sym1';
    %wavelet='coif1';

    n=3;
    [C, L] = wavedec(all_signal(k,:), n, wavelet); % Utilizacion de la funcion wavedec

    % Coeficientes de aproximación y detalle
    approx = appcoef(C, L, wavelet, n);
    details = detcoef(C, L, n);

```

Figura 3.6 Aplicación de la función wavedec

Coefficientes de Aproximación: Los coeficientes representan la parte suavizada de la señal a una escala más baja. Son resultado de la combinación de información de frecuencias más bajas y suelen capturar las características generales de la señal.

Coefficientes de Detalle: Estos coeficientes representan los detalles finos o las características de alta frecuencia presentes en la señal. Cada nivel de descomposición proporciona un conjunto de coeficientes de detalle que capturan las variaciones más finas en la señal.

En el ámbito de la detección de perturbaciones en señales eléctricas, las alteraciones suelen manifestarse a través de cambios rápidos y abruptos en la forma de onda, evidenciándose en componentes de alta frecuencia. En consecuencia, nos centramos en los coeficientes de detalle para capturar de manera efectiva la información asociada con estas perturbaciones. Posteriormente, utilizamos este conjunto de coeficientes para derivar un conjunto de características estadísticas y de tiempo-frecuencia, detalladas en la Tabla 3. Estas características se emplearon para llevar a cabo la clasificación de las señales, permitiéndonos identificar y caracterizar las perturbaciones eléctricas en estudio.

Conjunto de características estadísticas			
(1) Media	$\mu = \frac{1}{N} \sum_{n=1}^N x(n)$	(2) Varianza	$\sigma = \frac{1}{N} \sum_{n=1}^N (x(n) - \mu)^2$
(3) Sesgo	$\gamma = \frac{1}{N\sigma^3/2} \sum_{n=1}^N (x(n) - \mu)^3$	(4) Kurtosis	$k = \frac{1}{N\sigma^2} \sum_{n=1}^N (x(n) - \mu)^4$
(5) Suma de las amplitudes logarítmicas	$SLA = \sum_{n=1}^N \log(x(n))$	(6) Desviación media absoluta	$MAD = \frac{1}{N} \sum_{n=1}^N x(n) - \mu $
(7) Valor cuadrático medio	$RMSV = \sqrt{\frac{\sum_{n=1}^N x(n)^2}{N}}$	(8) Valor medio absoluto	$MAV = \frac{1}{N-1} \sum_{n=1}^N x(n+1) - x(n) $
(9) Máximo	$max = \max(x_1, x_2, x_3, \dots, x_n)$	(10) Mínimo	$min = \min(x_1, x_2, x_3, \dots, x_n)$
(11) Desviación Estándar	$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2}$		
Conjunto de características tiempo-frecuencia			
(12) Aplanamiento	$FLS = N \frac{\prod_{n=1}^N (x(n))^{\frac{1}{N}}}{\sum_{n=1}^N (x(n))^{\frac{1}{N}}}$	(13) Desviación espectral	$SRO = \lambda \sum_{n=1}^N x(n), \lambda = 0.85$
(14) Entropía Renyi normalizada	$NRE = \frac{1}{1-v} \log_2 \sum_{n=1}^N \left(\frac{x(n)}{N\mu} \right)^v, v = 3$	(15) Concentración de energía	$EC = \left[\sum_{n=1}^N \sqrt{ x(n) } \right]^2$
(16) Homogeneidad	$HOMO = \frac{1}{N-1} \sum_{n=1}^N \frac{1}{1 + x(n+1) - x(n) }$		

Tabla 3 Características estadísticas y de tiempo-frecuencia aplicadas a las señales.

3.3.5 Aplicación de la Transformada Wavelet Synchrosqueezing.

En este caso utilizamos la técnica de análisis espectral conocida como Transformada Wavelet Synchrosqueezing, mediante el software MATLAB, aprovechando la función “wsst” proporcionada por la plataforma, mediante la porción de algoritmo que podemos apreciar en la Figura 3.7. La WSST presenta una reducción en la difusión de energía en comparación con la transformada wavelet continua. La entrada, debe ser una señal unidimensional de valores reales con al menos cuatro muestras. La función “wsst” calcula la transformada synchrosqueezing utilizando la wavelet analítica de Morlet. Esta función nos permitió realizar un análisis detallado de las características tiempo-frecuencia de las señales con mayor precisión. Posteriormente, extrajimos un conjunto de características estadísticas y de tiempo-frecuencia de los resultados obtenidos con la función “wsst”. Estas características las utilizamos para realizar la clasificación de las señales de nuestra base de datos.

```
for x = 1:N
    % Acceder a la i-ésima tabla y realizar alguna operación en ella
    all_signal = data(x).tabla;

    for k = 1:ns
        c=c+1;

        % Calcular WSST a cada señal
        wsst_results = wsst(all_signal(k,:), fs);
```

Figura 3.7 Aplicación de la Transformada Wavelet Synchrosqueezing

3.4 Clasificación de las características obtenidas.

Una vez obtenidas las características después de la aplicación de las siguientes técnicas de análisis espectral, la transformada Wavelet, transformada de la constante Q, transformada de Fourier, transformada corta de Fourier y la transformada Wavelet Synchrosqueezing, cada una de estas para todas las señales eléctricas, se procedió a su clasificación utilizando métodos de aprendizaje automático implementados en MATLAB. Este proceso implica la identificación del método de clasificación más adecuado para el conjunto particular de características extraídas. A continuación, se describen los pasos realizados:

3.4.1 Obtención de características.

Se utilizaron técnicas de análisis espectral en las señales eléctricas para identificar y recopilar un conjunto significativo de características. Estas características proporcionan información detallada sobre la distribución de frecuencias y otras propiedades espectrales de las señales. Se clasifican en dos grupos principales: características estadísticas y características de tiempo-frecuencia, como se muestra en la Tabla 3.

3.4.2 Preparación de datos

Las características obtenidas fueron organizadas en una matriz de datos, donde cada fila representa una muestra de señal y cada columna representa una característica específica. Como se puede apreciar en la Figura 3.8 donde están ploteadas las características de las señales afectadas por las perturbaciones, después de aplicar la técnica de la Transformada Corta de Fourier y las señales sin ruido. Cada matriz contiene 1500 señales en total, distribuidas en 150 señales por cada una de las 10 perturbaciones. Es importante destacar que, para cada técnica de análisis espectral aplicada, se dispuso de una matriz separada que contiene las señales afectadas por diferentes niveles de ruido, así como señales sin ruido.




Figura 3.8 Gráfica 3D de las diez perturbaciones al aplicar la STFT

3.4.3 Clasificación con MATLAB

Se utilizó la aplicación Classification Learner, que es una herramienta poderosa para entrenar modelos y clasificar datos utilizando técnicas de aprendizaje automático supervisado. En la figura 3.8 se puede apreciar el ambiente de esta App de Matlab.

3.4.4 Exploración de datos

La aplicación permitió explorar el conjunto de datos, entender su estructura e identificar características y etiquetas potenciales.

3.4.5 Selección de características

Se pudieron seleccionar características relevantes del conjunto de datos para ser utilizadas en el entrenamiento de los modelos de clasificación. La selección de características es crucial para mejorar el rendimiento y la eficiencia de los modelos.

3.4.6 Esquemas de validación

La aplicación proporciona diversos esquemas de validación para evaluar el rendimiento de los modelos entrenados, como validación cruzada, validación de retención y validación con conjuntos de datos independientes.

3.4.7 Entrenamiento de modelos

Se pueden elegir entre una variedad de algoritmos de clasificación disponibles en la aplicación, incluidos árboles de decisión, análisis discriminante, máquinas de vectores de soporte, regresión logística, vecinos más cercanos, clasificación bayesiana, métodos de conjunto y clasificación de redes neuronales. La aplicación facilitó el entrenamiento de estos modelos en las características y etiquetas seleccionadas.

3.4.8 Entrenamiento automatizado

La aplicación ofrece funcionalidad de entrenamiento automatizado, lo que nos permitió buscar automáticamente el mejor tipo de modelo de clasificación. Esto nos ahorró tiempo y esfuerzo al identificar el modelo más adecuado para el conjunto de datos sin intervención manual.

3.4.9 Evaluación de resultados

Después de entrenar los modelos, pudimos evaluar el rendimiento de cada modelo utilizando métricas de evaluación como precisión, recall, puntuación F1, curvas ROC y matrices de confusión.

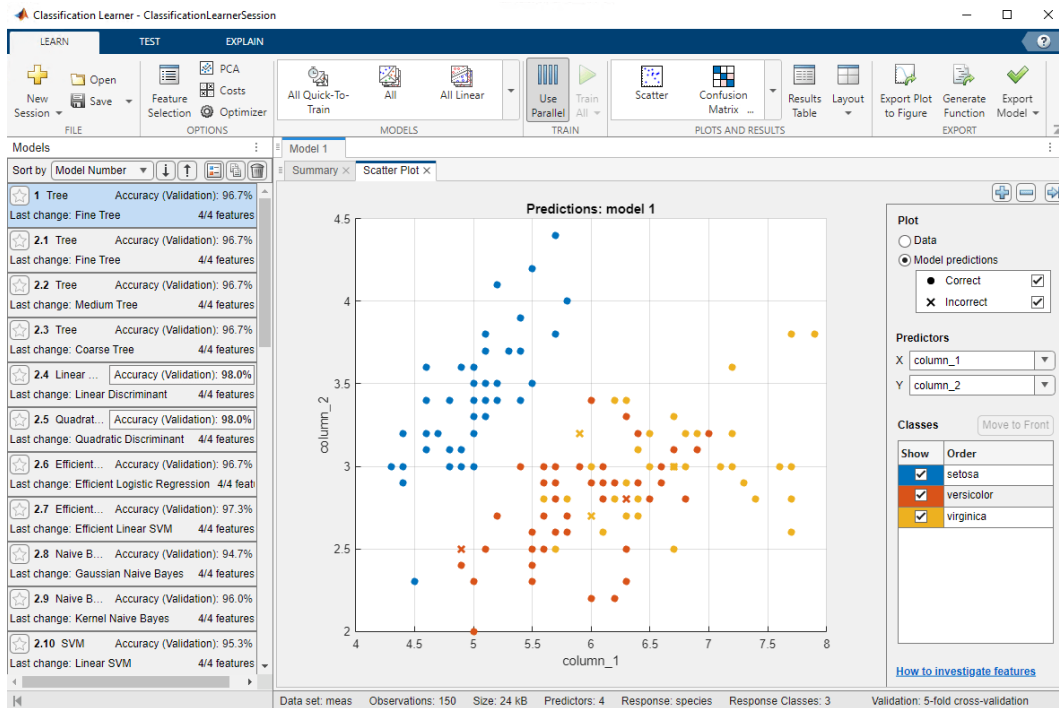


Figura 3.9 Ambiente de la APP Classification Learner de Matlab

3.4.10 Evaluación del rendimiento

Cada método de clasificación se evaluó utilizando técnicas de validación cruzada para estimar su rendimiento en términos de precisión, sensibilidad, especificidad y otras métricas relevantes. Se buscó identificar el método que proporcionara los mejores resultados de clasificación para las características específicas de las señales eléctricas.

