



Universidad Autónoma de Querétaro

Facultad de Ingeniería

Metodologías de aprendizaje profundo para mejorar la
detección e identificación de perturbaciones de la calidad de
la energía

Tesis

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

Presenta:

Artvin Darién González Abreu

Dirigido por:

Dr. Roque Alfredo Osornio Rios

Codirigido por:

Dr. Miguel Delgado Prieto

 (Universidad Politécnica de Cataluña)

San Juan del Río, Querétaro, julio de 2023



Dirección General de Bibliotecas y Servicios Digitales
de Información



Metodologías de aprendizaje profundo para mejorar la
detección e identificación de perturbaciones de la
calidad de la energía

por

Artvin Darién González Abreu

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

Clave RI: IGDCC-222929



Universidad Autónoma de Querétaro
Facultad de Ingeniería
Doctorado en Mecatrónica

**Metodologías de aprendizaje profundo para mejorar la
detección e identificación de perturbaciones de la calidad
de la energía**

Tesis

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

Presenta:

Artvin Darién González Abreu

Dirigido por:

Dr. Roque Alfredo Osornio Rios

Sinodales

Dr. Roque Alfredo Osornio Rios
Presidente

Dr. Miguel Delgado Prieto
Secretario

Dr. Juan José Saucedo Dorantes
Vocal

Dr. Arturo Yosimar Jaen Cuellar
Suplente

Dr. Martín Valtierra Rodríguez
Suplente

San Juan del Río, Querétaro, julio 2023

Resumen

El uso eficaz de la energía eléctrica es una cuestión importante en los tiempos actuales, donde se han desarrollado nuevas tecnologías que involucren una optimización de recursos para aprovechar correctamente la generación de la energía. Debido a la propia generación y naturaleza eléctrica de las cargas, la red eléctrica puede sufrir diversos fenómenos considerados disturbios eléctricos, que son una alteración de la forma de onda establecida a la cual los equipos y dispositivos eléctricos están diseñados para funcionar correctamente. A pesar de que ya existen normas y estándares donde estos fenómenos están definidos y caracterizados, no reflejan la realidad actual de los ambientes eléctricos, los cuales pueden llevar a fenómenos eléctricos no antes vistos o combinaciones de varios disturbios presentados de manera simultánea. La detección e identificación de disturbios y de condiciones anómalas de la calidad de la energía es la cuestión fundamental de este trabajo de investigación. Mediante la implementación de técnicas de aprendizaje profundo, se llevan a cabo distintas metodologías para mejorar la detección e identificación tanto de los disturbios eléctricos como de condiciones que no estén consideradas en la norma, adicionando el enfoque de detección de novedad para fenómenos eléctricos que no están considerados en los estándares actuales y aquellos que pueden no llegar a haberse presentado con anterioridad. El uso de aprendizaje profundo se justifica debido a la alta gestión de datos que estas técnicas permiten, llevando así una mejora y un espectro de aquello que no está dado dentro de lo establecido como conocido en la detección e identificación en la calidad de la energía.

Palabras claves: aprendizaje profundo, calidad de la energía, detección de novedad.

Abstract

Efficient use of electrical energy is an important issue in today's times, where new technologies have been developed that involve optimizing resources to make the best use of energy generation. Due to the loads' very generation and electrical nature, the electrical network can suffer various phenomena considered electrical disturbances, which alter the established waveform to which electrical equipment and devices are designed to function correctly. Although there are already norms and standards where these phenomena are defined and characterized, they do not reflect the current reality of electrical environments, which can lead to electrical phenomena not seen before or combinations of several disturbances presented simultaneously. The detection and identification of disturbances and anomalous power quality conditions is the fundamental issue of this research work. By implementing deep learning techniques, different methodologies are carried out to improve the detection and identification of both electrical disturbances and conditions that are not considered in the standard, adding the novelty detection approach for electrical phenomena that are not considered in the current standards and those that may not have been presented before. The use of deep learning is justified due to the high data management that these techniques allow, thus bringing an improvement and a spectrum that is not given within the established as known in the detection and identification of power quality.

Keywords: deep learning, power quality, novelty detection.

Dedicatorias

A mi tía Josefa y a mi abuelo Héctor, siempre estarán en mi recuerdo con mucho cariño.

Agradecimientos

En primer lugar a mi mamá y a mi papá, principalmente con su esfuerzo y gracias a su educación desde casa he podido avanzar muy lejos en la vida.

A mi hermano, mis tías, tíos, primos y familia que siempre me han apoyado dentro y más allá de sus posibilidades.

Al Dr. Roque por siempre poder contar con su apoyo, disponibilidad, empatía, paciencia y guía a lo largo del desarrollo del proyecto.

Agradezco enormemente a mi coasesor, el Dr. Miguel Delgado por toda la atención, paciencia, disponibilidad y esfuerzo que me otorgo tanto en mi estancia en el extranjero, así como de manera remota. De la misma manera agradezco al grupo de MCIA que me trato de manera espectacular en mi estancia en su universidad.

A mis amigos y compañeros de posgrado, Omar, Jean Karlo, Daniel Jaramillo, Robert, Ervin, Salvador, Isra y aquellos con los que compartí clase y cubículos en el tiempo del posgrado.

A mis profesores, de alguna forma son figuras aspiracionales en las que uno puede tomar referencia para ser una mejor persona con sus enseñanzas, consejos y forma de actuar.

De manera general quiero agradecer a cada una de las personas que he tenido el placer de conocer en las diferentes épocas de mi vida, y de las cuales he aprendido y me han aportado tanto de manera personal y profesional.

Índice general

Resumen	i
Abstract	ii
Dedicatorias.....	iii
Agradecimientos	iv
Índice general.....	v
Índice de figuras	viii
Índice de tablas	x
1. Introducción	1
1.1. Antecedentes	1
1.2. Descripción del problema	13
1.3. Justificación	14
1.4. Hipótesis y Objetivos.....	15
1.4.1. Hipótesis	15
1.4.2. Objetivos.....	15
1.5. Planteamiento general.....	16
2. Fundamentación teórica	18
2.1. Calidad de la energía.....	18
2.1.1. Disturbios eléctricos	18
2.2. Técnicas de Aprendizaje Profundo	26
2.3. Detección de novedad.....	31
2.3.1. Métodos probabilísticos.....	32
2.3.2. Métodos basados en dominio	34
2.3.3. Métodos basados en distancia	35
2.4. Evaluación de modelos de aprendizaje profundo y detección de novedad.....	37

2.4.1.	Herramientas para evaluar modelos de aprendizaje profundo.....	37
2.4.2.	Herramientas para evaluar modelos de detección de novedad.....	40
3.	Metodología.....	42
3.1.1.	Señales sintéticas.....	43
3.1.2.	Señales de bases de datos.....	44
4.	Casos de estudio y puesta de experimentos.....	47
4.1.	Identificación.....	47
4.2.	Detección.....	49
4.3.	Fotovoltaica.....	51
4.4.	Aerogeneración.....	52
5.	Resultados y discusión.....	53
5.1.	Resultados de la identificación.....	53
5.2.	Resultados de la detección.....	56
5.3.	Resultados del estudio en señales de fotovoltaica.....	58
5.3.1.	Subcaso 1a.....	58
5.3.2.	Subcaso 1b.....	59
5.3.3.	Subcaso 1c.....	61
5.3.4.	Subcaso 1d.....	62
5.3.5.	Subcaso 1e.....	63
5.4.	Resultados del estudio en señales de aerogeneración.....	64
5.4.1.	Subcaso 2a.....	64
5.4.2.	Subcaso 2b.....	65
5.4.3.	Subcaso 2c.....	67
5.4.4.	Subcaso 2d.....	68
5.4.5.	Subcaso 2e.....	69

6. Conclusiones.....	71
Referencias Bibliográficas	73
Apéndice	80
Publicaciones: Contribuciones de tesis.....	80
Publicaciones: Colaboraciones y otros trabajos	82

Índice de figuras

Figura 1.1. Planteamiento general del proyecto (Fuente: autoría propia).	16
Figura 2.1. Disturbio eléctrico transitorio oscilatorio (Fuente: autoría propia).....	20
Figura 2.2. Disturbio eléctrico aumento de voltaje (Fuente: autoría propia).	21
Figura 2.3. Disturbio eléctrico caída de voltaje (Fuente: autoría propia).....	21
Figura 2.4. Disturbio eléctrico armónicos (Fuente: autoría propia).	23
Figura 2.5. Disturbio eléctrico muescas (Fuente: autoría propia).	24
Figura 2.6. Disturbio eléctrico ruido (Fuente: autoría propia).	24
Figura 2.7. Disturbio eléctrico fluctuaciones (Fuente: autoría propia).....	25
Figura 2.8. Diagrama de conjuntos jerárquico de la inteligencia artificial (Fuente: autoría propia).....	26
Figura 2.9. Flujo del aprendizaje automático y del aprendizaje profundo. (Fuente: autoría propia).....	27
Figura 2.10. Autoencoder apilado compuesto de dos autoencoders. (Fuente: Cardoso, 2019)	30
Figura 2.11. Ejemplo de matriz de confusión (Fuente: autoría propia).....	38
Figura 3.1. Diagrama general de la metodología seguida (Fuente: autoría propia).	42
Figura 4.1. Diagrama para la experimentación con la identificación de disturbios eléctricos (Fuente: autoría propia).	47
Figura 5.1. Reconstrucción por el autoencoder y vector de error (Fuente: autoría propia)..	53
Figura 5.2. Evolución del rendimiento de los escenarios para la detección de novedad (Fuente: autoría propia).	57
Figura 5.3. Gráfico del rendimiento de las técnicas para el subcaso 1a (Fuente: autoría propia).....	59
Figura 5.4. Gráfico del rendimiento de las técnicas para el subcaso 1b (Fuente: autoría propia).....	60

Figura 5.5. Gráfico del rendimiento de las técnicas para el subcaso 1c (Fuente: autoría propia).....	61
Figura 5.6. Gráfico del rendimiento de las técnicas para el subcaso 1d (Fuente: autoría propia).....	62
Figura 5.7. Gráfico del rendimiento de las técnicas para el subcaso 1e (Fuente: autoría propia).....	63
Figura 5.8. Gráfico del rendimiento de las técnicas para el subcaso 2a (Fuente: autoría propia).....	65
Figura 5.9. Gráfico del rendimiento de las técnicas para el subcaso 2b (Fuente: autoría propia).....	66
Figura 5.10. Gráfico del rendimiento de las técnicas para el subcaso 2c (Fuente: autoría propia).....	67
Figura 5.11. Gráfico del rendimiento de las técnicas para el subcaso 2d (Fuente: autoría propia).....	68
Figura 5.12. Gráfico del rendimiento de las técnicas para el subcaso 2e (Fuente: autoría propia).....	69

Índice de tablas

Tabla 3.1. Indicadores estadísticos considerados para la caracterización de la señal eléctrica	45
Tabla 4.1. Disturbios eléctricos considerados	48
Tabla 4.2. Tipos de disturbios dentro de los considerados	49
Tabla 4.3. Configuración de cada escenario para la detección de novedad	49
Tabla 4.4. Propuestas para la detección de novedad	50
Tabla 4.5. Subcasos establecidos para la experimentación de señales reales de generación fotovoltaica para la detección de novedad.....	51
Tabla 4.6. Subcasos establecidos para la experimentación con señales reales de generación eólica para la detección de novedad	52
Tabla 5.1. Rendimiento de la identificación y clasificación de disturbios eléctricos.....	54
Tabla 5.2. Rendimiento de clasificación a diferentes niveles de ruido.	55
Tabla 5.3. Matriz de confusión para la clasificación de las señales de bases de datos	56
Tabla 5.4. Nomenclatura de las técnicas de detección de novedad evaluadas	57
Tabla 5.5. Rendimientos de cada técnica para el subcaso 1a.	59
Tabla 5.6. Rendimientos de cada técnica para el subcaso 1b.	60
Tabla 5.7. Rendimientos de cada técnica para el subcaso 1c.	61
Tabla 5.8. Rendimientos de cada técnica para el subcaso 1d.	62
Tabla 5.9. Rendimientos de cada técnica para el subcaso 1e.	64
Tabla 5.10. Rendimientos de cada técnica para el subcaso 2a.	65
Tabla 5.11. Rendimientos de cada técnica para el subcaso 2b.	66
Tabla 5.12. Rendimientos de cada técnica para el subcaso 2c.	67
Tabla 5.13. Rendimientos de cada técnica para el subcaso 2d.	68
Tabla 5.14. Rendimientos de cada técnica para el subcaso 2e.	70

1. Introducción

La calidad de la energía eléctrica es un tema de interés y ha llegado a consolidarse como una importante área de investigación desde hace unos años, debido a los indeseables efectos que un inadecuado suministro de energía eléctrica puede producir sobre la maquinaria y los dispositivos conectados a la red. La calidad de la energía se refiere a una correcta energía eléctrica respecto a una amplitud y frecuencia establecidas para un adecuado uso por los dispositivos y sistemas eléctricos. La cadena de suministro eléctrico incluye las fases de generación, transmisión y consumo. Es en el nivel de consumo, comúnmente de corriente alterna (CA), entre 120 V a 600 V donde se encuentran la mayoría de las cargas y conexiones en los sistemas eléctricos (American National Standards Institute, 2006). Consecuentemente es en este nivel donde existe un mayor interés en aplicar procedimientos de monitoreo de la calidad de la energía (Singh et al., 2015). Los sistemas eléctricos de CA están desarrollados para actuar bajo un voltaje sinusoidal a una magnitud dada y frecuencia típicamente de 50 o 60 Hz.

Específicamente la detección y clasificación de las perturbaciones de la calidad de la energía eléctrica ha sido una preocupación inquietante debido, por un lado, al número creciente de cargas potencialmente perturbadoras conectadas a la línea eléctrica y, por otro, a la susceptibilidad de ciertas cargas a la presencia de estas perturbaciones. Las perturbaciones se pueden presentar de manera individual o combinada, siempre con cierta dependencia de la instalación y bajo diferentes niveles de severidad, lo que hace difícilmente caracterizarles a priori en toda su posible variabilidad de aparición. Estos patrones complejos de disturbios pueden representar condiciones anómalas, efectos de otros elementos de las máquinas u operaciones que están fuera de las normas que describen los comportamientos no deseados de la calidad de la energía. Para afrontar este reto de monitorización y supervisión se han planteado múltiples técnicas y estudios para la detección y clasificación de las perturbaciones eléctricas y de condiciones no previamente identificadas.

1.1. Antecedentes

La expresión “calidad de la energía” alude a las características óptimas de las señales de corriente y de la fuente de voltaje que son demandadas por la cargas eléctricas de

manera lineal o no lineal. Estas cualidades especifican a una onda sinusoidal ideal que contiene exclusivamente la componente fundamental, sin desviaciones en frecuencia y con amplitud constante. El estándar IEEE 1159-2019 (IEEE Recommended Practice for Monitoring Electric Power Quality, 2019) clasifica los fenómenos electromagnéticos como: impulso, oscilaciones, sobretensiones, subtensiones, interrupciones, desplazamiento DC, fluctuaciones de tensión y frecuencia, entre otros, y para los cuales se establecen índices sobre parámetros eléctricos acorde a las formas de onda de las señales de corriente y voltaje con las cuales se puede estimar perfectamente la calidad de la energía, estos índices sirven para cuantificar y diagnosticar los disturbios eléctricos.

Sin embargo, debido a los escenarios industriales prácticos, en los que coexisten diferentes cargas eléctricas como convertidores de estado sólido, dispositivos de iluminación con balastos electrónicos, elementos de calefacción controlados, fuentes de alimentación de imanes, cargadores de baterías, hornos, accionamientos de velocidad ajustable, sistemas de aire acondicionado, bombas o ascensores, entre otros, las perturbaciones pueden producirse en forma de combinaciones múltiples. Por lo tanto, dando lugar a patrones complejos que no están directamente representados por las clásicas descripciones de perturbaciones simples (Liu et al., 2018). De hecho, la naturaleza de las perturbaciones de la calidad de la energía incluye una combinación no periódica y desigual de perturbaciones junto con los ciclos de trabajo de las cargas eléctricas relacionadas conectadas a la red de suministro de energía bajo monitoreo. Este hecho representa un desafío actual en el diagnóstico de la calidad de la energía, dado que ese número de posibles patrones de perturbación y las variantes relacionadas, superan las capacidades de los métodos disponibles, normalmente restringidos a un número reducido de perturbaciones.

En este sentido, la comunidad científica, lleva tiempo intentando, por un lado, detectar, lo antes posible la aparición de perturbaciones (detectándolas en sus etapas iniciales) y, segundo, identificarlas automáticamente. Como resultado de las investigaciones y estudios realizados desde hace unos años, se identifica una confluencia de la comunidad científica respecto a la metodología global para realizar la detección y clasificación de perturbaciones en una red eléctrica. La mayor parte de la literatura relacionada en el campo señala que el enfoque de detección e identificación de fallas basado en datos representa la estrategia de

monitoreo de la calidad de la energía más prometedora (Minh and Van, 2020). Específicamente, la comunidad científica está investigando y proponiendo soluciones basadas en cinco etapas fundamentales a la hora de abordar el problema. Estas etapas pueden ser denominadas tal como: (i) Procesado de las señales eléctricas, (ii) Estimación de indicadores característicos, (iii) Reducción de dimensionalidad, (iv) Modelado del comportamiento y, (v) Clasificación de perturbaciones. Bajo esta estructura existen múltiples propuestas para investigar las posibilidades que ofrecen múltiples técnicas y combinaciones con el propósito final de ampliar la fiabilidad y la precisión del proceso de detección y clasificación.

Así, respecto al procesado de las señales, se recurre a aplicar enfoques de dominio de tiempo, dominio de frecuencia y dominio de tiempo-frecuencia junto con distintas metodologías, como serían la transformada wavelet, la transformada Hilbert, la transformada de Gabor, la transformada de Gabor-Wigner, la transformada S y la transformada de Hilbert-Huang entre otras. Los trabajos descritos a continuación muestran algunas de las técnicas mencionadas anteriormente, que han sido aplicadas significativamente para la detección y clasificación de perturbaciones, siempre combinadas con algunas de las etapas descritas anteriormente y materializadas bajo técnicas estadísticas, pero también propias de la inteligencia artificial. Este es el caso del trabajo presentado por Manikandan & Samantaray (2015), donde se estudió un nuevo método para la detección y clasificación de perturbaciones únicas y combinadas utilizando una descomposición de la señal dispersa en una matriz de diccionario híbrido sobrecargada, descomponiendo las señales en detalle y aproximación. Las características de la señal eléctrica se extraen de las señales de aproximación y detalle; y después utilizan un algoritmo de árbol de decisión jerárquico para la clasificación de las perturbaciones, demostrando la existencia y oportunidad de extraer patrones característicos de la señal eléctrica. El método demostró precisión y solidez en la detección de perturbaciones únicas y combinadas probando perturbaciones simuladas y sintéticas. De manera similar, Li et al. (2016), presentaron un nuevo algoritmo para la detección y clasificación de perturbaciones basadas en la combinación de la transformada S de doble resolución y una variante de las máquinas de soporte vectorial, donde redujeron la complejidad computacional sin descuidar la información útil de la señal original y este algoritmo se puede implementar en aplicaciones integradas en tiempo real. Se mostró la

efectividad del método mediante simulaciones por computadora y experimentos prácticos, también con perturbaciones únicas y combinadas. Kumar et al. (2016) realizaron una metodología basada en componentes simétricos en el dominio del tiempo para la detección y clasificación de varias perturbaciones de la calidad de la energía, en la cual la señal de perturbación se procesa para descubrir los componentes simétricos de todas las fases en el dominio del tiempo, presentan resultados simulados y en tiempo real para una serie de perturbaciones y así demostrar la efectividad del método. El trabajo concluye que al ser una técnica en el dominio del tiempo y, por lo tanto, de bajo costo computacional, facilita su adopción para el monitoreo y evaluación en línea de perturbaciones. Ese mismo año Mendes et al. (2016) propusieron un método para la detección de perturbaciones que operaba en un espacio multidimensional, donde la característica está representada en un espacio con dimensión igual a la ventana de la señal procesada, pero con una complejidad computacional reducida y haciendo uso de una medida de desviación para cuantificar las perturbaciones. En el trabajo presentado por Mahela & Shaik (2017), consideraron el cálculo de características estadísticas mediante el análisis multiresolución de señales basado en la transformada S para caracterizar varias perturbaciones y su reconocimiento posterior. En la clasificación de las perturbaciones de la calidad de la energía también se encuentra la problemática en la selección óptima de aquellas características que permitan mejorar la clasificación, de tal forma que sea más precisa y minimizando el tiempo computacional, relacionado a esto Jamali et al. (2018) presentaron un método en el cual mediante el uso de características eficientes de la señal eléctrica se logró la clasificación precisa con una complejidad computacional mínima. Utilizaron una frecuencia de muestreo de 6.4 kHz en 10 ciclos de formas de onda distorsionadas para la extracción de las características mediante el uso de diferentes funciones de transformación y diversos algoritmos que permiten la selección precisa de las características de la señal. El trabajo valida la precisión del método mediante diferentes estudios de simulación. Por otra parte Jeevitha & Mabel (2018) propusieron un algoritmo que consistía en la selección de características óptimas de los disturbios en la calidad de la energía eléctrica basándose en la transformada wavelet discreta y en la red neuronal probabilística. Las señales de perturbación pueden cubrir un amplio espectro de frecuencias debido a su alta tasa de muestreo y pueden producir gran cantidad de datos que conlleven a la necesidad de un alto espacio de almacenamiento, así, en su trabajo, la transformada wavelet

discreta es utilizada para analizar las señales de perturbación y para reducir el espacio de almacenamiento necesario, en tanto que la red neuronal se utiliza como clasificador de los disturbios. Jamali et al. (2018) presentaron un estudio en el que se centra la atención en la etapa de selección de características, exploran el rendimiento logrado por diferentes subconjuntos de características extraídas de las técnicas habituales de procesamiento de señales. El inconveniente de este enfoque, a pesar de lograr un buen rendimiento, es la necesidad de caracterizar la señal mediante diversas técnicas de procesamiento de señales que dan lugar a una complejidad computacional mucho mayor. Así mismo, el trabajo presentado por Cortes-Robles et al. (2020), se sustenta en la descomposición en modo variacional de la señal original y el análisis de cuantificación de la recurrencia, logra una caracterización adecuada de las señales eléctricas antes de su identificación siguiendo un enfoque basado en los datos. Karasu & Saraç (2020) propusieron un método novedoso para extraer las características de la señal argumentando que transformar la señal unidimensional en señales bidimensionales es útil para la etapa de extracción de características. Con el fin de clasificación, evaluaron los diferentes modelos de aprendizaje de máquinas como el vecino más cercano, el perceptrón multicapa y la máquina de soporte vectorial para determinar cuál de estos modelos presenta un mejor rendimiento con su propuesta. Todos los trabajos relacionados, sin embargo, concluyen que no existe un dominio superior que se ocupe de la caracterización de la señal, pero la fusión de la información representa el enfoque más prometedor (Li et al., 2016). La reducción de esos conjuntos de indicadores numéricos en lo que respecta a su importancia para caracterizar las perturbaciones representa un paso fundamental basado en los datos. La información no significativa y redundante debe ser descartada o atenuada para optimizar las tareas posteriores de reconocimiento de patrones. Algunos autores, como Kumar et al. (2016) o Zhu et al. (2019), consideran que los algoritmos clásicos son el Análisis de Componentes Principales (PCA, *Principal Component Analysis*) o los métodos de selección secuencial hacia adelante. Sin embargo, al tratarse de una mayor variedad de patrones, como lo requieren las aplicaciones actuales de monitoreo de las perturbaciones de la calidad de la energía, estos enfoques tienen un rendimiento limitado (Mishra, 2019). Los métodos existentes para la clasificación de disturbios eléctricos presentan imprecisión en el proceso de selección de indicadores significativos, además existe una falta de datos de entrenamiento adecuadamente etiquetados (Jian and Wang, 2021). En

definitiva, la detección precisa y la clasificación de las perturbaciones de la calidad de la energía en los sistemas de distribución eléctrica son un paso clave para determinar las causas de estos eventos antes de que se pueda tomar una contramedida adecuada, habilitando así la implementación de posteriores sistemas de mantenimiento y control predictivo.

