



Universidad Autónoma de Querétaro

Facultad de Ingeniería

Doctorado en ingeniería

**Sistema colaborativo de clasificación y análisis de múltiples perturbaciones eléctricas
en una micro red con un sistema neuronal de aprendizaje profundo.**

TESIS

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

Presenta:

M.C. Alma Eliza Guerrero Sánchez

Dirigido por:

Dr. Edgar Alejandro Rivas Araiza

Centro Universitario

Querétaro, QRO

México.

Enero 2024

La presente obra está bajo la licencia:
<https://creativecommons.org/licenses/by-nc-nd/4.0/deed.es>



CC BY-NC-ND 4.0 DEED

Atribución-NoComercial-SinDerivadas 4.0 Internacional

Usted es libre de:

Compartir — copiar y redistribuir el material en cualquier medio o formato

La licenciante no puede revocar estas libertades en tanto usted siga los términos de la licencia

Bajo los siguientes términos:



Atribución — Usted debe dar [crédito de manera adecuada](#), brindar un enlace a la licencia, e [indicar si se han realizado cambios](#). Puede hacerlo en cualquier forma razonable, pero no de forma tal que sugiera que usted o su uso tienen el apoyo de la licenciante.



NoComercial — Usted no puede hacer uso del material con [propósitos comerciales](#).



SinDerivadas — Si [remezcla, transforma o crea a partir](#) del material, no podrá distribuir el material modificado.

No hay restricciones adicionales — No puede aplicar términos legales ni [medidas tecnológicas](#) que restrinjan legalmente a otras a hacer cualquier uso permitido por la licencia.

Avisos:

No tiene que cumplir con la licencia para elementos del material en el dominio público o cuando su uso esté permitido por una [excepción o limitación](#) aplicable.

No se dan garantías. La licencia podría no darle todos los permisos que necesita para el uso que tenga previsto. Por ejemplo, otros derechos como [publicidad, privacidad, o derechos morales](#) pueden limitar la forma en que utilice el material.



Universidad Autónoma de Querétaro

Facultad de Ingeniería

Doctorado en Ingeniería

Sistema colaborativo de clasificación y análisis de múltiples perturbaciones eléctricas en una micro red con un sistema neuronal de aprendizaje profundo.

TESIS

Que como parte de los requisitos para obtener el grado de
Doctorado en Ingeniería

Presenta:

M.C. Alma Eliza Guerrero Sánchez

Dirigido por:

Dr. Edgar Alejandro Rivas Araiza

SINODALES

Dr. Edgar Alejandro Rivas Araiza
Presidente

Firma

Dr. Juvenal Rodríguez Reséndiz
Secretario

Firma

Dr. Saúl Tovar Arriaga
Vocal

Firma

Dr. Mariano Garduño Aparicio
Suplente

Firma

Dr. Manuel Toledano Ayala
Suplente

Firma

Dr. Manuel Toledano Ayala
Director de la Facultad

Dra. Ma. Guadalupe Flavia Loarca Piña
Director de Investigación y Postgrado

Centro Universitario
Querétaro, QRO
México.
Enero 2024

© 2024 - M.C. Alma Eliza Guerrero Sánchez

All rights reserved.

Everybody want to know what i would do if i didn't win.

I guess we'll never know.

Kanye West

Acknowledgments

A CONAHCYT y a la Universidad Autónoma de Querétaro por el apoyo otorgado para realizar estos estudios. Así como al departamento de posgrado de la facultad de ingeniería.

A los Doctores Rivas Araiza, Doctor José Luis González Cordoba, Juvenal Rodríguez, Garduño Aparicio, Saúl Tovar e Irineo Torres Pacheco. Así como a cada uno de mis maestros Doctores de la maestría y del doctorado

A mi mamá y mis hermanos, por apoyarme en mi proyectos desde el día cero por darme fortaleza, valor y por escucharme. A mi mamá que gracias a ella soy la persona en la que me forjado. A mi madrina Beatriz por enseñarme Algebra, la piedra angular de la ingeniería.

A mis compañeros de maestría en instrumentación y control y del doctorado en ingeniería.

A pinwis, molly, Scamp, hachi, luna, michu y kiara por ser pequeños angelitos en mi vida.

Al amor de mi universo por apoyarme, escucharme y llegar a mi vida en el momento preciso, por ser la compañera de vida que siempre le pedí a Dios.

A Dios y a la virgen por todas las bendiciones dadas en mi camino.

Abstract

The present thesis focuses on developing an approach based on deep neural networks to classify and analyze various electrical disturbances in power systems. In the context of electrical systems, disturbances are abnormal or transient events that can affect the flow of energy and cause problems in the quality of the energy supplied. Identifying and classifying these disturbances accurately and efficiently ensures reliable and safe system operation. The study begins with a comprehensive review of existing electrical disturbance classification techniques, highlighting their advantages and limitations. It is highlighted that deep neural networks, a branch of machine learning, have shown great potential in classifying complex and non-linear data. A deep neural network architecture specifically adapted for classifying electrical disturbances is proposed in the following. Different types of neural layers, such as convolutional and recurrent, are used to capture relevant features of disturbances in the input data. The data set used for model training and evaluation comprises multiple electrical disturbance records obtained from actual measurements of power systems. Data augmentation and preprocessing techniques are applied to improve the robustness and generalization of the model. Once the deep neural network is trained, a comprehensive evaluation of its performance in terms of classification accuracy, sensitivity, and specificity is performed. The results are compared with other existing classification techniques to demonstrate the efficacy and superiority of the proposed approach. In addition to the classification, a detailed analysis of the identified electrical disturbances is carried out. Model interpretation and data visualization techniques are explored to understand better the underlying factors contributing to each type of disturbance. In summary, this thesis presents an approach based on deep neural networks for classifying and analyzing multiple electrical disturbances in power systems. The results demonstrate this approach's effectiveness in terms of classification accuracy and analysis capacity. The study contributes to monitoring and diagnosing electrical systems, providing a powerful tool to identify and understand electrical disturbances and take appropriate corrective actions to maintain the quality and reliability of electrical supply.

Resumen

La tesis presente se centra en el desarrollo de un enfoque basado en redes neuronales profundas para la clasificación y análisis de diversas perturbaciones eléctricas en sistemas de energía. En el contexto de los sistemas eléctricos, las perturbaciones son eventos anormales o transitorios que pueden afectar el flujo de energía y causar problemas en la calidad de la energía suministrada. Identificar y clasificar estas perturbaciones de manera precisa y eficiente es esencial para garantizar el funcionamiento confiable y seguro del sistema. El estudio comienza con una revisión exhaustiva de las técnicas de clasificación de perturbaciones eléctricas existentes, destacando sus ventajas y limitaciones. Se destaca que las redes neuronales profundas, una rama del aprendizaje automático, han demostrado un gran potencial en la clasificación de datos complejos y no lineales. A continuación, se propone una arquitectura de red neuronal profunda adaptada específicamente para la clasificación de perturbaciones eléctricas. Se utilizan diferentes tipos de capas neuronales, como convolucionales y recurrentes, para capturar las características relevantes de las perturbaciones en los datos de entrada. El conjunto de datos utilizado para el entrenamiento y evaluación del modelo se compone de múltiples registros de perturbaciones eléctricas obtenidos de mediciones reales en sistemas de energía. Se aplican técnicas de preprocesamiento y aumento de datos para mejorar la robustez y generalización del modelo. Una vez que la red neuronal profunda está entrenada, se realiza una evaluación exhaustiva de su rendimiento en términos de precisión de clasificación, sensibilidad y especificidad. Se comparan los resultados con otras técnicas de clasificación existentes para demostrar la eficacia y superioridad del enfoque propuesto. Además de la clasificación, se lleva a cabo un análisis detallado de las perturbaciones eléctricas identificadas. Se exploran técnicas de interpretación de modelos y visualización de datos para comprender mejor los factores subyacentes que contribuyen a cada tipo de perturbación. En resumen, esta tesis presenta un enfoque basado en redes neuronales profundas para la clasificación y análisis de múltiples perturbaciones eléctricas en sistemas de energía. Los resultados obtenidos demuestran la efectividad de este enfoque en términos de precisión de clasificación y capacidad de análisis. El estudio contribuye al campo de la monitorización y diagnóstico de sistemas eléctricos, brindando una herramienta poderosa para identificar y comprender las perturbaciones eléctricas y tomar acciones correctivas adecuadas para mantener la calidad y confiabilidad del suministro eléctrico.