3.4.11 Selección del mejor método

Finalmente, se seleccionó el método de clasificación que demostró el mejor rendimiento en la tarea de clasificación de las señales eléctricas basado en las características extraídas.

4 Capítulo 4

4.1 Pruebas y Resultados

En este capítulo se presentan los resultados de la investigación, destacando el análisis numérico y la clasificación de perturbaciones realizados mediante el software MATLAB. Este enfoque proporcionó una comprensión detallada de los datos recopilados, permitiendo la identificación de patrones significativos y la caracterización precisa de las perturbaciones estudiadas. Estos resultados son esenciales para alcanzar el objetivo central de la investigación y proporcionan valiosa información para estudios futuros.

4.2 Prueba 1. Técnica transformada constante-Q sin SNR

La base de datos utilizada consta de 1500 señales (filas) con 16 características (columnas) estadísticas y de tiempo-frecuencia. Las cuales son las siguientes, media, varianza, sesgo, kurtosis, suma de las amplitudes logarítmicas, desviación media absoluta, valor cuadrático medio, valor medio absoluto, máximo, mínimo, desviación estándar, aplanamiento, desviación espectral, entropía renyi normalizada, concentración de energía y homogeneidad. Las clases corresponden a 10 perturbaciones eléctricas las cuales son señal normal, interrupción, hueco de tensión, pico de tensión, transitorio oscilatorio, armónicos, parpadeo, muesca, armónicos con hueco de tensión y armónicos con pico de tensión. Todas se analizan sin ruido, con SNR (relación señal-ruido) de 40 dB, 30 dB y 10 dB, lo que permite evaluar el rendimiento de los modelos de clasificación en condiciones realistas. Hay que destacar que de este modo fueron 150 señales de cada perturbación eléctrica las que se estudiaron, además de sus diferentes niveles de ruido, lo que indica que la base de datos es balanceada. Tanto el entrenamiento como la prueba de los modelos de clasificación de aprendizaje automático se hacen utilizando la Apps Classification Learner proporcionada por el software Matlab, donde de forma automática se clasifican las clases en todos los modelos y se obtienen los mejores

resultados de cada técnica aplicada.

En esta primera prueba se realizó todo lo descrito anteriormente después de aplicar la técnica de análisis espectral transformada constante-Q. Primeramente se realizó con las señales limpias sin ningún tipo de ruido SNR. Se puede apreciar en la Figura 4.1 el modelo después de obtenidas las características al aplicar la técnica, se graficó la varianza vs la media. Y en la Figura 4.2 se aprecia la matriz de confusión del modelo Cubic SVM, con la función kernel Cubic, un tiempo de entrenamiento de 43.22 segundos y un valor de Exactitud de 91.8 % que fue el de mejor resultado de todos los modelos evaluados para esta prueba.

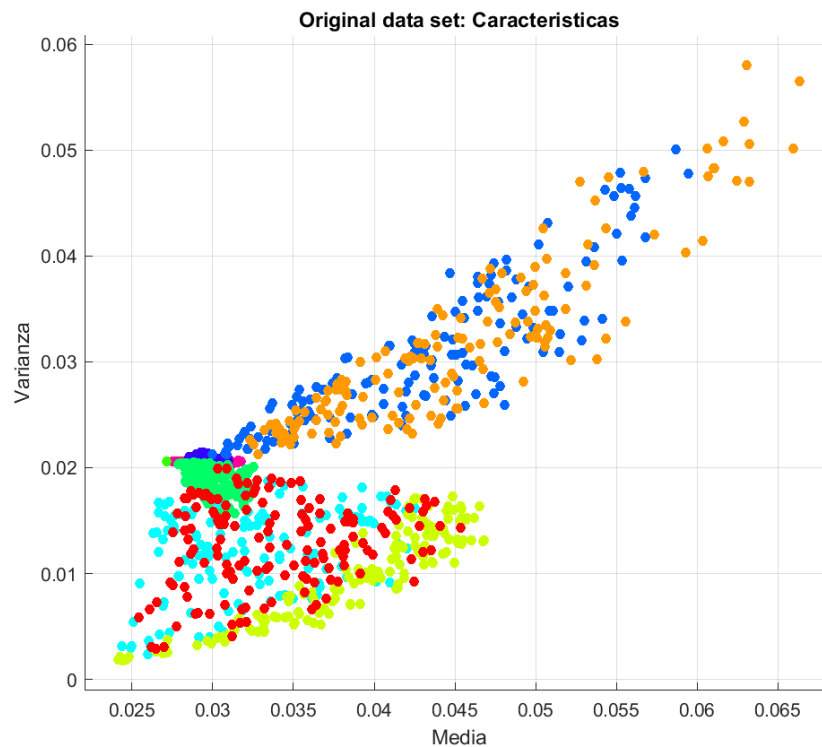


Figura 4.1 Gráfica de las características varianza vs media de la técnica transformada constante Q

Model 1.3

True Class	Harmonics_with_Sag	111		11		1	25				2	
	Harmonics_with_Swell		127					22	1			
	Interruption	7		138			5					
	Normal				150							
	Notch	1				149						
	Sag	21		8		1	120					
	Swell		14					132	4			
	flicker								150			
	harmonics									149	1	
	oscl_transient								4		146	
		Predicted Class										

Figura 4.2 Matriz de confusión del modelo Cubic SVM con la técnica transformada constante Q

4.3 Prueba 2. Técnica transformada constante-Q con 40 dB

En esta prueba se utilizó la técnica de análisis espectral transformada constante-Q. Se realizó con una relación señal- ruido SNR de 40 dB. Se puede apreciar en la Figura 4.3 el modelo después de obtenidas las características al aplicar la técnica, se graficó la varianza vs la media. Y en la Figura 4.4 se aprecia la matriz de confusión del modelo Cubic SVM, con la función kernel Cubic, un tiempo de entrenamiento de 43.89 segundos y un valor de Exactitud de 90.4 % que fue el de mejor resultado de todos los modelos evaluados para esta prueba.




Figura 4.3 Gráfica de las características varianza vs media de la técnica transformada constante Q con un SNR de 40 dB

Model 1

True Class	Harmonics_with_Sag 40dB	Harmonics_with_Swell 40dB	Interruption 40dB	Normal 40dB	Notch 40dB	Sag 40dB	Swell 40dB	flicker 40dB	harmonics 40dB	oscl_transient 40dB
Harmonics_with_Sag 40dB	107		15		2	24				2
Harmonics_with_Swell 40dB		129					19	2		
Interruption 40dB	2		140			8				
Normal 40dB				150						
Notch 40dB	2				148					
Sag 40dB	26		12		3	109				
Swell 40dB		10					136	4		
flicker 40dB								148		2
harmonics 40dB									148	2
oscl_transient 40dB								7		143

Predicted Class

Figura 4.4 Matriz de confusión del modelo Cubic SVM en la técnica transformada constante Q con un SNR de 40 dB

4.4 Prueba 3. Técnica transformada constante-Q con 20 dB

En esta prueba se utilizó la técnica de análisis espectral transformada constante-Q. Se realizó con una relación señal- ruido SNR de 20 dB. Se puede apreciar en la Figura 4.5 el modelo después de obtenidas las características al aplicar la técnica, se graficó la varianza vs la media. Y en la Figura 4.6 se aprecia la matriz de confusión del modelo Cubic SVM, con la función kernel Cubic, un tiempo de entrenamiento de 37.40 segundos y un valor de Exactitud de 90.0 % que fue el de mejor resultado de todos los modelos evaluados para esta prueba.




Figura 4.5 Gráfica de las características varianza vs media de la técnica transformada constante Q con un SNR de 20 dB

Model 1.10

True Class	Harmonics_with_Sag 20dB	111		14		4	18			1	2	
	Harmonics_with_Swell 20dB		129					20	1			
	Interruption 20dB	6		140			4					
	Normal 20dB				143	4					3	
	Notch 20dB	5			7	134	1		2		1	
	Sag 20dB	14		11		3	122					
	Swell 20dB		10					135	5			
	flicker 20dB								147		3	
	harmonics 20dB									149	1	
	oscl_transient 20dB				4	2			4		140	
		Predicted Class										

Figura 4.6 Matriz de confusión del modelo Cubic SVM en la técnica transformada constante Q con un SNR de 20 dB

4.5 Prueba 4. Técnica transformada constante-Q con 10 dB

En esta prueba se utilizó la técnica de análisis espectral transformada constante-Q. Se realizó con una relación señal- ruido SNR de 10 dB. Se puede apreciar en la Figura 4.7 el modelo después de obtenidas las características al aplicar la técnica, se graficó la varianza vs la media. Y en la Figura 4.8 se aprecia la matriz de confusión del modelo Medium Neural Network, con la activación ReLU, un tiempo de entrenamiento de 26.55 segundos y un valor de Exactitud de 80.5 % que fue el de mejor resultado de todos los modelos evaluados para esta prueba.




Figura 4.7 Gráfica de las características varianza vs media de la técnica transformada constante Q con un SNR de 10 dB

Model 1.26

Harmonics_with_Sag 10dB	105		13		1	30			1	
Harmonics_with_Swell 10dB		124					25			1
Interruption 10dB	10		135			5				
Normal 10dB				116	9			11		14
Notch 10dB	2			17	121			4		6
Sag 10dB	27		11			111		1		
Swell 10dB		21					126	3		
flicker 10dB				9	6	1	2	123		9
harmonics 10dB								1	144	5
oscl_transient 10dB				33	4			5	6	102
	Harmonics_with_Sag 10dB	Harmonics_with_Swell 10dB	Interruption 10dB	Normal 10dB	Notch 10dB	Sag 10dB	Swell 10dB	flicker 10dB	harmonics 10dB	oscl_transient 10dB

Predicted Class

Figura 4.8 Matriz de confusión del modelo Medium Neural Network en la técnica transformada constante Q con un SNR de 10 dB

4.6 Prueba 5. Técnica transformada de Fourier sin SNR

En esta prueba se utilizó la técnica de análisis espectral transformada de Fourier. Se realizó con las señales limpias sin ruido. Se puede apreciar en la Figura 4.9 el modelo después de obtenidas las características al aplicar la técnica, se graficó la varianza vs la media. Y en la Figura 4.10 se aprecia la matriz de confusión del modelo Medium Neural Network, con la activación ReLU, un tiempo de entrenamiento de 13.15 segundos y un valor de Exactitud de 97.2 % que fue el de mejor resultado de todos los modelos evaluados para esta prueba.