De manera local, aunque también con impacto internacional, los siguientes trabajos de investigación se han realizado en la Universidad Autónoma de Querétaro y son precedentes importantes en el avance de este campo de investigación; Valtierra-Rodriguez et al. (2014), presentaron una nueva metodología dual soportada en redes neuronales para detectar y clasificar perturbaciones únicas y combinadas, una parte consiste en una red lineal adaptativa para la estimación armónica e interarmónica y por otra parte una red neuronal para el reconocimiento de patrones utilizando los histogramas horizontales y verticales de una forma de onda de voltaje específica. Por lo tanto, combinando las redes neuronales descritas puede realizar la detección y clasificación de ciertas perturbaciones incluso cuando aparecen simultáneas. Elvira-Ortiz et al. (2018) presentaron el uso de un sistema de monitoreo de calidad de energía aplicado en tres escenarios diferentes, el sistema adquiere y almacena datos durante períodos prolongados, y luego los datos pueden procesarse para identificar las perturbaciones de la calidad de la energía en la red eléctrica, mostrando que el equipo puede adquirir, almacenar y procesar datos para identificar una amplia gama de alteraciones en la calidad de la energía. En este mismo año Rodríguez-Guerrero et al. (2018) propusieron un enfoque híbrido que integra algoritmos genéticos y optimización de enjambre de partículas con otras técnicas que hacen uso de sus capacidades individuales para encontrar automáticamente un amplio rango de disturbios en la calidad de la energía presentes en una señal de voltaje o corriente, independientemente de su naturaleza. Para lograr esta parametrización de enfoque híbrido, se adopta un modelo completo para automatizar la búsqueda de cada uno de sus parámetros, el enfoque propuesto se valida mediante señales sintéticas, señales reales de una base de datos de IEEE y lecturas de un proceso real. De manera similar Guillén-García et al. (2019), presentaron una metodología con la finalidad de clasificar e identificar los tipos de carga en entornos industriales, donde las cantidades de energía eléctrica y los valores actuales se utilizan para establecer índices con el fin de usarlos como características para un algoritmo y realizar la clasificación de carga, su experimentación se realiza en una instalación de atención médica que recopila datos

eléctricos en diferentes cuadros de distribución eléctrica. Relacionado con las fuentes de energía renovable Elvira-Ortiz et al. (2022) propusieron una metodología para la detección de disturbios de la calidad de la energía en redes que cuentan con suministro de energía eólica. Realizan una extracción de indicadores en múltiples dominios de la señal eléctrica y mediante algoritmos genéticos y análisis de componentes principales reducen la dimensionalidad de los datos con el fin de optimizar los datos que son enviados a una estructura de red neuronal llamada mapas de autoorganización para la detección de seis diferentes perturbaciones.

Recientemente la creciente integración de las fuentes de energía renovable en los sistemas de energía eléctricos han generado nuevos retos en la planificación y operación de la red eléctrica, por lo que se requiere investigar y analizar adecuadamente los impactos de las energías renovables en el sistema de energía (Bayindir et al., 2016), principalmente porque tienen un impacto significativo en la estabilidad de la transmisión de la electricidad debido a la naturaleza impredecible de las fuentes. En resumen, el estudio e investigación de nuevas metodologías que permitan identificar anomalías está siendo, en los últimos años, un campo de creciente actividad. Sin embargo, se identifican dos áreas de actualidad que están atrayendo y requieren la atención de la comunidad científica. Una de ellas, se refiere a la capacidad de detección de perturbaciones, que considera la asignación de una etiqueta al efecto caracterizado, la detección de perturbaciones se refiere a una caracterización del conocimiento disponible respecto al funcionamiento y operación de la red eléctrica monitorizada. Esto incluye su operación normal, pero también su operación bajo perturbaciones previamente caracterizadas. Así, la tarea de detección de perturbaciones debe ser capaz de revelar su globalidad, nuevos comportamientos en la red de distribución supervisada respecto de aquellos patrones conocidos. Esta funcionalidad tiene un alto impacto en los sistemas de monitorización y supervisión, ya que, actualmente la mayoría de metodologías estudiadas, no afrontan directamente la situación de evaluación de los sistemas de diagnóstico bajo escenarios nuevos no previamente caracterizados, lo que resulta, generalmente, en falsos positivos o, en el peor caso, falsos negativos.

Este campo de estudio, aunque existen algunas experiencias de aplicación en el entorno de la calidad de la energía, es en otras aplicaciones donde se encuentra de forma más

amplia bajo estudio. En especial teniendo en cuenta esta capacidad de detección de novedades, que permite la detección de datos/patrones nuevos (desconocidos) está ha tenido un pronunciado aumento en los últimos años debido a la fuerza impulsora de aplicaciones como el monitoreo de sistemas críticos para la seguridad y la detección de nuevos objetos en secuencias de imágenes. En el trabajo de Khutlang & Nelwamondo (2015) presentaron una segmentación automática de la capa papilar para la aplicación de escáneres biométricos de huellas dactilares donde utilizan la epidermis como el objetivo de la detección de novedades que se aplica a los cortes de imágenes en los cuales el contorno de la capa papilar se segmenta como el límite entre el objetivo y las clases de rechazo que resultan de la detección de novedades. Otro trabajo es el de Ding et al. (2015), en el cual realizaron el enfoque de descripción de límite de conjunto de niveles para la detección de novedades que trata el límite no lineal directamente en el espacio de entrada y lleva a cabo amplios experimentos en conjuntos de datos de referencia para evaluar el método propuesto y compararlo con cuatro métodos de detección de novedad representativos y concluyen que puede detectar anomalías de manera efectiva con su método. Actualmente hay varios estudios que investigan la utilidad de técnicas de detección de novedades en flujos de datos, uno de ellos es el presentado por De Faria et al. (2015), donde propusieron una nueva metodología de evaluación para la detección de novedad multiclase en flujos de datos capaces de tratar con: aprendizaje no supervisado, matriz de confusión que aumenta a lo largo del tiempo, matriz de confusión con una columna que representa los ejemplos desconocidos y representación de las medidas de evaluación a lo largo del tiempo; finalmente evalúan el rendimiento de su metodología propuesta con conjuntos de datos reales y artificiales. Como una aplicación en robótica Soares et al. (2016) propusieron un método de Detección de Novedades con distancia de compresión Normalizada (NDN, *Novelty Detection with Normalized Compression Distance*) para contribuir al control de navegación de los robots móviles. Primero utilizan un algoritmo genético para la planificación de la ruta y luego utiliza el NDN para reconocer diferentes características ambientales, realizaron experimentos en un simulador de robótica y en un ambiente interior real y para finalizar compararon el rendimiento del NDN con una red neuronal entrenada para reconocer cambios en el entorno, y concluyeron indicando que NDN es un enfoque prometedor como control de navegación en robots móviles. Recientemente Cabral & De Oliveira (2017) presentaron en su trabajo una metodología para generar

ejemplos de novedad artificial para guiar el proceso de optimización de parámetros y demuestran que el enfoque utilizado al utilizar muestras artificiales es competitivo respecto al utilizar muestras reales de novedad, y más tarde Sayyed (2017) explica el concepto general para detectar los datos de novedad que se utilizan en la taxonomía de los métodos de conjuntos de niveles, debido a que el objetivo principal de su trabajo es identificar los datos importantes que normalmente se pierden durante el proceso de entrenamiento.

La segunda área de actualidad que está atrayendo y, de la misma manera, requiere la atención de la comunidad científica, se refiere al aprendizaje profundo, el cual alude a una parte de los métodos existentes en el conjunto de la inteligencia artificial que imita los mecanismos de la mente humana para procesar registros e inferir resultados. Las técnicas de aprendizaje de máquinas, especialmente las basadas en redes neuronales, han atraído cada vez más atención en las últimas décadas y han sido ampliamente utilizadas en minería de datos, visión computacional, reconocimiento de datos y clasificación. Sin embargo, las redes neuronales clásicas aún presentan limitaciones a su aplicabilidad. Desde la perspectiva de la ingeniería, se requiere muy a menudo un trabajo extenso en lo que se refiere a la reducción de dimensionalidad de los indicadores extraídos para evitar problemas de pérdida de rendimiento, lo que, a su vez, repercute en una limitación en la variabilidad de la información asumible por una misma estructura neuronal. En este sentido, un reciente avance en el entorno de la inteligencia artificial y los enfoques de aprendizaje automático es la introducción del aprendizaje profundo.

En este sentido, las aplicaciones de redes neuronales tradicionales implementan arquitecturas poco profundas, siendo la red neuronal de propagación hacia adelante (FNN, *Feed-forward Neural Network*) con tres capas la más común, donde la primera capa corresponde a las entradas, la intermedia a una capa oculta, y la capa final a las salidas. En tales redes, las entradas son un conjunto de señales cuidadosamente seleccionadas y procesadas obtenidas mediante la reducción de características y/o el conocimiento de ingeniería, porque no pueden aprender características complejas y relaciones de los datos en bruto. En contraste, el aprendizaje profundo asume un planteamiento de aprendizaje de características, es decir, las características se descubren en lugar de seleccionarse. Esto es posible aprovechando las propiedades de las redes profundas, donde las capas iniciales

extraen las características significativas de una manera no supervisada y las capas finales asignan estas características al objetivo predeterminado (clasificación). Al seguir este enfoque, la red resultante puede trabajar con un conjunto más amplio de entradas, permitiendo una variabilidad mayor de la información. Sin embargo, a mayor número de capas en la red, se hace más palpable un problema práctico, donde el algoritmo clásico de propagación (*feed-forward*), no actualiza los pesos a través de las capas durante el proceso de entrenamiento, ya que el gradiente se vuelve demasiado pequeño para influir en un cambio significativo e impide un aprendizaje correcto de las primeras capas. Este es un problema conocido como el desvanecimiento del gradiente. En esta dirección, ha llegado a demostrarse en los últimos años, que varias técnicas pueden ser eficaces para aliviar este problema, incluido el uso de diferentes arquitecturas de red, como la red neuronal convolucional (CNN, *Convolutional Neural Network*), o el uso de técnicas de regularización, como el método de deserción. Ejemplos de la diversidad de estas aplicaciones son como el trabajo de Yuan et al. (2015) donde en el campo de visión por computadora, específicamente el reconocimiento de escenas, propusieron una arquitectura profunda para el reconocimiento de la escena explorando la información estructural de los datos y haciendo un mapeo entre la capa visible y la capa oculta y gracias a este enfoque se puede diseñar una arquitectura profunda para aprender las características de alto nivel para el reconocimiento de manera no supervisada, sus resultados muestran mejoría respecto a la técnica de reconocimiento de escenas utilizada comúnmente. Continuando con aplicaciones en visión, Wu et al. (2015) modelaron el aprendizaje profundo en un marco de aprendizaje con supervisión deficiente, en la configuración cada imagen sigue una doble suposición de múltiples instancias donde sus propuestas de objetos y posibles anotaciones de texto pueden considerarse como dos conjuntos de instancias, al llevar a cabo experimentos extensivos se probó que el marco de aprendizaje profundo propuesto logra un rendimiento convincente en tareas de visión, incluida la clasificación y la anotación de imágenes. En otro campo Park et al. (2016) presentaron la puesta en práctica de un Sistema en Chip (SoC, *System on a Chip*) para permitir que las aplicaciones de aprendizaje profundo se ejecuten con plataformas de bajo costo como dispositivos móviles o portátiles adoptando una arquitectura flexible para tareas y explota el paralelismo múltiple para cubrir funciones complejas de la red de aprendizaje profundo convolucional, argumentan presentar el procesador de interferencia/aprendizaje

profundo más eficiente energéticamente y proporcionan las características del mismo. Más tarde Lee et al. (2017) describieron en su trabajo una plataforma de aprendizaje profundo distribuido, BAIPAS (*Big Data and AI based Predication and Analysis System*), proponiendo la gestión de la localidad de los datos como una forma de reducir el tiempo de entrenamiento con datos masivos (*big data*), la plataforma proporciona aprendizaje rápido, fácil instalación y monitoreo de la plataforma, los datos se distribuyen y almacenan en el espacio de almacenamiento del trabajador-servidor con la finalidad de proporcionar el aprendizaje rápido. Como otra aplicación Wang & Pei (2018) presentaron una descripción del proceso de aprendizaje automático con aplicaciones de aprendizaje profundo, donde introducen la teoría básica y su fusión para formar varias estructuras de aprendizaje de núcleo profundo para mejorar el rendimiento del algoritmo en la práctica. Abbas (2018) plantea en su trabajo incrementar el rendimiento del aprendizaje profundo utilizando un algoritmo propuesto denominado RFHTMC (*Random Forest y HTM Cortical Learning Algorithm*), donde su metodología depende de minimizar el error porcentual absoluto medio debido a que este es un indicador del alto rendimiento del procedimiento de pronóstico y en adición a la superposición del ciclo de trabajo que su alto porcentaje es un indicador de la velocidad de operación de la clasificación.

Como se puede apreciar, se están estudiando técnicas de aprendizaje profundo en múltiples campos de aplicación industrial que tratan de conjuntos de datos de alta dimensión y de múltiples patrones (Wang and Chen, 2019). Existen algunos trabajos que exploran la idoneidad de esas técnicas en el monitoreo de las redes eléctricas, y cada vez están siendo más aplicadas a la clasificación de las perturbaciones de la calidad de la energía. Aunque las prestaciones resultantes son prometedoras, la falta de un procedimiento común para configurar y ajustar los algoritmos representa todavía una deficiencia que evita su consideración sobre las aplicaciones industriales reales (Liu et al., 2019). El trabajo presentado por Shen et al., (2019) explora las capacidades del aprendizaje profundo en la calidad de la energía utilizando una CNN en unión con once indicadores estadísticos calculados sobre los cuatro componentes principales de las señales eléctricas utilizando una versión modificada de PCA. De la misma manera, utilizan la estructura de la red neuronal para realizar la etapa de clasificación. En este trabajo se consideraron dos clases de perturbaciones múltiples analizadas como la aparición de las perturbaciones no en el mismo

instante del tiempo porque algunas de las perturbaciones consideradas son contrarias en definición y la aparición simultánea de esas dos perturbaciones, es conceptualmente opuesta. Sin embargo, el método presenta buenas capacidades con datos simulados. Su introducción como parte del procedimiento basado en datos representa, sin embargo, el paso adelante necesario para alcanzar la caracterización y gestión requeridas de múltiples patrones que se reconocerán más adelante en combinación con los algoritmos de clasificación, como las conocidas redes neuronales (Thirumala et al., 2018). Recientemente, Sekar et al., (2022) combinaron CNN y una red de memoria de corto-largo plazo (LSTM, *long short-term memory*) como un método para detectar y clasificar disturbios eléctricos, validaron su propuesta simulando un sistema híbrido en *softwares* computacionales. En el trabajo de Oliveira and Bollen, (2023) se presenta una discusión y revisión de las últimas aplicaciones de la tecnología de aprendizaje profundo en el campo de la calidad de la energía, donde se discute que las principales barreras para implementar esta tecnología se debe a la falta de transparencia de los métodos de aprendizaje profundo, a la falta de bases de datos bien establecidas para comparar el rendimiento de diferentes propuestas y a la de novedad en la funcionalidad respecto a metodologías clásicas cuando las disturbios son individuales o clásicos ya establecidos en las normas.

En resumen, como se puede apreciar, aunque existen diversas metodologías y trabajos que desarrollan y realizan la monitorización y clasificación de diversos fenómenos eléctricos, existe una necesidad importante en el progreso de metodologías o modelos con la facultad para la detección de señales o eventos que pudieran suscitarse y describirse como anormales y que no se encuentran caracterizados previamente por las normas internacionales sobre calidad de la energía. Este hecho, en consecuencia, lleva a una necesidad de planteamiento, también, de índices o parámetros óptimos que indiquen y permitan identificar eventuales acontecimientos ya sea que se presenten de manera individual o combinada. De la misma manera, respecto a la identificación de las perturbaciones, los enfoques de aprendizaje profundo se presentan actualmente como una potencial vía de aplicación donde investigar sus mayores capacidades de generalización respecto a los patrones característicos de perturbaciones, así como su mayor capacidad en asumir variabilidad en señales y eventos. De la misma manera, se infiere la utilización de técnicas de aprendizaje profundo con la intención de lograr una extracción automática de indicadores significativos sobre las señales,

que, combinados con los propios de un enfoque de ingeniería pueden permitir una mayor capacidad de identificación de perturbaciones y condiciones.

1.2. Descripción del problema

La identificación y clasificación de las perturbaciones eléctricas empleando distintas metodologías son llevadas a cabo en distintos trabajos mencionados anteriormente, aunque existen actualmente algunos trabajos respecto a la detección de novedad en este ámbito, se ha identificado una falta importante en metodologías de detección de novedad, específicamente bajo dos estudios: (i) estructuras de detección de novedad para mejorar la detección de patrones no caracterizados a priori, y (ii) enfoques que permitan desarrollar una estructura de detección de novedad bajo un aprendizaje incremental.

Otra de las problemáticas consiste en determinar enfoques óptimos como la combinación de técnicas de procesado como puede ser la consideración de técnicas de aprendizaje profundo. A pesar de que la teoría del aprendizaje profundo ha estado disponible durante décadas, tres avances recientes están ayudando en el aumento de su adopción: (i) algoritmos de entrenamiento efectivos, (ii) capacidades de adquirir grandes volúmenes de datos que son necesarios para el aprendizaje profundo se ha vuelto una posibilidad en los últimos años, y (iii) el incremento de la potencia de cómputo que ha permitido que la utilización de algoritmos de entrenamiento sea factible. Dentro de los retos detectados se observa el que las estructuras de aprendizaje profundo permitan un aprendizaje evolutivo eficaz en el ámbito de calidad de la energía, también si los indicadores automáticos serán útiles en este campo de aplicación. Por último, mencionar que las características o ventajas del aprendizaje profundo recientemente se han estudiado o aplicado en el ámbito de la calidad de la energía y con el objetivo de mejorar los modelos de entrenamiento para la detección y clasificación de los disturbios eléctricos.

Dentro de la problemática social que este trabajo busca atender es el uso eficiente de la energía eléctrica. Debido al constante cambio en el sector energético con políticas favoreciendo la transición hacia el uso de energías verdes que generen un menor impacto sobre el medio ambiente, se tienen que afrontar las debilidades ya existentes en la red eléctrica y además las limitaciones que estas nuevas fuentes de generación conllevan como lo son la variabilidad de generación por su misma naturaleza. Además los problemas que se

presentaban en las redes eléctricas para el uso efectivo de la energía eléctrica deben considerarse en el nuevo marco establecido para las futuras generaciones. Si bien los disturbios eléctricos que se pueden presentar en el nivel residencial, incluso a nivel comercial pudieran no repercutir de una manera significativa en el rendimiento de los aparatos o equipos conectados, es a nivel industrial donde pequeñas afectaciones impactan de mayor manera en los procesos de aquellos bienes y servicios que se ofertan. Se aprecia claramente como una deficiente calidad de la energía llega a repercutir en regiones que dependen de la producción de las empresas que se encuentran conectadas a lo largo de la red eléctrica con afectaciones. De manera recíproca se encuentra la problemática de los equipos propios en la industria que inyectan a la red eléctrica disturbios ya sea por su mala operación, conexión o fabricación. En este sentido, es importante llevar a cabo un análisis entre la relación existente entre las afectaciones ocasionadas de la red hacia los equipos y de manera inversa.

1.3. Justificación

La detección e identificación de disturbios eléctricos en la calidad de la energía es un área que continúa en constante investigación, el uso creciente en la actualidad de fuentes de energía renovables conduce a la necesidad de explorar cómo afectan en el sistema eléctrico ya sea induciendo nuevos fenómenos o novedades, se requiere también el desarrollo de nuevas metodologías que permita la intervención adecuada y oportuna ante estos fenómenos eléctricos.

La detección de novedad para detectar señales o comportamientos de la calidad de la energía que no se tienen previamente caracterizados, como comportamientos nuevos o anormales, servirá para detectar dichas anomalías y mejorar la fiabilidad del diagnóstico. De la misma manera, la detección de novedad permitirá el descubrimiento de nuevos patrones, su caracterización, y su preparación para un posterior aprendizaje y aumento de las capacidades de supervisión, ya sea bajo escenarios de perturbaciones específicas de manera aislada, o en caso que se presenten combinadas, lo cual representa una seria problemática actualmente.

La aplicación de estrategias de aprendizaje profundo, pretenden afrontar directamente la actual falta de capacidades de generalización frente a ligeras variaciones de los patrones caracterizados, el comúnmente llamado efecto de sobreajuste de los modelos.

En este sentido, los enfoques de aprendizaje profundo evitarán la selección de características como único enfoque de extracción de patrones y, en su lugar, tratarán directamente con los datos de red, permitiendo el llamado aprendizaje de extremo a extremo (de la señal a la clasificación). Este concepto, aunque a través de una estructura compleja que requiere de amplia investigación, conducirá a tres potencialidades: (i) el aumento de las capacidades de generalización, ya que se dispone de capacidades de interpolación espacial de órdenes superiores, (ii) la extracción y visualización de la importancia de indicadores a través del análisis de las capas resultantes, y (iii) la transferencia de aprendizaje, ya que datos adicionales pueden aprenderse de manera incremental sin la necesidad de un reentrenamiento completo del modelo.

El análisis del impacto de los fenómenos de la calidad de la energía lograra un mayor entendimiento entre la importancia de poder caracterizar e identificar adecuadamente toda la variabilidad de perturbaciones que pudieran suscitarse en la red eléctrica. Al tener en cuenta metodologías para la detección de perturbaciones no previamente definidas en normas permitirá llevar el monitoreo de condición a sectores donde una mayor variabilidad de efectos anómalos puedan presentarse.

1.4. Hipótesis y Objetivos

1.4.1. Hipótesis

El desarrollo de una nueva metodología basada en sistemas de detección de novedad y aprendizaje profundo permitirá la mejora en la detección e identificación de perturbaciones individuales o combinadas referentes a la calidad de la energía eléctrica; mediante la selección de indicadores estadísticos que mejor caractericen los disturbios eléctricos.

1.4.2. Objetivos

- **General**

Generar una metodología para la detección y clasificación de fallos eléctricos basadas en sistemas incrementales de aprendizaje profundo con la finalidad de detectarlas e identificarlas, ya sea bajo un escenario de aparición individual, combinadas o inclusive no previamente caracterizadas.

- **Particulares**

1. Determinar enfoques óptimos en las técnicas de procesado para la detección y clasificación de perturbaciones en la calidad de la energía eléctrica.
2. Desarrollar técnicas de aprendizaje profundo capaces de extraer indicadores y gestionar múltiples clases o patrones.
3. Proponer la algoritmia de las técnicas de detección y clasificación de perturbaciones de la calidad de la energía que permita su programación para su aplicación en sistemas eléctricos.
4. Caracterizar anomalías o perturbaciones en calidad de la energía mediante las metodologías de detección de novedad.
5. Aplicar las técnicas de aprendizaje profundo en señales de calidad de la energía sintéticas, de bases de datos o simuladas para comprobar la metodología propuesta.
6. Aplicar los sistemas desarrollados en señales reales de instalaciones para comprobar y validar el uso de modelos de aprendizaje profundo y detección de novedad en la detección y clasificación de perturbaciones en la calidad de la energía.

1.5. Planteamiento general

En el diagrama a bloques mostrado en la Figura 1.1 se presenta el planteamiento general del proyecto y que está compuesto por 5 bloques, los cuales se describen a continuación.