Palabras clave: Inteligencia artificial, clasificación, redes neuronales profundas,

Contents

Acknowledgments	i
Abstract	iii
Resumen	v
Contents	vii
List of Figures	ix
List of Tables	xi
1 Introducción	1
1.1 Antecedentes	1
1.2 Justificación	3
1.3 Planteamiento del Problema	6
1.4 Hipótesis y objetivos	9
1.4.1 Hipótesis	9
1.4.2 Objetivo general	9
1.4.3 Objetivo particulares	9
1.5 Estructura de la tesis	10
2 Estado del arte	11
2.1 La evolución de las microrredes eléctricas	11
2.2 Inteligencia artificial en las Microrredes Smart Grids	13
2.3 Inteligencia artificial en la clasificación de las perturbaciones eléctricas	16
3 Fundamentación Teórica	19
3.1 Descripción de las perturbaciones que afectan la CEE en las MRE	19
3.2 Descomposición de modo empírico.	23
3.3 Redes Neuronales Artificiales Profundas.	24
3.3.1 Arquitectura de las Redes neuronales Artificial Profundas	25
3.4 Métricas de evaluación.	29

4	Metodología	33
4.1	Metodología de desarrollo general	33
4.2	Generador de múltiples perturbaciones eléctricas	35
4.3	Algoritmo de detección de perturbaciones	37
4.4	Diseño y desarrollo de Red Neuronal Profunda	38
4.4.1	Base de datos no relacional.	38
4.4.2	Diseño y desarrollo de Red Neuronal Profunda.	39
4.5	Banco de pruebas	41
5	Resultados	47
5.1	Análisis de características de múltiples perturbaciones eléctricas.	47
5.2	Desarrollo de Red neuronal Profunda.	50
5.3	Desempeño en banco de pruebas.	50
5.3.1	Desempeño con red neuronal profunda	50
5.3.2	Desempeño en tiempo real con aprendizaje automático	53
5.4	Discusiones	53
6	Conclusión	67
	References	71
	Appendix A Modelos matemáticos de múltiples perturbaciones eléctricas	73
	Appendix B Acreditación Inglés	77
	Appendix C Primer Artículo Publicado	79
	Appendix D Registro de software	81
	Appendix E Segundo Artículo Publicado	83

List of Figures

1.1	Estructura Tradicional de una Microrred Eléctrica.	2
1.2	Modos de operación: a) Microrred eléctrica en modo red b) Microrred eléctrica en modo isla	3
1.3	Modelo de generación eléctrica basado en Hidrocarburos.	4
1.4	Sistemas de monitoreo tradicional en microrredes eléctricas.	7
1.5	Propuesta colaborativa de monitoreo con estrategias de inteligencia artificial	8
2.1	Evolución del concepto de microrred eléctrica a microrred eléctrica inteligente.	12
2.2	Áreas principales de las microrredes eléctricas inteligentes.	13
2.3	Aportaciones de inteligencia artificial en los últimos años.	14
2.4	Áreas de aplicación de inteligencia artificial en las microrredes eléctricas inteligentes.	15
2.5	Perturbaciones eléctricas	18
3.1	Diferencias entre Deep learning y Machine learning.	25
3.2	Neurona: Unidad básica de RNA.	25
3.3	Arquitectura básica de una Red Neuronal Artificial.	27
3.4	Diferencias entre redes neuronales tradicionales y multitareas.	29
3.5	Matriz de confusión	30
4.1	Metodología de desarrollo general.	33
4.2	Menú principal del generador de perturbaciones.	36
4.3	Menú principal del generador de perturbaciones.	37
4.4	Vista secundaria de síntesis de perturbaciones eléctricas.	38
4.5	Validación cruda K-Fold.	40
4.6	Validación cruda K-Fold.	41
5.1	Extracción de características con EMD en perturbación en amplitud tipo sag: a) perturbación sin ruido. b) Perturbación con ruido	48
5.2	Extracción de características con EMD en perturbación en amplitud transitorio oscilatorio: a) perturbación sin ruido. b) Perturbación con ruido	49
5.3	Extracción de características con EMD en perturbación en amplitud transitorio oscilatorio: a) perturbación sin ruido. b) Perturbación con ruido	57
5.4	Extracción de características con EMD en perturbación tipo espiga: a) perturbación sin ruido. b) Perturbación con ruido	58

5.5	Extracción de características con EMD en perturbación muesca o notch: a) perturbación sin ruido. b) Perturbación con ruido	59
5.6	Extracción de características con EMD en perturbación flicker o parpadeo: a) perturbación sin ruido. b) Perturbación con ruido	60
5.7	Arquitectura de red neuronal multitareas	61
5.8	curvas de entrenamiento del modelo para la tarea de clasificación.. . . .	62
5.9	curvas de entrenamiento del modelo para la tarea de predicción de datos o análisis..	62
5.10	Iteraciones de entrenamiento utilizando validación cruzada.	63
5.11	matriz de confusión en red neuronal - Parte 1.	63
5.12	matriz de confusión en red neuronal - Parte 1.	64
5.13	Análisis con factor cresta.	64
5.14	Análisis en voltaje por unidad (p.u).	65
5.15	Matriz de confusión parte 1- Máquina de soporte vectorial.	65
5.16	Matriz de confusión parte 2- Máquina de soporte vectorial.	66
B.1	Acreditación de inglés	77
C.1	Primer articulo Publicado	79
D.1	Registro de software.	81
E.1	Segundo articulo Publicado.	83

List of Tables

3.1	Características de perturbaciones eléctricas	20
3.2	Modelos Matemáticos.	21
3.3	Perturbaciones eléctricas: Origen y Consecuencias.	22
3.4	Métricas de evaluación.	30
5.1	Descripción de capas en red neuronal profunda.	51
5.2	Hiperparámetros en red neuronal profunda.	52
5.3	Tabla comparativa de metodologías de extracción de características de señales.	55
5.4	Tabla comparativa de metodologías de extracción de características de señales.	56

Introducción

1.1 Antecedentes

Hoy en día, con la introducción del concepto de industria 4.0, los requerimientos para los sistemas de producción, transmisión y distribución de la energía eléctrica han cambiado enormemente. Estos cambios representan un importante acontecimiento en la evolución de los nuevos conceptos y metodologías orientadas a la planeación y operación de los sistemas de energía eléctrica [1]. En los últimos años, los trabajos de investigación sobre la generación y distribución de la energía eléctrica se han enfocado en la micro generación eléctrica distribuida, la cual habilita la integración de diferentes fuentes de energía renovables en la red eléctrica en forma de generadores eléctricos distribuidos [2]. Sin embargo, la integración de estos dispositivos, junto con un aumento en la demanda de la calidad de la energía eléctrica (CEE) ha motivado el desarrollo de las Microrredes Eléctricas Inteligentes [3]. Una Microrred Eléctrica (MRE) es un sistema autónomo de distribución de energía eléctrica que contiene cargas y recursos energéticos distribuidos, los cuales se pueden operar de forma controlada y coordinada [4]. Estas MRE contienen diferentes tipos de generadores de energía eléctrica distribuida tales como: paneles solares, aerogeneradores, generadores de combustible sólido, unidades de almacenamiento de energía, así como diferentes cargas y dispositivos de control, que permiten la gestión de la energía eléctrica en la MRE . Así mismo, una MRE Inteligente o Micro Smart Grid, puede definirse como una MRE que utiliza tecnologías avanzadas de información, comunicación y procesamiento de datos para monitorear y controlar la generación y transmisión de la energía eléctrica distribuida de una manera más eficiente, flexible, sostenible y segura [5]. Un ejemplo de una MRE se puede observar en la figura 1.1 .

En esta microrred se pueden ver diferentes tipos de generadores de energía renovables conectados a una red de generación eléctrica centralizada por medio de un sistema de gestión de energía. En este tipo de microrred, las fuentes de energía renovables son conectadas al sistema de gestión de energía, el cual se encarga de almacenar la energía eléctrica generada para que pueda ser utilizada posteriormente por las cargas. Por otro lado, el sistema de gestión de energía se encarga de conmutar entre la microrred eléctrica formada por los generadores de energía renovables y la red eléctrica centralizada. Cuando la energía en las unidades de almacenamiento no es la suficiente para alimentar a las cargas, el sistema de gestión conecta estas a la red centralizada, de lo contrario, si las condiciones de almacenamiento y generación de energía renovable son buenas, las cargas permanecerán conectadas a la microrred. Además, en la MRE mostrada en la figura 1 podemos observar un elemento importante dentro de la infraestructura de una microrred eléctrica: las cargas.