Figura 4.9 Gráfica de las características varianza vs media de la técnica transformada de Fourier

Model 1.26

True Class	Harmonics with Sag	141			1	4				1	3
	Harmonics with Swell		145				4				1
	Normal			150							
	Notch				149						1
	Sag	6				136				8	
	Swell		5				144	1			
	flicker						1	149			
	harmonics								150		
	interruption	1				2				147	
	oscl_transient		1					1		1	147
		Predicted Class									
		Harmonics with Sag	Harmonics with Swell	Normal	Notch	Sag	Swell	flicker	harmonics	interruption	oscl_transient

Figura 4.10 Matriz de confusión del modelo Medium Neural Network con la técnica transformada de Fourier

4.7 Prueba 6. Técnica transformada de Fourier con 40 dB

En esta prueba se utilizó la técnica de análisis espectral transformada de Fourier. Se realizó con una relación señal-ruido SNR de 40 dB. Se puede apreciar en la Figura 4.11 el modelo después de obtenidas las características al aplicar la técnica, se graficó la varianza vs la media. Y en la Figura 4.12 se aprecia la matriz de confusión del modelo Cubic SVM, con la función kernel Cubic, un tiempo de entrenamiento de 15.56 segundos y un valor de Exactitud de 92.9 % que fue el de mejor resultado de todos los modelos evaluados para esta prueba.




Figura 4.11 Gráfica de las características varianza vs media de la técnica transformada de Fourier con SNR de 40 dB

Model 1.10

Flicker_40dB	150									
Harmonics_40dB	1	149								
Harmonics_with_Sag_40dB			125	5	2	1		17		
Harmonics_with_Swell_40dB				133					17	
Interruption_40dB			3	143					4	
Notch_40dB			2		146	2				
Oscillatory_Transients_40dB				1	1	148				
Pure_Sin_40dB							150			
Sag_40dB			20		9	1			120	
Swell_40dB				20					130	
	Flicker_40dB	Harmonics_40dB	Harmonics_with_Sag_40dB	Harmonics_with_Swell_40dB	Interruption_40dB	Notch_40dB	Oscillatory_Transients_40dB	Pure_Sin_40dB	Sag_40dB	Swell_40dB

Predicted Class

Figura 4.12 Matriz de confusión de la transformada de Fourier con SNR de 40dB

4.8 Prueba 7. Técnica transformada de Fourier con 20 dB

En esta prueba se utilizó la técnica de análisis espectral transformada de Fourier. Se realizó con una relación señal-ruido SNR de 20 dB. Se puede apreciar en la Figura 4.13 el modelo después de obtenidas las características al aplicar la técnica, se graficó la varianza vs la media. Y en la Figura 4.14 se aprecia la matriz de confusión del modelo Medium Neural Network, con la activación ReLU, un tiempo de entrenamiento de 27.45 segundos y un valor de Exactitud de 86.0 % que fue el de mejor resultado de todos los modelos evaluados para esta prueba.




Figura 4.13 Gráfica de las características varianza vs media de la técnica transformada de Fourier con SNR de 20 dB

Model 1.26

True Class	Flicker_20dB	144					3	1		2	
	Harmonics_20dB	1	149								
	Harmonics_with_Sag_20dB		1	112		6				31	
	Harmonics_with_Swell_20dB				109					41	
	Interruption_20dB			3		144				3	
	Notch_20dB			4			132	4	4	6	
	Oscillatory_Transients_20dB	7					4	137	2		
	Pure_Sin_20dB						1	1	148		
	Sag_20dB			27		4	11			108	
	Swell_20dB	1			42						107
			Flicker_20dB	Harmonics_20dB	Harmonics_with_Sag_20dB	Harmonics_with_Swell_20dB	Interruption_20dB	Notch_20dB	Oscillatory_Transients_20dB	Pure_Sin_20dB	Sag_20dB
	Predicted Class										

Figura 4.14 Matriz de confusión del modelo Medium Neural Network en la técnica transformada de Fourier con SNR de 20 dB

4.9 Prueba 8. Técnica transformada de Fourier con 10 dB

En esta prueba se utilizó la técnica de análisis espectral transformada de Fourier. Se realizó con una relación señal-ruido SNR de 10 dB. Se puede apreciar en la Figura 4.15 el modelo después de obtenidas las características al aplicar la técnica, se graficó la varianza vs la media. Y en la Figura 4.16 se aprecia la matriz de confusión del modelo Medium Neural Network, con la activación ReLU, un tiempo de entrenamiento de 26.93 segundos y un valor de Exactitud de 74.2 % que fue el de mejor resultado de todos los modelos evaluados para esta prueba.




Figura 4.15 Gráfica de las características varianza vs media de la técnica transformada de Fourier con SNR de 10 dB

Model 1.26

Flicker_10dB	112				5	16	14	1	2	
Harmonics_10dB	1	145	1			3				
Harmonics_with_Sag_10dB		2	97		9	6			36	
Harmonics_with_Swell_10dB		2		99		1			48	
Interruption_10dB			8		141				1	
Notch_10dB	7		8			106	4	15	10	
Oscillatory_Transients_10dB	26	2				7	91	24		
Pure_Sin_10dB	17					4	1	128		
Sag_10dB			38		7	15		1	89	
Swell_10dB	2			43					105	
	Flicker_10dB	Harmonics_10dB	Harmonics_with_Sag_10dB	Harmonics_with_Swell_10dB	Interruption_10dB	Notch_10dB	Oscillatory_Transients_10dB	Pure_Sin_10dB	Sag_10dB	Swell_10dB

Predicted Class

Figura 4.16 Matriz de confusión del modelo Medium Neural Network en la técnica transformada de Fourier con SNR de 10 dB

4.10 Prueba 9. Técnica transformada corta de Fourier sin SNR

En esta prueba se utilizó la técnica de análisis espectral transformada corta de Fourier. Se realizó con las señales limpias. Se puede apreciar en la Figura 4.17 el modelo después de obtenidas las características al aplicar la técnica, se graficó la varianza vs la media. Y en la Figura 4.18 se aprecia la matriz de confusión del modelo Wide Neural Network, con la activación ReLU, un tiempo de entrenamiento de 36.36 segundos y un valor de Exactitud de 98.3 % que fue el de mejor resultado de todos los modelos evaluados para esta prueba.




Figura 4.17 Gráfica de las características varianza vs media de la técnica transformada corta de Fourier

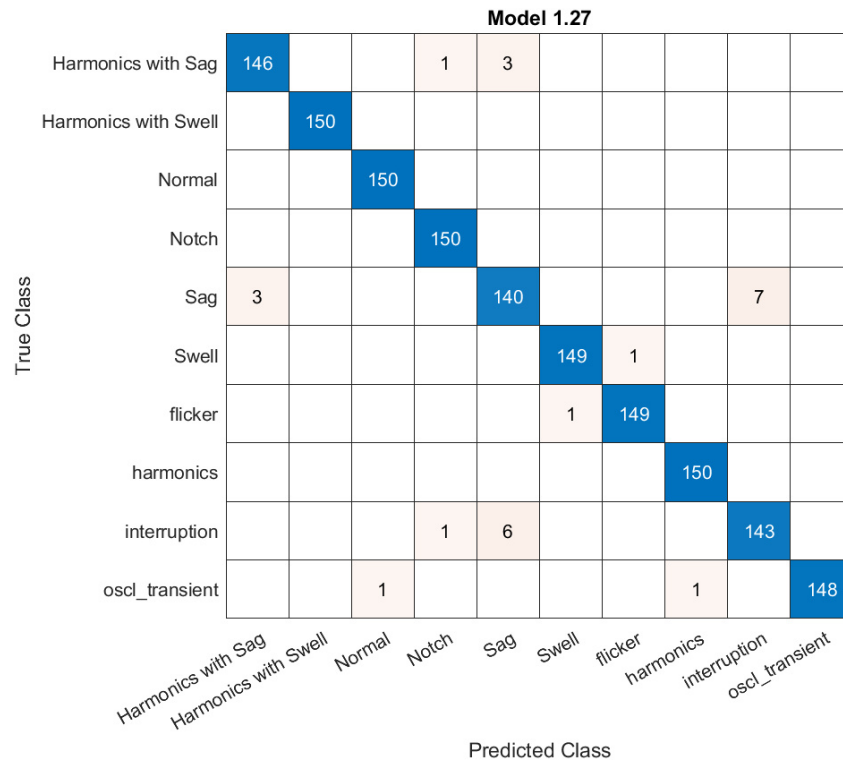


Figura 4.18 Matriz de confusión del modelo Wide Neural Network en la técnica transformada corta de Fourier

4.11 Prueba 10. Técnica transformada corta de Fourier con 40 dB

En esta prueba se utilizó la técnica de análisis espectral transformada corta de Fourier. Se realizó con una relación señal-ruido SNR de 40 dB. Se puede apreciar en la Figura 4.19 el modelo después de obtenidas las características al aplicar la técnica, se graficó la varianza vs la media. Y en la Figura 4.20 se aprecia la matriz de confusión del modelo Cubic SVM, con la función kernel Cubic, un tiempo de entrenamiento de 10.79 segundos y un valor de Exactitud de 95.5 % que fue el de mejor resultado de todos los modelos evaluados para esta prueba.




Figura 4.19 Gráfica de las características varianza vs media de la técnica transformada corta de Fourier con SNR de 40 dB

Model 1.10

Flicker_40dB	150								
Harmonics with Sag_40dB	136		1	5			1	7	
Harmonics with Swell_40dB		145					1		4
Harmonics_40dB			148				2		
Interruption_40dB	3			133					14
Normal_40dB					150				
Notch_40dB						150			
Oscillatory_Transients_40dB							150		
Sag_40dB	1	4			21			1	123
Swell_40dB	2		1						147

Predicted Class

Figura 4.20 Matriz de confusión del modelo Cubic SVM en la técnica transformada corta de Fourier con SNR de 40 dB

4.12 Prueba 11. Técnica transformada corta de Fourier con 20 dB

En esta prueba se utilizó la técnica de análisis espectral transformada corta de Fourier. Se realizó con una relación señal-ruido SNR de 20 dB. Se puede apreciar en la Figura 4.21 el modelo después de obtenidas las características al aplicar la técnica, se graficó la varianza vs la media. Y en la Figura 4.22 se aprecia la matriz de confusión del modelo Narrow Neural Network, con la activación ReLU, un tiempo de entrenamiento de 25.66 segundos y un valor de Exactitud de 94.1 % que fue el de mejor resultado de todos los modelos evaluados para esta prueba.




Figura 4.21 Gráfica de las características varianza vs media de la técnica transformada corta de Fourier con SNR de 20 dB

Model 1.25

True Class	Flicker_20dB	147				1	1		1		
	Harmonics with Sag_20dB		134		3		1	1	11		
	Harmonics with Swell_20dB			149						1	
	Harmonics_20dB				150						
	Interruption_20dB		5			134				11	
	Normal_20dB						145	2	2	1	
	Notch_20dB		1				4	143	1	1	
	Oscillatory_Transients_20dB						6	1	143		
	Sag_20dB	1	10			21		1		117	
	Swell_20dB	1									149
			Predicted Class								

Figura 4.22 Matriz de confusión del modelo Medium Neural Network en la técnica transformada corta de Fourier con SNR de 20 dB

4.13 Prueba 12. Técnica transformada corta de Fourier con 10 dB

En esta prueba se utilizó la técnica de análisis espectral transformada corta de Fourier. Se realizó con una relación señal-ruido SNR de 10 dB. Se puede apreciar en la Figura 4.23 el modelo después de obtenidas las características al aplicar la técnica, se graficó la varianza vs la media. Y en la Figura 4.24 se aprecia la matriz de confusión del modelo Narrow Neural Network, con la activación ReLU, un tiempo de entrenamiento de 24.95 segundos y un valor de Exactitud de 85.3 % que fue el de mejor resultado de todos los modelos evaluados para esta prueba.