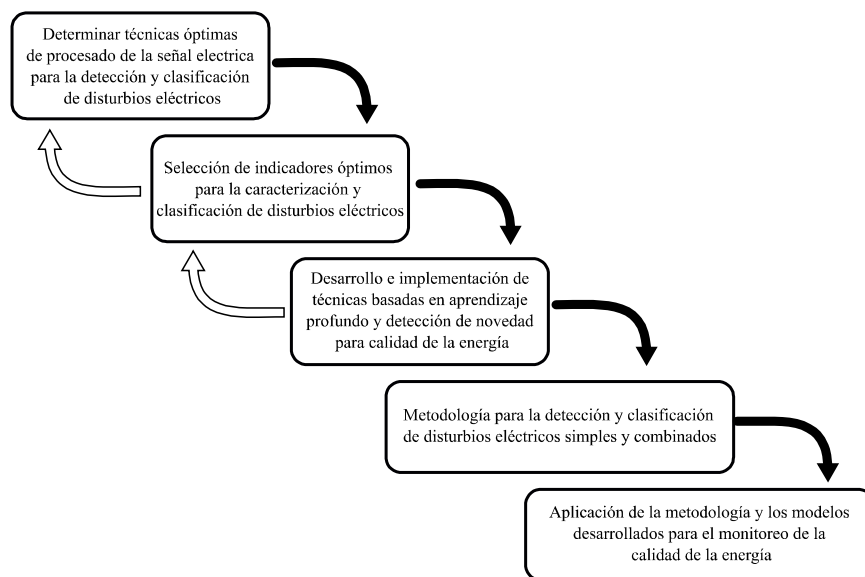


Figura 1.1. Planteamiento general del proyecto (Fuente: autoría propia).

El primer bloque se refiere a la determinación de las técnicas para el procesado de la señal eléctrica para la detección y clasificación de disturbios eléctricos, establecer aquellas técnicas más óptimas que permitan a posterior lograr una detección e identificación adecuada de las perturbaciones eléctricas. A continuación, se encuentra el bloque de selección de indicadores óptimos que permitan al sistema que se propone desarrollar basado en detección de novedad y aprendizaje profundo la detección y clasificación óptima de los disturbios eléctricos. Después sigue el bloque referente al desarrollo de las técnicas basadas en aprendizaje profundo y detección de novedad para la calidad de la energía, en esta parte del diagrama es donde se encuentra la aportación de estas técnicas al desarrollo que ya existe acerca de la detección y clasificación de los disturbios en la calidad de la energía. En este paso de la metodología en función de los resultados es posible que se requiera regresar en la metodología para realizar cambios en el desarrollo de las técnicas de aprendizaje profundo y detección de novedad, es por eso que en este bloque se presenta una ramificación de retorno hacia bloques anteriores. Posteriormente, el siguiente bloque es la obtención de la metodología para la detección y clasificación de disturbios eléctricos, ya sea simples o combinados. Para finalizar, como último bloque se encuentra la implementación y aplicación de esta metodología y los modelos desarrollados para el monitoreo de la calidad de la energía eléctrica bajo condiciones o disturbios establecidos en norma o condiciones de anomalías no presentadas con anterioridad.

2. Fundamentación teórica

En esta sección se presentan parte esencial de los fundamentos y descripción de los temas involucrados en el trabajo de investigación. En primer lugar, se describen los conceptos relacionados a la calidad de la energía y los disturbios presentados en esta. Después se consideran los temas específicos de investigación, se describen las técnicas de aprendizaje profundo y a continuación lo referente a detección de novedad. Para finalizar se mencionan las herramientas de evaluación para los modelos de aprendizaje profundo y detección de novedad.

2.1. Calidad de la energía

La calidad de la energía eléctrica se describe como las características y condiciones adecuadas de la señal eléctrica suministrada a los equipos y dispositivos que les permita mantener su continuidad sin que perjudique su desempeño ni cause fallas a sus componentes (Bollen and Gu, 2006). La forma de onda ideal de voltaje está definida formalmente en la ecuación (1):

$$V(t) = V_m \sin(\omega t + \varphi) \quad (1)$$

donde $V(t)$ es el voltaje sinusoidal, V_m es la amplitud de la señal, ω es la frecuencia angular, y φ es la fase de la señal. Se puede decir que existe un problema de calidad de la energía eléctrica cuando ocurre cualquier desviación de la tensión, la corriente o la frecuencia respecto a sus condiciones de operación previstas y que provoque la mala operación de los equipos y deteriore la economía o el bienestar de los usuarios (Sankaran, 2002). Cualquier desviación de este tipo se considera un disturbio de la calidad de la energía. El acrecentamiento en la aplicación de equipos y dispositivos electrónicos puede causar perturbaciones electromagnéticas y, a su vez, estos equipos pueden ser altamente sensibles a estos fenómenos, lo que ha incrementado el interés por la calidad de la energía en los últimos años (Singh et al., 2015).

2.1.1. Disturbios eléctricos

El estándar IEEE 1159-2019 (IEEE Recommended Practice for Monitoring Electric Power Quality, 2019) dispone el procedimiento para el monitoreo del sistema eléctrico monofásico y polifásico de corriente alterna y la guía para una adecuada comprensión de los

resultados obtenidos, asimismo además detalla los diversos tipos de fenómenos electromagnéticos que se presentan en las redes eléctricas. Los diferentes tipos de perturbaciones, disturbios o fenómenos electromagnéticos que pueden ocurrir en un sistema eléctrico de potencia y que se consideran en el estudio de la calidad de la energía están basados en esta norma. Los fenómenos electromagnéticos se clasifican principalmente en siete categorías, dependiendo de las características de su espectro armónico, su amplitud y su duración. Por lo tanto, se encuentran fenómenos transitorios, variaciones de corta duración, variaciones de larga duración, desbalances de tensión, distorsión de la forma de onda, fluctuaciones de tensión y variaciones de la frecuencia, a continuación, se describen de manera general cada uno de los fenómenos mencionados de acuerdo al estándar IEEE 1159-2019.

i. Transitorios

Los transitorios son eventos repentinos cuyo término proviene de la componente de voltaje y corriente que se debe a la transición entre dos estados estacionarios y que tiene una duración limitada, estos se encuentran clasificados en dos categorías, impulsivo y oscilatorio.

a. Transitorio impulsivo

Un transitorio impulsivo es un cambio repentino en la condición de estado estable del voltaje, corriente o ambos, que es unidireccional en polaridad, positivo o negativo, están normalmente caracterizados por sus tiempos de levantamiento y caída, aunque pueden ser también descritos por su contenido espectral.

b. Transitorio oscilatorio

Un transitorio oscilatorio consiste de un voltaje o corriente cuyos valores instantáneos cambian de polaridad rápidamente, están descritos por su contenido espectral, duración y magnitud. La Figura 2.1 muestra una señal eléctrica con un disturbio transitorio oscilatorio.

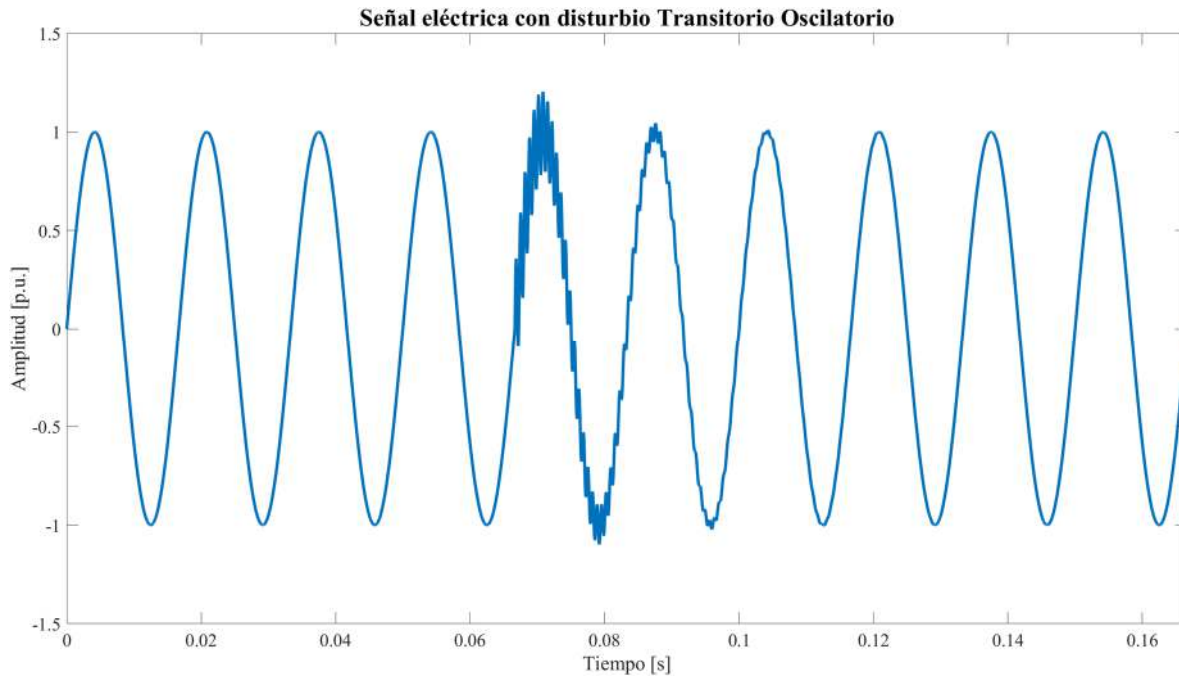


Figura 2.1. Disturbio eléctrico transitorio oscilatorio (Fuente: autoría propia).

ii. Variaciones de corta duración

Las variaciones de voltaje de corta duración son causadas por conexiones intermitentes en el cableado de alimentación, condiciones de falla o la energización de grandes cargas. Dependiendo de las condiciones del sistema y de la ubicación de la falla, la variación se puede presentar como aumentos temporales de voltaje, caídas de voltaje o una total pérdida de voltaje (interrupción). Cada tipo de variación puede ser designada como instantánea, momentánea o temporal.

a. Aumento de voltaje

Se define como un incremento en el voltaje o corriente rms (*root mean square*, valor cuadrático medio) en la frecuencia de la red para duraciones de 0.5 ciclos a 1 minuto. Las magnitudes se describen por su voltaje restante y típicamente entre 1.1 y 1.8 p.u. (*per unit*, por unidad). Los aumentos de voltaje están caracterizados por su duración y magnitud.

b. Caída de voltaje

Es un decremento en la tensión nominal entre 0.1 p.u. y 0.9 p.u. para duraciones de 0.5 ciclos hasta 1 minuto.

c. Interrupción

Una interrupción sucede cuando la fuente de corriente o voltaje de la carga se aminorara a menos de 0.1 p.u. por un periodo de tiempo que no supera un minuto; las interrupciones son determinadas por su duración debido a que la magnitud de voltaje es siempre inferior al 10% de la nominal.

La Figura 2.2 y la Figura 2.3 muestran dos de las variaciones de corta duración mencionadas, aumento de voltaje y caída de voltaje respectivamente.

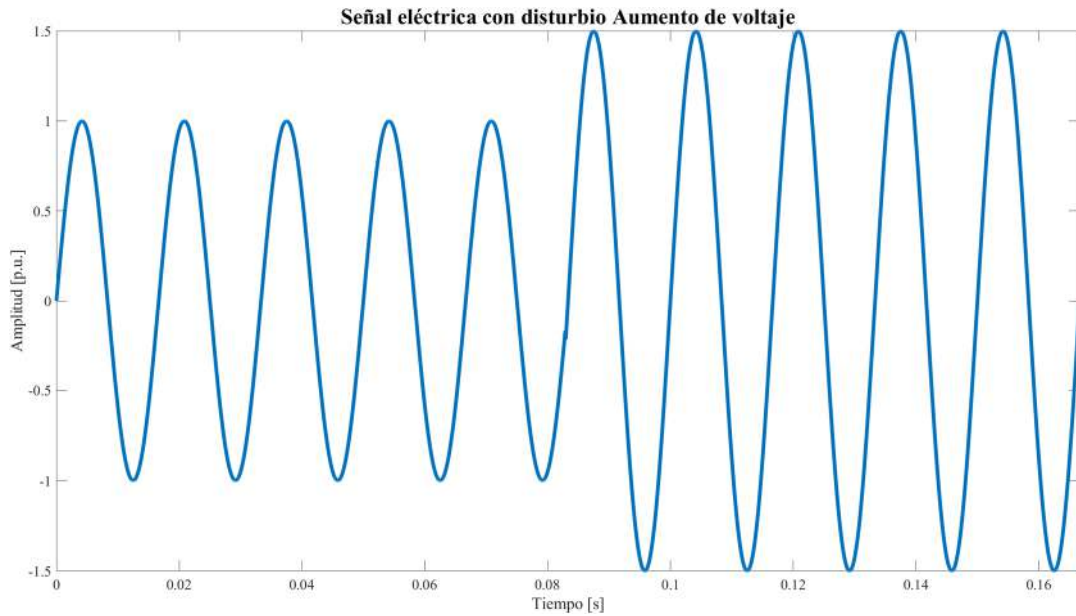


Figura 2.2. Disturbio eléctrico aumento de voltaje (Fuente: autoría propia).

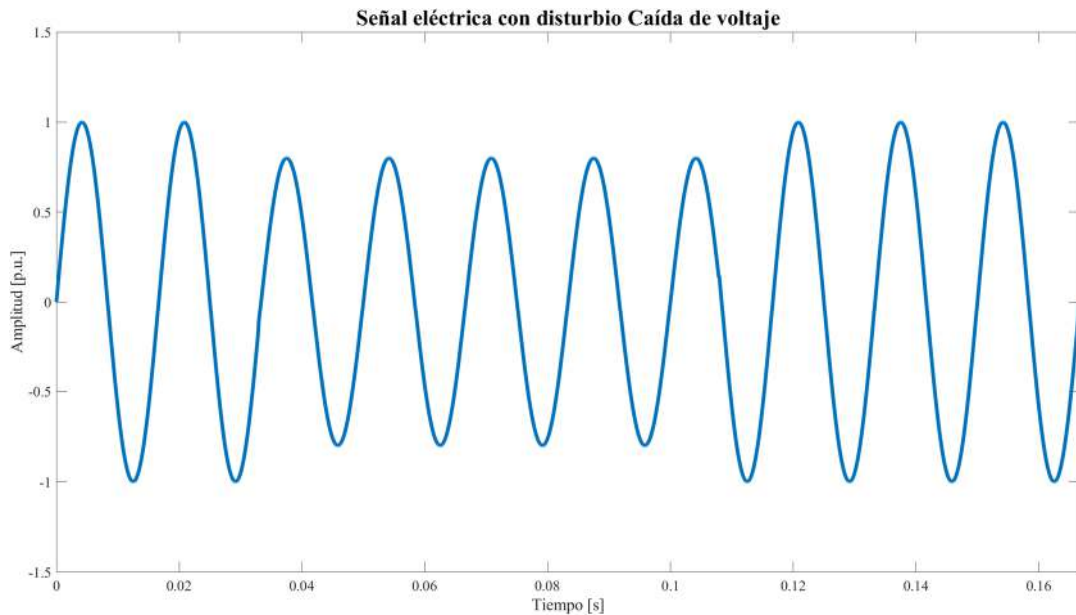


Figura 2.3. Disturbio eléctrico caída de voltaje (Fuente: autoría propia).

iii. Variaciones de larga duración

Las variaciones de larga duración pueden ser sobretensiones o subtensiones, dependiendo de la causa de la variación, en general no son producto de fallas del sistema, son en consecuencia debido a las variaciones de carga en el sistema y las operaciones de conmutación del sistema, se consideran presentes cuando estas anomalías exceden más de un minuto.

iv. Desbalance de la tensión

El desbalance de tensión en un sistema trifásico se explica como la relación de la magnitud de la componente de secuencia negativa a la magnitud de la componente de secuencia positiva, expresada como porcentaje, puede aplicarse para voltaje como para corriente, normalmente el desbalance de tensión de un servicio trifásico es inferior al 3%.

v. Distorsión de la forma de onda

La distorsión en la forma de onda se define como una variación del estado estable de una señal eléctrica sinusoidal ideal caracterizada mayormente por el contenido espectral de la variación, se encuentran cinco tipos principales de distorsión: desplazamiento DC, armónicos, interarmónicos, muescas y ruido.

a. Desplazamiento DC

Es la presencia de un voltaje de corriente directa en un sistema de potencia de corriente alterna, la corriente directa en redes de corriente alterna puede ser perjudicial debido a un incremento en la saturación del transformador, atenuación adicional del aislamiento y otros efectos adversos.

b. Armónicos

Los armónicos son típicamente voltajes o corrientes sinusoidales que tienen altas frecuencias y que son múltiplos enteros de la frecuencia a la cual el sistema de alimentación está diseñado para operar. Los armónicos se combinan con el voltaje o corriente fundamental y producen distorsión de la forma de onda. La Figura 2.4 muestra una señal eléctrica con armónicos.

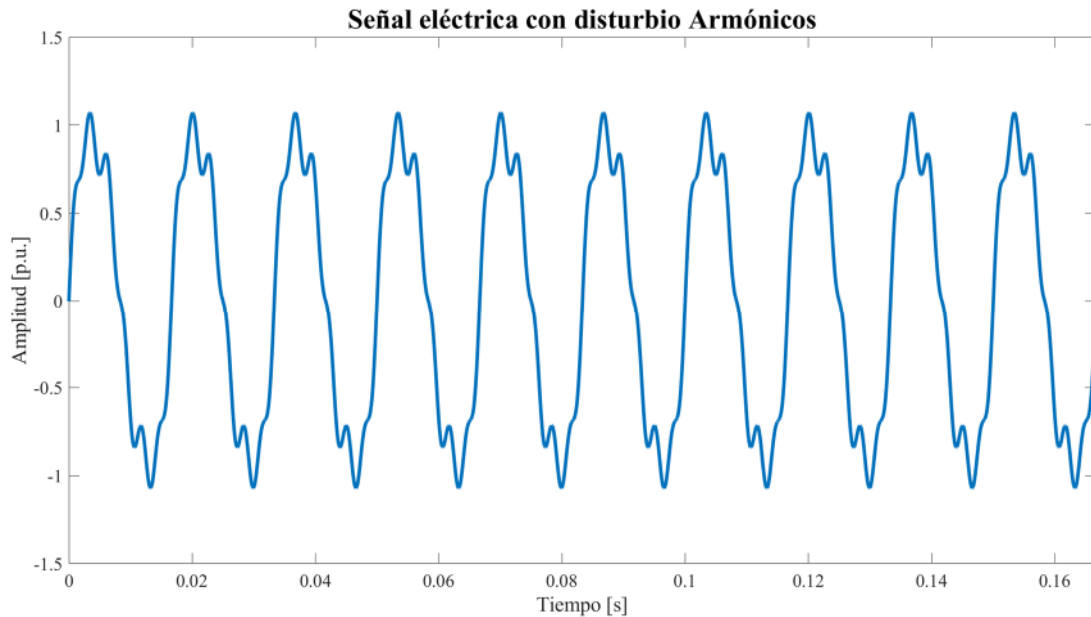


Figura 2.4. Disturbio eléctrico armónicos (Fuente: autoría propia).

c. Interarmónicos

Los interarmónicos son las componentes que contiene la forma de onda de voltaje y corriente que no son múltiplo entero de la frecuencia del sistema, para medirlos es necesario medir sobre un periodo más largo que un ciclo. La presencia de interarmónicos puede ser interpretada en el dominio del tiempo como la señal siendo periódica, pero con un período de más de un ciclo.

d. Muestras

El disturbio eléctrico conocido como muescas es un disturbio en la forma de onda de voltaje con duración menor de medio ciclo y presenta polaridad opuesta a la señal de operación, puede ser caracterizado a través del espectro armónico del voltaje afectado. La Figura 2.5 muestra una señal eléctrica con este tipo de disturbio.

e. Ruido

El ruido son señales eléctricas no deseadas con contenido espectral de ancho de banda menor de 200 kHz superpuestas sobre el voltaje o corriente del sistema en conductores de fase, o encontrado en conductores neutrales o líneas de señal. El rango de frecuencia y nivel de magnitud del ruido depende de la fuente que produce el ruido y las características

del sistema. La magnitud típica del ruido es menor del 1% de la magnitud del voltaje. La Figura 2.6 muestra este tipo de fenómeno eléctrico.

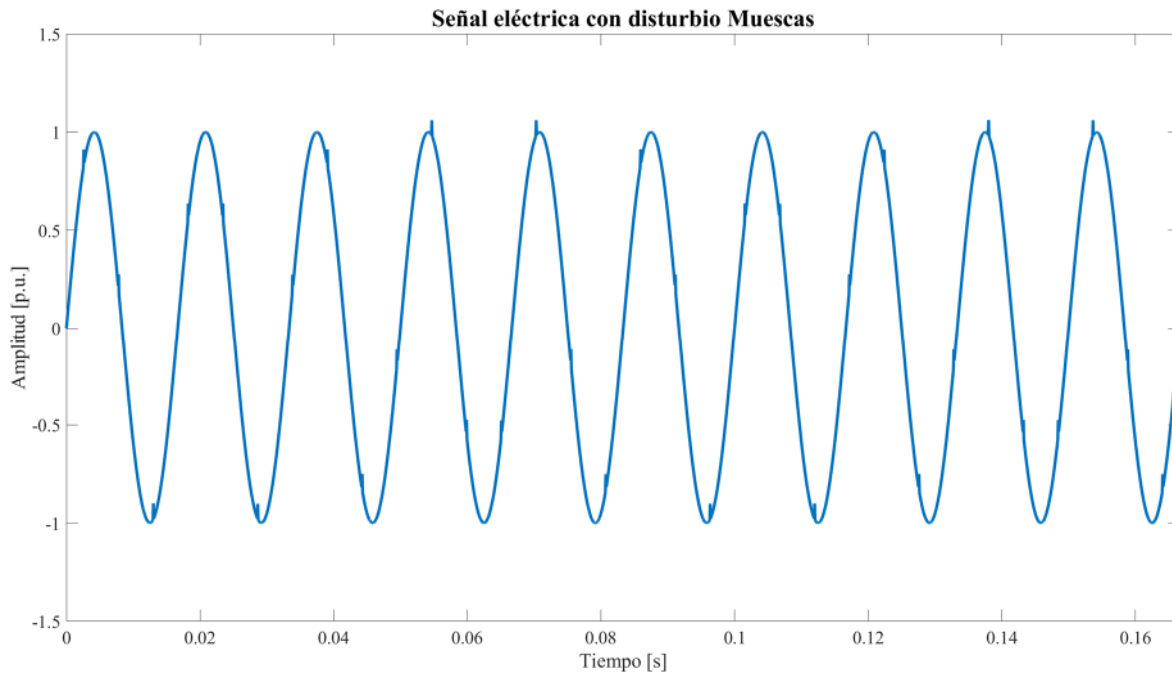


Figura 2.5. Disturbio eléctrico muescas (Fuente: autoría propia).