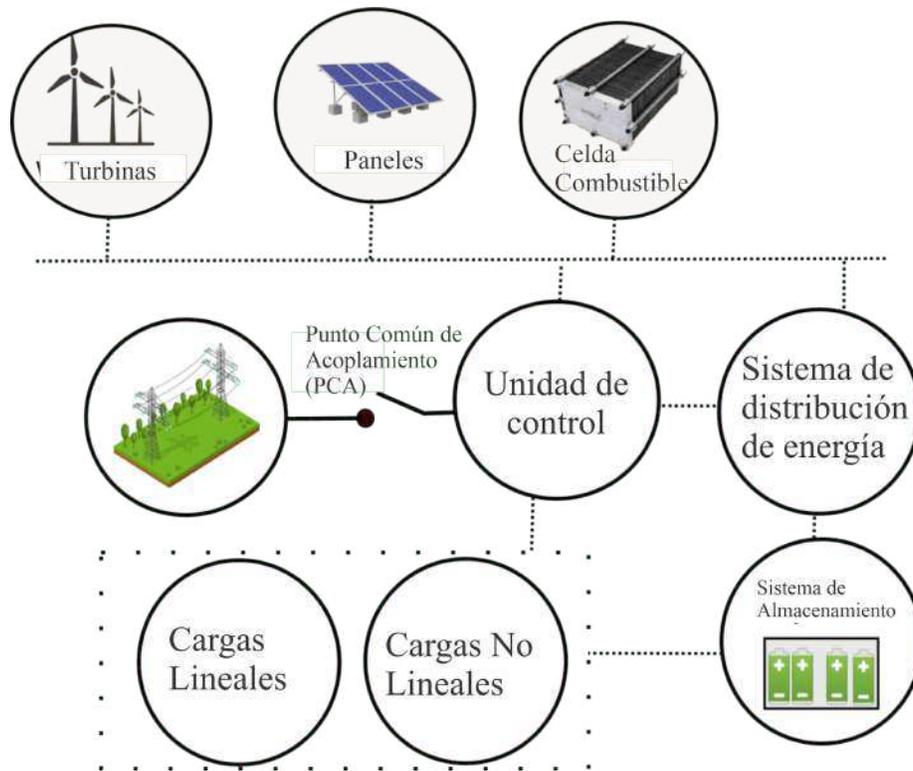
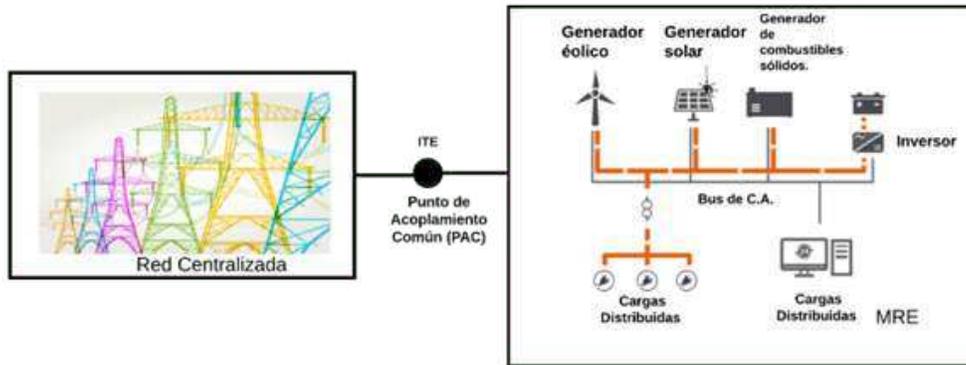


Figure 1.1: Estructura Tradicional de una Microrred Eléctrica.

Dentro de una MRE existen diferentes tipos de cargas de entre las cuales destacan las cargas críticas, a las cuales siempre se les debe suministrar energía [5]. Las cargas críticas son llamadas así porque de ellas dependen procesos de gran importancia, cuyo paro o mal funcionamiento puede poner en riesgo la vida de las personas, ocasionar cuantiosas pérdidas económicas o generar un impacto negativo relevante en la generación de la energía dentro de un corto o mediano plazo [2]. Por otro lado, tenemos las cargas controlables, que son las cargas a las que se les puede dejar de suministrar un porcentaje de energía como los sistemas de iluminación y los sistemas de ventilación, entre otros. Finalmente, las cargas móviles, las cuales a lo largo del día se les debe suministrar una cantidad determinada de energía durante un intervalo de tiempo determinado, sin requerir que esto suceda a una hora concreta del día; como, por ejemplo, sistemas de riego en casas residenciales, sistemas de iluminación [4]. Por otro lado las microrredes eléctricas tienen dos modos de operación. El primero es "modo red" (grid-connected mode) y el segundo es "modo isla" (islanded mode) se refieren a dos estados operativos diferentes en los que una microrred puede funcionar y se muestran en la figura 1.2.

De manera general en el modo red, la microrred está conectada a la red eléctrica principal, también conocida como red de distribución. En este modo, la microrred puede importar y exportar energía de la red eléctrica según sea necesario. La microrred puede obtener energía de fuentes renovables y almacenamiento de energía, y también puede utilizar la red eléctrica principal como respaldo en caso de insuficiencia de energía local. En el modo isla, la microrred se desconecta de la red eléctrica principal y opera de manera autónoma. En este modo, la microrred se basa en sus propias fuentes de generación de energía, como paneles solares, turbinas eólicas, generadores diésel



(a)



(b)

Figure 1.2: Modos de operación: a) **Microrred eléctrica en modo red** b) **Microrred eléctrica en modo isla**

o sistemas de almacenamiento de energía. La microrred suministra energía a sus cargas internas sin depender de la red eléctrica principal. El modo isla es particularmente útil en áreas remotas o durante interrupciones en la red eléctrica principal, ya que permite mantener el suministro de energía localmente. Es importante destacar que una microrred puede cambiar entre el modo red y el modo isla según las condiciones y los requerimientos energéticos. Por ejemplo, en caso de una interrupción en la red eléctrica principal, la microrred puede cambiar automáticamente al modo isla para mantener la continuidad del suministro. Una vez que se restablece la conexión con la red eléctrica principal, la microrred puede volver al modo red y aprovechar los beneficios de la red principal, como la compensación de energía y el respaldo. La capacidad de cambiar entre estos modos de operación es una característica clave de las microrredes y les proporciona flexibilidad y resiliencia en la gestión de la energía.

1.2 Justificación

El modelo de generación eléctrica basado en Hidrocarburo para cubrir la demanda de energía, tiene un número de deficiencias. En la figura 1.3 observamos un diagrama del funcionamiento de la

infraestructura mencionada.

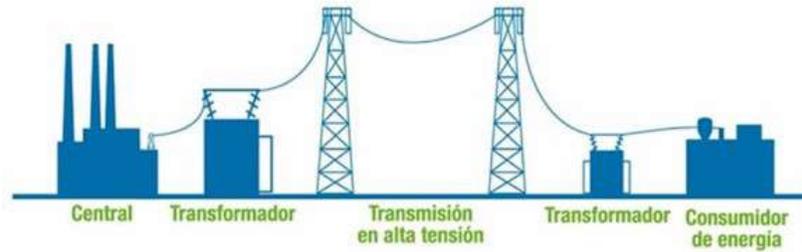


Figure 1.3: Modelo de generación eléctrica basado en Hidrocarburos.

Este esquema funciona con elementos no renovables y mediante líneas de alta tensión la energía llega a los usuarios finales. Del 100% de energía generada en la central al consumidor solo le llega el 60% de la energía, esto representa una clara deficiencia de la estructura. Además de esto, esta arquitectura genera una serie de consecuencias negativas para la sociedad. Como la contaminación ambiental por la serie de gases nocivos que se liberan en el ambiente. Para dar solución a la reducción de gases y contaminantes y además cubrir la demanda energética se propone el uso de estructuras de microrredes eléctricas con recursos de energía renovables. El cambio de tendencia hacia un sistema energético sostenible basado en la eficiencia y las energías renovables requerirá así, la sustitución de un sistema energético complejo y fuertemente implantado por otro basado en conceptos como las microrredes [1]. Hoy en día, los estudios sobre la generación de energía eléctrica se han enfocado en la integración de diversas fuentes de energías renovables como los paneles solares y los generadores eólicos, con diversas unidades de almacenamiento de energía y diferentes sistemas de compensación de disturbios eléctricos [2]. La integración de estos dispositivos junto con una mayor demanda de energía eléctrica de mayor calidad ha motivado el desarrollo de las denominadas microrredes inteligentes o micro-smart grids. Estas microrredes además de ser capaces de satisfacer la demanda energética tienen que mantener el balance entre la energía demandada y la energía generada por la red. Es por esta razón que la microrred debe estar enfocada en mejorar la eficiencia eléctrica a través de la integración de un sistema de control que ayude a mantener la energía eléctrica generada en función de la energía eléctrica demandada en la red [3]. Sin embargo, como se presenta en los antecedentes debido a diversos factores como la alta variabilidad temporal de las fuentes de energía renovables a lo largo del día, así como a la naturaleza intermitente de las cargas, la calidad de la energía eléctrica generada en la microrred es afectada. Por esta razón, los procesos de generación y distribución de la energía eléctrica renovable en la microrred demandan el uso de nuevas metodologías de control que consideren la operación conjunta y colaborativa de las diferentes fuentes de energía renovables y las unidades de almacenamiento de energía junto con los compensadores eléctricos para la mitigación ponderada de los múltiples disturbios eléctricos que pueden ser presentados en la microrred, garantizando la eficiencia individual de los generadores eléctricos, aumentando su vida útil y estabilizando la microrred en un ambiente seguro y confiable [3]. Apartir del hecho de las múltiples perturbaciones las cuales son consecuencia de los generadores de energía renovables, se solicita la demanda de una metodología de control para estas infraestructuras para aumentar la calidad de energía. Como se presenta en la sección de antecedentes existen ya varias metodologías clásicas o inteligentes. Sin embargo, normalmente no compensan de manera múltiple y simultáneamente las perturbaciones que se presentan en la estructura. Además normalmente se necesita más de una metodología para poder cubrir todas las

perturbaciones. Debido a esto, en la presente propuesta se propone el diseño, desarrollo e implementación de un sistema de control Neuro-difuso de aprendizaje profundo para la compensación y control colaborativo de múltiples disturbios eléctricos en una microrred eléctrica de fuentes de energía renovables. Además, se plantea que el sistema de control propuesto sea desarrollado en plataformas de hardware reconfigurables para la integración de distintos algoritmos avanzados de control, monitoreo y procesamiento de las señales de la microrred.