Figura 4.23 Gráfica de las características varianza vs media de la técnica transformada corta de Fourier con SNR de 10 dB

Model 1.25

Flicker_10dB	132				16				2	
Harmonics with Sag_10dB		127		2	5				16	
Harmonics with Swell_10dB	1	146							3	
Harmonics_10dB	1		143				6			
Interruption_10dB		6			130				14	
Normal_10dB	11					113	12	14		
Notch_10dB	1	1				23	121	3	1	
Oscillatory_Transients_10dB	1			5		26	6	112		
Sag_10dB	3	14			19				114	
Swell_10dB	2		6						142	
	Flicker_10dB	Harmonics with Sag_10dB	Harmonics with Swell_10dB	Harmonics_10dB	Interruption_10dB	Normal_10dB	Notch_10dB	Oscillatory_Transients_10dB	Sag_10dB	Swell_10dB

Predicted Class

Figura 4.24 Matriz de confusión del modelo Narrow Neural Network en la técnica transformada corta de Fourier con SNR de 10 dB

4.14 Prueba 13. Técnica transformada Wavelet sin SNR

En esta prueba se utilizó la técnica de análisis espectral transformada Wavelet con la wavelet madre Coiflets (coif2) y tres niveles de descomposición. Se realizó con las señales limpias sin ruido. Se puede apreciar en la Figura 4.25 el modelo después de obtenidas las características al aplicar la técnica, se graficó la varianza vs la media. Y en la Figura 4.26 se aprecia la matriz de confusión del modelo Narrow Neural Network, con la activación ReLU, un tiempo de entrenamiento de 7.49 segundos y un valor de Exactitud de 99.2 % que fue el de mejor resultado de todos los modelos evaluados para esta prueba.




Figura 4.25 Gráfica de las características varianza vs media de la técnica transformada Wavelet

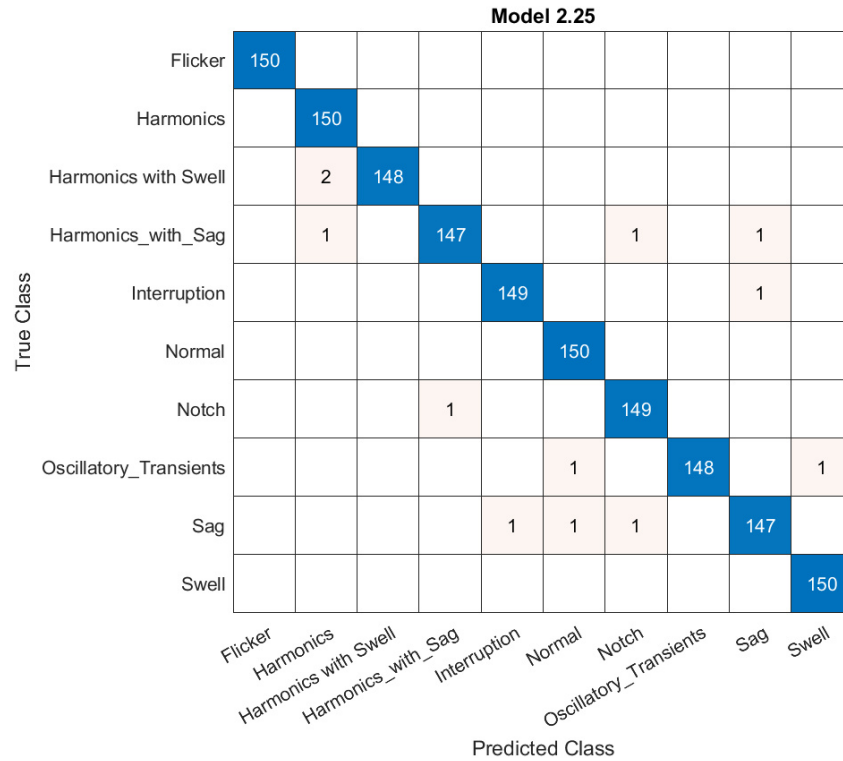


Figura 4.26 Matriz de confusión del modelo Narrow Neural Network en la técnica transformada Wavelet

4.15 Prueba 14. Técnica transformada Wavelet con 40 dB

En esta prueba se utilizó la técnica de análisis espectral transformada Wavelet con la wavelet madre Coiflets (coif1) y tres niveles de descomposición. Se realizó con una relación señal-ruido SNR de 40 dB. Se puede apreciar en la Figura 4.27 el modelo después de obtenidas las características al aplicar la técnica, se graficó la varianza vs la media. Y en la Figura 4.28 se aprecia la matriz de confusión del modelo Bagged Trees, con árbol de decisiones, un tiempo de entrenamiento de 9.20 segundos y un valor de Exactitud de 94.2 % que fue el de mejor resultado de todos los modelos evaluados para esta prueba.




Figura 4.27 Gráfica de las características varianza vs media de la técnica transformada Wavelet con SNR de 40 dB

Model 1.21

Flicker 40dB	147						3			
Harmonics 40dB		146					4			
Harmonics with Swell 40dB		1	131						18	
Harmonics_with_Sag 40dB		1		134	3		3		9	
Interruption 40dB				1	143				6	
Normal 40dB						150				
Notch 40dB				1		1	147		1	
Oscillatory_Transients 40dB		6				2		142		
Sag 40dB				7	5				138	
Swell 40dB		2	1	15						
	Flicker 40dB	Harmonics 40dB	Harmonics with Swell 40dB	Harmonics_with_Sag 40dB	Interruption 40dB	Normal 40dB	Notch 40dB	Oscillatory_Transients 40dB	Sag 40dB	Swell 40dB

Predicted Class

Figura 4.28 Matriz de confusión del modelo Bagged Trees en la técnica transformada Wavelet con SNR de 40 dB

4.16 Prueba 15. Técnica transformada Wavelet con 20 dB

En esta prueba se utilizó la técnica de análisis espectral transformada Wavelet con la wavelet madre Coiflets (coif1) y tres niveles de descomposición. Se realizó con una relación señal-ruido SNR de 20 dB. Se puede apreciar en la Figura 4.29 el modelo después de obtenidas las características al aplicar la técnica, se graficó la varianza vs la media. Y en la Figura 4.30 se aprecia la matriz de confusión del modelo Bagged Trees, con árbol de decisiones, un tiempo de entrenamiento de 8.94 segundos y un valor de Exactitud de 83.9 % que fue el de mejor resultado de todos los modelos evaluados para esta prueba.




Figura 4.29 Gráfica de las características varianza vs media de la técnica transformada Wavelet con SNR de 20 dB

Model 1.21

Flicker 20dB	136	3				6		5		
Harmonics 20dB	5	140				1		4		
Harmonics with Swell 20dB		1	112							37
Harmonics_with_Sag 20dB		1		110	1		7		31	
Interruption 20dB				4	141				5	
Normal 20dB	3					135	8	4		
Notch 20dB	3					16	126		5	
Oscillatory_Transients 20dB	11	1				11		127		
Sag 20dB				14	14		3		119	
Swell 20dB	2	3	33							112

Predicted Class

Figura 4.30 Matriz de confusión del modelo Bagged Trees en la técnica transformada Wavelet con SNR de 20 dB

4.17 Prueba 16. Técnica transformada Wavelet con 10 dB

En esta prueba se utilizó la técnica de análisis espectral transformada Wavelet con la wavelet madre Coiflets (coif1) y tres niveles de descomposición. Se realizó con una relación señal-ruido SNR de 10 dB. Se puede apreciar en la Figura 4.31 el modelo después de obtenidas las características al aplicar la técnica, se graficó la varianza vs la media. Y en la Figura 4.32 se aprecia la matriz de confusión del modelo Quadratic Discriminant, estructura de covarianza completa, un tiempo de entrenamiento de 13.83 segundos y un valor de Exactitud de 69.5 % que fue el de mejor resultado de todos los modelos evaluados para esta prueba.




Figura 4.31 Gráfica de las características varianza vs media de la técnica transformada Wavelet con SNR de 10 dB

Model 2.5

Flicker 10dB	87	8				45	3	7		
Harmonics 10dB	7	125	1			2		13		2
Harmonics with Swell 10dB		1	93							56
Harmonics_with_Sag 10dB		1	1	95	3		13		37	
Interruption 10dB				8	135		1		6	
Normal 10dB	21	1				113	6	9		
Notch 10dB	8		1	4		30	104	2	1	
Oscillatory_Transients 10dB	24	5				38	1	82		
Sag 10dB				34	6	1	25		84	
Swell 10dB	1	4	21							124

Predicted Class

Figura 4.32 Matriz de confusión del modelo Quadratic Discriminant en la técnica transformada Wavelet con SNR de 10 dB

4.18 Prueba 17. Técnica transformada Wavelet Synchrosqueezing sin SNR

En esta prueba se utilizó la técnica de análisis espectral transformada Wavelet Synchrosqueezing. Se realizó con las señales limpias sin ruido. Se puede apreciar en la Figura 4.33 el modelo después de obtenidas las características al aplicar la técnica, se graficó la varianza vs la media. Y en la Figura 4.34 se aprecia la matriz de confusión del modelo Quadratic SVM, con la función kernel Quadratic y método multiclase uno por uno, un tiempo de entrenamiento de 10.77 segundos y un valor de Exactitud de 99.8 % que fue el de mejor resultado de todos los modelos evaluados para esta prueba.




Figura 4.33 Gráfica de las características varianza vs media de la técnica transformada Wavelet Synchrosqueezing




Figura 4.34 Matriz de confusión del modelo Quadratic SVM en la técnica transformada Wavelet Synchrosqueezing

4.19 Prueba 18. Técnica transformada Wavelet Synchrosqueezing con 40 dB

En esta prueba se utilizó la técnica de análisis espectral transformada Wavelet Synchrosqueezing. Se realizó con una relación señal-ruido SNR de 40 dB. Se puede apreciar en la Figura 4.35 el modelo después de obtenidas las características al aplicar la técnica, se graficó la varianza vs la media. Y en la Figura 4.36 se aprecia la matriz de confusión del modelo Bagged Trees, tipo de aprendizaje arboles de decisión, con un tiempo de entrenamiento de 7.63 segundos y un valor de Exactitud de 99.7 % que fue el de mejor resultado de todos los modelos evaluados para esta prueba.