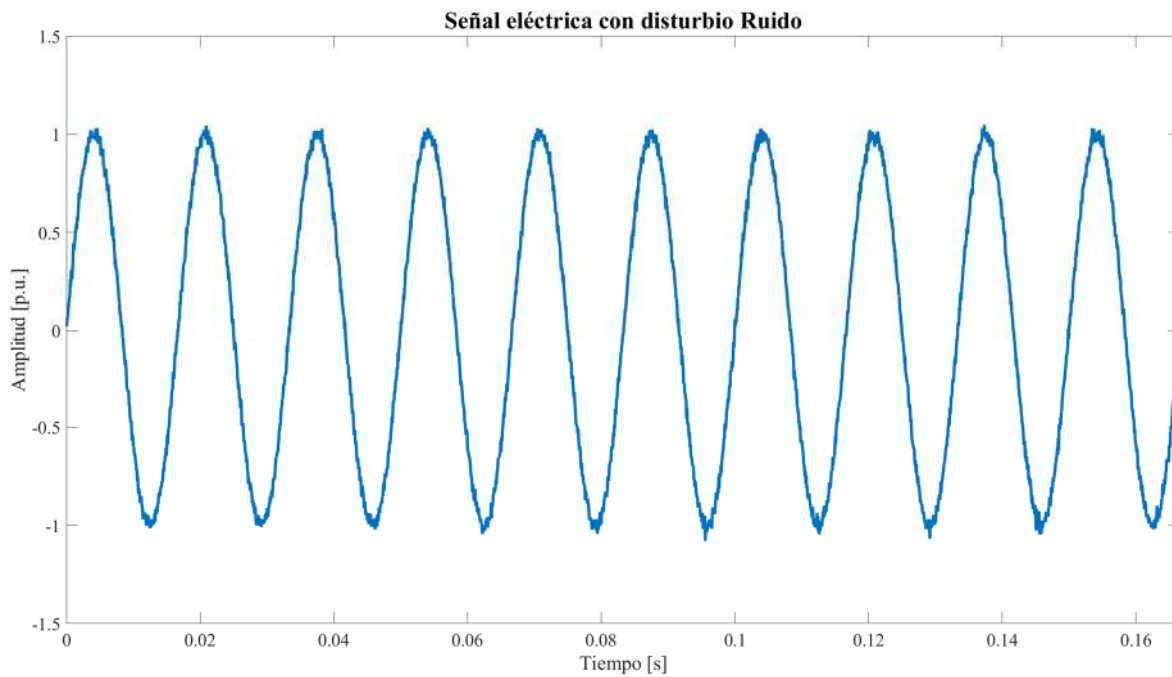


Figura 2.6. Disturbio eléctrico ruido (Fuente: autoría propia).

vi. Fluctuaciones de la tensión

Las fluctuaciones de la tensión son variaciones sistemáticas de la envolvente de voltaje o una serie de cambios de voltaje aleatorios, cuya magnitud no excede los rangos de voltaje de 0.95 p.u. a 1.05 p.u., cualquier carga que tenga variaciones cíclicas significativas, especialmente en el componente reactivo, puede causar fluctuaciones de voltaje. La Figura 2.7 muestra este tipo de fenómeno.




Figura 2.7. Disturbio eléctrico fluctuaciones (Fuente: autoría propia).

vii. Variaciones de la frecuencia

Las variaciones de la frecuencia son las variaciones en la frecuencia fundamental del sistema de alimentación respecto a su valor nominal especificado, la frecuencia del sistema está directamente vinculada con la velocidad de rotación de los generadores del sistema, la frecuencia depende del equilibrio entre la carga y la capacidad de la generación disponible, cuando este equilibrio cambia, se producen pequeños cambios en la frecuencia, el tamaño del cambio de la frecuencia y su duración dependen de las características de carga y la respuesta del sistema de generación.

2.2. Técnicas de Aprendizaje Profundo

El aprendizaje profundo (*Deep Learning*), es un subconjunto de un campo más general de la inteligencia artificial llamado aprendizaje automático (*Machine Learning*) como queda reflejado en la Figura 2.8, el cual se basa en la idea de aprender del ejemplo para después inferir automáticamente la respuesta a un estímulo similar.

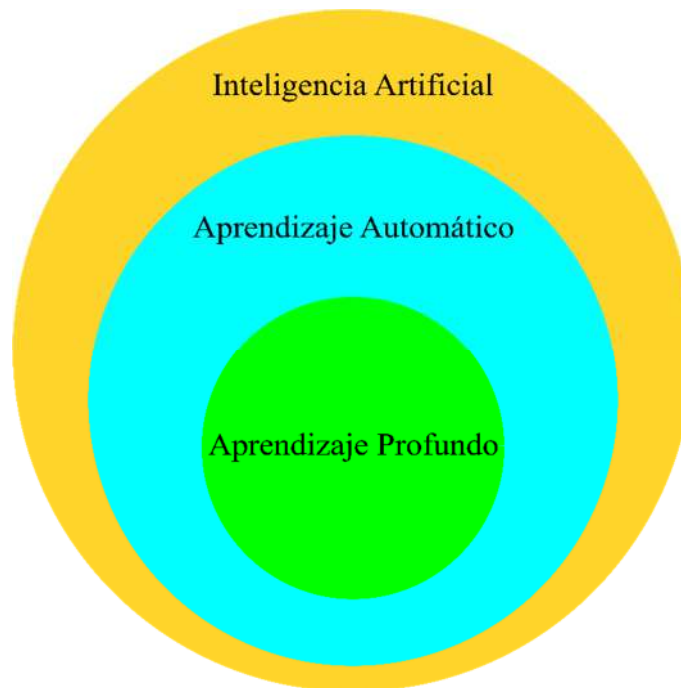


Figura 2.8. Diagrama de conjuntos jerárquico de la inteligencia artificial (Fuente: autoría propia).

En el aprendizaje automático, en lugar de enseñar a una computadora una lista masiva de reglas para resolver el problema, se le presenta un conjunto de estímulos y respuestas asociadas para la generación de un modelo de comportamiento. Durante el entrenamiento del modelo se le permite evaluar ejemplos y se le proporciona un conjunto de instrucciones y/o reglas para modificar el modelo cuando comete un error. Se espera que, con el tiempo y las diferentes iteraciones, un modelo adecuado sea capaz de resolver problemas con gran precisión (Buduma and Lacascio, 2017). Como rama del aprendizaje automático, el aprendizaje profundo intenta modelar representaciones jerárquicas detrás de los datos y clasificar patrones mediante el apilamiento de múltiples capas de módulos de procesamiento de información en arquitecturas jerárquicas.

El aprendizaje profundo pretende la consideración de grandes cantidades de estímulos y respuestas, no necesariamente en relación con muchos estímulos diferentes, si no también, muchas variantes sobre un conjunto finito de estímulos que deben ser identificadas de manera diferente. Es en este sentido que las técnicas y procedimientos de aprendizaje automático saturan en su capacidad de respuesta, no siendo capaces de gestionar tal cantidad de patrones y sufriendo pérdidas de precisión en los diagnósticos y/o efectos de sobreajuste.

Recientemente, el aprendizaje profundo se ha adoptado con éxito en diversas áreas, como la visión por ordenador, el reconocimiento automático del habla, el procesamiento del lenguaje natural, el reconocimiento de audio y la bioinformática, hasta la fecha, existen varias arquitecturas de aprendizaje profundo y este tema de investigación está creciendo rápidamente, en el que se desarrollan nuevos modelos continuamente. Aunque son diferentes las arquitecturas que permiten ser implementadas en el aprendizaje profundo, una de las principales características y diferencias entre el aprendizaje automático y los algoritmos de aprendizaje profundo está en la posibilidad de extracción automática de características. En los algoritmos de aprendizaje automático se necesita definir el conjunto de características que se van a utilizar para caracterizar una señal, ya sea desde un punto de vista de ingeniería o puramente estadístico. Por el contrario, en las técnicas de aprendizaje profundo, las características se pueden extraer automáticamente mediante algoritmos específicos. En este sentido la extracción manual de características es difícil y compleja, requiere de mucho tiempo y requiere experiencia en el dominio de aplicación. La Figura 2.9 muestra el flujo del aprendizaje automático y el aprendizaje profundo y cuál es su diferencia de una respecto a otra.

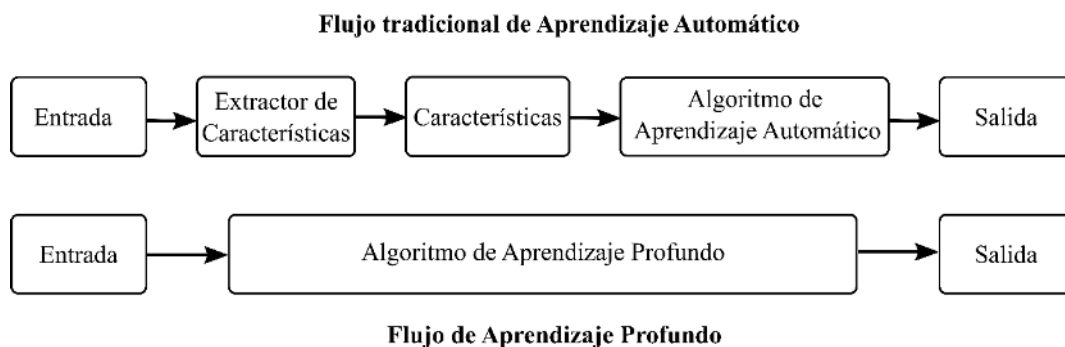


Figura 2.9. Flujo del aprendizaje automático y del aprendizaje profundo. (Fuente: autoría propia)

El aprendizaje profundo integra el aprendizaje de características y la construcción de modelos en un modelo seleccionando diferentes núcleos o ajustando los parámetros a través de la optimización de extremo a extremo. Esto permite descubrir desde la misma señal patrones característicos que ayuden a la identificación y clasificación, sobre todo, si se combinan con indicadores propios de ingeniería. Una de las estructuras más comunes en aprendizaje profundo son las redes neuronales con múltiples capas ocultas dando lugar a operaciones no lineales multinivel. En estas estructuras se transfiere la representación (o características), de cada capa de la entrada original a una representación más abstracta en las capas superiores para encontrar las estructuras inherentes complejas. Por ejemplo, las características de una imagen tales como partes de borde, esquina, contorno y objeto, se abstraen capa por capa de una imagen. Estas representaciones de entidades resumidas se ingresan luego en la capa clasificadora para realizar tareas de clasificación y regresión. En general, el aprendizaje profundo es una estructura de aprendizaje de extremo a extremo que permite una mínima inferencia humana, y los parámetros del modelo de aprendizaje profundo se capacitan conjuntamente.

Las aplicaciones de las redes neuronales tradicionales (NN, *neural networks*) representan enfoques poco profundos, siendo la red de tres capas (es decir, capas de entrada, oculta y de salida), la arquitectura más común. En esas redes poco profundas, los estímulos de entrada deben ser un conjunto cuidadosamente seleccionado de parámetros obtenidos por medio de la reducción de características y/o la ingeniería de características porque las NN se ven muy afectadas por la presencia de información no significativa y redundante, lo que dificulta el proceso de aprendizaje de características complejas y la relación a partir de los datos (Goodfellow et al., 2016). Por el contrario, el aprendizaje profundo adopta un enfoque de aprendizaje de las características, es decir, las relaciones entre los estímulos de entrada se descubren en lugar de darse, aprovechando las propiedades de las redes profundas, en las que las capas iniciales extraen rasgos significativos de manera no supervisada y las capas finales trazan un mapa de esos rasgos hasta el objetivo o respuesta (Buduma and Lacascio, 2017). Siguiendo este enfoque, la red resultante puede trabajar con un conjunto más amplio de entradas, en el que la etapa de entrenamiento identifica rasgos significativos para la caracterización y el reconocimiento de patrones asignando pesos de manera autónoma.

2.2.1. Autoencoder

A este respecto, el autoencoder es una técnica de aprendizaje profundo inspirada en las estructuras de las redes neuronales, entrenada para replicar su entrada en su salida. Así, la estructura del autoencoder se divide en dos partes principales: codificador y decodificador. El codificador se ocupa de la representación de la información de la capa anterior en una dimensión reducida. De lo contrario, el decodificador toma la información comprimida resultante de la capa anterior y la devuelve a su dimensión original. La etapa de entrenamiento de un autoencoder es de manera no supervisada y se basa en la optimización de una función de costo para minimizar el error entre la entrada y su reconstrucción resultante en la salida. Sin embargo, la consideración de múltiples capas en redes profundas se debe a que las deficiencias del algoritmo clásico de retro propagación no logran actualizar los pesos a través de las capas durante el proceso de entrenamiento, ya que el gradiente se vuelve demasiado pequeño para influir en un cambio e impide el aprendizaje, un problema conocido como el desvanecimiento del gradiente (Goodfellow et al., 2016). Una de las soluciones más eficaces es la aplicación de sencillos autoencoders de tres capas entrenados individualmente y apilados posteriormente, donde cada capa posterior utiliza la capa oculta del codificador anterior como entrada. Después de que el conjunto de autoencoders se apila, el autoencoder profundo se afina. Así pues, se suele considerar que el apilamiento de diferentes autocodificadores reduce o comprime los datos de entrada a una baja dimensionalidad sin perder la información pertinente para reconstruir la señal original a la salida de la estructura. Un ejemplo de este tipo de autoencoder apilado se muestra en la Figura 2.10, donde la capa oculta de menor dimensión (es decir, dos en este ejemplo), representa el conjunto reducido de información resultante del proceso de reducción del aprendizaje de las características. Se considera que esa capa se utiliza como entrada de un algoritmo de clasificación posterior como una red neuronal simple (Cardoso, 2019).

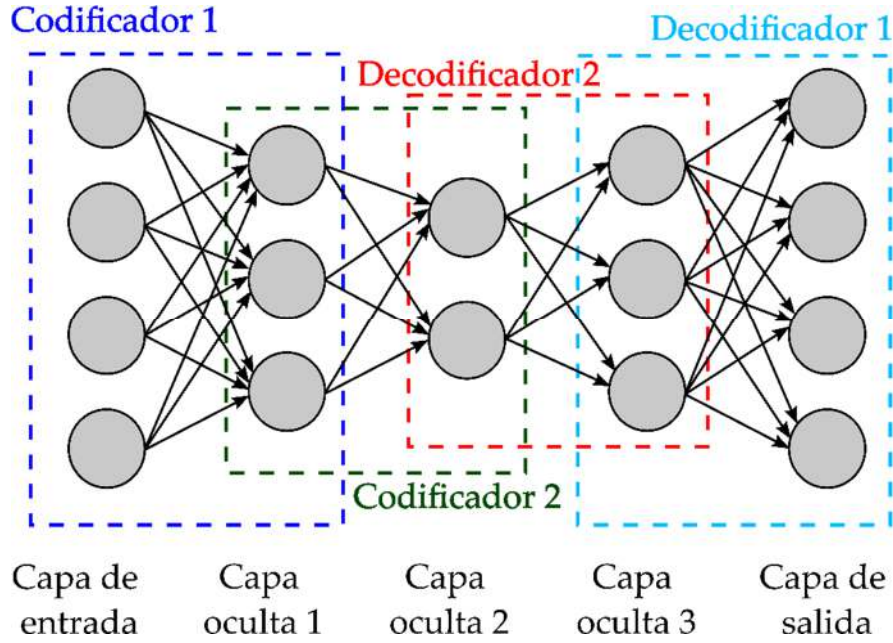


Figura 2.10. Autoencoder apilado compuesto de dos autoencoders. (Fuente: Cardoso, 2019)

Los autoencoders regularizados utilizan una función de pérdida que anima al modelo a tener otras propiedades además de la capacidad de copiar su entrada a su salida. Añadiendo penalizaciones a la función de costo, un autoencoder podría incluir la escasez de la representación, la pequeñez en el derivado de la representación y la robustez al ruido o a las entradas que faltan. Estos coeficientes son el término de regularización de L2W (*L2 regularization weights*), el término de regularización de la dispersión y el término de proporción de dispersión. Así, la función de costo, $J(x)$, relacionada con un autoencoder regularizado se presenta en (2).

$$J(x) = L(x, \hat{x}) + \lambda * \Omega_{weights} + \beta * \Omega_{sparsity} \quad (2)$$

donde $L(x, \hat{x})$ es una función de pérdida (por ejemplo, Error Cuadrático Medio, MSE, *mean square error*), que mide el error entre la entrada x y la reconstrucción \hat{x} . λ es el coeficiente para el término de regularización de L2W $\Omega_{weights}$, y β es el coeficiente para el término de regularización de la dispersión $\Omega_{sparsity}$. El término de regularización $\Omega_{weights}$ se muestra en (3):

$$\Omega_{weights} = \sum_l^L \sum_j^N \sum_i^K (w_{ji}^{(l)})^2 \quad (3)$$

donde L es el número de capas ocultas (es decir, una para un autoencoder básico), N es el número de muestras, K es el número de variables en el conjunto de datos de entrenamiento, y $w_{ji}^{(l)}$ representa el valor de los pesos indexados por $l, j, i = 1, 2, 3, \dots$. También, siguiendo el término de regularización de la escasez, la divergencia Kullback – Leibler = $\Omega_{sparsity}$ se muestra en (4):

$$\Omega_{sparsity} = \sum_{i=1}^{D^{(l)}} KL(\rho \parallel \hat{\rho}_i) = \sum_{i=1}^{D^{(l)}} \rho \log\left(\frac{\rho}{\hat{\rho}_i}\right) + (1 - \rho) \log\left(\frac{1 - \rho}{1 - \hat{\rho}_i}\right) \quad (4)$$

este término se amplifica cuando el valor medio de la probabilidad de activación, $\hat{\rho}_i$, de una neurona i y su valor deseado, el término de proporción de dispersión, ρ , no están cerca. Por lo tanto, tal función de coste $J(x)$ se enfoca como un problema de optimización durante el proceso de entrenamiento del autoencoder.

2.3. Detección de novedad

La detección de novedad se refiere a la detección de patrones nuevos o desconocidos descritos por la señal o señales consideradas de un sistema y, para los que la algoritmia de reconocimiento automático de patrones no ha sido entrenada (Markou & Singh, 2003). En este sentido, aunque obviada durante muchos años, la detección de novedad es uno de los requisitos fundamentales de un buen sistema de clasificación o identificación basado en inteligencia artificial, ya que las medidas realizadas sobre un sistema bajo monitorización pueden ofrecer eventualmente patrones que no se conocían en el momento de entrenar el modelo de clasificación.

El enfoque para la implementación de un procedimiento de detección de novedad se refiere a menudo como clasificación de clase única (*one-class classification problem*), en la que el modelo de detección de novedad se entrena con muestras correspondiente a una sola clase, lo que se considera la clase normal, o, en caso de disponer de múltiples patrones de respuesta, lo que se consideraría el conocimiento disponible (Pimentel et al., 2014). En este sentido un detector confiable de novedades tiene una superficie límite compacta cerrada que debe incluir solo los datos normales o conocimiento disponible. Por lo tanto, debe detectar cualquier medida que se encuentre en la parte exterior de la superficie límite como una

novedad de comportamiento del sistema bajo supervisión. Así, la detección de novedades ayuda a tratar y analizar los datos numéricos en gran cantidad, en los que el objeto puede aparecer, desaparecer o evolucionar durante un cierto período de tiempo. La detección de novedades se realiza en muchos casos utilizando los métodos de conjunto de niveles, que son una colección bien establecida y poderosa de algoritmos algebraicos para las superficies que están implícitas y que cambian con el tiempo. En general, las técnicas de detección de novedad se clasifican en tres grandes familias: probabilísticas, de dominio y de distancia (Miljković, 2016).

2.3.1. Métodos probabilísticos

Los enfoques probabilísticos para la detección de novedades se basan en la estimación de la función de densidad de probabilidad de los datos (Nassif et al., 2021). La distribución resultante puede entonces ser un umbral para definir los límites de la normalidad en el espacio de datos y probar si una muestra de prueba proviene de la misma distribución o no. En términos generales, estas técnicas se ubican en enfoques paramétricos y no paramétricos, en los que los primeros imponen un modelo restrictivo a los datos, lo que resulta en un gran sesgo cuando el modelo no se ajusta a los datos, mientras que los últimos configuran un modelo muy flexible. Los modelos de mezcla gaussianos y los estimadores de densidad de núcleo han demostrado ser populares.

i. Modelos de mezcla gaussiano

Un modelo de mezcla gaussiano (GMM, *Gaussian Mixture Models*) es una función de densidad de probabilidad paramétrica representada como una suma ponderada de las densidades de componentes Gaussianos, se emplean usualmente como un modelo paramétrico de la distribución de probabilidad de mediciones o características continuas en diversas aplicaciones. Un modelo de mezcla gaussiano $p(x|\lambda)$ es una suma ponderada de las M componentes de densidades gaussianas, y esto es representado por (5):

$$p(x|\lambda) = \sum_{i=1}^M w_i g(x|\mu_i, \Sigma_i) \quad (5)$$

Donde x es un vector de datos de valor continuo en dimensión D (medición o características), w_i son los pesos mixtos y $g(x|\mu_i, \Sigma_i)$ son las densidades de los componentes gaussianos.

En las aplicaciones de detección de novedad, los modelos de mezcla gaussianos estiman la densidad de probabilidad de la clase objetivo (la clase normal o el conjunto de conocimiento), dada por un conjunto de entrenamiento, generalmente utilizando menos núcleos que la cantidad de patrones en el conjunto de entrenamiento. Aunque los modelos de mezcla gaussianos se han utilizado y explorado en muchos estudios para la detección de novedades, pueden sufrir el requerimiento de una gran cantidad de ejemplos de entrenamiento para estimar los parámetros del modelo.

ii. Estimaciones multivariadas de densidad de núcleo

Las estimaciones multivariadas de la densidad del núcleo son enfoques flexibles para estimar las densidades de una distribución de datos dada sobre la cual no hay información disponible sobre el tipo de la distribución subyacente.

Para conjuntos de datos multidimensionales, se aplican estimaciones multivariadas de la densidad de núcleo. Dado un vector aleatorio d -dimensional $\mathbf{X} = (X_1, \dots, X_d)^T$ donde X_1, \dots, X_d son variables aleatorias unidimensional, el vector \mathbf{X}_i representa la i -ésima observación de las d variables: $\mathbf{X}_i = (X_{i1}, \dots, X_{id})$, donde $i = 1, \dots, n$, y n corresponde al número total de observaciones. La variable X_{ij} es la i -ésima observación de la variable aleatoria X_j , donde $j = 1, \dots, d$. La función de densidad de probabilidad de \mathbf{X} esta dada por el conjunto de la función de densidad de probabilidad de las variables aleatorias $(X_1, \dots, X_d)^T$ (6):

$$f(\mathbf{X}) = f(X_1, \dots, X_d) \quad (6)$$

Las funciones de núcleo son aplicadas a las distancias escaladas, en un caso unidimensional: $u = (x - X_i)/h$, donde h es el parámetro llamado ancho de banda y x es la observación actualmente analizada. En la versión multivariada, el ancho de banda puede ser establecida individualmente para cada distancia $(x - X_i)$, obteniendo un ancho de banda de dimensión d : $h = (h_1, \dots, h_d)$. La función de densidad de probabilidad depende altamente de la selección del ancho de banda del vector parámetro.

2.3.2. Métodos basados en dominio

Los métodos basados en el dominio requieren que se cree un límite basado en la estructura del conjunto de datos de entrenamiento. Estos métodos suelen ser insensibles al muestreo específico y la densidad de la clase objetivo, porque describen el límite de la clase objetivo o el dominio, y no la densidad de la clase. La pertenencia de clase a datos desconocidos se determina luego por su ubicación con respecto al límite.

Las máquinas de vectores de soporte (SVM, *Support Vector Machine*) son una técnica popular para formar límites de decisión que separan los datos en diferentes clases. Los puntos de entrenamiento que se encuentran cerca del límite que define este margen de separación se denominan vectores de soporte. Las SVM se han utilizado para la detección de novedades en dos enfoques relacionados y que se describen a continuación.

i. Descripción de datos de vectores de soporte

Un conjunto de vectores de soporte que describe el límite de la esfera construye un límite de decisión de forma esférica alrededor de un conjunto de objetos. Tiene la posibilidad de transformar los datos en nuevos espacios de características sin mucho costo de cómputo adicional. Al utilizar los datos transformados, esta descripción de datos de vectores de soporte puede obtener descripciones de datos más flexibles y precisos. El problema de minimización para delimitar el radio de la esfera se expresa como el Lagrangiano (7):

$$L = \sum_i \alpha_i (x_i \cdot x_i) - \sum_{i,j} \alpha_i \alpha_j (x_i \cdot x_j) \quad (7)$$

Bajo las restricciones de $0 \leq \alpha_i \leq C$, $\sum \alpha_i = 1$. Donde α_{ij} son los multiplicadores de Lagrange, x_{ij} son los puntos de entrenamiento de los datos, la variable C da la compensación entre simplicidad (volumen de la esfera) y el número de errores (número de objetos rechazados).

ii. Máquina de vectores de soporte de un clase

El objetivo de las máquinas de vectores de soporte de una clase (OC-SVM, *One Class Support Vector Machine*) es separar una clase de muestras objetivo de todas las otras muestras de clase. En este tipo de problema, una clase se caracteriza correctamente, llamada

clase objetivo; mientras que, para las otras clases, por lo general, no hay mediciones disponibles.