1.3 Planteamiento del Problema

Las redes eléctricas actuales son modelos centralizados; esto quiere decir, que la producción y transmisión de la energía eléctrica se gestiona desde grandes centrales eléctricas que además utilizan fuentes de energía basadas en combustibles fósiles altamente contaminantes. En estos sistemas de generación centralizados, la energía recorre grandes distancias desde el sitio donde se produce hasta el lugar donde se consume la energía eléctrica, lo que supone una considerable pérdida de energía en el camino. Además, en estos sistemas centralizados, la energía se va produciendo en relación con la demanda, basados en el equilibrio entre la producción y el consumo; aunque generalmente se juega con un margen de maniobra bastante alto para responder a los imprevistos; es decir, se produce más energía de la que realmente se necesita y al final, lo que no se utiliza se desecha. Un modelo eléctrico alternativo es una microrred eléctrica inteligente. En estas microrredes, la mayoría de la producción eléctrica proviene de fuentes de energía renovables y solo se utilizan combustibles fósiles cuando no hay suficiente energía, por lo que con este modelo de producción de energía descentralizado se contamina menos. La filosofía de este modelo inteligente es producir de manera local únicamente la energía que se necesita, y así evitar las pérdidas de energía por el transporte. Además, las microrredes eléctricas tienen sistemas de almacenamiento para guardar la energía sobrante y utilizarla cuando se necesite; de esta manera la energía no se produce en exceso, y se evita su desperdicio. Así mismo, en este tipo sistemas de generación distribuida, la generación y distribución de la energía se gestiona mediante un sistema de monitoreo, el cual envía la energía a donde se requiere y almacena los sobrantes. Sin embargo, la creciente integración de equipos eléctricos sensibles a pequeñas variaciones eléctricas presentes en la forma de onda de la señal eléctrica producida en las microrredes, tienen como consecuencia pérdidas millonarias en la reparación y remplazo de equipos en el sector industrial, dado que tanto en las industrias, como en los hospitales del sector salud, se destina una gran cantidad de dinero para el mantenimiento, reparación y calibración de equipos dañados por disturbios eléctricos presentes en el subministro de energía. Debido a esto, el desarrollo de sistemas de monitoreo y análisis de múltiples disturbios eléctricos presentes en las microrredes ha sido un tema de gran importancia en los últimos años. Esta importancia es debido a que los sistemas propuestos en la literatura no consideraran las diferentes fuentes de perturbaciones en la microrred tales como: los disturbios eléctricos externos (fallas atmosféricas, días nublados para los generadores solares y días con fluctuaciones eólicas para los generadores de viento, así como los disturbios eléctricos producidos por la conmutación de diferentes tipos de cargas conectadas a la microrred), los disturbios propios de los actuadores (fallas en los generadores distribuidos, frecuencias de conmutación, switcheo capacitores o de sistemas de almacenamiento de energía, sobre voltajes, factor de potencia, armónicos etc.) y los disturbios eléctricos generados por la introducción aleatoria de cargas en la microrred (arranques de motores, fuentes conmutadas, entre otros). A este respecto, la operación de los sistemas de monitoreo y análisis de las microrredes para los sistemas de compensación de perturbaciones eléctricas se ha venido dando en forma tal que los ajustes proporcionados por los actuadores no aseguran las mejores condiciones de la microrred, esto al no tener la capacidad de compensar una combinación de múltiples disturbios eléctricos por medio de acciones cuantificadas en función del grado en el que se presenta el disturbio en la microrred. Así mismo, los dispositivos de monitoreo y análisis de los generadores distribuidos desarrollados a base de semiconductores y electrónica de potencia constituyen una parte de la microrred la cual produce resonancia por los dispositivos de impedancia variable, lo que conlleva a un sistema de monitoreo y análisis mucho menos confiable. En este sentido, y de acuerdo con lo presentado en los antecedentes de esta propuesta, el esquema

de monitoreo utilizado en las microrredes para mantener el balance entre la energía demandada y la energía generada. En este esquema, cada generador de energía renovable (generadores distribuidos) es el encargado de satisfacer la demanda energética requerida en la microrred por medio de la inyección de la potencia requerida por la carga. Esta operación generalmente se logra mediante el monitoreo de alguna señal de referencia entre la carga y el generador.

Como se puede observar en la figura 1.4, los sistemas de monitoreo utilizados en las microrredes reportados hasta la fecha generalmente son sistemas de entrada simple-salida simple SISO (Simple Input – Simple Output), los cuales solo consideran una perturbación o un solo nivel de referencia para la generación de la energía en la microrred. En este punto, la retroalimentación del sistema está dada por el monitoreo de alguno de los parámetros eléctricos propios de la carga. Así mismo, el modelo de la planta es un factor apremiante para el diseño de este tipo de sistemas, para los cuales no siempre es fácil la obtención de un modelo matemático, principalmente por su dependencia con las cargas conectadas a la microrred, las cuales generalmente son de naturaleza no lineal, además de que su conexión en la microrred es aleatoria. Por otro lado, la arquitectura de monitoreo presentada en la figura 1.4 en la mayoría de los casos no considera la presencia de otros tipos de perturbaciones, ocasionando fallas en la operación de la microrred, y donde el actuador utilizado (en este caso el generador distribuido) también genera repercusiones en la línea, lo que produce una reducción en la CEE además de una ineficiencia a la hora de compensar las diferentes perturbaciones introducidas a la microrred.

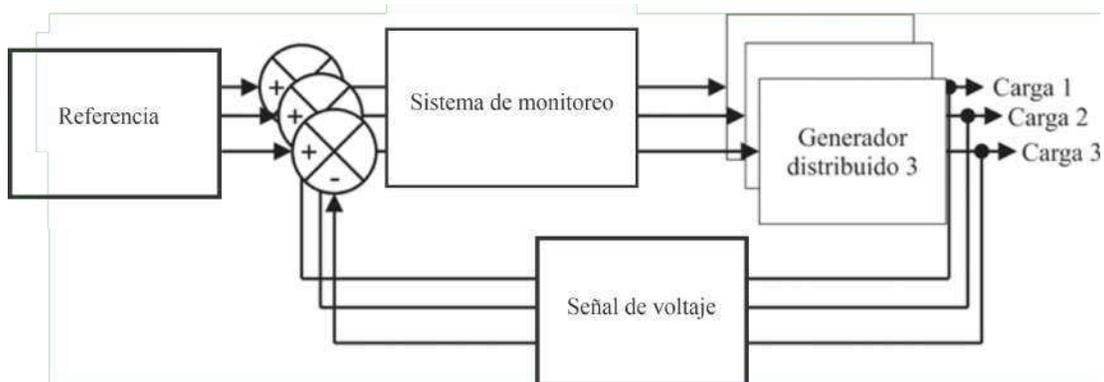


Figure 1.4: Sistemas de monitoreo tradicional en microrredes eléctricas.

Para dar solución al problema de monitoreo y análisis de múltiples disturbios eléctricos presentados en la microrred eléctrica de energías renovables un esquema de múltiples entradas-múltiples salidas MIMO (Multiple Input – Multiple Output) es planteado. En este planteamiento, los diferentes tipos de disturbios eléctricos son agregados a la microrred por medio de perturbaciones eléctricas externas, tales como: cambios atmosféricos, arranques de motores y diferentes tipos de cargas no lineales, entre otras; así como perturbaciones eléctricas adheridas a la microrred por medio del uso de los generadores y actuadores eléctricos; como se muestra en la figura 1.4. El presente trabajo de investigación plantea el monitoreo, análisis y clasificación de diferentes tipos de disturbios integrando una metodología de monitoreo, análisis y clasificación basada en un sistema neuronal de aprendizaje profundo para el monitoreo, detección, clasificación y cuantificación de la microrred eléctrica.