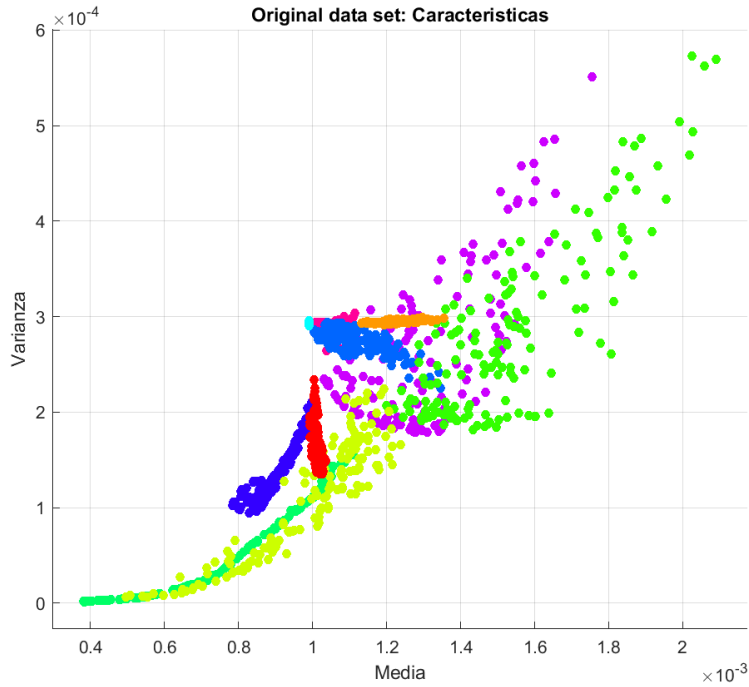


Figura 4.35 Gráfica de las características varianza vs media de la técnica transformada Wavelet Synchrosqueezing con SNR de 40 dB

Model 1.21

Flicker 40dB	149									1
Harmonics 40dB		150								
Harmonics_with_Sag 40dB			150							
Harmonics_with_Swell 40dB			2	148						
Interruption 40dB					150					
Normal 40dB						150				
Notch 40dB				1			149			
Sag 40dB								150		
Swell 40dB			1						149	
oscl_transient 40dB										150

Predicted Class

Figura 4.36 Matriz de confusión del modelo Bagged Trees en la técnica transformada Wavelet Synchrosqueezing con SNR de 40 dB

4.20 Prueba 19. Técnica transformada Wavelet Synchronsqueezing con 20 dB

En esta prueba se utilizó la técnica de análisis espectral transformada Wavelet Synchronsqueezing. Se realizó con una relación señal-ruido SNR de 20 dB. Se puede apreciar en la Figura 4.37 el modelo después de obtenidas las características al aplicar la técnica, se graficó la varianza vs la media. Y en la Figura 4.38 se aprecia la matriz de confusión del modelo Bagged Trees, tipo de aprendizaje arboles de decisión, con un tiempo de entrenamiento de 7.90 segundos y un valor de Exactitud de 98.0 % que fue el de mejor resultado de todos los modelos evaluados para esta prueba.




Figura 4.37 Gráfica de las características varianza vs media de la técnica transformada Wavelet Synchronsqueezing con SNR de 20 dB

Model 1.21

Harmonics_with_Sag 20dB	148		1					1		
Harmonics_with_Swell 20dB		149						1		
Interruption 20dB			150							
Normal 20dB				146						4
Notch 20dB	1			7	136				1	5
Sag 20dB						150				
Swell 20dB							150			
flicker 20dB								150		
harmonics 20dB					1				149	
oscl_transient 20dB				6	2					142
	Harmonics_with_Sag 20dB	Harmonics_with_Swell 20dB	Interruption 20dB	Normal 20dB	Notch 20dB	Sag 20dB	Swell 20dB	flicker 20dB	harmonics 20dB	oscl_transient 20dB

Predicted Class

Figura 4.38 Matriz de confusión del modelo Bagged Trees en la técnica transformada Wavelet Synchrosqueezing con SNR de 20 dB

4.21 Prueba 20. Técnica transformada Wavelet Synchrosqueezing con 10 dB

En esta prueba se utilizó la técnica de análisis espectral transformada Wavelet Synchrosqueezing. Se realizó con una relación señal-ruido SNR de 10 dB. Se puede apreciar en la Figura 4.39 el modelo después de obtenidas las características al aplicar la técnica, se graficó la varianza vs la media. Y en la Figura 4.40 se aprecia la matriz de confusión del modelo Trilayered Neural Network, con la activación ReLU, con un tiempo de entrenamiento de 30.36 segundos y un valor de Exactitud de 87.7 % que fue el de mejor resultado de todos los modelos evaluados para esta prueba.




Figura 4.39 Gráfica de las características varianza vs media de la técnica transformada Wavelet Synchrosqueezing con SNR de 10 dB

Model 1.29

Harmonics_with_Sag 10dB	137	1	2			4	1	4	1	
Harmonics_with_Swell 10dB		135					13		2	
Interruption 10dB	1		149							
Normal 10dB				112	20			5		13
Notch 10dB	1			28	102			1	2	16
Sag 10dB	3		1			144		2		
Swell 10dB		8					141	1		
flicker 10dB				3	3	2	1	140		1
harmonics 10dB		2							145	3
oscl_transient 10dB				24	13			1	2	110
	Harmonics_with_Sag 10dB	Harmonics_with_Swell 10dB	Interruption 10dB	Normal 10dB	Notch 10dB	Sag 10dB	Swell 10dB	flicker 10dB	harmonics 10dB	oscl_transient 10dB

Predicted Class

Figura 4.40 Matriz de confusión del modelo Trilayered Neural Network en la técnica transformada Wavelet Synchrosqueezing con SNR de 10 dB

Como se pudo apreciar en los acápites anteriores, se llevaron a cabo 20 pruebas divididas en cinco técnicas distintas: Transformada Constante Q, Transformada de Fourier, Transformada Corta de Fourier, Transformada Wavelet y Transformada Wavelet Synchronizing. Cada técnica fue evaluada en cuatro condiciones diferentes: señales limpias, señales con una relación señal-ruido (SNR) de 40 dB, 20 dB y 10 dB. Para cada prueba, se registraron dos métricas principales: la precisión (Exactitud) y el tiempo de entrenamiento. Estos resultados fueron compilados en una tabla comparativa para evaluar el rendimiento relativo de cada técnica en condiciones de señal limpias y con diferentes niveles de ruido, como se puede apreciar en la Tabla 4. Después del análisis de los resultados, se concluyó que la mejor técnica para el estudio de señales con perturbaciones es la Transformada Wavelet Synchronizing. Esta conclusión se basó en la combinación de una alta precisión en la clasificación de las señales y un tiempo de entrenamiento razonable en comparación con las otras técnicas evaluadas. Como siguiente paso, se propone comparar este modelo con trabajos previos realizados en el mismo campo, lo que proporcionará una evaluación más completa de su eficacia y relevancia en relación con otras investigaciones existentes.

Igualmente he de destacar que se dispone de una amplia variedad de técnicas y enfoques en el procesamiento de señales para identificar y extraer características de los problemas de calidad de la energía eléctrica (PQD). En la Tabla 5 se resumen algunas de estas metodologías, junto con los tipos de señales empleadas y los entornos en los que han sido evaluadas. Además, se proporciona el nivel de precisión alcanzado durante el proceso de clasificación. Y al final se presenta nuestro modelo para ser comparado con todos estos trabajos anteriores.

	Señal sin Ruido		SNR 40 dB		SNR 20 dB		SNR 10 dB	
	Exactitud (%)	Tiempo Entrenamiento (s)	Exactitud (%)	Tiempo Entrenamiento (s)	Exactitud (%)	Tiempo Entrenamiento (s)	Exactitud (%)	Tiempo Entrenamiento (s)
Técnica de análisis espectral								
Transformada Constante Q	91.8	43.22	90.4	43.89	90.0	37.40	80.5	26.55
Transformada de Fourier	97.2	13.15	92.9	15.56	86.0	27.45	74.2	26.93
Transformada Corta de Fourier	98.3	36.36	95.5	10.79	94.1	25.66	85.3	24.95
Transformada Wavelet	99.2	7.49	94.2	9.20	83.9	8.94	69.5	13.83
Transformada Wavelet Sincrosqueezing	99.8	10.77	99.7	7.63	98.0	7.90	87.7	30.36

Tabla 4 Comparación entre las cinco técnicas de análisis espectral utilizadas

Referencia	Detección y extracción de características	Técnica de Clasificación	Tipo de señales	No. de PQD	Ambiente	Porcentaje de Acierto
Biswal [44] (2014)	Híbrido EMD + HT	BNT	Sintéticas	6 simples 2 compuestas	Simulación (Matlab)	97.90 %
Biswal y Dash [45] (2013)	FDST	DT	Sintéticas	6 simples 7 compuestas	Simulación (Matlab)	99.28 %
Cai and Cao [6] (2019)	WVD	CNN	Sintéticas	6 simples 3 compuestas	Simulación (Matlab)	99.67 %
Chang [7] (2017)	Híbrido DWT + DFT	SVM	Sintéticas	6 simples	Simulación (EMTP)	99.48 %
De y Debnath [53] (2017)	Correlación DWT+DFT	Basado en lógica difusa	Sintéticas + Reales	8 simples 9 compuestas	Real (LabVIEW)	99.04 %
Eristi [11] (2018)	DWT/MRA	LSSVM	Reales	4 simples	Real (FPGA)	99.71 %
García [54] (2020)	DWT/MRA	KNN	Sintéticas	7 simples	Simulación (Matlab)	98.85 %
Li [4] (2016)	DRST	DAG-SVM	Sintéticas	6 simples 2 compuestas	Simulación (Matlab)	99.31 %
Markovska [55] (2020)	DWT	RF	Reales	8 simples 12 compuestas	Real (myRIO1900)	95.00 %
Meena [56] (2018)	ST	DT	Sintéticas	10 compuestas	Simulación (Matlab)	96.67 %
Pandya [5] (2020)	Híbrido ST + HT	DT	Sintéticas	16 compuestas	Simulación (Matlab)	97.93 %
Puliyadi [3] (2017)	ST	DT	Sintéticas	7 simples 16 compuestas	Simulación (Matlab)	98.55 %
Ribeiro [57] (2018)	HOS	MLP+BC	Reales	6 simples 14 compuestas	Real (FPGA)	97.8 %
Rodrigues-Junior [2] (2021)	Basado en FFT RMS+THD	DT	Reales	7 simples 5 compuestas	Real (TI-RTOS)	94.9 %
Shaik y Reddy [51] (2018)	FEFS	MCSVM	Sintéticas	6 simples 2 compuestas	Simulación (Matlab)	98.65 %
Zhang [58] (2011)	Híbrido RMS + DFT	DT	Sintéticas	7 simples 2 compuestas	Simulación (Matlab)	99.00 %
Trabajo Propuesto	WSST	QSVM	Sintéticas	8 simples 2 compuestas	Simulación (Matlab)	99.80 %

Tabla 5 Comparación del rendimiento del método propuesto con otras referencias

ABREVIATURAS DE LA TABLA 5:

EMD (Empirical Mode Decomposition) en inglés, descomposición en modo empírico.

HT (Hilbert Transform) en inglés, transformada hilbert.

BNT (Balance Neural Tree) en inglés, árbol neuronal balanceado.

FDST (Fast Discrete S-Transform) en inglés, transformada s rápida discreta.

DT (Decision Tree) en inglés, árbol de decisión.

WVD (Wigner-Ville Distribution) en inglés, distribución de wigner-ville.

CNN (Convolutional Neural Network) en inglés, red neuronal convolucional.