Considerando $X = [x_1, \dots, x_N]^T \in R^{N \times M}$, que denota el conjunto de datos normal, y $x_i, i = 1, \dots, N$ denota las muestras de entrenamiento caracterizados por M características numéricas, entonces, para obtener el límite, un modelo de optimización se considera como se presenta en las ecuaciones (8) y (9):

$$\min \left\{ \frac{\|w\|^2}{2} + \frac{1}{Nv} \sum_{i=1}^N \xi_i - \rho \right\} \quad (8)$$

$$w \cdot \Phi(x) \geq \rho - \xi_i, \xi_i \geq 0 \quad (9)$$

Donde v es un parámetro de regularización y ξ_i es la variable estacionaria para el punto x_i . Las constantes w y ρ son el vector normal y el desplazamiento del hiperplano, respectivamente.

2.3.3. Métodos basados en distancia

Estos métodos representan un enfoque de detección de novedad similar a la estimación de la función de densidad de probabilidad. Los métodos basados en la distancia se basan en métricas de distancia bien definidas para calcular la distancia, como criterios de similitud, entre los puntos de datos (Ding et al., 2014). Los enfoques basados en la distancia no requieren un conocimiento previo de la distribución de los datos y comparten algunas suposiciones comunes con los enfoques probabilísticos. Generalmente, en conjuntos de datos de alta dimensión, es computacionalmente costoso calcular la distancia entre puntos de datos y, como consecuencia, estas técnicas carecen de escalabilidad. Los métodos basados en la distancia intentan caracterizar el área del espacio de datos ocupado por los datos normales, asignándoles a los datos de prueba una puntuación de novedad basada en algún tipo de métrica de distancia. Estas técnicas requieren un cálculo de medición de distancia entre un par de puntos de datos, cuando se aplican a la detección de novedades, suponen que la medida de la distancia puede discriminar entre puntos de datos nuevos y normales.

i. k Vecinos más cercanos

La idea principal de esta técnica, k Vecinos más cercanos (k -NN, *k-Nearest Neighbours*), es que los datos normales se proyectan cerca de sus vecinos, mientras que las

novedades se proyectaran lejos de sus vecinos. Es decir, considerando un punto de datos desconocido x , este punto se acepta como normal si la distancia a su vecino más cercano y , en el conjunto de entrenamiento es menor o igual que la distancia desde y al vecino más cercano de y en el conjunto de entrenamiento. De lo contrario, se considera x como una novedad. La distancia euclidiana es la opción más popular para los atributos continuos univariados y multivariados como se presenta en la ecuación (10).

$$\|x - y\| = \sqrt{\sum_{i=1}^D (x_i - y_i)^2} \quad (10)$$

Se pueden usar varias métricas de distancia bien definidas para calcular la distancia entre dos puntos de datos, que se pueden distribuir ampliamente en métodos basados en la distancia y métodos basados en la densidad local en el que se considera la distancia al promedio de los k vecinos más próximos.

La detección de novedad ha ganado mucha atención en la investigación, los enfoques para la detección de novedades incluyen los enfoques frecuentista y bayesiano, la teoría de la información, las estadísticas de valores extremos, los métodos de vectores de soporte, otros métodos de núcleo y las redes neuronales (Pimentel et al., 2014).

La detección de novedades tiene muchas aplicaciones prácticas de la vida real en diferentes dominios, y es de crucial importancia en aplicaciones que involucran grandes conjuntos de datos adquiridos de sistemas críticos. Estos incluyen la detección de fallas en sistemas industriales complejos, daños estructurales y fallas en sistemas de seguridad electrónicos. Detectar eventos nuevos es una habilidad importante de cualquier esquema de clasificación de señales. Dado que nunca es posible entrenar un sistema de aprendizaje automático en todas las posibles clases de objetos con los datos que probablemente encuentre el sistema, es importante que sea capaz de diferenciar entre información de objetos conocidos y desconocidos durante las pruebas. En la práctica, se ha realizado mediante varios estudios que la detección de novedades es una tarea extremadamente desafiante. Es por esta razón que existen varios modelos de detección de novedad que se ha demostrado que funcionan bien en diferentes datos. Es evidente que no existe un mejor modelo único para la detección de la novedad y que el éxito depende no solo del tipo de método utilizado, sino también de las propiedades estadísticas de los datos manejados (Carino et al., 2018).

2.4. Evaluación de modelos de aprendizaje profundo y detección de novedad

En esta sección se presentan las herramientas para la evaluación de los modelos creados con las técnicas de aprendizaje profundo y con los modelos de detección de novedad. Si bien la creciente tecnología permite tener modelos más precisos para el monitoreo de condiciones de fallos, la interpretación de los resultados que estos modelos de nuevas técnicas o algoritmos como lo son el aprendizaje profundo y la detección de novedad son importantes entenderlos para concluir y valorar las respuestas del sistema.

2.4.1. Herramientas para evaluar modelos de aprendizaje profundo

Una de las principales e importantes consideraciones al entrenar el modelo de aprendizaje profundo, es no utilizar el set de datos entero para esta tarea. Existen particiones típicas de muestras para el entrenamiento y para la etapa de prueba. Las más comunes son manejar 70/30, 80/20 e incluso 90/10. Es importante usar datos nuevos, es decir, que el modelo entrenado no los haya evaluado previamente en la etapa de entrenamiento, para prevenir el sobreajuste, lo que equivale a un modelo que solo está bien entrenado para los datos que ya evaluó y no puede generalizar, no tiene ese balance. En ocasiones se requerirá evaluar en primera instancia el modelo para ajustar los hiperpárametros, en este caso se crea una tercera partición de datos comúnmente llamada para evaluación, y los porcentajes de las muestras se modifican siendo lo más típico 60% para el entrenamiento, 20% para la validación y 20% para la prueba. Aclarar que esto dependerá mucho de la disponibilidad de los datos que se cuenten y la aplicación del modelo de aprendizaje profundo.

- **Métricas de clasificación**

Para medir el rendimiento de los modelos de aprendizaje profundo realizando clasificaciones, existen 4 tipos de respuestas para las muestras evaluadas:

- *Verdadero positivo*: la predicción del modelo indica que una observación pertenece a la clase a la que realmente pertenece.
- *Verdadero negativo*: el modelo predice que la observación no pertenece a la clase a la que verdaderamente pertenece.

- *Falso positivo*: ocurre cuando la predicción indica que la observación pertenece a una clase que en realidad no.
- *Falso negativo*: en esta situación la predicción indica que una observación no pertenece a una clase a la que realmente si pertenece.

Estas 4 respuestas son visualizadas en una matriz de confusión, esto es una gráfica donde visualmente se aprecia a manera resumida las predicciones del modelo contra las verdaderas asignaciones de las observaciones para cada clase. La Figura 2.11 representa un ejemplo de una matriz de confusión para una clasificación de 2 clases. Este concepto de matriz de confusión se puede extender hasta las clases, condiciones o etiquetas que se tengan en la aplicación por evaluar, es decir, clasificación de múltiples clases.

		Predicción	
		0	1
Etiqueta real	0	35 Verdaderos negativos	5 Falsos positivos
	1	8 Falsos negativos	32 Verdaderos positivos

Figura 2.11. Ejemplo de matriz de confusión (Fuente: autoría propia).

Existen tres principales métricas usadas para evaluar el rendimiento de un modelo de clasificación:

1. **Exactitud**: es el porcentaje de predicciones correctas. Se calcula dividiendo el número de predicciones correctas entre el número total de predicciones como se muestra en la ecuación (11).

$$Exactitud = \frac{Predicciones\ correctas}{Predicciones\ totales} \quad (11)$$

2. **Precisión**: es la fracción de muestras relevantes (verdaderos positivos) dentro de todas las muestras que fueron predichas de pertenecer a cierta clase.

$$\text{Precisión} = \frac{\text{Verdaderos positivos}}{\text{Verdaderos positivos} + \text{Falsos positivos}} \quad (12)$$

3. **Exhaustividad:** se define como la fracción de muestras que fueron predichas de pertenecer a una clase con respecto a todas las muestras que verdaderamente pertenecen a esa clase.

$$\text{Exhaustividad} = \frac{\text{Verdaderos positivos}}{\text{Verdaderos positivos} + \text{Falsos negativos}} \quad (13)$$

Precisión y exhaustividad son útiles en los casos donde las clases no están distribuidas uniformemente. Es útil entender que la exactitud por sí solo puede no llegar a ser realmente informativo respecto a la efectividad de un modelo.

Para los modelos de regresión se tienen otro tipo de métricas, debido a que ahora las predicciones se desenvuelven dentro de un rango continuo en lugar de un rango discreto como lo pueden ser el número de clases. Dentro de las métricas más utilizadas se encuentran la varianza explicada, el error cuadrático medio y el coeficiente R^2 .

La meta principal de cualquier modelo de aprendizaje automático es aprender de los ejemplos y generalizar algún grado de conocimiento respecto a la tarea para la cual fue entrenado. Sin embargo en ocasiones la habilidad de aprender de los ejemplos se ve limitada, los modelos ponen poca atención a los datos presentados, este tipo de modelos contienen alto sesgo (*bias*) y se conoce que tienen subajuste. Por el otro lado, en ocasiones el modelo aprende demasiado de los datos de entrenamiento, esto conlleva a una poca generalización por parte del modelo porque solo se centró en los datos de entrenamiento. Este tipo de modelos contiene alta varianza y se denominan que contienen sobreajuste. En resumen un modelo con alto *bias* está limitado en aprender la tendencia de los datos y por lo tanto esta subajustado a los datos. Un modelo con alta varianza aprende demasiado de los datos de entrenamiento y se sobreajusta al modelo no consiguiendo generalizar. El mejor modelo deberá de estar en medio de estos dos extremos.

Las curvas de validación permiten encontrar el punto óptimo entre el subajuste y el sobreajuste de un modelo para construir un modelo que generalice bien. Una curva de validación es un gráfico del error del modelo en función de algún hiperparámetro del modelo que controla la tendencia a sobreajustar o desajustar los datos. El parámetro que se elija depende del modelo específico que se esté evaluando. Generalmente, el parámetro elegido

tendrá algún grado de control sobre la complejidad del modelo. En esta curva, se traza tanto el error de entrenamiento como el error de validación del modelo. Combinando ambos errores, es posible diagnosticar si un modelo tiene un sesgo o una varianza elevados. En la región en la que tanto el error de entrenamiento como el de validación son altos, el modelo está sujeto a un sesgo elevado. En este caso, no ha sido capaz de aprender de los datos y su rendimiento es deficiente. En la región en la que el error de entrenamiento y el error de validación divergen, con el error de entrenamiento manteniéndose bajo y el error de validación aumentando, se empiezan a ver los efectos de una alta varianza. El error de entrenamiento es bajo porque se están sobreajustando los datos y aprendiendo demasiado de los ejemplos de entrenamiento, mientras que el error de validación sigue siendo alto porque el modelo no es capaz de generalizar de los datos de entrenamiento a los nuevos datos.

2.4.2. Herramientas para evaluar modelos de detección de novedad

En general, los métodos de detección de novedad construyen algún modelo de un conjunto de entrenamiento que se selecciona para que no contenga ejemplos (o muy pocos) de la clase importante (es decir, novedosa). Las puntuaciones de novedad se asignan luego a los datos, y las desviaciones de la normalidad se detectan de acuerdo con un límite de decisión que generalmente se conoce como el umbral de novedad. Se utilizan diferentes métricas para evaluar la efectividad y la eficiencia de los métodos de detección de novedad. La efectividad de las técnicas de detección de novedad se puede evaluar de acuerdo con la cantidad de puntos de datos nuevos que se identifican correctamente y también con la cantidad de datos normales que se clasifican incorrectamente como datos nuevos. Este último también se conoce como la tasa de falsa alarma. Las curvas de la característica operativa del receptor se usan generalmente para representar la compensación entre la tasa de detección y la tasa de falsa alarma.

Las técnicas de detección de novedad deben apuntar a tener una alta tasa de detección mientras se mantiene baja la tasa de falsas alarmas. La eficiencia de los enfoques de detección de novedad se evalúa de acuerdo con el costo computacional y la complejidad tanto temporal como espacial. Las técnicas eficientes de detección de novedad deben ser escalables a conjuntos de datos grandes y de alta dimensión. Además, dependiendo de la tarea específica de detección de novedad, la cantidad de memoria requerida para implementar

la técnica se considera generalmente como una importante medida de evaluación de desempeño.

3. Metodología

En este capítulo se presenta el desarrollo de la metodología empleada para la detección e identificación de disturbios eléctricos mediante técnicas de aprendizaje profundo y detección de novedad. La Figura 3.1 presenta el diagrama general de la metodología seguida en este trabajo para la ejecución y alcance de los objetivos proyectados. A continuación, se especifican cada una de las fases que constituyen la metodología.

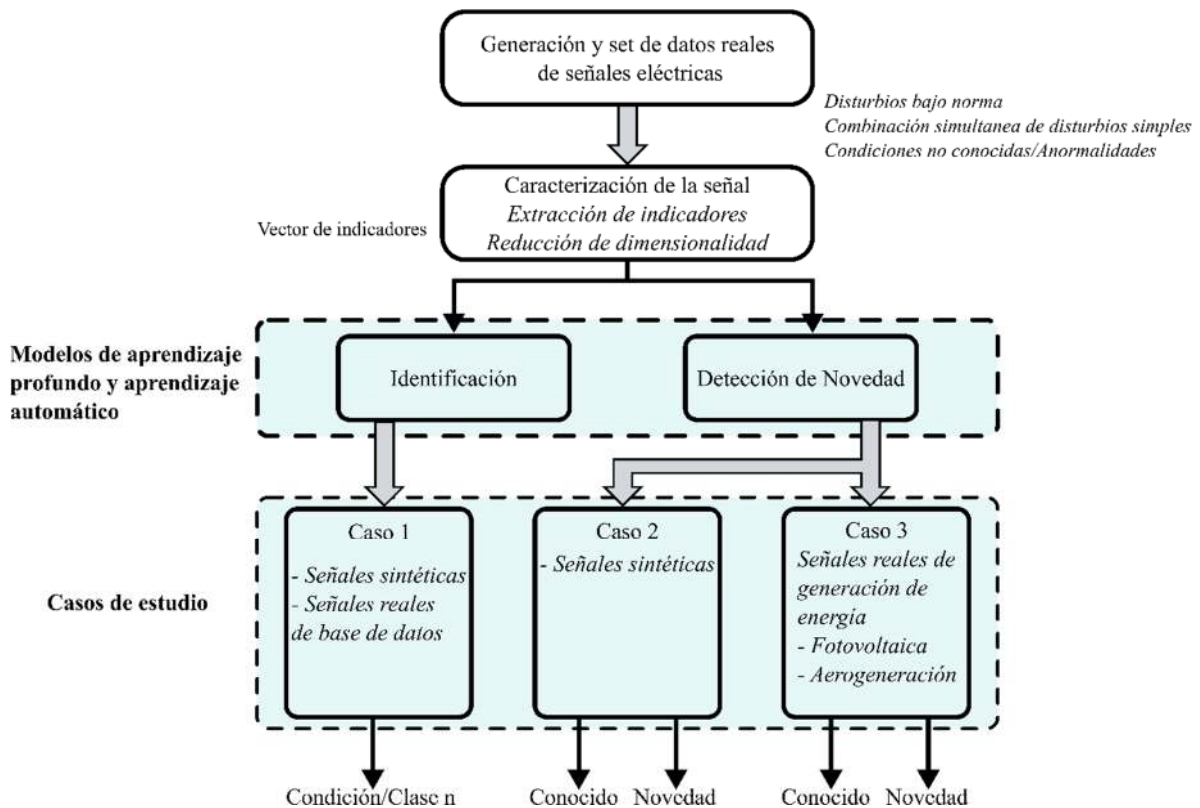


Figura 3.1. Diagrama general de la metodología seguida (Fuente: autoría propia).

El diagrama consta de diferentes etapas, la primera etapa comprende la generación de señales que representan las condiciones de disturbios eléctricos definidos en la norma, las combinaciones de estos disturbios que representan señales no definidas por los estándares y las señales de bases de datos reales que contienen afectaciones identificadas de condiciones de operación y condiciones anormales no previamente identificadas. La etapa dos se refiere a la caracterización adecuada de las señales eléctricas bajo estudio para su posterior procesamiento. En la etapa número 3 están definidos los modelos de aprendizaje profundo y aprendizaje automático para la identificación de los disturbios eléctricos y para la detección

de novedad en las señales. En la última etapa se tienen tres bloques en paralelo que corresponden a los diferentes casos de estudio llevados a cabo para la validación de las metodologías de detección e identificación de las condiciones de fallo o de operación en las señales eléctricas.

3.1. Generación de señales y conjunto de señales reales

En el desarrollo de las propuestas para la identificación de disturbios eléctricos y detección de novedad se requieren señales que representen toda la variedad posible de las condiciones de la señal eléctrica. En este trabajo de investigación estas señales eléctricas fueron obtenidas de dos maneras: (i) mediante la generación sintética con las ecuaciones que caracterizan cada tipo de fallo y que además permiten generar las distintas combinaciones con estos disturbios simples, y (ii) señales reales obtenidas de bases de datos, de dominio público y de grupos de investigación relacionados con la generación de energía eléctrica.

3.1.1. Señales sintéticas

Debido a que la señal eléctrica ideal y los tipos de disturbios descritos en la norma están bien definidos en términos de sus parámetros y variaciones de los mismos, es posible generar sintéticamente mediante *software* estas condiciones de fallo. Además es posible sintéticamente hacer combinaciones de disturbios eléctricos, estas condiciones a pesar de no estar definidas en los estándares, la comunidad científica las utiliza para validar sus propuestas. En el mismo sentido fueron consideradas en este trabajo. Aclarar que las combinaciones que se tomaron en cuenta son de ocurrencia simultánea, es decir se presentaban al mismo tiempo en la señal y no tenían conflicto de definición, es decir conceptualmente es posible que ocurran. Tomando por ejemplo el disturbio armónicos con una caída de voltaje que puede ocurrir simultáneamente, a diferencia de un aumento de voltaje y una caída de voltaje que tan solo en definición ya son opuestos. En este trabajo las condiciones de la señal eléctrica generadas sintéticamente son: condición normal/ideal, caída de voltaje, aumento de voltaje, interrupción, fluctuaciones, armónicos, oscilatorio transitorio y muescas. A partir de estas señales se consideraron algunas combinaciones de estas para representar condiciones de fallo anormales. La frecuencia de muestreo de las señales generadas sintéticamente es de 15.36 kHz. Adicionalmente se utilizaron señales con ruido

agregado, tres relaciones señal a ruido (SNR, *signal-to-noise ratio*) fueron utilizadas: 50 dB, 40 dB y 30 dB.

3.1.2. Señales de bases de datos

Para validar las propuestas se utilizaron señales de bases de datos reales, en el caso de la identificación se utilizó una base de datos de la IEEE, que es típicamente utilizada con el mismo propósito en otros trabajos de investigación: (Alam et al., 2020), (Thirumala et al., 2019), (Liu et al., 2019). Esta primera base de datos contiene señales eléctricas con afectaciones que no están etiquetadas de manera oficial por lo que se requirió un trabajo adicional de establecer las condiciones para cada señal de la base de datos. La segunda base de datos de señales reales fue adquirida mediante pruebas experimentales de sistemas de generación eólica y fotovoltaica. En estas señales se encuentran identificadas afectaciones ya definidas y otras afectaciones debido a condiciones de operación anormales.

3.2. Caracterización de la señal y reducción de dimensionalidad

La caracterización de la señal eléctrica, consiste en la extracción de indicadores que describan la señal eléctrica. Como se mencionó en los antecedentes, es común tomar diferentes dominios de la señal para lograr una caracterización adecuada. En esta etapa se consideró extraer indicadores en el dominio del tiempo, en el dominio de la frecuencia y en el dominio de tiempo-frecuencia. En el dominio del tiempo se calculan los indicadores utilizando la señal original. Para caracterizar la señal en el dominio de la frecuencia, se utilizó la Transformada Rápida de Fourier (FFT, *Fast Fourier Transform*). Para el dominio tiempo-frecuencia se utilizó Descomposición Empírica en Modos (EMD, *Empirical Mode Decomposition*) y se utilizaron las dos primeras Funciones de Modo Intrínseco (IMF, *Intrinsic Mode Function*), para la caracterización en este dominio. En la caracterización de las señales eléctricas se tomaron veinte indicadores, algunos de carácter estadístico y otros no estadísticos. El tamaño de la representación final es de ochenta indicadores, veinte en el dominio del tiempo, veinte en el dominio de la frecuencia y cuarenta en el dominio tiempo-frecuencia debido al uso de las 2 IMF's. Los veinte indicadores utilizados se muestran en la Tabla 3.1.

Tabla 3.1. Indicadores estadísticos considerados para la caracterización de la señal eléctrica

1	Media	6	Varianza	11	Factor Impulso	16	Energía
2	Máximo Valor	7	Factor forma RMS	12	Asimetría	17	Entropía
3	Raíz Cuadrática Media	8	Factor forma SRM	13	Curtosis	18	Rango
4	Media de la Raíz Cuadrada	9	Factor cresta	14	5° Momento	19	Factor Forma
5	Desviación estándar	10	Factor Latitud	15	6° Momento	20	Log energía-entropía

Una vez obtenidos los indicadores convenientemente seleccionados una etapa de reducción de dimensionalidad es llevada a cabo con la finalidad de descartar información no relevante y reducir el tamaño de la representación como optimización para su posterior procesado.

La reducción de dimensionalidad y el modelado de comportamiento se llevan a cabo por una técnica de aprendizaje profundo que consiste en una estructura de autoencoders apilados (SAE, *Stacked Auto Encoders*). La estructura del autoencoder es de 80-70-50-30, es decir, la entrada es del tamaño de la representación y pasa a través de tres etapas de reducción llegando a un tamaño final de treinta indicadores. El proceso de configuración de SAE se lleva a cabo mediante una búsqueda de malla, se realiza una búsqueda gruesa y una fina para configurar adecuadamente los hiperparámetros de acuerdo a recomendaciones en el estado del arte. Los hiperparámetros configurados son los parámetros de regularización, el número de épocas, verificando que el proceso de codificar y decodificar el vector de información el error sea mínimo. La cantidad de señales utilizadas es de 900 para el entrenamiento y 100 para la etapa de prueba. Esta metodología es parte importante del aporte desarrollado en este trabajo, el uso de herramientas de aprendizaje profundo para reducir la dimensión y caracterizar eficientemente las señales eléctricas para su posterior identificación y detección de novedad.

3.3. Modelos de aprendizaje profundo y aprendizaje automático

Los bloques de Identificación y Detección de Novedad son los bloques donde se encuentran los modelos de aprendizaje profundo y de aprendizaje automático. La entrada a estos modelos es el vector de indicadores en una dimensión reducida que se evaluó ya sea para identificación, es decir, poner una etiqueta al efecto caracterizado, o en otro caso para detección de novedad, es decir, indicar si la señal caracterizada pertenece a un conjunto de conocimiento ya establecido o no. Según sea el tipo de evaluación, se tendrán diferentes modelos para cada tarea, estos serán descritos en la puesta de experimentación en el capítulo siguiente. De estos bloques se desprenden tres casos de estudio, uno para la identificación y dos para la detección de novedad.

3.4. Casos de estudio

Se tienen tres casos de estudios, uno para identificación y dos para la detección de novedad. En el primer caso, se trabajó con señales sintéticas y reales de base de datos para evaluar mediante técnicas de aprendizaje profundo la detección y clasificación de disturbios eléctricos. En el caso número dos, referente a la detección de novedad se utilizaron señales sintéticas para crear distintos escenarios de complejidad y evaluar con diversos enfoques la detección de novedad de señales que no se consideran en un conjunto de conocimiento que va cambiando, agregando más señales al conjunto de conocimiento y dificultando el proceso de detección adecuada. Finalmente, para el tercer caso, de la misma manera sobre detección de novedad, se utilizaron señales reales de dos fuentes de generación eléctrica, fotovoltaica y aerogeneración, con el propósito de evaluar la detección de novedad con señales reales adquiridas. Estos tres casos se describen más específicamente en el siguiente capítulo.