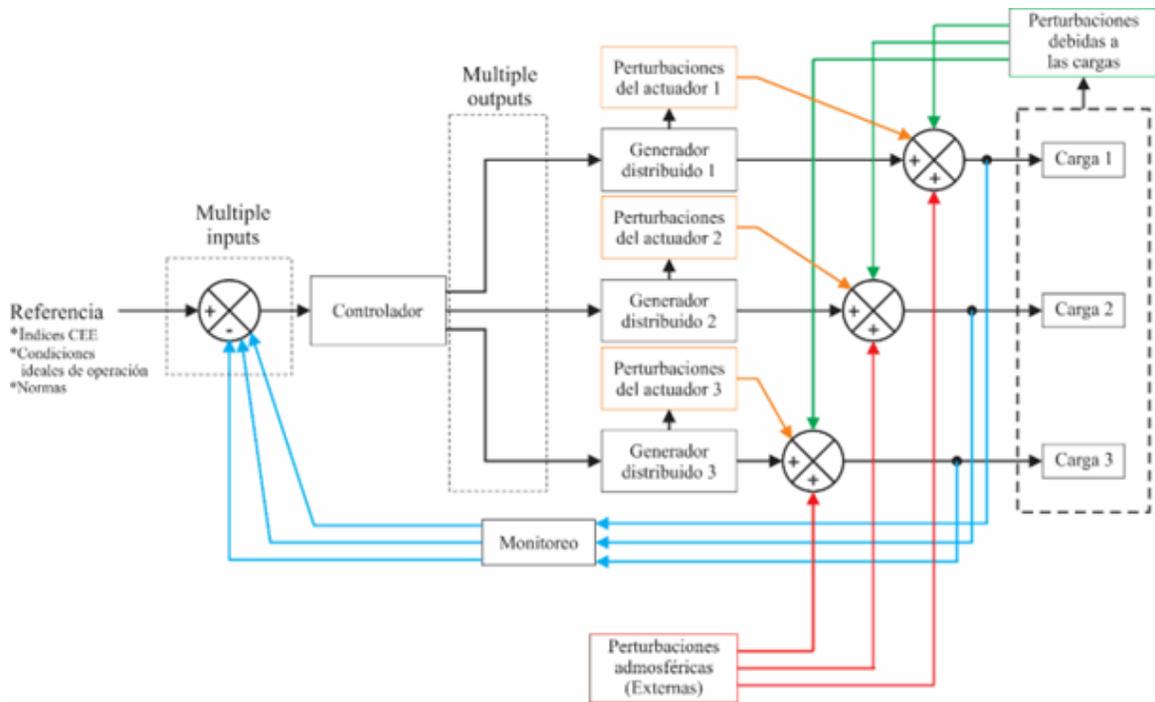


Figure 1.5: Propuesta colaborativa de monitoreo con estrategias de inteligencia artificial

Con este ámbito expuesto anteriormente, la presente propuesta de investigación presenta una vertiente científica. El control por lógica difusa relacionadas por tener menor consumo que otros en cuanto a memoria y rapidez de proceso en combinación con el aprendizaje profundo cuya propiedad relacionada con el procesamiento simultaneo de diferentes demandas, genera una alta probabilidad de sinergismo de estas dos metodologías dentro del área de inteligencia artificial, lógica difusa y redes neuronales de aprendizaje profundo. Esto con el objetivo de obtener una metodología para el control de la MRE y la compensación de perturbaciones de manera simultánea.

1.4 Hipótesis y objetivos

1.4.1 Hipótesis

El desarrollo de un sistema neuronal de aprendizaje profundo permitirá analizar y clasificar múltiples perturbaciones eléctricas en la microrred cuando ocurren de forma individual, conjunta y/o simultánea, para lograr una monitorear y analizar la calidad en la energía eléctrica en las señales de voltaje de una MRE de fuentes de energía renovable.

1.4.2 Objetivo general

Diseñar, desarrollar e implementar una red neuronal de aprendizaje profundo para clasificar y analizar múltiples perturbaciones eléctricas presentadas en un

1.4.3 Objetivo particulares

- Delimitar el espacio y dispositivos que conforman la Microrred Eléctrica
- Desarrollar un sistema de control individual para la regulación de voltaje.
- Diseñar y desarrollar un sistema de generación de disturbios eléctricos reconfigurable para la inyección de perturbaciones en la microrred.
- Diseñar y desarrollar set de datos para entrenamiento del modelo neuronal profundo
- Desarrollar neuronal de aprendizaje profundo para el análisis, monitoreo y clasificación colaborativa de múltiples perturbaciones eléctricas.

1.5 Estructura de la tesis

Dentro de esta tesis se presenta el diseño, desarrollo, diversas pruebas y análisis de un Sistema colaborativo de clasificación y análisis de múltiples perturbaciones eléctricas en una microrred con un sistema neuronal de aprendizaje profundo.

- En el capítulo 2 se presenta el estado del arte el capítulo se divide en dos partes: primero abordamos la evolución de las microrredes eléctricas y su evolución al concepto de las microrredes inteligentes. Posteriormente el papel que juega la inteligencia artificial en las microrredes eléctricas y algunos ejemplos de algoritmos inteligentes en las microrredes. Enfatizando en las aportaciones de analizadores de perturbaciones eléctricas.
- En el capítulo 3 se presentan conceptos teóricos necesarios para el desarrollo de la presente investigación.
- En el capítulo 4 se presenta la metodología de desarrollo así como los casos de estudio en el cual se desarrollo las pruebas de desempeño. Además se presenta la instrumentación utilizada para el desarrollo.
- En el capítulo 5 se presentan los resultados de la investigación los cuales fueron obtenidos en los casos de estudio presentados.
- En el capítulo 6 se muestran las conclusiones finales del desarrollo del proyecto, así como elementos importantes descubiertos a lo largo del desarrollo de la presente investigación.

Estado del arte

Esta sección se divide en tres partes fundamentales para comprender la evolución y la diversidad en metodologías en clasificación de perturbaciones eléctricas. Aparte también se muestra el papel de la inteligencia artificial en distintos ámbitos de las microrredes eléctricas. Las secciones que se discuten en este capítulo son:

- La evolución de las microrredes eléctricas al concepto de las microrredes eléctricas inteligentes o micro smart grids.
- La inteligencia artificial en las microrredes eléctricas.
- La inteligencia artificial en las perturbaciones eléctricas, donde se discute a profundidad este tema.

Puntos importantes para comprender y analizar la importancia de los estudios en el área de generadores y distribuidores de energía eléctrica.

2.1 La evolución de las microrredes eléctricas

El concepto de Microrred Eléctrica (MG) ha evolucionado junto con el desarrollo del ser humano y sus necesidades en la demanda de electricidad. Una Micro Smart Grid (Microrred Eléctrica Inteligente (MEI)) es un tipo de microrred eléctrica que incorpora tecnologías avanzadas de comunicación, detección y control para optimizar el funcionamiento y la gestión del sistema energético local [6]. La figura 2.4 muestra un diagrama que explica los contextos en los que las microrredes eléctricas tradicionales evolucionaron a Microrred Eléctrica Inteligente (MEI) y cómo evolucionaron las características de estas estructuras.

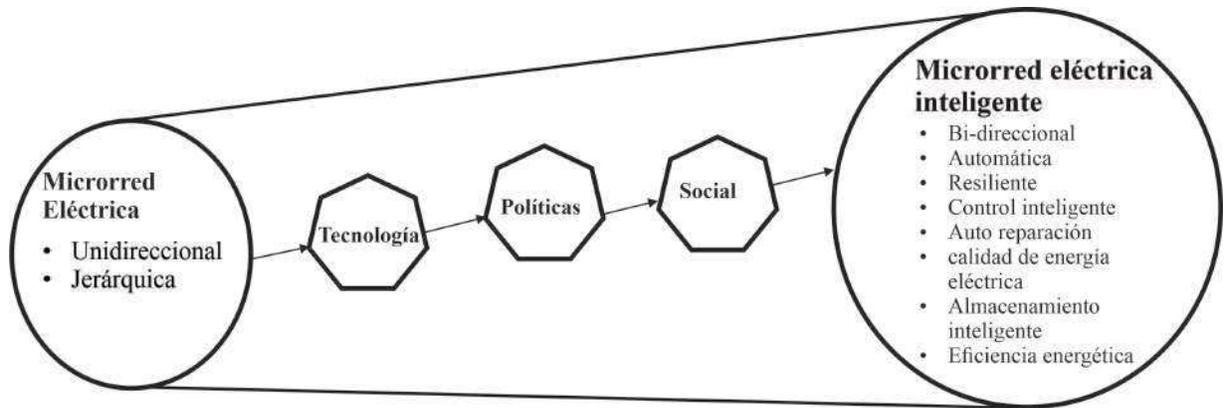


Figure 2.1: Evolución del concepto de microrred eléctrica a microrred eléctrica inteligente.