DWT (Discrete Wavelet Transform) en inglés, transformada wavelet discreta.

DFT (Discrete Fourier Transform) en inglés, transformada de fourier discreta.

FFT (Fast Fourier Transform) en inglés, transformada rápida de fourier.

MRA (Multiresolution Analysis) en inglés, análisis multiresolución.

EMTP (ElectroMagnetic Transients Program) en inglés, transitorios electromagnéticos.

SVM (Support Vector Machine) en inglés, máquina de soporte de vectores.

LSSVM (Least-Squares Support Vector Machine) en inglés, máquina de soporte de vectorial de mínimos cuadrados.

FPGA (Field Programmable Gate Array) en inglés, matriz de puertas programable en campo.

KNN (K-Nearest Neighbors) en inglés, vecinos más cercanos de k.

DRST (Double Resolution S-Transform) en inglés, transformada S de doble resolución.

DAG-SVM (Directed Acyclic Graph SVM) en inglés, SVM de grafo dirigido acíclico.

RF (Random Forest) en inglés, bosque aleatorio.

ST (Stockwell Transform) en inglés, transformada stockwell.

HOS (Higher Order Statistics) en inglés, estadísticas de orden superior.

BC (Bayesian Classifier) en inglés, clasificador bayesiano.

MLP (Multilayer Perceptron) en inglés, perceptrón multicapa.

RMS (Root Mean Square) en inglés, valor eficaz.

THD (Total Harmonic Distortion) en inglés, distorsión armónica total.

RTOS (Real-Time Operating System) en inglés, sistema operativo en tiempo real.

FEFS (Flexible Entropy Based Feature Selection) en inglés, selección de características basada en entropía flexible.

MCSVM (Multi Class SVM) en inglés, máquina de vectores de soporte multiclase.

4.22 Discusión de resultados

La evaluación de las técnicas de transformada para la clasificación de perturbaciones eléctricas reveló variaciones significativas en precisión y tiempo de entrenamiento bajo diferentes condiciones de señal. Entre las técnicas evaluadas—Transformada Constante Q, Transformada de Fourier, Transformada Corta de Fourier, Transformada Wavelet y Transformada Wavelet Synchrosqueezing—la Transformada Wavelet Synchrosqueezing demostró ser la más efectiva en términos de precisión, especialmente en condiciones de bajo SNR.

4.23 Interpretación de los resultados

La Transformada Wavelet Synchrosqueezing obtuvo la mayor exactitud en todas las condiciones de SNR evaluadas, alcanzando un 99.8% sin ruido, un 99.7% con SNR de 40 dB, un 98.0% con SNR de 20 dB y un 87.7% con SNR de 10 dB. Este rendimiento superior destaca su capacidad para manejar perturbaciones con alta precisión incluso en presencia de ruido significativo. En comparación, la Transformada Wavelet, aunque efectiva, mostró una disminución más pronunciada en precisión con el aumento del ruido, evidenciando una menor robustez en entornos ruidosos.

4.24 Comparación con otros estudios

Nuestros resultados coinciden con estudios que sugieren que las técnicas basadas en wavelet pueden ser más efectivas para el análisis de señales perturbadas debido a su capacidad para captar características temporales y frecuenciales específicas (frecuencias instantáneas) [19][20]. En comparación con técnicas tradicionales como la Transformada de Fourier y la Transformada Corta de Fourier, que ofrecieron una alta precisión en condiciones de baja relación señal a ruido pero menos efectivas en ambientes ruidosos, la Transformada Wavelet Synchrosqueezing mostró una ventaja clara en manejar escalas de disminución por cada 10dBs de ruido.

4.25 Implicaciones de los resultados

La capacidad superior de la Transformada Wavelet Synchrosqueezing para mantener alta precisión y razonable tiempo de entrenamiento en condiciones de bajo SNR sugiere que esta técnica tiene un gran potencial para mejorar los sistemas de monitoreo y diagnóstico en tiempo real. La implementación de esta técnica podría optimizar la detección de problemas eléctricos, especialmente en entornos donde el ruido es un factor importante, llevando a una posible reevaluación y mejora de los sistemas actuales que utilizan técnicas tradicionales.

4.26 Fortalezas y limitaciones

Una fortaleza significativa de este estudio es la exhaustiva comparación entre técnicas, proporcionando una visión clara de la eficacia relativa bajo diversas condiciones de ruido. Sin embargo, la principal limitación es el uso de datos sintéticos, que aunque válidos para la prueba inicial, podrían no capturar todas las variaciones reales de las señales perturbadas. La incorporación de datos reales en futuras investigaciones podría proporcionar una evaluación más precisa y completa.

4.27 Análisis de clases afectadas

En términos de precisión global, la Transformada Wavelet Synchrosqueezing mostró un rendimiento sobresaliente en comparación con las demás técnicas, especialmente en señales con bajo SNR. Las clases de señales perturbadas con alta frecuencia se beneficiaron notablemente de esta técnica, mientras que otras técnicas como la Transformada de Fourier y la Transformada Corta de Fourier fueron menos efectivas bajo condiciones de bajo SNR. Esto sugiere que una posible área de mejora sería ajustar el modelo para manejar mejor las señales con características de frecuencia más bajas o variadas.

5 CONCLUSIONES

En esta tesis se planteó el desarrollo de una metodología robusta para la detección y clasificación de perturbaciones eléctricas en redes mediante técnicas avanzadas de procesamiento de señales y aprendizaje automático. La metodología propuesta se fundamenta en el análisis espectral de las señales eléctricas, utilizando transformadas de Fourier (FFT), transformada corta de Fourier, transformada Constante-Q, transformada Wavelet y transformada Wavelet Synchrosqueezing, complementadas con diversos métodos de clasificación implementados en MATLAB.

Los resultados obtenidos en la fase de pruebas sugieren que las técnicas de análisis espectral y los métodos de clasificación empleados lograron identificar con precisión las perturbaciones eléctricas, incluso en condiciones de ruido significativo. En particular, la transformada Wavelet Synchrosqueezing demostró una capacidad superior para extraer información entre diferentes tipos de perturbaciones, proporcionando características que permitieron su clasificación.

El uso de algoritmos de aprendizaje automático, como máquinas de vectores de soporte (SVM), redes neuronales y árboles de decisión, en combinación con las características extraídas, resultó en un desempeño notable en la clasificación de perturbaciones. Los esquemas de validación cruzada confirmaron la efectividad de los modelos entrenados, destacando la precisión y robustez de las técnicas implementadas.

La evaluación comparativa reveló que la transformada Wavelet Synchrosqueezing fue particularmente efectiva en condiciones de alta relación señal-ruido (SNR), mientras que las demás transformadas mostraron una reducción en el desempeño a medida que el ruido aumentaba.

En el proceso de clasificación de señales con perturbaciones eléctricas, se identificaron y utilizaron un conjunto de características que proporcionaron una mejora significativa en la precisión de la clasificación. Estas características se dividieron en dos categorías principales, estadísticas y tiempo-frecuencia. La combinación de estas características permitió una

clasificación más precisa y robusta de las señales con perturbaciones eléctricas, demostrando la importancia de considerar tanto aspectos estadísticos como de tiempo-frecuencia en el análisis de señales.

En cuanto al rendimiento general, se observó que la clasificación de datos mostró un mejor desempeño en las señales sin ruido en las cinco técnicas desarrolladas, la transformada constante-Q obtuvo una exactitud de 91.8 %, la transformada de Fourier una exactitud de 97.2 %, la transformada corta de Fourier una exactitud de 98.3 %, la transformada de Wavelet una exactitud de 99.2 %. Pero en la técnica transformada Wavelet Synchrosqueezing además de las señales sin ruido igualmente se obtuvo un buen desempeño de las señales con altas relaciones señal-ruido (SNR), se obtuvo una exactitud de 99.8 % sin ruido, 99.7 % con 40 dB, 98.0 % con 20 dB y 87.7 % con 10 dB. Esto sugiere que la metodología propuesta mantiene un desempeño competitivo incluso en condiciones desafiantes.

Finalmente, la investigación demostró que la metodología propuesta mejora significativamente el potencial de técnicas de procesamiento de señales y clasificación existentes en la literatura, proporcionando una herramienta eficaz para la detección y análisis de perturbaciones en redes eléctricas.

6 REFERENCIAS

- [1] Y. Yoldaş, A. Önen, S. M. Muyeen, A. V. Vasilakos, and İ. Alan, "Enhancing smart grid with microgrids: Challenges and opportunities," *Renewable and Sustainable Energy Reviews*, vol. 72, pp. 205–214, 2017. doi: 10.1016/j.rser.2017.01.064.
- [2] M. Farhoodnea, A. Mohamed, H. Shareef, and H. Zayandehroodi, "Power quality impact of renewable energy based generators and electric vehicles on distribution systems," *Procedia Technology*, vol. 11, pp. 11–17, 2013. doi: 10.1016/j.protcy.2013.12.156.
- [3] IEEE, "IEEE Recommended Practice for Monitoring Electric Power Quality," IEEE Std 1159-2009, 2009, doi: 10.1109/IEEESTD.2009.5154067.
- [4] J. Li, Z. Teng, Q. Tang, and J. Song, "Detection and Classification of Power Quality Disturbances Using Double Resolution S-Transform and DAG-SVMs," *IEEE Transactions on Instrumentation and Measurement*, vol. 65, no. 10, pp. 2302–2312, Oct. 2016, doi: 10.1109/TIM.2016.2578518.
- [5] V. Pandya, R. R. Choudhary, O. Prakash Mahela, and S. Choudhary, "Detection and Classification of Complex Power Quality Disturbances Using Hybrid Algorithm Based on Combined Features of Stockwell Transform and Hilbert Transform," in *2020 IEEE International Students' Conference on Electrical, Electronics and Computer Science (SCEECS)*, 2020, pp. 1–6, doi: 10.1109/SCEECS48394.2020.5.
- [6] K. Cai, W. Cao, L. Aarniovuori, H. Pang, Y. Lin, and G. Li, "Classification of Power Quality Disturbances Using Wigner-Ville Distribution and Deep Convolutional Neural Networks," *IEEE Access*, vol. 7, pp. 119099–119109, 2019, doi: 10.1109/ACCESS.2019.2937193.
- [7] P. C. Chang, G. W. Chang, M. H. Shih, Y. Y. Chen, Y. H. Hong, and Y. K. Yeh, "A hybrid approach for detection and classification of power quality disturbances," *IEEE Power & Energy Society General Meeting*, 2017, doi: 10.1109/PESGM.2017.8274397.
- [8] S. Alshahrani, M. Abbod, B. Alamri, and G. Taylor, "Evaluation and classification of power quality disturbances based on discrete Wavelet Transform and artificial neural

- networks," *2015 50th International Universities Power Engineering Conference (UPEC)*, 2015, doi: 10.1109/upec.2015.7339928.
- [9] P. Kanirajan and V. Suresh Kumar, "Power quality disturbance detection and classification using wavelet and RBFNN," *Applied Soft Computing*, vol. 35, pp. 470–481, 2015, doi: 10.1016/j.asoc.2015.05.048.