4. Casos de estudio y puesta de experimentos

En este capítulo se describirá de manera detallada cada uno de las experimentaciones realizadas, los casos mencionados en la sección anterior, en qué consisten, el objetivo de cada uno, la puesta del experimento y en el capítulo 5 se describirán los resultados de cada uno de ellos. Se realizaron tres experimentaciones, la primera relacionada con la detección e identificación de disturbios eléctricos en la calidad de la energía mediante aprendizaje profundo. La segunda y tercera experimentación son sobre detección de novedad, la segunda involucra escenarios de complejidad conforme el conjunto de conocimiento va aumentado y la tercera experimentación consistió en utilizar señales reales de generación alternativa, fotovoltaica y aerogeneración, para construir subcasos de estudio con las perturbaciones que se tenían en dichos sistemas.

4.1. Identificación

En la primera experimentación, el objetivo consiste en validar la tecnología de aprendizaje profundo para la detección e identificación de las perturbaciones de la calidad de la energía. Se propone un diagrama de flujo mostrado en la Figura 4.1 basado en la metodología basada en datos que se mencionó en el capítulo 1.

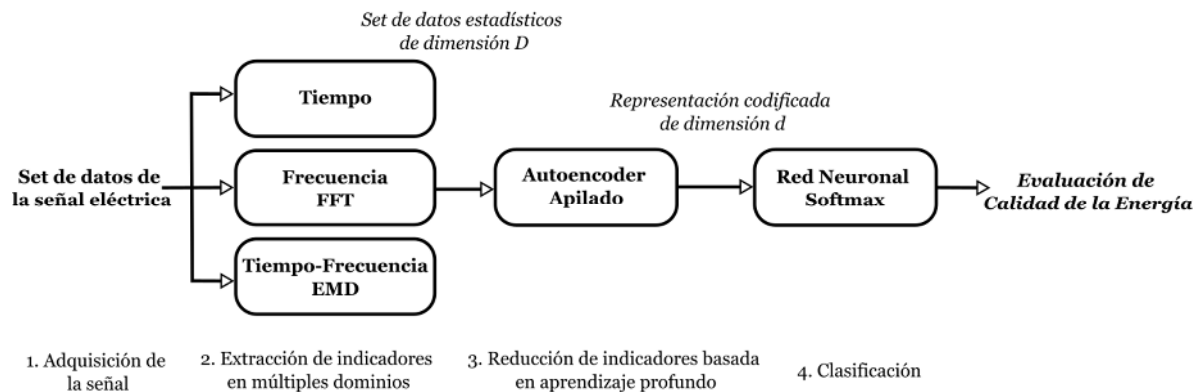


Figura 4.1. Diagrama para la experimentación con la identificación de disturbios eléctricos (Fuente: autoría propia).

La contribución de esta experimentación radica en la propuesta de un método novedoso de diagnóstico basado en el aprendizaje profundo aplicado a las perturbaciones de

la calidad de la energía. En esta experimentación se incluyen los siguientes aspectos clave: i) un marco común para la configuración del método de diagnóstico y la puesta a punto de algoritmos basados en mediciones cuantitativas, ii) uso del autoencoder como técnica de aprendizaje profundo capaz de caracterizar patrones complejos de perturbaciones de potencia, iii) la consideración de perturbaciones simples, pero también la combinación de perturbaciones dobles y triples bajo diferentes relaciones señal/ruido.

Las señales consideradas para la primera etapa de entrenamiento y validación son disturbios simples, combinaciones de dos y combinaciones de tres disturbios, la Tabla 4.1 resume las condiciones que se tomaron en cuenta para esta experimentación.

Tabla 4.1. Disturbios eléctricos considerados

C1 Normal	C7 Oscilatorio Transitorio	C13 Armónicos con oscilatorio transitorio
C2 Caída de voltaje	C8 Muestras	C14 Armónicos con fluctuaciones
C3 Aumento de voltaje	C9 Caída de voltaje con Armónicos	C15 Armónicos con Muestras
C4 Interrupción	C10 Caída de voltaje con Oscilatorio transitorio	C16 Caída de voltaje con Armónicos y con Oscilatorio Transitorio
C5 Fluctuaciones	C11 Aumento de voltaje con Armónicos	C17 Aumento de voltaje con Armónicos y con Oscilatorio Transitorio
C6 Armónicos	C12 Aumento de voltaje con Oscilatorio Transitorio	

Estas clases consideradas se crearon sintéticamente mediante la descripción matemática que permite simularlas. Para la etapa de validación con señales reales se trabajó con señales de base de datos de la IEEE , estas señales contienen distintas afectaciones y sirven para validar metodologías de detección e identificación de perturbaciones.

La siguiente etapa acerca de extracción de indicadores y reducción de dimensionalidad se siguió como fue descrita en el capítulo 3 de la metodología, se calcularon indicadores para la señal en el dominio del tiempo, en el dominio de la frecuencia utilizando FFT y en el dominio de tiempo-frecuencia mediante el uso de EMD. La reducción de indicadores se llevó a cabo por la estructura de SAE y por último para la etapa final de

clasificación se utilizó una red neuronal *softmax* para la identificación de las 17 clases consideradas en esta experimentación.

4.2. Detección

Para la experimentación de detección de novedad se realizaron dos experimentaciones. La primer experimentación tiene como objetivo integrar la detección de novedad para un sistema de monitoreo de disturbios eléctricos.

En esta primer experimentación se consideraron las 17 condiciones de disturbio que en la primer experimentación, sin embargo, se dividieron en tres tipos de disturbios, simples, la combinación de dos y en la combinación de tres, tal como se muestra en la Tabla 4.2.

Tabla 4.2. Tipos de disturbios dentro de los considerados

Tipo	Clases
Disturbios simples	C1-C8
Combinación de 2 disturbios	C9-C15
Combinación de 3 disturbios	C16-C17

En esta ocasión se plantearon escenarios de complejidad, esto quiere decir, inicialmente se considera un conjunto de conocimiento base y un conjunto de clases que son novedad para el sistema. Avanzando en complejidad, un disturbio que se consideraba novedad es ahora parte del conjunto de conocimiento. Con las clases consideradas se planteó que el conjunto inicial de conocimiento constaba de los disturbios simples, los disturbios que son combinación de dos, son aquellos que se iban ir agregando al conjunto de conocimiento, y los disturbios de combinación triple siempre pertenecen a la condición de novedad. Bajo estas consideraciones se tenían distintas variaciones para cada escenario. La síntesis de estas permutaciones se muestra en la Tabla 4.3.

Tabla 4.3. Configuración de cada escenario para la detección de novedad

Escenario #	1	2	3	4	5	6	7	8
Clases Conocidas	8	9	10	11	12	13	14	15
Clases Novedad	9	8	7	6	5	4	3	2
Variaciones	1	7	21	35	35	21	7	1

Para la caracterización de las señales se consideró lo realizado en la experimentación anterior, es decir 80 indicadores, 20 en el dominio del tiempo, 20 para el dominio de la frecuencia y 20 para cada una de las 2 IMF para el dominio tiempo frecuencia.

Para el modelado de comportamiento y reducción de dimensionalidad se considera la misma estructura de autoencoder apilados de 80-70-50-30 con la configuración anterior descrita, es decir una búsqueda de malla para la configuración de cada modelo y para cada variación de cada uno de los escenarios.

Para la detección de novedad se probaron distintas configuraciones de técnicas de reducción de indicadores y técnicas de detección de novedad. Para la reducción de indicadores se propusieron diversas alternativas, la primera es ingresar los datos de la señal sin procesar, lo que comúnmente se conoce como datos en bruto (*Raw Data*), esto quiere decir que se tomaron los 80 indicadores y se evaluaron en las técnicas propuestas. La segunda alternativa fue utilizar PCA para la reducción de dimensionalidad y la tercera propuesta es la de procesar la señal mediante la estructura de SAE. Para la detección de novedad se utilizaron dos técnicas clásicas de detección de novedad, k-NN y OC-SVM.

De manera final se propusieron 2 alternativas, una de modelos especializados de OC-SVM y un esquema de ensamble, es decir, la combinación de dos técnicas y mediante un esquema de votación determinar la salida del modelo. La Tabla 4.4 resume las opciones de técnicas evaluadas en esta etapa.

Tabla 4.4. Propuestas para la detección de novedad

Propuesta	Reducción de dimensionalidad	Técnica de detección de novedad
Raw k-NN	Datos sin procesar	k-NN
Raw OC-SVM	Datos sin procesar	OC-SVM
PCA k-NN	PCA	k-NN
PCA OC-SVM	PCA	OC-SVM
SAE k-NN	SAE	k-NN
SAE OC-SVM	SAE	OC-SVM
Modelos especializados de OC-SVM	SAE	OC-SVM
Esquema de ensamble	SAE	OC-SVM y k-NN

4.3. Fotovoltaica

En la tercera experimentación se trabajó con dos casos de estudio en particular, señales de una fuente de generación fotovoltaica y de una fuente de aerogeneración. Para ambos casos lo que se realizó fue la comparativa de 6 técnicas de detección de novedad para los disturbios que se contaban en las señales obtenidas. Las seis técnicas que se compararon fueron de distinto tipo, son k-NN, OC-SVM, GMM, SAE, Mapas Autoorganizados (SOM, *Self-Organizing Maps*) y Bosque de Aislamiento (IF, *Isolation Forest*).

En lo relacionado al caso de la fotovoltaica, se contaba con señales con disturbio oscilatorio transitorio y debidas a condiciones meteorológicas. Bajo estas señales se crearon 5 subcasos para el análisis de estas técnicas, donde se variaba lo que se consideraba conjunto de conocimiento y lo que representaba como novedad. La Tabla 4.5 muestra los subcasos considerados para el caso de estudio de fotovoltaica.

Tabla 4.5. Subcasos establecidos para la experimentación de señales reales de generación fotovoltaica para la detección de novedad

Subcaso	Conocido	Novedad
a	Normal	OT
b	Normal	CM
c	Normal y OT	CM
d	Normal y CM	OT
e	Normal	OT y CM

OT: Oscilatorio Transitorio; CM: Condición Meteorológica.

Para esta experimentación, debido a que las señales consideradas eran pocas solo se utilizaron 60 de los 80 indicadores con los que se venía caracterizando la señal eléctrica, en este caso no se utilizó la segunda IMF del dominio tiempo frecuencia.

La estructura del autoencoder es de 60-50-40-25, siguiendo la misma metodología de configuración previamente trabajada en las experimentaciones anteriores.

4.4. Aerogeneración

Para el caso de estudio de las señales de aerogeneración, las señales con la que se contaba tenían la condición de caída de voltaje y de fluctuaciones. Los subcasos para esta experimentación están presentados en la Tabla 4.6.

Tabla 4.6. Subcasos establecidos para la experimentación con señales reales de generación eólica para la detección de novedad

Subcaso	Conocido	Novedad
a	Normal	Fluctuaciones
b	Normal	Caída de voltaje
c	Normal y Fluctuaciones	Caída de voltaje
d	Normal y Caída de voltaje	Fluctuaciones
e	Normal	Fluctuaciones y Caída de voltaje

La parte de caracterización, reducción de indicadores se mantiene igual que en la experimentación para la fotovoltaica.

5. Resultados y discusión

En esta sección se exponen y discuten los resultados de los casos de experimentación descritos en el capítulo anterior. Primero se muestran lo relacionado a la identificación de patrones, después la detección de novedad y por último a los casos de estudio de señales reales para la detección de novedad.

5.1. Resultados de la identificación

En primer lugar, relacionado a la identificación se presenta una muestra de la reconstrucción realizada por el autoencoder. Esto se realiza con el objetivo de visualizar el trabajo hecho por el autoencoder referente a la reducción de dimensionalidad. El vector de indicadores estadísticos en los tres dominios del tiempo es reducido mediante esta estructura de red neuronal profunda con la finalidad de comprimir la información. Esta codificación en menor dimensión deberá de ser útil para poder llevar a cabo una clasificación de disturbios eléctricos de manera eficiente. La Figura 5.1 muestra un vector de indicadores completo, es decir los 80 indicadores estadísticos calculados y la reconstrucción ejecutada por el autoencoder apilado. La segunda gráfica muestra el vector de error, donde se muestra claramente que el orden de magnitud de este vector se encuentra entre los 0.01. Este valor en promedio representa una buena codificación de la información, es decir la información codificada realmente representa el vector de entrada.

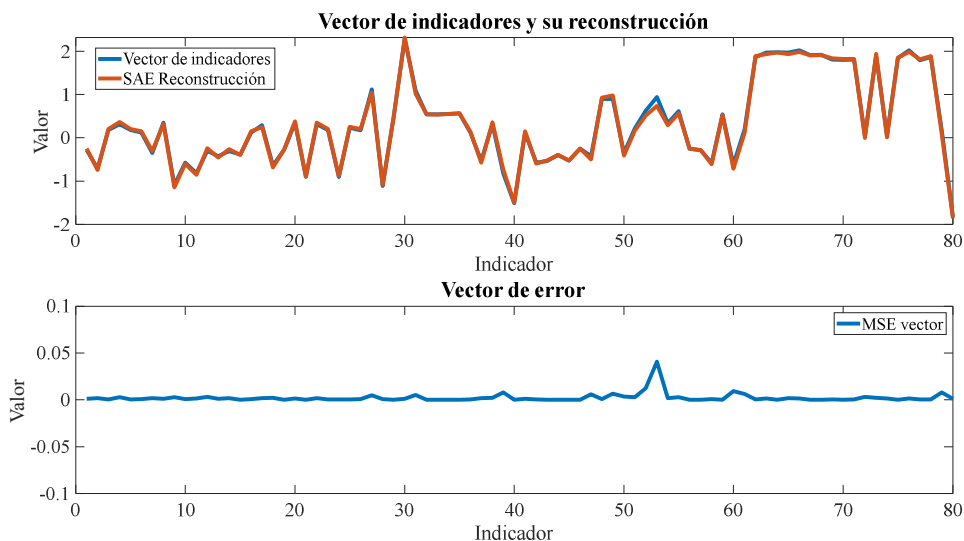


Figura 5.1. Reconstrucción por el autoencoder y vector de error (Fuente: autoría propia).

Una vez asegurándonos que la reducción de dimensionalidad representaba de manera fiel la señal eléctrica de manera codificada, se realizó la clasificación de los diferentes disturbios eléctricos generados sintéticamente y considerados para esta primera experimentación. La Tabla 5.1 muestra los rendimientos de clasificación para cada una de las 17 clases consideradas en este caso de estudio.

Tabla 5.1. Rendimiento de la identificación y clasificación de disturbios eléctricos

	Disturbio eléctrico	Rendimiento (%)
C1	Normal	100
C2	Caída de voltaje	99
C3	Aumento de voltaje	100
C4	Interrupción	100
C5	Fluctuaciones	100
C6	Armónicos	100
C7	Oscilatorio Transitorio	100
C8	Muecas	99
C9	Caída de voltaje con Armónicos	98
C10	Caída de voltaje con Oscilatorio transitorio	100
C11	Aumento de voltaje con Armónicos	99
C12	Aumento de voltaje con Oscilatorio Transitorio	100
C13	Armónicos con Oscilatorio transitorio	99
C14	Armónicos con Fluctuaciones	99
C15	Armónicos con Muecas	100
C16	Caída de voltaje con Armónicos y con Oscilatorio Transitorio	98
C17	Aumento de voltaje con Armónicos y con Oscilatorio transitorio	100

Se observa como la propuesta de identificación y clasificación de disturbios eléctricos tiene un rendimiento satisfactorio para todas las condiciones evaluadas. De las 17 condiciones, solo 2 de ellas cuentan con el menor rendimiento siendo un 98%, 5 con 99% y las demás con un rendimiento excelente. Las razones a estas variaciones de rendimiento son debidas a los tipos de condiciones, es decir las características de los disturbios llegan a resultar similares en comportamiento a otros disturbios y el modelo de aprendizaje profundo

no es capaz de identificar adecuadamente las condiciones. Resaltar que esto no es en todas las ocasiones, podemos indicar que un 98% es un porcentaje de identificación aceptable.

Para una evaluación más robusta de la propuesta para la identificación y clasificación de disturbios eléctricos, se avaluó bajo escenarios de ruido eléctrico considerando que este es causado por los equipos eléctricos, dispositivos de medición y otros aparatos conectados a la red eléctrica. La Tabla 5.2 muestra los resultados de clasificación general de las tres relaciones señal-ruido evaluadas.

Tabla 5.2. Rendimiento de clasificación a diferentes niveles de ruido.

	SNR			
	50 dB	40 dB	30 dB	Promedio
Rendimiento	98.35 %	98.37 %	97.48 %	98.06 %

Se aprecia claramente que el rendimiento global se ve poco afectado por la aparición de ruido en diferentes niveles. Esta disminución del rendimiento se debe a un ligero aumento en la clasificación incorrecta de las señales que contienen tres disturbios simultáneos, es decir, en aparición combinada.

Para la validación de la experimentación de la identificación de disturbios con señales reales la Tabla 5.3 muestra los resultados de la clasificación de las señales de base de datos experimentales de la IEEE.

Las señales de base de datos contenían solo algunas condiciones de disturbios, de las 48 muestras evaluadas, se puede observar que solo 4 fueron clasificadas incorrectamente, dando un rendimiento del 91.66 % respecto a estas señales consideradas. Con la evaluación de señales reales, además de verificar el funcionamiento de la metodología basada en herramientas de aprendizaje profundo, se observó la incorrecta clasificación de algunas señales con disturbios eléctricos que pudieran compartir ciertas características en común.

Tabla 5.3. Matriz de confusión para la clasificación de las señales de bases de datos

		Condición real								
		2	4	5	9	10	12	13	16	17
Predicción	2	17								
	4		1							
	5				2	1				
	9				11			1		
	10					1				
	12						1			
	13							2		
	16								5	
	17									6

5.2. Resultados de la detección

En el caso de estudio 2, se evaluaron distintos enfoques para la detección de novedad bajo diversos escenarios de complejidad donde el conjunto de conocimiento aumentaba y se dificultaba de esta manera determinar si una señal con ciertas características el modelo ya la tenía en cuenta o esta formaba parte de una condición no antes vista. Para los resultados de la propuesta de detección de novedad para el caso de estudio 2, la Figura 5.2 muestra las curvas de evolución de rendimiento para cada escenario, el valor en cada punto de la gráfica es un promedio de las variaciones en cada uno de ellos. La Tabla 5.4 muestra la nomenclatura de las técnicas presentadas en la evaluación del rendimiento.

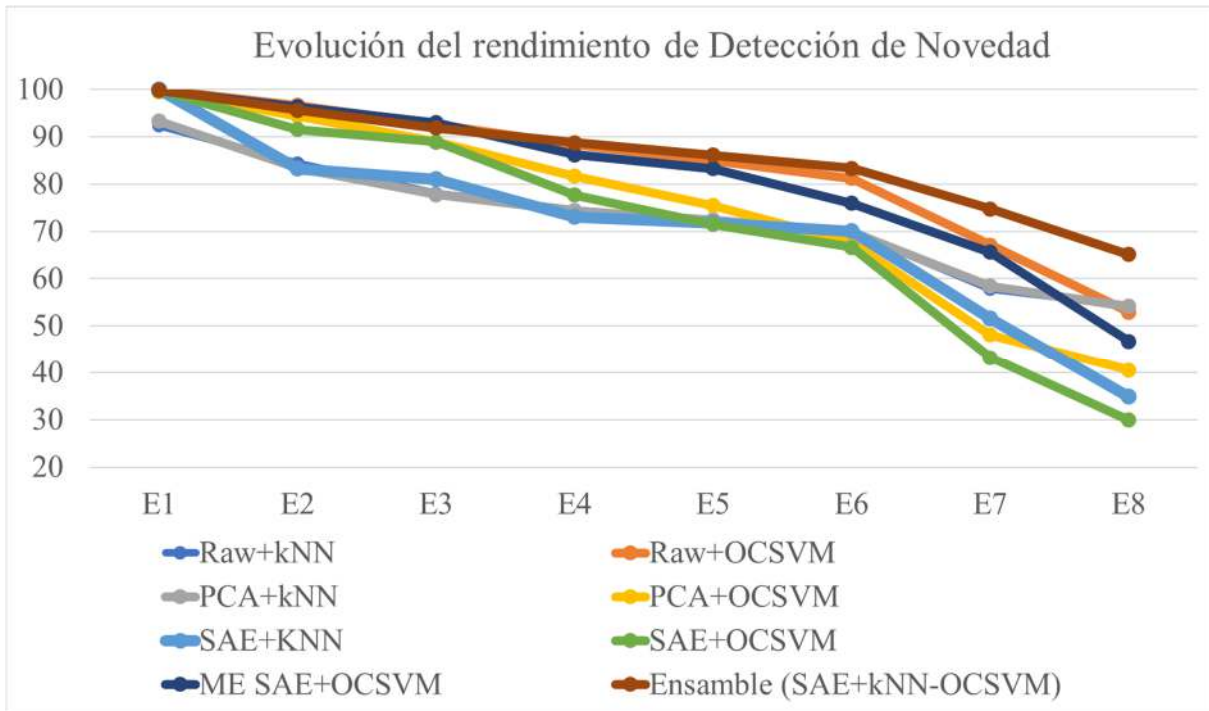


Figura 5.2. Evolución del rendimiento de los escenarios para la detección de novedad (Fuente: autoría propia).

Tabla 5.4. Nomenclatura de las técnicas de detección de novedad evaluadas

Propuesta	Descripción
Raw+kNN	Datos sin procesar y k vecinos más cercanos
Raw+OCSVM	Datos sin procesar y máquina de vectores de soporte de una clase
PCA+kNN	Análisis de componentes principales y k vecinos más cercanos
PCA+OCSVM	Análisis de componentes principales y máquina de vectores de soporte de una clase
SAE+kNN	Autoencoders apilados y k vecinos más cercanos
SAE+OCSVM	Autoencoders apilados y máquina de vectores de soporte de una clase
ME SAE+OCSVM	Modelos especializados de autoencoders apilados y máquina de vectores de soporte de una clase
Ensamble (SAE+kNN-OCSVM)	Modelos especializados de máquina de vectores de soporte de una clase y k vecinos más cercanos

Como se observa de la gráfica la mayoría de las técnicas parten de un rendimiento similar del 100% y mantienen un rendimiento aceptable incluso hasta el escenario 4 manteniéndose a valores cercanos al 90%. Los enfoques que manejan la técnica de k-vecinos cercanos son las que inmediatamente empiezan a empeorar el rendimiento desde el escenario

2 y manteniendo esa separación de rendimiento en los escenarios posteriores. Los enfoques que contienen solo la técnica de máquina de soporte vectorial de una clase mantienen un rendimiento estable aunque siguiendo la tendencia de decaimiento del rendimiento. Se aprecia claramente en la gráfica que del escenario 6 al escenario 7 existe una pendiente más pronunciada para la mayoría de las técnicas, esto indica que la complejidad de este nivel se vuelve grande para estos enfoques, donde entre más clases tiene el conjunto de conocimiento, resulta difícil discernir si la muestra es novedad o pertenece a lo ya conocido. Al final la propuesta que mejor mantuvo el rendimiento hasta el último nivel de complejidad es el enfoque de ensamble, utilizando las 2 técnicas, k-vecinos cercano y máquinas de soporte vectorial de una clase, mediante un esquema de votación se logró mantener el rendimiento por encima de 60% en el último escenario.

5.3. Resultados del estudio en señales de fotovoltaica

Para el caso de estudio 3 se dividirán los resultados de acuerdo a cada tipo de forma de generación de energía eléctrica, en cada sección se muestran las gráficas y tablas de cada subcaso de estudio analizado y descrito en el capítulo anterior, comenzando con los subcasos propuestos para la generación de energía fotovoltaica.

5.3.1. Subcaso 1a

En la primera experimentación con las señales reales provenientes de una fuente de generación fotovoltaica, donde el conjunto de conocimiento solo corresponde la condición ideal de la señal y como prueba para la evaluación de la condición de novedad se evaluaron las 6 técnicas con señales conteniendo disturbio oscilatorio transitorio. La Tabla 5.5 resume los resultados obtenidos para este subcaso y la Figura 5.3 muestra la gráfica del rendimiento para las 6 técnicas consideradas.