En los últimos años hemos sido testigos de la evolución tecnológica en distintos sistemas como comunicaciones, materiales, computadoras, microcontroladores. Esto debido a Un ejemplo es la necesidad de un conjunto de componentes de Tecnologías de la Información y la Comunicación (TIC) para comunicaciones bidireccionales. Surgieron metodologías y herramientas para sumar a la infraestructura, como el Internet de las Cosas o los medidores inteligentes [7]. La diversidad de generadores de energía distribuida exige estrategias de control y coordinación entre los generadores distribuidos. Finalmente, los avances fundamentales en la electrónica de potencia han revolucionado las microrredes eléctricas tradicionales a lo que son las microrredes inteligentes. En el ámbito político, los engranajes que iniciaron la evolución de las microrredes eléctricas convencionales residen en las políticas y demandas del mercado de calidad y gestión energética con los consumidores. Derivado de ello, los incentivos y protecciones a los consumidores en impuestos y regulación de precios han hecho que más personas se sumen al consumo de energías limpias, lo que incrementa el uso de Micro Smart Grid. En el ámbito social, se encuentran situaciones como la necesidad de energía verde y el aumento de la demanda energética; son los principales incentivos para el uso de microrredes eléctricas. Al mismo tiempo, el consumidor presenta la necesidad de excelente calidad, confiabilidad, consistencia, seguridad y privacidad en las infraestructuras [8]. Este punto vuelve al tecnológico; debido a los requisitos de calidad en la tecnología de la energía eléctrica, su desarrollo influye en las estrategias de control inteligente.

La definición formal de Microrred Eléctrica Inteligente es la colección de todas las tecnologías, conceptos y topologías. Enfoques que permiten que las jerarquías de generación, transmisión y distribución sean reemplazadas por un entorno integral, orgánicamente inteligente y completamente integrado donde los objetivos de los procesos comerciales y las necesidades de todas las partes interesadas están respaldados por el intercambio eficiente. de datos, servicios y transacciones [9]. En la Figura 2.2, se presenta un diagrama de elementos esenciales en la arquitectura de un Microrred Eléctrica Inteligente. Estos elementos también representan un desafío científico y tecnológico y afectan la interoperabilidad de todo un sistema de Microrred Eléctrica Inteligente.

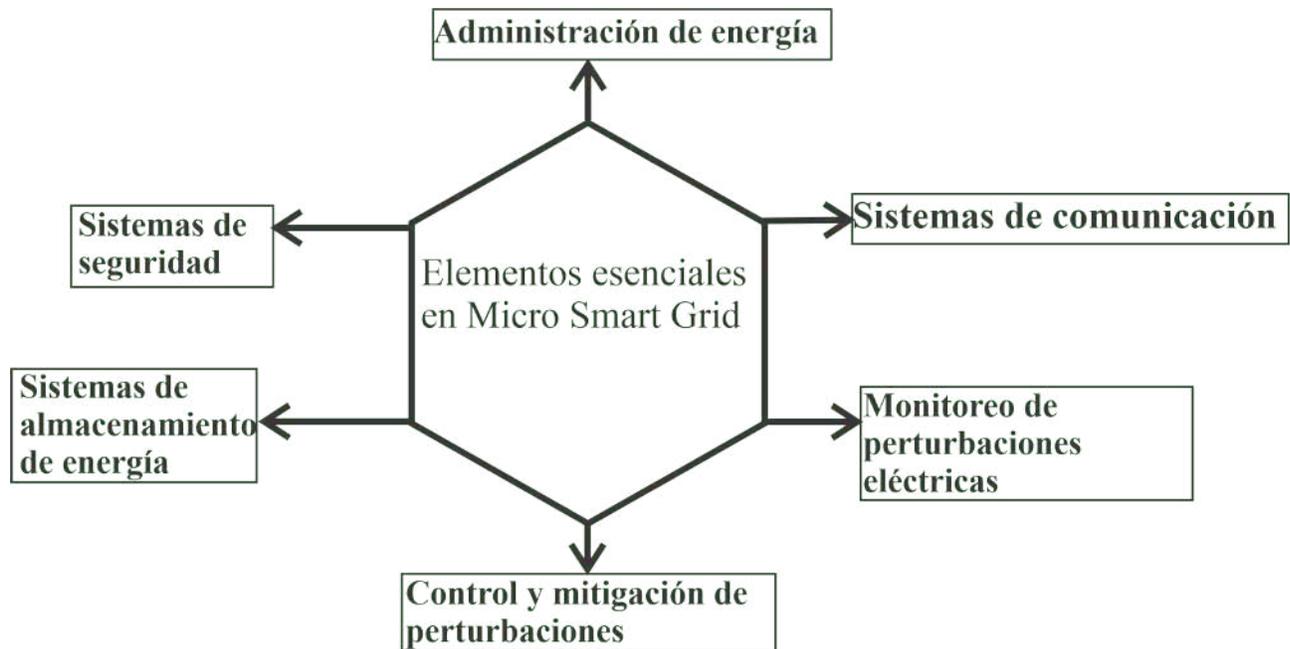


Figure 2.2: Áreas principales de las microrredes eléctricas inteligentes.

Estas áreas resumen la arquitectura y los desafíos en una Microrred Eléctrica Inteligente. Cada uno de estos desafíos tiene diferentes niveles de complejidad debido a la variabilidad en las cargas, la generación, el consumo y los elementos de hardware, entre otros factores. La variabilidad aumenta la complejidad de estos retos, por lo que la inteligencia artificial se ha convertido en una herramienta suficientemente robusta para afrontar la evolución tecnológica y la escalabilidad. Las aportaciones de la inteligencia artificial para afrontar los diferentes retos de cada campo son diversas. La figura 2.3 muestra un gráfico del número de aportes por año de inteligencia artificial en la red Micro Smart; esta búsqueda se realizó con Scopus Preview, la mayor base de datos de resúmenes y citas de literatura revisada por pares: revistas científicas, libros y actas de congresos. Los criterios de búsqueda de estos artículos se limitaron a las palabras clave de este artículo, como inteligencia artificial, algoritmos inteligentes, microrredes y microrredes integradas, y también para cuantificar solo artículos de revistas. En las siguientes secciones se discuten, analizan de manera breve algunas de estas aportaciones profundizando en la clasificación de señales.

2.2 Inteligencia artificial en las Microrredes Smart Grids

En la siguiente figura se muestra un compilado de las distintas estrategias

Cada una de estas implementaciones tienen un objetivo general, a veces varía porque muchos investigadores desarrollan metodologías pesadas y estafalarias multiobjetivos a veces poco óptimas. En los siguientes puntos se muestran los objetivos generales de la inteligencia artificial en cada uno de los ámbitos en las microrredes eléctricas inteligentes.

- **Modos de operación:** Realizar una suave transición de la microrred de modo red a modo isla y viceversa. Es decir realizar metodologías inteligentes para apartir de mediciones de

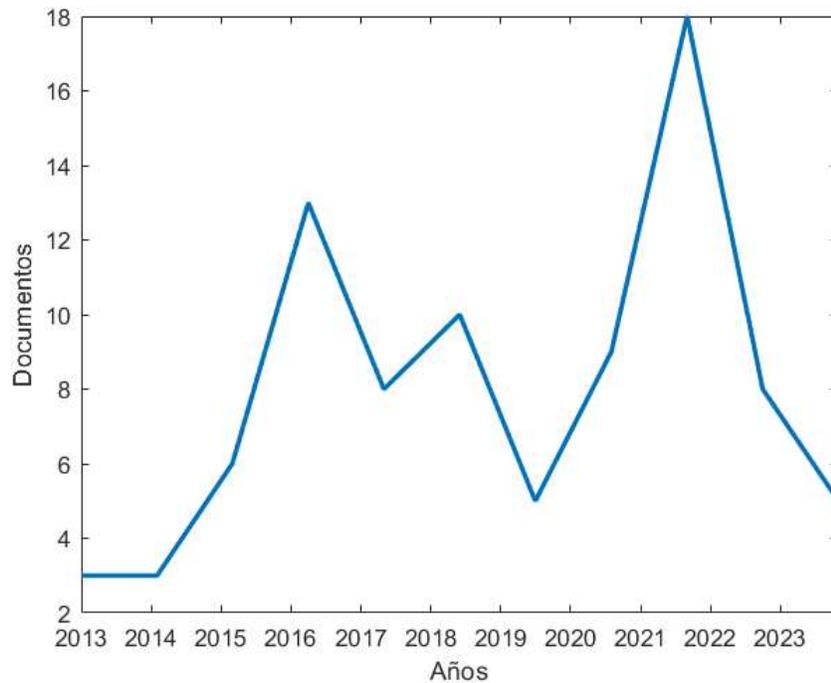


Figure 2.3: Aportaciones de inteligencia artificial en los últimos años.

generación y consumo se realice la correcta transición de la microrred y además realizar este cambio sin afectar la arquitectura de generación y administración de energía.