- [10] M. Lopez-Ramirez, E. Cabal-Yepez, L. Ledesma-Carrillo, H. Miranda-Vidales, C. Rodriguez-Donate, and R. Lizarraga-Morales, "FPGA-Based Online PQD Detection and Classification through DWT, Mathematical Morphology and SVD," *Energies*, vol. 11, no. 4, p. 769, 2018, doi: 10.3390/en11040769.
- [11] B. Eristi, O. Yildirim, H. Eristi, and Y. Demir, "A new embedded power quality event classification system based on the wavelet transform," *Int. Trans. Electr. Energy Syst.*, vol. e2597, 2018, doi: 10.1002/etep.2597.
- [12] W. L. Rodrigues Junior, F. A. da S. Borges, R. de A. L. Rabelo, and J. J. P. C. Rodrigues, "A Methodology for Detection of Power Quality Disturbances in the Context of Demand Side Management," in *Proc. 2019 4th Int. Conf. Smart Sustainable Technol. (SpliTech)*, 2019, doi: 10.23919/splitech.2019.87829.
- [13] R. Igual and C. Medrano, "Research challenges in real-time classification of power quality disturbances applicable to microgrids: A systematic review," *Renewable Sustainable Energy Rev.*, vol. 132, p. 110050, 2020, doi: 10.1016/j.rser.2020.110050.
- [14] R. Igual, C. Medrano, F. J. Arcega, and G. Mantescu, "Integral mathematical model of power quality disturbances," in *Proc. 18th Int. Conf. Harmonics Quality Power (ICHQP)*, 2018, doi: 10.1109/ichqp.2018.8378902.
- [15] M. Valtierra-Rodriguez, R. de J. Romero-Troncoso, R. A. Osornio-Rios, and A. Garcia-Perez, "Detection and classification of single and combined power quality disturbances using neural networks," *IEEE Trans. Industrial Electronics*, vol. 61, no. 5, pp. 2473–2482, 2014, doi: 10.1109/tie.2013.2272276.

- [16] S.-H. Cho, G. Jang, and S.-H. Kwon, "Time-frequency analysis of power-quality disturbances via the Gabor-Wigner transform," *IEEE Trans. Power Delivery*, vol. 25, no. 1, pp. 494–499, 2010, doi: 10.1109/tpwrd.2009.2034832.
- [17] A.-S. Hussein and M.-N. Hawas, "Power quality analysis based on simulation and Matlab/Simulink," *Indonesian J. Electr. Eng. Comput. Sci.*, vol. 16, pp. 1144–1153, 2019, doi: 10.11591/ijeecs.v16.i3.pp1144-1153.
- [18] P. K. A. Puliyadi and A. K. Loganathan, "Detection and classification of complex power quality disturbances using S-transform amplitude matrix-based decision tree for different noise levels," *Int. Trans. Electr. Energy Syst.*, vol. 27, no. 4, p. e2286, 2016, doi: 10.1002/etep.2286.
- [19] P. J. Burke, D. I. Stern, and S. B. Bruns, "The Impact of Electricity on Economic Development: A Macroeconomic Perspective," *Int. Rev. Environ. Resource Econ.*, vol. 12, no. 1, pp. 85–127, 2018, doi: 10.1561/101.00000101.
- [20] Ł. Michalec, M. Jasiński, T. Sikorski, Z. Leonowicz, Ł. Jasiński, and V. Suresh, "Impact of Harmonic Currents of Nonlinear Loads on Power Quality of a Low Voltage Network—Review and Case Study," *Energies*, vol. 14, no. 12, p. 3665, 2021, doi: 10.3390/en14123665.
- [21] A. Arranz-Gimon, A. Zorita-Lamadrid, D. Morinigo-Sotelo, and O. Duque-Perez, "A Review of Total Harmonic Distortion Factors for the Measurement of Harmonic and Interharmonic Pollution in Modern Power Systems," *Energies*, vol. 14, no. 20, p. 6467, 2021, doi: 10.3390/en14206467.
- [22] A.-D. Gonzalez-Abreu, R.-A. Osornio-Rios, A.-Y. Jaen-Cuellar, M. Delgado-Prieto, J.-A. Antonino-Daviu, and A. Karlis, "Advances in Power Quality Analysis Techniques for Electrical Machines and Drives: A Review," *Energies*, vol. 15, no. 5, p. 1909, 2022, doi: 10.3390/en15051909.
- [23] J. Li, H. Liu, D. Wang, and T. Bi, "Classification of Power Quality Disturbance Based on S-Transform and Convolution Neural Network," *Frontiers in Energy Research*, vol. 9, p. 708131, 2021, doi: 10.3389/fenrg.2021.708131.

- [24] C. Burrus, H. Guo, and R. Gopinath, *Introduction to Wavelets and Wavelet Transform—A Primer*. [Online]. Available: <https://www.researchgate.net/publication/246532602>
- [25] S. G. Mallat, *A Theory for Multiresolution Signal Decomposition: The Wavelet Representation*, *Fundamental Papers in Wavelet Theory*. [Online]. Available: <https://doi.org/10.1515/9781400827268.494>
- [26] L. Angrisani, P. Daponte, M. D’Apuzzo, and A. Testa, “A measurement method based on the wavelet transform for power quality analysis,” *IEEE Transactions on Power Delivery*, vol. 13, no. 4, pp. 990–998, Oct. 1998. doi: 10.1109/61.714415.
- [27] M. Portnoff, “Time-frequency representation of digital signals and systems based on short-time Fourier analysis,” *IEEE Transactions on Acoustics, Speech, and Signal Processing*, vol. 28, no. 1, pp. 55–69, Feb. 1980. doi: 10.1109/tassp.1980.1163359.
- [28] S. Zhou, B. Tang, and R. Chen, “Comparison between non-stationary signals fast Fourier transform and wavelet analysis,” in *2009 International Asia Symposium on Intelligent Interaction and Affective Computing*, 2009, pp. 117–120. doi: 10.1109/asia.2009.31.
- [29] A. Gudiño-Ochoa, J. Jalomo-Cuevas, D. Sánchez-Jiménez, and R. Ochoa-Ornelas, “Detección de armónicos e interarmónicos en la calidad de energía aplicando la transformada wavelet synchrosqueezing,” *Difu100ci@, Revista de difusión científica, ingeniería y tecnologías*, vol. 16, no. 3, pp. 132–141, 2022. [Online]. Available: <http://difu100cia.uaz.edu.mx/index.php/difuciencia/article/view/316>
- [30] C. J. C. Burges, “Data mining and knowledge discovery,” *Data Mining and Knowledge Discovery*, vol. 2, no. 2, pp. 121–167, 1998. doi: 10.1023/a:100971592355
- [31] V. N. Vapnik, “An overview of statistical learning theory,” *IEEE Transactions on Neural Networks*, vol. 10, no. 5, pp. 988–999, 1999. doi: 10.1109/72.788640.
- [32] R. Hecht-Nielsen, “Applications of counterpropagation networks,” *Neural Networks*, vol. 1, no. 2, pp. 131–139, 1988. doi: 10.1016/0893-6080(88)90015-6.
- [33] IEEE, “IEEE Recommended Practice for Monitoring Electric Power Quality,” *IEEE Std 1159-2019*, no. 1, 2019. doi: 10.1109/ieeestd.2019.8796486.

- [34] J. C. Brown, "Calculation of a constant Q spectral transform," *The Journal of the Acoustical Society of America*, vol. 89, no. 1, pp. 425–434, 1991. doi: 10.1121/1.400476.
- [35] P. B. Bachhav, M. Todisco, M. Mossi, C. Beaugeant, and N. Evans, "Artificial bandwidth extension using the constant Q transform," in *2017 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2017. doi: 10.1109/icassp.2017.7953218.
- [36] D. Dorran and R. Lawlor, "An efficient audio time-scale modification algorithm for use in a subband implementation," in *International Conference on Digital Audio Effects (DAFx)*, London, England, 2003. doi: 10.21427/D7DP5Q.
- [37] C. Schörkhuber and A. Klapuri, "Constant-Q transform toolbox for music processing," in *Proceedings of the 7th Sound and Music Computing Conference*, Barcelona, Spain, 2010, pp. 3-6. Available: https://code.soundsoftware.ac.uk/publications/53?project_id=constant-q-toolbox
- [38] H. Bo, H. Li, L. Ma, and B. Yu, "A Constant Q Transform based approach for robust EEG spectral analysis," in *2014 International Conference on Audio, Language and Image Processing*, Shanghai, China, 2014, pp. 66-71. doi:10.1109/icalip.2014.7009757.
- [39] R. A. Dobre and C. Negrescu, "Automatic music transcription software based on constant Q transform," in *2016 8th International Conference on Electronics, Computers and Artificial Intelligence (ECAI)*, Bucharest, Romania, 2016, pp. 1-6. doi:10.1109/ecai.2016.7861193.
- [40] H. Markiewicz and A. Klajn, *Power Quality Application Guide: Voltage Disturbances. Standard EN 50160 - Voltage Characteristics in Public Distribution Systems*, Wroclaw University of Technology, Wroclaw, Poland, 2004.
- [41] D. S. Dorr, T. M. Gruz, M. B. Hughes, R. E. Jurewicz, G. Dang, and J. L. McClaine, "Interpreting recent power quality surveys to define the electrical environment," in *IAS '96. Conference Record of the 1996 IEEE Industry Applications Conference Thirty-First IAS Annual*, 1996, pp. 1–5, doi:10.1109/ias.1996.5.

- [42] M. A. S. Masoum and E. F. Fuchs, "Introduction to Power Quality," in *Power Quality in Power Systems and Electrical Machines*, pp. 1–104, 2015, doi:10.1016/b978-0-12-800782-2.
- [43] A. D. Poularikas, Ed., *The Handbook of Formulas and Tables for Signal Processing*. Boca Raton, FL: CRC Press LLC, 1999, pp. i–xvi. Department of Electrical and Computer Engineering, The University of Alabama in Huntsville.
- [44] E. Styvaktakis, M. H. J. Bollen, and I. Y. H. Gu, "Automatic classification of power system events using RMS voltage measurements," in *Proc. IEEE Power Eng. Soc. Summer Meeting*, 2002, doi: 10.1109/PSS.2002.1043446.
- [45] M. Biswal and P. K. Dash, "Detection and characterization of multiple power quality disturbances with a fast S-transform and decision tree based classifier," *Digital Signal Processing*, vol. 23, no. 4, pp. 1071–1083, 2013, doi: 10.1016/j.dsp.2013.02.012.
- [46] K. Cai, B. Alalibo, W. Cao, Z. Liu, Z. Wang, and G. Li, "Hybrid approach for detecting and classifying power quality disturbances based on the variational mode decomposition and deep stochastic configuration network," *Energies*, vol. 11, no. 11, p. 3040, 2018, doi: 10.3390/en11113040.
- [47] H. Erişti and Y. Demir, "A new algorithm for automatic classification of power quality events based on wavelet transform and SVM," *Expert Systems with Applications*, vol. 37, no. 6, pp. 4094–4102, 2010, doi: 10.1016/j.eswa.2009.11.015.
- [48] P. G. V. Axelberg, I. Y.-H. Gu, and M. H. J. Bollen, "Support Vector Machine for Classification of Voltage Disturbances," *IEEE Transactions on Power Delivery*, vol. 22, no. 3, pp. 1297–1303, Jul. 2007, doi: 10.1109/tpwrd.2007.900065.