Figura 5.3. Gráfico del rendimiento de las técnicas para el subcaso 1a (Fuente: autoría propia).

Tabla 5.5. Rendimientos de cada técnica para el subcaso 1a.

Técnica / Clase	Conocido	Novedad	Total
Autoencoder apilado	88	100	94
Máquina de soporte vectorial de una clase	98.5	100	99.25
k-vecinos cercanos	94.5	100	97.25
Modelos de mezcla gaussianos	78	100	89
Mapas autoorganizados	96.5	100	98.25
Bosques de aislamiento	96	100	98

Se observa que de las seis técnicas evaluadas la única que presenta un rendimiento no aceptable en evaluar muestras ya conocidas es el modelo de mezcla gaussiano, el autoencoder apilado tiene un rendimiento regular al acercarse al 90% y las otras cuatro técnicas restantes su rendimiento es de 94% hacia arriba, siendo la superior máquina de soporte vectorial de una clase solo un punto por encima respecto a mapas autoorganizados. Para la detección de novedad en este subcaso todas las técnicas realizan un buen trabajo. Que los modelos de mezcla gaussianos no puedan determinar un conjunto de conocimiento con la señal ideal es de tener en consideración.

5.3.2. Subcaso 1b

Para el subcaso 1b de la experimentación con las señales reales provenientes de una fuente de generación fotovoltaica, el conjunto de conocimiento sigue correspondiendo solo

a la condición ideal de la señal, y como prueba para la evaluación de la condición de novedad se evaluaron muestras de señales con afectaciones debido a condiciones meteorológicas. La Figura 5.4 muestra la gráfica del rendimiento para las 6 técnicas consideradas y la Tabla 5.6 resume los resultados obtenidos para este subcaso.

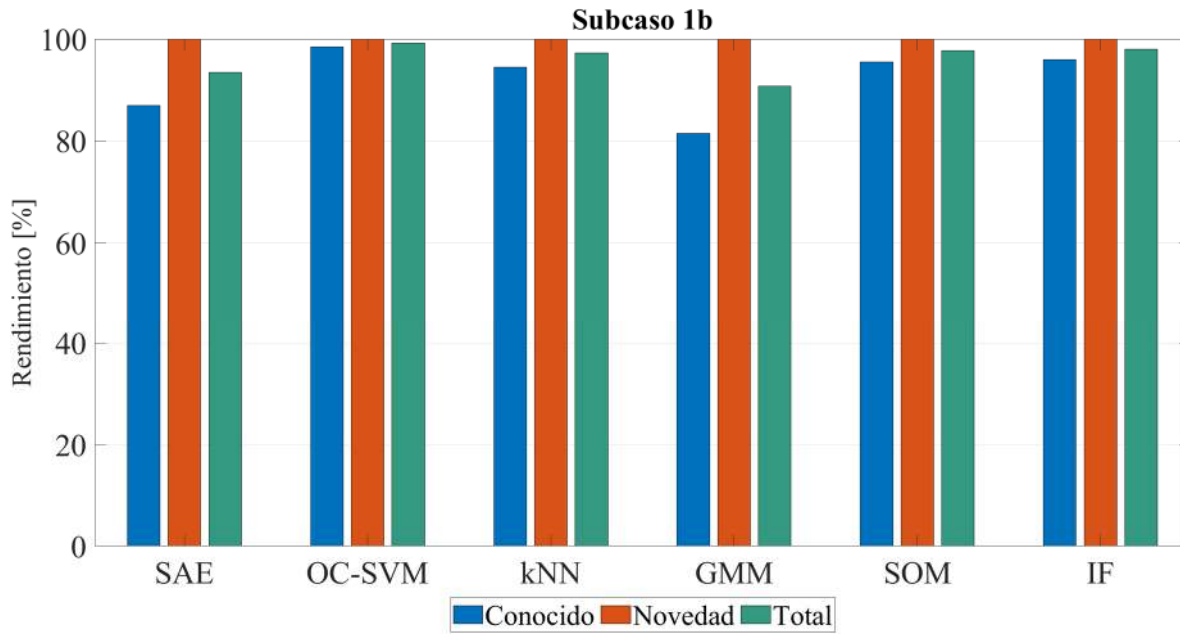


Figura 5.4. Gráfico del rendimiento de las técnicas para el subcaso 1b (Fuente: autoría propia).

Tabla 5.6. Rendimientos de cada técnica para el subcaso 1b.

Técnica / Clase	Conocido	Novedad	Total
Autoencoder apilado	87	100	93.5
Máquina de soporte vectorial de una clase	98.5	100	99.25
k-vecinos cercanos	94.5	100	97.25
Modelos de mezcla gaussianos	81.5	100	90.75
Mapas autoorganizados	95.5	100	97.75
Bosques de aislamiento	96	100	98

Este subcaso resulta similar que el anterior en rendimientos, se mantiene como la superior máquina de soporte vectorial de una clase, no obstante las demás técnicas de igual forma presentan un rendimiento perfecto en detectar nuevos comportamientos respecto al conjunto de conocimiento establecido. Del mismo modo al subcaso anterior el modelo de mezcla gaussiano tiene un rendimiento alrededor del 80% en detectar las condiciones ya conocidas y el autoencoder apilado cerca del 90%, siendo las 2 técnicas con los peores rendimientos.

5.3.3. Subcaso 1c

En el subcaso 1c, el conjunto de conocimiento se amplía, ahora a la condición normal se agrega la condición de disturbio oscilatorio transitorio y la señal a evaluar como novedad será aquella que contenga afectaciones debidas a condiciones meteorológicas. La Figura 5.5 muestra la gráfica del rendimiento para las 6 técnicas consideradas y la Tabla 5.7 resume los resultados obtenidos para este subcaso 1c.




Figura 5.5. Gráfico del rendimiento de las técnicas para el subcaso 1c (Fuente: autoría propia).

Tabla 5.7. Rendimientos de cada técnica para el subcaso 1c.

Técnica / Clase	Conocido	Novedad	Total
Autoencoder apilado	95	100	97.5
Máquina de soporte vectorial de una clase	79.5	100	89.75
k-vecinos cercanos	93.5	95	94.25
Modelos de mezcla gaussianos	66	98.5	82.25
Mapas autoorganizados	99	15	57
Bosques de aislamiento	97.5	86.5	89.5

Respecto a detectar lo conocido, la técnica de modelos de mezcla gaussiano continua presentando un mal rendimiento y en esta ocasión la máquina de soporte vectorial de una clase apenas llega alrededor de un 80%. Sin embargo vemos que para la detección de novedad los mapas autoorganizados caen por completo en su rendimiento llegando apenas a un 15%. Las otras técnicas mantienen un adecuado rendimiento en detectar la novedad quizás

excepto los bosques de aislamiento. Por lo que el autoencoder apilado resulta la mejor al conseguir un rendimiento global cercano al 98% seguida de k-vecinos más cercanos al acercarse a un resultado total de 95%.

5.3.4. Subcaso 1d

En esta experimentación se intercambian las condiciones de fallo respecto al subcaso anterior, ahora lo que se agregara al conjunto de conocimiento es la condición meteorológica y a evaluar como novedad serán las señales con disturbio oscilatorio transitorio. La Figura 5.6 muestra la gráfica del rendimiento para las 6 técnicas consideradas y la

Tabla 5.8 resume los resultados obtenidos para este subcaso.




Figura 5.6. Gráfico del rendimiento de las técnicas para el subcaso 1d (Fuente: autoría propia).

Tabla 5.8. Rendimientos de cada técnica para el subcaso 1d.

Técnica / Clase	Conocido	Novedad	Total
Autoencoder apilado	90.5	100	95.25
Máquina de soporte vectorial de una clase	83.5	100	91.75
k-vecinos cercanos	91.5	100	95.75
Modelos de mezcla gaussianos	77	100	88.5
Mapas autoorganizados	91	69	77.5
Bosques de aislamiento	97	80	88.5

Casi de igual manera que el subcaso anterior se aprecia los modelos de mezcla gaussianos como la máquina de soporte vectorial presentan un rendimiento más limitado, sin embargo esta vez alrededor del 80%. Y en esta experimentación los mapas autoorganizados a pesar de no presentar aun un muy buen rendimiento, el decaimiento es tan pronunciado como en el subcaso anterior, siendo aún la técnica con el peor rendimiento en detectar las novedades con un casi 70%. Entre las mejores técnicas para esta evaluación la diferencia es de medio punto porcentual ahora en esta ocasión presentándose superior k-vecinos más cercano respecto al autoencoder apilado. A pesar de tener un buen rendimiento de detección de la condición establecida como conocida, los bosque de aislamiento presentan un rendimiento regular en detectar la novedad que de manera global hacen caer su rendimiento e igual a los modelos de mezcla gaussianos por debajo del 90 %.

5.3.5. Subcaso 1e

Para el subcaso 1e, el conjunto de conocimiento es de nuevo solo la condición ideal y en esta ocasión se evalúan como novedad las señales de oscilatorio transitorio y de condición meteorológica. La Figura 5.7 muestra la gráfica del rendimiento para las 6 técnicas consideradas y la Tabla 5.9 resume los resultados obtenidos para este subcaso.




Figura 5.7. Gráfico del rendimiento de las técnicas para el subcaso 1e (Fuente: autoría propia).

Tabla 5.9. Rendimientos de cada técnica para el subcaso 1e.

Técnica / Clase	Conocido	Novedad	Total
Autoencoder apilado	87.5	100	93.75
Máquina de soporte vectorial de una clase	99	100	99.5
k-vecinos cercanos	94	100	97
Modelos de mezcla gaussianos	82.5	100	91.25
Mapas autoorganizados	96.5	90	93.25
Bosques de aislamiento	96.5	100	98.25

En este subcaso, se observa que las seis técnicas evaluadas presentan cierto porcentaje de error al detectar la señal ideal como parte del conocimiento, sin embargo en detectar la novedad tienen un rendimiento excelente, la única que presenta un rendimiento del 90% es la de mapas de autoorganización. Máquina de soporte vectorial de una clase se presenta como la mejor técnica, seguida de bosques de aislamiento y k-vecinos más cercano al tener un 97% o superior de rendimiento total. La diferencia en el rendimiento global entre el autoencoder apilado y los mapas autoorganizados es menor de 1%, teniendo un comportamiento más regular en detectar las 2 condiciones los mapas autoorganizados, siendo la diferencia entre ambas condiciones de 6.5% a diferencia del 12.5 que existe entre detectar lo conocido de la novedad con el autoencoder apilado.

5.4. Resultados del estudio en señales de aerogeneración

Para los subcasos de generación eólica de igual manera se presenta brevemente el experimento realizado y se muestran las gráficas y valores de los rendimientos logrados por cada técnica.

5.4.1. Subcaso 2a

Para esta experimentación el conjunto de conocimiento corresponde solo a la condición ideal de la señal, y como prueba para la evaluación de la condición de novedad se evaluaron muestras de señales con el disturbio eléctrico fluctuaciones. La Figura 5.8 muestra la gráfica del rendimiento para las 6 técnicas consideradas y la Tabla 5.10 resume los resultados obtenidos para este subcaso.




Figura 5.8. Gráfico del rendimiento de las técnicas para el subcaso 2a (Fuente: autoría propia).

Tabla 5.10. Rendimientos de cada técnica para el subcaso 2a.

Técnica / Clase	Conocido	Novedad	Total
Autoencoder apilado	87.33	100	93.68
Máquina de soporte vectorial de una clase	98.33	100	99.18
k-vecinos cercanos	93.66	100	96.85
Modelos de mezcla gaussianos	80.68	100	90.33
Mapas autoorganizados	96	75.01	85.5
Bosques de aislamiento	93.66	100	96.84

Específicamente se observa un dominio superior de la técnica de máquina de soporte vectorial de una clase al lograr superar el 99 %. Bosques de aislamiento y k-vecinos cercanos tienen una diferencia mínima en rendimiento de cada condición y por lo tanto de manera global son idénticas. Los mapas de autoorganización presentaron el mínimo rendimiento no logrando alcanzar el 90 %.

5.4.2. Subcaso 2b

Para el subcaso 2b, el conjunto de conocimiento sigue correspondiendo solo a la condición ideal de la señal, y como prueba para la evaluación de la condición de novedad se evaluaron muestras de señales con disturbio caída de voltaje. La Figura 5.9 muestra la gráfica del rendimiento para las 6 técnicas consideradas y la Tabla 5.11 resume los resultados obtenidos para este subcaso.




Figura 5.9. Gráfico del rendimiento de las técnicas para el subcaso 2b (Fuente: autoría propia).

Tabla 5.11. Rendimientos de cada técnica para el subcaso 2b.

Técnica / Clase	Conocido	Novedad	Total
Autoencoder apilado	85.01	100	92.5
Máquina de soporte vectorial de una clase	100	100	100
k-vecinos cercanos	94.33	100	97.18
Modelos de mezcla gaussianos	80.33	100	90.17
Mapas autoorganizados	97.33	76.67	87.01
Bosques de aislamiento	95.33	100	97.68

En esta evaluación la técnica de máquina de soporte vectorial de una clase se mantiene como la mejor al presentar un rendimiento perfecto en cada rubro. Ahora el rendimiento presentado entre bosques de aislamiento y k-vecinos cercanos difiere por medio punto por ciento, teniendo más efectividad en reconocer muestras de condición conocida la técnica de bosques de aislamiento. A pesar de ser la única técnica en fallar al reconocer por completo las condiciones de novedad, los mapas autoorganizados se encuentran ligeramente por debajo de los modelos de mezcla gaussianos que a su vez están casi los mismos puntos por debajo de la técnica de autoencoder. Estos tres alrededor del 90% de rendimiento global.

5.4.3. Subcaso 2c

En este experimento, al conjunto de conocimiento se le agregara la condición de disturbio fluctuaciones, y como evaluación de la novedad solo se consideró el disturbio caída de voltaje. La Figura 5.10 muestra la gráfica del rendimiento para las 6 técnicas consideradas y la Tabla 5.12 resume los resultados obtenidos para este subcaso.




Figura 5.10. Gráfico del rendimiento de las técnicas para el subcaso 2c (Fuente: autoría propia)

Tabla 5.12. Rendimientos de cada técnica para el subcaso 2c.

Técnica / Clase	Conocido	Novedad	Total
Autoencoder apilado	87.34	100	93.66
Máquina de soporte vectorial de una clase	69.675	100	84.825
k-vecinos cercanos	91.67	100	95.83
Modelos de mezcla gaussianos	74.335	98.335	86.335
Mapas autoorganizados	92.645	80.005	86.345
Bosques de aislamiento	94.66	81.67	88.175

Para este subcaso se presenta una variación respecto a lo que se venía presentando en las evaluaciones anteriores. Solo tres técnicas superan el 90% en detectar correctamente muestras de la condición de conocido, k-NN, SOM y IF. Respecto a la novedad la mitad de las técnicas presentaron un rendimiento perfecto, SAE, OC-SVM y k-NN. Concluyendo que la superior fue k-vecinos más cercanos seguida de autoencoder apilado, ambas sobrepasan el 90% en el rendimiento total. Las 4 técnicas restantes se mantienen alrededor de un 85% de

rendimiento global, aunque difieren en el balance de sus rendimientos respecto a las 2 condiciones.

5.4.4. Subcaso 2d

En el subcaso 2d, el conjunto de conocimiento ahora contiene tanto la condición ideal como la del disturbio correspondiente a una caída de voltaje. Para la evaluación de la condición de novedad se evaluaron muestras de señales con disturbio fluctuaciones. La Figura 5.11 muestra la gráfica del rendimiento para las 6 técnicas consideradas y la Tabla 5.13 resume los resultados obtenidos para este subcaso.




Figura 5.11. Gráfico del rendimiento de las técnicas para el subcaso 2d (Fuente: autoría propia).

Tabla 5.13. Rendimientos de cada técnica para el subcaso 2d.

Técnica / Clase	Conocido	Novedad	Total
Autoencoder apilado	88	100	94
Máquina de soporte vectorial de una clase	64.33	100	82.17
k-vecinos cercanos	91	100	95.5
Modelos de mezcla gaussianos	83.66	86.665	85.175
Mapas autoorganizados	94.995	25.335	60.16
Bosques de aislamiento	96.66	47.67	72.17

El comportamiento de las técnicas para la evaluación de este subcaso resulta similar al subcaso anterior. Empezando por la novedad, las tres primeras técnicas resultan en un

rendimiento ideal. De estas tres k-vecinos más cercanos es la que mejor resultados presenta en detectar lo conocido, resultando de igual forma en la mejor técnica para esta evaluación. Sin embargo el autoencoder apilado no difiere tanto, convirtiéndose en la segunda mejor técnica para este subcaso. Es importante destacar el rendimiento respecto a la novedad que presentan las técnicas de bosques de aislamiento y mapas de autoorganización, el primero acercándose a 50% y el segundo enfoque apenas con la cuarta parte de un rendimiento evaluado en 100%. Aun logrando en una detección alrededor del 95% para lo conocido, el hecho de tener tan bajo rendimiento las coloca como las 2 peores técnicas de manera global en esta evaluación.

5.4.5. Subcaso 2e

Para el último subcaso de la experimentación con las señales reales provenientes de una fuente de generación eólica, el conjunto de conocimiento corresponde solo a la condición ideal de la señal, y ahora como prueba para la evaluación de la condición de novedad se evaluaron muestras de señales tanto con disturbio caída de voltaje y con disturbio fluctuaciones.. La Figura 5.12 muestra la gráfica del rendimiento para las 6 técnicas consideradas y la Tabla 5.14 resume los resultados obtenidos para este subcaso.




Figura 5.12. Gráfico del rendimiento de las técnicas para el subcaso 2e (Fuente: autoría propia).

Tabla 5.14. Rendimientos de cada técnica para el subcaso 2e.

Técnica / Clase	Conocido	Novedad	Total
Autoencoder apilado	82.33	100	91.18
Máquina de soporte vectorial de una clase	99.33	100	99.67
k-vecinos cercanos	91.99	100	96.01
Modelos de mezcla gaussianos	80.67	100	90.33
Mapas autoorganizados	92.33	75.34	83.84
Bosques de aislamiento	93.67	100	96.84

En este subcaso se presenta una variación respecto a lo que se venía presentando en las evaluaciones anteriores. Cuatro técnicas superan el 90% en detectar correctamente muestras de la condición de conocido, máquina de soporte vectorial, k-vecinos cercanos, mapas autoorganizados y bosques de aislamiento. Respecto a la novedad, a excepción de los mapas autoorganizados, las técnicas presentan un rendimiento perfecto. Observando el rendimiento global se concluye que la técnica superior es máquina de soporte vectorial de una clase seguida de k-vecinos cercanos y bosques de aislamiento. Debido a su mal desempeño en detectar la novedad, el rendimiento total de los mapas autoorganizados se queda cerca de un 85% de rendimiento global, representando la técnica con más bajo rendimiento.

6. Conclusiones

La detección e identificación de disturbios eléctricos fue llevada a cabo bajo una metodología que involucró la caracterización de la señal eléctrica en diferentes dominios y mediante indicadores estadísticos y no estadísticos que después mediante el aprendizaje profundo se conseguía una caracterización eficiente para su posterior procesamiento y correcta identificación.

La técnica de aprendizaje profundo que se consideró para mejorar la caracterización de la señal eléctrica y su posterior procesamiento fue la red neuronal conocida como autoencoder que consiste en representar la información en una menor dimensión, bajo este principio se conservaba solo la información importante de la caracterización de la señal y de esta manera el proceso de detección y clasificación de disturbios resultó ser eficaz y con un rendimiento superior.

Debido a que las técnicas de aprendizaje profundo permiten la gestión con grandes volúmenes de datos y múltiples patrones, esto dio oportunidad de implementar estas técnicas en calidad de la energía ya que en esta área se pueden identificar distintas condiciones de fallo u operación de las cuales es importante identificar de manera oportuna. La adaptabilidad a distintas variaciones de señales permitió la correcta clasificación de al menos 17 clases, conteniendo disturbios con complejidad resultante a la combinación de 2 e incluso 3 disturbios de manera simultánea.

La implementación de metodologías basadas en aprendizaje profundo para la identificación de disturbios sobre señales reales que no eran propias llevaron a una validación de esta propuesta, en este caso el uso de autoencoder. Si bien es sabido que en el ámbito de la calidad de la energía no existen bases de datos bien definidas para la validación de metodologías para la monitorización, la contemplada resultó de gran utilidad.

Para realizar la detección de novedad se implementaron diversas configuraciones de técnicas para evaluar distintos escenarios donde se consideró que el conjunto del conocimiento y de la novedad iba cambiando. Esto permitió ver la evolución del rendimiento de las técnicas evaluadas y determinar que un ensamble de técnicas resulta en una propuesta adecuada para evaluar conjuntos con diversas clases como lo es en calidad de la energía.

Se realizó la evaluación de distintas técnicas de detección de novedad sobre señales reales de instalaciones de generación de energía eólica y fotovoltaica. La finalidad fue observar el comportamiento de las técnicas ante afectaciones reales de condiciones no antes presentadas o anormales en estos sistemas. Se obtuvo un rendimiento variado entre las técnicas, debido a la naturaleza de los fallos y a las propias ventajas y limitaciones de las técnicas evaluadas.

Se pueden apreciar áreas de oportunidad de investigación como lo es la configuración de las técnicas de aprendizaje profundo y detección de novedad, también en la metodología general de detección e identificación de disturbios eléctricos en la selección eficiente de indicadores que mejor caractericen la señal eléctrica bajo toda su variabilidad y aparición de perturbaciones.

Otro punto pendiente es el aprendizaje incremental, es decir, una vez detectada la novedad o aquellas condiciones que un sistema de monitoreo no conoce, ser capaz de agregarla a su conjunto de conocimiento, esto se presenta como un paso necesario para cualquier sistema basado en inteligencia artificial.

Referencias Bibliográficas

Abbas, M. A. 2018. Improving deep learning performance using random forest HTM cortical learning algorithm. Proc. IWDRL 2018 2018 1st Int. Work. Deep Represent. Learn. 13–18. doi:10.1109/IWDRL.2018.8358209.

Alam, M. R., F. Bai, R. Yan, and T. K. Saha. 2020. Classification and Visualization of Power Quality Disturbance-Events using Space Vector Ellipse in Complex Plane. IEEE Trans. Power Deliv. 8977:1–1. doi:10.1109/TPWRD.2020.3008003. Available from: <https://ieeexplore.ieee.org/document/9136729/>

American National Standards Institute. 2006. ANSI C84.1-2006 American National Standard for Electric Power Systems and Equipment - Voltage Ratings (60 Hertz). Am. Natl. Stand. Inst. 1–24. Available from: http://webstore.ansi.org/RecordDetail.aspx?sku=ANSI+C84.1-2011&sourcekeyword=_inurl%3Awebstore.ansi.org%23inurl%3Asku%3Dansi&source=google&adgroup=ANSI-Standards&gclid=CjwKEAjwt-r27BRCzsNyzrMrM-j0SJACp2TiBBcEHUJI0KrXwKZWrJlPlZ6w5A1K-hALlj3c9iHPnihoCAhnw_we

Bayindir, R., S. Demirbas, E. Irmak, U. Cetinkaya, A. Ova, and M. Yesil. 2016. Effects of renewable energy sources on the power system. Proc. - 2016 IEEE Int. Power Electron. Motion Control Conf. PEMC 2016. 388–393. doi:10.1109/EPEPEMC.2016.7752029.

Bollen, M. H. J., and I. Y.-H. Gu. 2006. Signal Processing of Power Quality Disturbances. John Wiley & Sons, Inc., Hoboken, NJ, USA. Available from: <http://doi.wiley.com/10.1002/0471931314>

Buduma, N., and N. Lacascio. 2017. Fundamentals of Deep Learning. First Edti. (M. Loukides and S. Cutt, editors.). O'REILLY. Available from: <http://arxiv.org/abs/1603.05691>

Cabral, G. G., and A. L. I. De Oliveira. 2017. Novelty Detection Based on Genuine Normal and Artificially Generated Novelty Examples. Proc. - 2016 5th Brazilian Conf. Intell. Syst. BRACIS 2016. 319–324. doi:10.1109/BRACIS.2016.065.