- **Administración de energía:** Balanceo entre administración de energía entre generación y consumo de energía, con el objetivo que la estructura de generación de energía sea independiente de generadores ajenos a la microrred eléctrica.
- **Monitoreo de calidad de energía eléctrica:** Monitorear, clasificar y analizar los fenómenos electromagnéticos que afectan la calidad de energía eléctrica en la microrred eléctrica.
- **Compensación de perturbaciones eléctricas:** Una vez detectadas tomar acciones para compensar las perturbaciones eléctricas. Esto usualmente se realiza con compensadores síncronos estáticos (STATCOM, del inglés static synchronous compensator) los cuales son elementos de electrónica de potencia avanzada.
- **Dimensionamiento del sistema de almacenamiento:** Optimización de los recursos de almacenamiento para administración de la energía eléctrica en las cargas que consumen la energía generada. Este objetivo se trata como si fuera un problema de optimización debido a esto la programación evolutiva es muy recurrente en esta área.
- **Sistemas de comunicación:** Asegurar la comunicación de dos vías de la microrred eléctrica inteligente además de optimizar las rutas de comunicación.
- **Sistemas de seguridad:** Asegurar la integridad, confiabilidad y disposición de los sistemas de

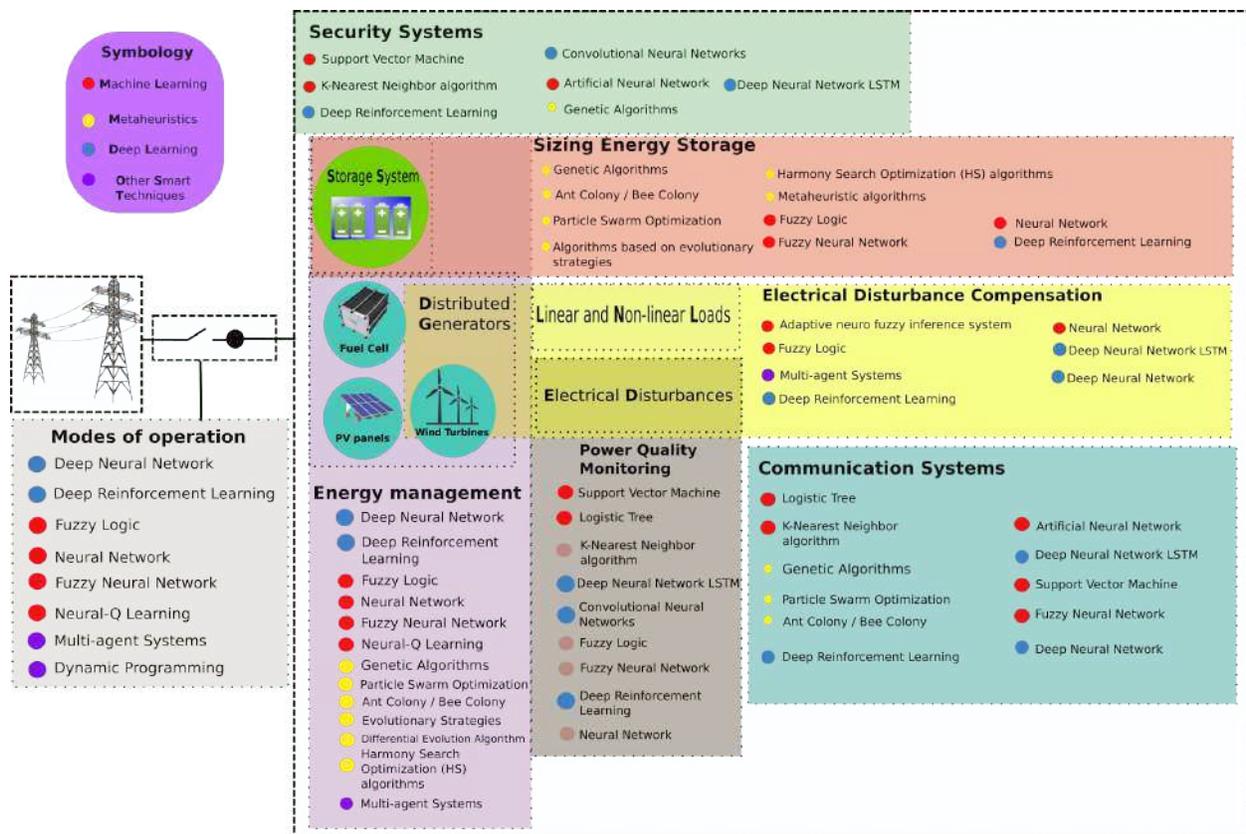


Figure 2.4: Áreas de aplicación de inteligencia artificial en las microrredes eléctricas inteligentes.

comunicación dentro de la microrred, es decir asegurar los componentes básicos y principales de la ciberseguridad en la microrred eléctrica.

En la siguiente sección vamos a profundizar en el papel de la inteligencia artificial en la clasificación de múltiples perturbaciones eléctricas, así como analizar la metodología de desarrollo.

2.3 Inteligencia artificial en la clasificación de las perturbaciones eléctricas

Los fenómenos electromagnéticos que perturban la calidad de la energía eléctrica en sistemas con generadores de energía eléctrica se denominan fenómenos o perturbaciones de la calidad de la energía. Estos fenómenos que afectan la calidad de la energía (PQ) se originan por diferentes motivos, por ejemplo, la constante integración de los generadores de energía sobre todos aquellos que tienden a ser inestables como la solar o la eólica. Estas perturbaciones podrían causar un alto costo en el mal funcionamiento de los equipos dentro de la infraestructura [10]. Además, también la naturaleza de algunas cargas, que podrían convertirse en cargas no lineales, como máquinas de soldar, hornos de arco eléctrico, dispositivos de conmutación de estado sólido, rectificadores e inversores, controles de iluminación, equipos informáticos y de procesamiento de datos, equipos de protección y relés, son los causantes de las perturbaciones que afectan al PQ [11]. La Figura 2.5 muestra las perturbaciones eléctricas que generalmente ocurren en el Microrred Eléctrica Inteligente (MEI) y afectan la calidad de la energía eléctrica.

Monitorear, detectar y analizar este fenómeno es esencial en los estudios de calidad eléctrica de las Microrred Eléctrica Inteligente (MEI) y cualquier sistema de generación de energía. Sin embargo, esta tarea no es un desafío fácil; varias perturbaciones eléctricas son ultrarrápidas y poco perceptibles para el ojo humano, entre otras características que se profundizarán en el capítulo siguiente. Por ello, la inteligencia artificial ha jugado un papel fundamental en el seguimiento, detección y análisis de perturbaciones eléctricas. Generalmente, la metodología de clasificación de perturbaciones consta de la fase de extracción de las características de la señal y la fase de clasificación con una metodología basada en inteligencia artificial. En la tabla ?? se presentan los trabajos más relevantes de los últimos años. Es fundamental mencionar que, especialmente en esta rama del estudio de las microrredes, las metodologías podrían ser más variadas y variadas. Como resultado, se realizó una selección de trabajos basados en aportes científicos y tecnológicos.

De manera general podemos notar como la metodología para clasificación de señales se resume en tres puntos básicos:

1. Obtención de datos.
2. Extracción de características.
3. Clasificación de perturbaciones eléctricas mediante etiquetas.

Podemos notar como una clasificación basada en solamente una etiqueta de salida, no nos proporciona una información significativa. El obtener una etiqueta o un identificador número solo nos muestra el tipo de perturbación sin embargo hay elementos los cuales deben ser cuantificados para determinar la gravedad de la perturbación y analizar la calidad de energía eléctrica.