- [49] B. Biswal, M. Biswal, S. Mishra, and R. Jalaja, "Automatic Classification of Power Quality Events Using Balanced Neural Tree," *IEEE Transactions on Industrial Electronics*, vol. 61, no. 1, pp. 521–530, Jan. 2014, doi: 10.1109/tie.2013.2248335.
- [50] N. Huang, D. Wang, L. Lin, G. Cai, G. Huang, J. Du, and J. Zheng, "Power quality disturbances classification using rotation forest and multi-resolution fast S-transform with

- data compression in time domain," *IET Generation, Transmission & Distribution*, vol. 13, no. 22, pp. 5091–5101, Nov. 2019, doi: 10.1049/iet-gtd.2018.5439.
- [51] A. Shaik and A. S. Reddy, "Flexible entropy based feature selection and multi class SVM for detection and classification of power quality disturbances," *Int. J. Intelligent Engineering and Systems*, vol. 11, no. 5, pp. 201–208, Oct. 2018, doi: 10.22266/ijies2018.1031.13.
- [52] M. Uyar, S. Yildirim, and M. T. Gencoglu, "An expert system based on S-transform and neural network for automatic classification of power quality disturbances," *Expert Systems with Applications*, vol. 36, no. 3, pp. 5962–5975, Mar. 2009, doi: 10.1016/j.eswa.2008.07.030.
- [53] S. De and S. Debnath, "Real-time cross-correlation-based technique for detection and classification of power quality disturbances," *IET Generation, Transmission & Distribution*, vol. 12, no. 3, pp. 688–695, Mar. 2018, doi: 10.1049/iet-gtd.2017.0507.
- [54] E. García-Rodríguez, E. Reyes-Archundia, J. A. Gutiérrez-Gnecchi, A. Méndez-Patino, M. V. Chávez-Báez, and J. C. Olivares-Rojas, "Detection and feature extraction of single power quality disturbances based on discrete wavelet transform, energy distribution and RMS extraction methods," in *2020 IEEE International Autumn Meeting on Power, Electronics and Computing (ROPEC)*, 2020, pp. 1–6, doi: 10.1109/ropec50909.2020.9258676.
- [55] M. Markovska, D. Taskovski, Z. Kokolanski, V. Dimchev, and B. Velkovski, "Real-time implementation of optimized power quality events classifier," *IEEE Transactions on Industry Applications*, vol. 56, no. 1, pp. 1–1, 2020, doi: 10.1109/tia.2020.2991950.
- [56] M. Meena, O. P. Mahela, M. Kumar, and N. Kumar, "Detection and classification of complex power quality disturbances using Stockwell transform and rule based decision tree," in *2018 International Conference on Smart Electric Drives and Power System (ICSEDPS)*, 2018, pp. 1–6, doi: 10.1109/icsedps.2018.853602.
- [57] E. G. Ribeiro, T. M. Mendes, G. L. Dias, E. R. S. Faria, F. M. Viana, B. H. G. Barbosa, and D. D. Ferreira, "Real-time system for automatic detection and classification of single

- and multiple power quality disturbances," *Measurement*, vol. 128, pp. 276–283, 2018, doi: 10.1016/j.measurement.2018.06.
- [58] M. Zhang, K. Li, and Y. Hu, "A real-time classification method of power quality disturbances," *Electric Power Systems Research*, vol. 81, no. 2, pp. 660–666, 2011, doi: 10.1016/j.epsr.2010.10.032.
- [59] Z. Oubrahim, Y. Amirat, M. Benbouzid, and M. Ouassaid, "Power quality disturbances characterization using signal processing and pattern recognition techniques: A comprehensive review," *Energies*, vol. 16, no. 6, p. 2685, 2023, doi: 10.3390/en16062685.
- [60] A. V. Oppenheim, A. S. Willsky, and S. H. Nawab, *Señales y sistemas*, 2nd ed. CRC Press, 1999.
- [61] E. N. Dialynas, "Interruption cost analysis for the electrical power customers in Greece," *16th International Conference and Exhibition on Electricity Distribution (CIRED 2001)*, 2001, doi: 10.1049/cp:20010749.
- [62] E. F. Fuchs and M. A. S. Masoum, "Introduction to Power Quality," in *Power Quality in Power Systems and Electrical Machines*, Academic Press, 2008, pp. 1-54. doi: 10.1016/B978-0-12-369536-9.X5000-3.
- [63] Y. Mohammadi, M. H. Moradi, and R. Chouhy Leborgne, "Locating the source of voltage sags: Full review, introduction of generalized methods and numerical simulations," *Renewable and Sustainable Energy Reviews*, vol. 77, pp. 821–844, 2017. doi: 10.1016/j.rser.2017.04.017.
- [64] Y.-K. Chen, X.-Z. Qiu, Y.-C. Wu, and C.-C. Song, "Compensation of voltage sags and swells using dynamic voltage restorer based on bi-directional H-bridge AC/AC converter," *Processes*, vol. 9, no. 9, p. 1541, 2021. doi: 10.3390/pr9091541.
- [65] Y. Shibuya, S. Fujita, and T. Shimomura, "Effects of very fast transient overvoltages on transformer," *IEE Proceedings - Generation, Transmission and Distribution*, vol. 146, no. 5, pp. 459, 1999. doi: 10.1049/ip-gtd:19990425.

- [66] M. Benaouadj, Z. Boumous, and S. Boumous, "Active harmonic filtering for improving power quality of an electrical network," *Journal Européen des Systèmes Automatisés*, vol. 55, no. 3, pp. 397-403, 2022. doi: 10.18280/jesa.550312.
- [67] S. A. Soliman and M. E. El-Hawary, "Measurement of power systems voltage and flicker levels for power quality analysis: a static LAV state estimation based algorithm," *Int. J. Electrical Power & Energy Systems*, vol. 22, no. 6, pp. 447-450, 2000. doi:10.1016/s0142-0615(00)00003-x.
- [68] D. Matvoz and M. Maksic, "Analysis of voltage notching in a low-voltage industrial network during the operation of a six-pulse AC/DC converter," in *2017 IEEE Power & Energy Society General Meeting*, Chicago, IL, USA, 2017, pp. 1-5. doi: 10.1109/pesgm.2017.8273979.
- [69] R. Sharma, M. Mishra, J. Nayak, B. Naik, and D. Pelusi, Eds., *Innovation in Electrical Power Engineering, Communication, and Computing Technology*. Lecture Notes in Electrical Engineering. Singapore: Springer, 2020. doi: 10.1007/978-981-15-2305-2.
- [70] S. M. Alessio, *Digital Signal Processing and Spectral Analysis for Scientists*. Signals and Communication Technology. Cham, Switzerland: Springer, 2016. doi: 10.1007/978-3-319-25468-5.
- [71] J. C. Bowman and Z. Ghoggali, "The Partial Fast Fourier Transform," *Journal of Scientific Computing*, vol. 76, no. 3, pp. 1578-1593, 2018. doi: 10.1007/s10915-018-0675-0.
- [72] V. Sukhoy and A. Stoytchev, "Generalizing the inverse FFT off the unit circle," *Scientific Reports*, vol. 9, no. 1, 2019. doi: 10.1038/s41598-019-50234-9.
- [73] L. Debnath, "Wavelet transforms and their applications," *Proceedings of the Indian National Science Academy - Part A*, vol. 64, no. 6, pp. 685-713, 1998.
- [74] C. Torrence and G.P. Compo, "A Practical Guide to Wavelet Analysis," *Bulletin of the American Meteorological Society*, vol. 79, no. 1, pp. 61-78, 1998. doi:10.1175/1520-0477(1998)079<0061 >2.0.CO;2.

- [75] I. Daubechies, J. Lu, and H.-T. Wu, "Synchrosqueezed wavelet transforms: An empirical mode decomposition-like tool," *Applied and Computational Harmonic Analysis*, vol. 30, no. 2, pp. 243–261, 2011. doi:10.1016/j.acha.2010.08.002.
- [76] P. Domingos, "A few useful things to know about machine learning," *Communications of the ACM*, vol. 55, no. 10, p. 78, 2012. doi:10.1145/2347736.2347755.
- [77] S. Mallat, "Understanding deep convolutional networks," *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, vol. 374, no. 2065, p. 20150203, 2016. doi:10.1098/rsta.2015.0203.
- [78] K. Sarkar, D. Bonnerjee, R. Srivastava, and S. Bagh, "A single layer artificial neural network type architecture with molecular engineered bacteria for reversible and irreversible computing," *Chemical Science*, vol. 12, no. 48, pp. 15821–15832, 2021. [Online]. Available: <https://doi.org/10.1039/d1sc01505b>.
- [79] R. Jozefowicz, W. Zaremba, and I. Sutskever, "An empirical exploration of recurrent network architectures," *Proceedings of the 32nd International Conference on Machine Learning*, vol. 37, pp. 2342–2350, 2015. [Online]. Available: <https://proceedings.mlr.press/v37/jozefowicz15.html>.
- [80] C. Mishra and D. L. Gupta, "Deep Machine Learning and Neural Networks: An Overview," *IAES International Journal of Artificial Intelligence (IJ-AI)*, vol. 6, no. 2, pp. 66–73, 2017. [Online]. Available: <https://doi.org/10.11591/ijai.v6.i2.pp66-73>.
- [81] D. E. Rumelhart, G. E. Hinton, and R. J. Williams, "Learning internal representations by error propagation," in *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*, vol. 1, D. E. Rumelhart and J. L. McClelland, Eds. Cambridge, MA: MIT Press, 1986, pp. 318–362. [Online]. Available: <https://doi.org/10.7551/mitpress/5236.003.0012>.
- [82] M. Buscema, *Back Propagation Neural Networks*, Semeion Research Center of Sciences of Communication, Rome, Italy, 1998. Available: Semeion.
- [83] Q. Wang, Y. Ma, K. Zhao, and Y. Tian, "A Comprehensive Survey of Loss Functions in Machine Learning," *Annals of Data Science*, 2020. doi: 10.1007/s40745-020-00253-5.

- [84] L. Bottou, F. E. Curtis, and J. Nocedal, "Optimization Methods for Large-Scale Machine Learning," *SIAM Review*, vol. 60, no. 2, pp. 223–311, 2018. doi: 10.1137/16m1080173.
- [85] M. A. Mercioni and S. Holban, "P-Swish: Activation Function with Learnable Parameters Based on Swish Activation Function in Deep Learning," *2020 International Symposium on Electronics and Telecommunications (ISETC)*, 2020, pp. 1–5, doi: 10.1109/isetc50328.2020.9301059.
- [86] M. D. Zeiler and R. Fergus, "Visualizing and Understanding Convolutional Networks," *European Conference on Computer Vision (ECCV)*, Zurich, Switzerland, 2014, pp. 818–833, doi: 10.1007/978-3-319-10590-1_53.
- [87] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov, "Dropout: A Simple Way to Prevent Neural Networks from Overfitting," *Journal of Machine Learning Research*, vol. 15, no. 56, pp. 1929–1958, 2014. [Online]. Available: <https://jmlr.org/papers/v15/srivastava14a.html>