Cardoso, E. S. 2019. Advanced energy management strategies for HVAC systems in smart buildings. Univesitat Politecnica de Catalunya.

Carino, J. A., M. Delgado-Prieto, J. A. Iglesias, A. Sanchis, D. Zurita, M. Millan, J. A. Ortega Redondo, and R. Romero-Troncoso. 2018. Fault Detection and Identification Methodology under an Incremental Learning Framework Applied to Industrial Machinery. *IEEE Access*. 6:49755–49766. doi:10.1109/ACCESS.2018.2868430.

Cortes-Robles, O., E. Barocio, J. Segundo, D. Guillen, and J. C. Olivares-Galvan. 2020. A qualitative-quantitative hybrid approach for power quality disturbance monitoring on microgrid systems. *Measurement*. 154:107453. doi:10.1016/j.measurement.2019.107453. Available from: <https://doi.org/10.1016/j.measurement.2019.107453>

Ding, X., Y. Li, A. Belatreche, and L. P. Maguire. 2014. An experimental evaluation of novelty detection methods. *Neurocomputing*. 135:313–327. doi:10.1016/j.neucom.2013.12.002. Available from: <http://dx.doi.org/10.1016/j.neucom.2013.12.002>

Ding, X., Y. Li, A. Belatreche, and L. P. Maguire. 2015. Novelty detection using level set methods. *IEEE Trans. Neural Networks Learn. Syst.* 26:576–588. doi:10.1109/TNNLS.2014.2320293.

Elvira-Ortiz, D. A., R. A. Osornio-Rios, D. Morinigo-Sotelo, H. Rostro-Gonzalez, and R. J. Romero-Troncoso. 2018. Power quality monitoring system under different environmental and electric conditions. *Proc. Int. Conf. Harmon. Qual. Power, ICHQP*. 2018-May:1–6. doi:10.1109/ICHQP.2018.8378846.

Elvira-Ortiz, D. A., J. J. Saucedo-Dorantes, R. A. Osornio-Rios, D. Morinigo-Sotelo, and J. A. Antonino-Daviu. 2022. Power Quality Monitoring Strategy Based on an Optimized Multi-Domain Feature Selection for the Detection and Classification of Disturbances in Wind Generators. *Electron*. 11. doi:10.3390/electronics11020287.

De Faria, E. R., I. R. Gonçalves, J. Gama, and A. C. P. De Leon Ferreira Carvalho. 2015. Evaluation of Multiclass Novelty Detection Algorithms for Data Streams. *IEEE Trans. Knowl. Data Eng.* 27:2961–2973. doi:10.1109/TKDE.2015.2441713.

Goodfellow, I., Y. Bengio, and A. Courville. 2016. *Deep Learning*. MIT Press. Available from: <http://www.deeplearningbook.org>

Guillén-García, E., L. Morales-Velazquez, A. L. Zorita-Lamadrid, O. Duque-Perez, R. A. Osornio-Rios, and R. de J. Romero-Troncoso. 2019. Identification of the electrical load by C-means from non-intrusive monitoring of electrical signals in non-residential buildings. *Int. J. Electr. Power Energy Syst.* 104:21–28. doi:10.1016/j.ijepes.2018.06.040. Available from: <https://doi.org/10.1016/j.ijepes.2018.06.040>

IEEE Recommended Practice for Monitoring Electric Power Quality. 2019. IEEE Std 1159-2019 (Revision IEEE Std 1159-2009). 1–98. doi:10.1109/IEEESTD.2019.8796486.

Jamali, S., A. R. Farsa, and N. Ghaffarzadeh. 2018. Identification of optimal features for fast and accurate classification of power quality disturbances. *Measurement.* 116:565–574. doi:10.1016/j.measurement.2017.10.034. Available from: <https://linkinghub.elsevier.com/retrieve/pii/S0263224117306589>

Jeevitha, S. R. S., and M. C. Mabel. 2018. Novel optimization parameters of power quality disturbances using novel bio-inspired algorithms: A comparative approach. *Biomed. Signal Process. Control.* 42:253–266. doi:10.1016/j.bspc.2018.02.003. Available from: <https://doi.org/10.1016/j.bspc.2018.02.003>

Jian, X., and X. Wang. 2021. A novel semi-supervised method for classification of power quality disturbance using generative adversarial network. *J. Intell. Fuzzy Syst.* 40:3875–3885. doi:10.3233/JIFS-191274.

Karasu, S., and Z. Saraç. 2020. Classification of power quality disturbances by 2D-Riesz Transform, multi-objective grey wolf optimizer and machine learning methods. *Digit. Signal Process.* 101:102711. doi:10.1016/j.dsp.2020.102711. Available from: <https://linkinghub.elsevier.com/retrieve/pii/S1051200420300567>

Khutlang, R., and F. V. Nelwamondo. 2015. Novelty detection-based internal fingerprint segmentation in optical coherence tomography images. *Proc. - 2014 2nd Int. Symp. Comput. Networking, CANDAR 2014.* 556–559. doi:10.1109/CANDAR.2014.73.

Kumar, P. K. A., V. J. Vijayalakshmi, J. Karpagam, and C. K. Hemapriya. 2016. Classification of power quality events using support vector machine and S-Transform. In: *2016 2nd International Conference on Contemporary Computing and Informatics (IC3I)*. Vol. 7. IEEE. p. 279–284. Available from: <http://ieeexplore.ieee.org/document/7917975/>

- Kumar, R., B. Singh, and D. T. Shahani. 2016. Symmetrical Components-Based Modified Technique for Power-Quality Disturbances Detection and Classification. *IEEE Trans. Ind. Appl.* 52:3443–3450. doi:10.1109/TIA.2016.2536665.
- Lee, M., S. Shin, S. Hong, and S. Song. 2017. BAIPAS: Distributed Deep Learning Platform with Data Locality and Shuffling. *Int. J. Educ. Inf. Technol.* 11:190–195. doi:10.1109/EECS.2017.10.
- Li, J., Z. Teng, Q. Tang, and J. Song. 2016. Detection and Classification of Power Quality Disturbances Using Double Resolution S-Transform and DAG-SVMs. *IEEE Trans. Instrum. Meas.* 65:2302–2312. doi:10.1109/TIM.2016.2578518.
- Li, P., J. Gao, D. Xu, C. Wang, and X. Yang. 2016. Hilbert-Huang transform with adaptive waveform matching extension and its application in power quality disturbance detection for microgrid. *J. Mod. Power Syst. Clean Energy.* 4:19–27. doi:10.1007/s40565-016-0188-5. Available from: <http://link.springer.com/10.1007/s40565-016-0188-5>
- Liu, H., F. Hussain, Y. Shen, S. Arif, A. Nazir, and M. Abubakar. 2018. Complex power quality disturbances classification via curvelet transform and deep learning. *Electr. Power Syst. Res.* 163:1–9. doi:10.1016/j.epsr.2018.05.018. Available from: <https://doi.org/10.1016/j.epsr.2018.05.018>
- Liu, H., F. Hussain, S. Yue, O. Yildirim, and S. J. Yawar. 2019. Classification of multiple power quality events via compressed deep learning. *Int. Trans. Electr. Energy Syst.* 29:1–14. doi:10.1002/2050-7038.12010. Available from: <https://onlinelibrary.wiley.com/doi/abs/10.1002/2050-7038.12010>
- Mahela, O. P., and A. G. Shaik. 2017. Recognition of power quality disturbances using S-transform based ruled decision tree and fuzzy C-means clustering classifiers. *Appl. Soft Comput.* 59:243–257. doi:10.1016/j.asoc.2017.05.061. Available from: <http://dx.doi.org/10.1016/j.asoc.2017.05.061>
- Manikandan, M. S., and S. R. Samantaray. 2015. Detection and classification of power quality disturbances using signal Sparse Signal Decomposition on Hybrid Dictionaries. *IEEE Trans. Instrum. Meas.* 64:27–38. doi:10.1109/APPEEC.2017.8308934.

- Markou, M., and S. Singh. 2003. Novelty detection: A review - Part 1: Statistical approaches. *Signal Processing*. 83:2481–2497. doi:10.1016/j.sigpro.2003.07.018.
- Mendes, T. M., D. D. Ferreira, and C. A. Duque. 2016. Multidimensional monitoring for power quality disturbance detection. *Proc. Int. Conf. Harmon. Qual. Power, ICHQP*. 2016-Decem:142–145. doi:10.1109/ICHQP.2016.7783450.
- Miljković, D. 2016. Review of Novelty Detection Methods.
- Minh Khoa, N., and L. Van Dai. 2020. Detection and Classification of Power Quality Disturbances in Power System Using Modified-Combination between the Stockwell Transform and Decision Tree Methods. *Energies*. 13:3623. doi:10.3390/en13143623. Available from: <https://www.mdpi.com/1996-1073/13/14/3623>
- Mishra, M. 2019. Power quality disturbance detection and classification using signal processing and soft computing techniques: A comprehensive review. *Int. Trans. Electr. Energy Syst.* 29. doi:10.1002/2050-7038.12008. Available from: <https://onlinelibrary.wiley.com/doi/abs/10.1002/2050-7038.12008>
- Nassif, A. B., M. A. Talib, Q. Nasir, and F. M. Dakalbab. 2021. Machine Learning for Anomaly Detection: A Systematic Review. *IEEE Access*. 9:78658–78700. doi:10.1109/ACCESS.2021.3083060. Available from: <https://ieeexplore.ieee.org/document/9439459/>
- Oliveira, R. A. de, and M. H. J. Bollen. 2023. Deep learning for power quality. *Electr. Power Syst. Res.* 214:108887. doi:10.1016/j.epsr.2022.108887. Available from: <https://doi.org/10.1016/j.epsr.2022.108887>
- Park, S. W., J. Park, K. Bong, D. Shin, J. Lee, S. Choi, and H. J. Yoo. 2016. An Energy-Efficient and Scalable Deep Learning/Inference Processor With Tetra-Parallel MIMD Architecture for Big Data Applications. *IEEE Trans. Biomed. Circuits Syst.* 9:838–848. doi:10.1109/TBCAS.2015.2504563.
- Pimentel, M. A. F., D. A. Clifton, L. Clifton, and L. Tarassenko. 2014. A review of novelty detection. *Signal Processing*. 99:215–249. doi:10.1016/j.sigpro.2013.12.026. Available from: <http://dx.doi.org/10.1016/j.sigpro.2013.12.026>

Rodriguez-Guerrero, M. A., A. Y. Jaen Cuellar, R. D. Carranza-Lopez-Padilla, R. A. Osornio-Rios, G. Herrera-Ruiz, and R. de J. Romero-Troncoso. 2018. Hybrid Approach Based on GA and PSO for Parameter Estimation of a Full Power Quality Disturbance Parameterized Model. *IEEE Trans. Ind. Informatics*. 14:1016–1028. doi:10.1007/s10704-006-8379-0.

Sankaran, C. 2002. *Power Quality*. CRC Press.

Sayyed, S., and R. Deolekar. 2017. A Conceptual Paper on Novelty Detection for Temporal Data using Level Set Methods. *Int. Conf. Electron. Comun. Aerosp. Technol.* 284–288.

Sekar, K., K. Kanagarathinam, S. Subramanian, E. Venugopal, and C. Udayakumar. 2022. An Improved Power Quality Disturbance Detection Using Deep Learning Approach. *Math. Probl. Eng.* 2022. doi:10.1155/2022/7020979.

Shen, Y., M. Abubakar, H. Liu, and F. Hussain. 2019. Power Quality Disturbance Monitoring and Classification Based on Improved PCA and Convolution Neural Network for Wind-Grid Distribution Systems. *Energies*. 12:1280. doi:10.3390/en12071280. Available from: <https://www.mdpi.com/1996-1073/12/7/1280>

Singh, B., A. Chandra, and K. Al-Haddad. 2015. *Power Quality: Problems and Mitigation Techniques*. 1st ed. Wiley. Available from: <http://ieeexplore.ieee.org/document/7128811/>

Soares, A., V. Santos, C. Toledo, F. Osorio, and A. Delbem. 2016. Novelty Detection Based on NCD for Navigation Control of Mobile Robots. *Proc. - 12th LARS Lat. Am. Robot. Symp. 3rd SBR Brazilian Robot. Symp. LARS-SBR 2015 - Part Robot. Conf. 2015*. 246–252. doi:10.1109/LARS-SBR.2015.48.

Thirumala, K., S. Pal, T. Jain, and A. C. Umarikar. 2019. A classification method for multiple power quality disturbances using EWT based adaptive filtering and multiclass SVM. *Neurocomputing*. 334:265–274. doi:10.1016/j.neucom.2019.01.038. Available from: <https://doi.org/10.1016/j.neucom.2019.01.038>

Thirumala, K., M. S. Prasad, T. Jain, and A. C. Umarikar. 2018. Tunable-Q Wavelet Transform and Dual Multiclass SVM for Online Automatic Detection of Power Quality Disturbances. *IEEE Trans. Smart Grid*. 9:3018–3028. doi:10.1109/TSG.2016.2624313.

Available from: <https://ieeexplore.ieee.org/document/7731206/>

Valtierra-Rodriguez, M., R. De Jesus Romero-Troncoso, R. A. Osornio-Rios, and A. Garcia-Perez. 2014. Detection and classification of single and combined power quality disturbances using neural networks. *IEEE Trans. Ind. Electron.* 61:2473–2482. doi:10.1109/TIE.2013.2272276.

Wang, J., and D. Pei. 2018. Kernel-based deep learning for intelligent data analysis. 1st Int. Conf. Electron. Instrum. Inf. Syst. EIIS 2017. 2018-Janua:1–5. doi:10.1109/EIIS.2017.8298716.

Wang, S., and H. Chen. 2019. A novel deep learning method for the classification of power quality disturbances using deep convolutional neural network. *Appl. Energy.* 235:1126–1140. doi:10.1016/j.apenergy.2018.09.160. Available from: <https://doi.org/10.1016/j.apenergy.2018.09.160>

Wu, J., Y. Yu, C. Huang, and K. Yu. 2015. Deep Multiple Instance Learning for Image Classification and Auto-Annotation. 3460–3469. doi:10.1109/CVPR.2015.7298968. Available from: https://jiajunwu.com/papers/dmil_cvpr.pdf

Yuan, Y., L. Mou, and X. Lu. 2015. Scene Recognition by Manifold Regularized Deep Learning Architecture. *IEEE Trans. Neural Networks Learn. Syst.* 26:2222–2233. doi:10.1109/TNNLS.2014.2359471.

Zhu, R., X. Gong, S. Hu, and Y. Wang. 2019. Power Quality Disturbances Classification via Fully-Convolutional Siamese Network and k-Nearest Neighbor. *Energies.* 12:4732. doi:10.3390/en12244732. Available from: <https://www.mdpi.com/1996-1073/12/24/4732>

Apéndice

Publicaciones: Contribuciones de tesis

- Artículos de congreso como primer autor
 - ETFA 2019 - Condition monitoring approach based on dimensionality reduction techniques for detecting power quality disturbances in cogeneration systems
 - ICREPQ 2020 - Power Quality Monitoring and Disturbances Classification based on Autoencoder and Neural Network for Electrical Power Supply
 - ETFA 2020 - Deep Learning based Condition Monitoring approach applied to Power Quality
 - ICREPQ 2021 - Novelty Detection on Power Quality Disturbances Monitoring
- Artículos de revista primer autor
 - Energies 2021 - A Novel Deep Learning-Based Diagnosis Method Applied to Power Quality Disturbances



Article

A Novel Deep Learning-Based Diagnosis Method Applied to Power Quality Disturbances

Artvin-Darien Gonzalez-Abreu ¹, Miguel Delgado-Prieto ², Roque-Alfredo Osornio-Rios ^{1,*}, Juan-Jose Saucedo-Dorantes ¹ and Rene-de-Jesus Romero-Troncoso ¹

¹ HSPdigital CA-Mecatronica, Engineering Faculty, Autonomous University of Queretaro, San Juan del Rio 76807, Queretaro, Mexico; agonzalez63@alumnos.uaq.mx (A.-D.G.-A.); jsaucedo@hspdigital.org (J.-J.S.-D.); troncoso@hspdigital.org (R.-d.-J.R.-T.)

² MCLIA Research Center, Department of Electronic Engineering, Technical University of Catalonia (UPC), 08034 Barcelona, Spain; miguel.delgado@mcia.upc.edu

* Correspondence: raosornio@hspdigital.org

Abstract: Monitoring electrical power quality has become a priority in the industrial sector background: avoiding unwanted effects that affect the whole performance at industrial facilities is an aim. The lack of commercial equipment capable of detecting them is a proven fact. Studies and research related to these types of grid behaviors are still a subject for which contributions are required. Although research has been conducted for disturbance detection, most methodologies consider only a few standardized disturbance combinations. This paper proposes an innovative deep learning-based diagnosis method to be applied on power quality disturbances, and it is based on three stages. Firstly, a domain fusion approach is considered in a feature extraction stage to characterize the electrical power grid. Secondly, an adaptive pattern characterization is carried out by considering a stacked autoencoder. Finally, a neural network structure is applied to identify disturbances. The proposed approach relies on the training and validation of the diagnosis system with synthetic data: single, double and triple disturbances combinations and different noise levels, also validated with available experimental measurements provided by IEEE 1159.2 Working Group. The proposed method achieves nearly a 100% hit rate allowing a far more practical application due to its capability of pattern characterization.

Keywords: autoencoder; deep learning; power quality disturbances; power quality monitoring



Citation: Gonzalez-Abreu, A.-D.; Delgado-Prieto, M.; Osornio-Rios, R.-A.; Saucedo-Dorantes, J.-J.; Romero-Troncoso, R.-d.-J. A Novel Deep Learning-Based Diagnosis Method Applied to Power Quality Disturbances. *Energies* **2021**, *14*, 2839. <https://doi.org/10.3390/en14102839>

Academic Editors: Ahmed Abu-Siada and Andrea Mariscotti

- Energies 2022 - Advances in Power Quality Analysis Techniques for Electrical Machines and Drives: A Review

Review

Advances in Power Quality Analysis Techniques for Electrical Machines and Drives: A Review

Artvin-Darien Gonzalez-Abreu ¹, Roque-Alfredo Osornio-Rios ¹, Arturo-Yosimar Jaen-Cuellar ¹, Miguel Delgado-Prieto², Jose-Alfonso Antonino-Daviu ³, and Athanasios Karlis ^{4,*}

¹ HSPdigital CA-Mecatronica, Engineering Faculty, Autonomous University of Queretaro, San Juan del Rio 76807, Queretaro, Mexico; agonzalez63@alumnos.uaq.mx (A.-D.G.-A.); raosornio@hspdigital.org (R.-A.O.-R.); ayjaen@hspdigital.org (A.-Y.J.-C.)

² MCIA Research Center Department of Electronic Engineering, Technical University of Catalonia (UPC), Barcelona, Spain; miguel.delgado@mcia.upc.edu (M.D.-P.)

³ Instituto Tecnológico de la Energía, Universitat Politècnica de València (UPV), Camino de Vera s/n, 46022 Valencia, Spain; joanda@die.upv.org (J.-A.A.-D.)

⁴ Department of Electrical & Computer Engineering, Democritus University of Thrace, Greece; akarlis@ee.duth.gr (A.K)

* Correspondence: akarlis@ee.duth.gr

Abstract: The electric machines are the elements most used at industry and represent the major power consumption of the productive processes. Particularly speaking, among all the electric machines the motor and drives play a key role since they literally allow the motion interchange in the industrial processes, it could be said that they are the medullar column for moving the rest of the mechanical parts. Hence their proper operation must be guaranteed in order to rise as much as possible their efficiency, which brings out as consequence economic benefits. This review presents a general overview of the reported works that address the efficiency topic in motors and drives and in the power quality of the electric grid. This work addresses the relation existing between the motors and drives that induce electric disturbances into the grid affecting its power quality, but also, these power disturbances present in the electrical network adversely affect, in turn, to the induction motors and their drives. In addition, the reported techniques that tackle the power quality disturbances detection, classification, and mitigations are discussed. Also, several works are reviewed in order to present the panorama that show the evolution and advances of the techniques and tendencies in both senses: motors and drives affecting the power source quality and the power quality disturbances affecting the efficiency of motors and drives. Finally, a discussion of trends in techniques and future work about power quality analysis from the motors and drives efficiency viewpoint is provided.

Keywords: Electrical drives, electrical machines, energy efficiency, energy-saving, induction motor, power quality

Citation: Lastname, F.; Lastname, F.; Lastname, F. Title. *Energies* **2021**, *14*, x. <https://doi.org/10.3390/xxxxx>

Academic Editor: Firstname Lastname

Received: date




Accepted: date

Published: date

- Sensors 2023 - Power Disturbance Monitoring through Techniques for Novelty Detection on Wind Power and Photovoltaic Generation

Article

Power Disturbance Monitoring through Techniques for Novelty Detection on Wind Power and Photovoltaic Generation

Artvin Darien Gonzalez-Abreu ¹, Roque Alfredo Osornio-Rios ^{1,*}, David Alejandro Elvira-Ortiz ¹, Arturo Yosimar Jaen-Cuellar ¹, Miguel Delgado-Prieto ² and Jose Alfonso Antonino-Daviu ³

¹ CA Mecatrónica, Facultad de Ingeniería, Universidad Autónoma de Querétaro, Av. Río Moctezuma 249, Querétaro 76807, Mexico

² MCI Research Center Department of Electronic Engineering, Technical University of Catalonia (UPC), 08034 Barcelona, Spain

³ Instituto Tecnológico de la Energía, Universitat Politècnica de València (UPV), Camino de Vera s/n, 46022 Valencia, Spain

* Correspondence: raosornio@hspdigital.org

Abstract: Novelty detection is a statistical method that verifies new or unknown data, determines whether these data are inliers (within the norm) or outliers (outside the norm), and can be used, for example, in developing classification strategies in machine learning systems for industrial applications. To this end, two types of energy that have evolved over time are solar photovoltaic and wind power generation. Some organizations around the world have developed energy quality standards to avoid known electric disturbances; however, their detection is still a challenge. In this work, several techniques for novelty detection are implemented to detect different electric anomalies (disturbances), which are k-nearest neighbors, Gaussian mixture models, one-class support vector machines, self-organizing maps, stacked autoencoders, and isolation forests. These techniques are applied to signals from real power quality environments of renewable energy systems such as solar photovoltaic and wind power generation. The power disturbances that will be analyzed are considered in the standard IEEE-1159, such as sag, oscillatory transient, flicker, and a condition outside the standard attributed to meteorological conditions. The contribution of the work consists of the development of a methodology based on six techniques for novelty detection of power disturbances, under known and unknown conditions, over real signals in the power quality assessment. The merit of the methodology is a set of techniques that allow to obtain the best performance of each one under different conditions, which constitutes an important contribution to the renewable energy systems.

Keywords: novelty detection; machine learning; power quality disturbance; wind generation; photovoltaic generation



Citation: Gonzalez-Abreu, A.D.; Osornio-Rios, R.A.; Elvira-Ortiz, D.A.; Jaen-Cuellar, A.Y.; Delgado-Prieto, M.; Antonino-Daviu, J.A. Power Disturbance Monitoring through Techniques for Novelty Detection on Wind Power and Photovoltaic Generation. *Sensors* **2023**, *23*, 2908. <https://doi.org/10.3390/s23062908>

Academic Editors:
Enrique Domínguez and Rafael M. Luque-Baena

Publicaciones: Colaboraciones y otros trabajos

- Artículos de colaboración (coautor)
 - ETFA 2020 - Analysis of Machine Learning based Condition Monitoring Schemes Applied to Complex Electromechanical Systems
 - ICREPQ 2021 - Uncertainty analysis for industries investing in energy equipment and renewable energy sources
 - Sensors 2021 - Deep-Compact-Clustering Based Anomaly Detection Applied to Electromechanical Industrial Systems

- Ponente en la Semana de la ciencia (Divulgación)