Referencia	Contribución	Técnica Usadas	Características Clave
[12]	Se implementa la transformada de S rápida de resolución múltiple (OM-FST) para extraer	Algoritmo Cart	La metodología presenta un porcentaje de precisión entre el 87% y el 97% incluso con ciertos decíbeles de ruido en la señal
[13]	Un método de aprendizaje profundo de circuito cerrado para la clasificación de perturbaciones eléctricas	Red neuronal convolucional profunda	El modelo convolucional reduce la dimensionalidad de las características de la señal para minimizar el consumo computacional y aumentar la velocidad del tiempo de respuesta
[14]	La metodología comprende varios elementos de redes neuronales artificiales en una única arquitectura para detectar, clasificar y procesar diferentes perturbaciones eléctricas	Nueva Red neuronal convolutiva	La red consta de una red inception-residual modificada unidimensional (ResNet)(1D-MIR) de cinco capas, una capa de conexión completa de tres capas y una de red convolucional profunda
[15]	Una red neuronal de convolución profunda (CNN) que consta de capas de convolución 2-D, normalización por lotes, abandono y agrupación máxima, está diseñada para capturar características, acelerar el entrenamiento y reducir el sobreajuste	red convolutiva	El rendimiento de la metodología oscila entre el 96% y el 97% incluso con múltiples perturbaciones y ruido de señal
[16]	La metodología híbrida comprende diferentes elementos dentro del campo del aprendizaje automático. Estratégicamente, se utilizaron las ventajas de otras metodologías para clasificar múltiples perturbaciones eléctricas	Clasificador inteligente basado en ML formado por un perceptrón multicapa y una máquina de vectores y Naive Bayes	El porcentaje de precisión oscila entre el 66% y el 99%. La variación en la precisión se debe que se implementan distintos modelos de ML para realizar un estudio y análisis.
[17]	Metodología evolutiva para la reducción de la dimensionalidad de los datos y modelo predictivo clasificador neuronal	Algoritmo adaptivo de enjambre de salpas y red neuronal simple	Reduce 76 características de la señal a 12

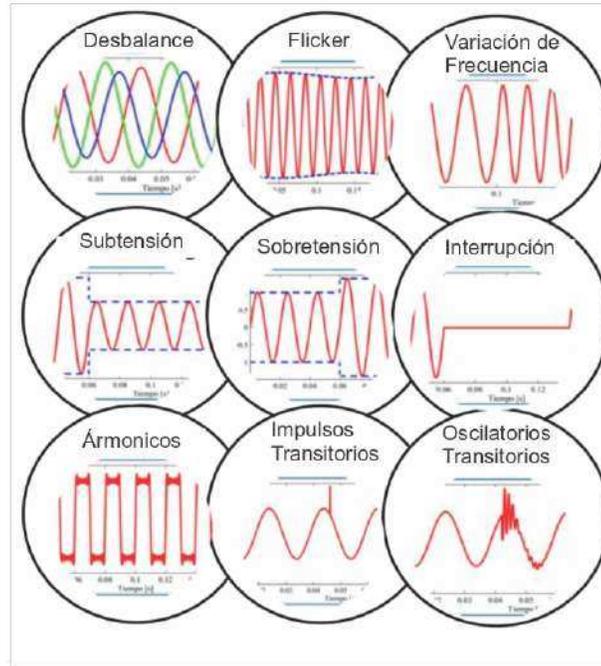


Figure 2.5: Perturbaciones eléctricas .

Referencia	Contribución	Técnica Usadas	Características Clave
[18]	Estrategia basada en Hilbert y wavelet con máquina de vectores de soporte	Máquinas de soporte vectorial	Detección de perturbaciones en frecuencia
[19]	Clasificación de fenómenos transitorios	Algoritmo de árbol de decisión (DT)	Trabaja con perturbaciones transitorias
[20]	Identifica perturbaciones que afectan la calidad de energía eléctrica	Múltiples clasificadores profundos con un método basado en votación por mayoría ponderada (QMV)	Se menciona inmunidad al ruido en la señal eléctrica

Fundamentación Teórica

3.1 Descripción de las perturbaciones que afectan la CEE en las MRE

La Calidad de Energía Eléctrica (CEE) es un aspecto primario en cualquier MRE de cualquier clasificación. Este concepto está adquiriendo actualmente una gran relevancia por la concienciación cada vez mayor que de ella depende la competitividad de las empresas al estar relacionada directamente con su eficiencia y productividad, principalmente en el sector industrial, observándose un interés cada vez mayor en su estudio con el propósito de optimizar los sistemas eléctricos o las instalaciones productivas. Desgraciadamente, esto se ve afectado por una serie de perturbaciones eléctricas las cuales se clasifican en variaciones de amplitud y variaciones de frecuencia. Las variaciones de amplitud implican que el nivel de tensión de servicio sea estable entorno a los márgenes tolerables. Y las variaciones de frecuencia implican que está se mantenga también de estable dentro de los márgenes respecto a la frecuencia del sistema (50 o 60 Hz).

En la tabla 3.1 se presenta una taxonomía de las perturbaciones que afectan la calidad de energía en una MRE. La variación en la magnitud de las señales de voltaje y corriente, tiempo de duración y contenido espectral directamente obtenida del estándar IEEE 1159-1995, el cual además de proporcionar esta información ofrece prácticas para mejorar la calidad de energía y como compensar ciertos disturbios eléctricos.

Table 3.1: Características de perturbaciones eléctricas

Perturbación	Contenido espectral	Espacio tiempo	Variación de la magnitud de voltaje Por unidad (p.u)
Perturbaciones de corta duración			
Interrupción		0.5 ciclos - 30 ciclos (temporal) 30 ciclos - 3 seg (momentáneo) 3 seg - 1 minuto (temporal)	<0.1 p.u
Caídas de voltaje		0.5 ciclos-30 ciclos (temporal) 30 ciclos - 3 seg (momentáneo) 3 seg - 1 minuto (temporal)	0.1-0.9 p.u
Swell		0.5 ciclos - 30 ciclos (temporal) 30 ciclos - 3 seg (momentáneo) 3 seg - 1 minuto (temporal)	1.1 p.u - 1.8 p.u
Variación de larga duración			
Interrupción (sostenida)		>1 minuto	
Subtensión		>1 minuto	0.4- 0.9 pu
Sobretensión		>1 minuto	1.1p.u - 1.5 p.u
Distorsión de forma de onda			
Desplazamiento de corriente		Estado estable	0%-0.1%
Armónicos		Estado estable	0%-0.3%
Muecas o hendiduras de tensión		Estado estable	0%-20%
Ruido		Estado estable	0%-2%
Transitorios			
Impulsos		50 s- 1ms	
Oscilatorios		<50 to >1ms	
Baja frecuencia	<5kHz	0.3 s-50 ms	0-4 p.u
Frecuencia Media	5-500 kHz	20	0-8 p.u
Alta frecuencia	0.5 Hz -5 MHz	5 s	0-4p.u
Desequilibrio de voltaje		Estado estable	0.5%-2%

Table 3.2: Modelos Matemáticos.

ID	Modelo Matemático	Parámetros matemáticos
1.- Sag	$v(t) = 180(1 - \alpha(u(t - t_1) - u(t - t_2))) \sin(\omega t - \phi)$	$0.1 \leq \alpha \leq 0.9$
2.- Swell	$v(t) = 180(1 + \beta(u(t - t_1) - u(t - t_2))) \sin(\omega t - \phi)$	$0.1 \leq \beta \leq 0.9$
3.- Interruption	$v(t) = 180(1 + \rho(u(t - t_1) - u(t - t_2))) \sin(\omega t - \phi)$	$0.9 \leq \rho \leq 1$

Podemos observar la duración o espacio de tiempo en que se desarrolla cada perturbación mostrada, además se presentan la clasificación de cada disturbio por tiempo de duración. Sin embargo, es importante conocer más a fondo este tipo de perturbaciones, como los modelos matemáticos demás de donde de originan y cuáles son las consecuencias, aspectos que se presentan a continuación. En este sentido, la tabla 3.2 enumera las formas de onda fundamental de las señales de voltaje y corriente, junto con las componentes correspondientes a las perturbaciones eléctricas.

Una descripción de los modelos matemáticos presentados en el anexo 1. No solo es importante solo saber el modelo matemático de las perturbaciones, también es importante conocer el origen y su consecuencia en las MRE. Esto con el fin de recalcar la importancia de clasificar y analizar estos fenómenos en la MRE, esto lo podemos ver en la tabla 3.3.

Table 3.3: Perturbaciones eléctricas: Origen y Consecuencias.

Perturbación	Origen	Consecuencia
Interrupción	Son consecuencias de fallas en el sistema de energía eléctrica, averías en inversores o errores en sistemas de control [21]	Afectan a los aparatos electrónicos y de iluminación, en algunos casos puede dañar las herramientas electrónicas de arranque suave y los sistemas de control [21]
Sag	Suelen estar asociadas con fallas de monitoreo, además puede ser causados por la conmutación de grandes cargas [22]	Variaciones de velocidad de las máquinas de inducción y una disminución trivial en la salida de un banco de capacitores pueden ocurrir en este tipo de perturbaciones [23]
Swell	Se asocian con situaciones de falla de monitoreo con situaciones de falla de monitoreo en el sistema de energía eléctrica. También puede deberse a conmutación de carga o conmutación de condensador [22].	Puede causar fallas en el equipo sujeto a la frecuencia de incidencia. Los dispositivos electrónicos, que contienen unidades de velocidad ajustable, unidad central de procesamiento y controladores automáticos [21]
Subtensión	Se originan por la conmutación de las cargas, o conmutación de un banco de condensadores [23]	Producen una gran pérdida por calentamiento en los motores de inducción debido al aumento en la corriente en los motores de inducción. [21]
Sobretensión	Son el resultado de conmutación de carga, conmutación del banco de capacitores [23].	Puede causar fallas en equipos electrónicos, electrodomésticos entre otros
Desequilibrio de voltaje	Causados por cargas desequilibradas polifásicas así como anomalías en los bancos de los capacitores [23]	Causan calentamiento en motores de inducción, así como un desbalance en las corrientes de línea [23].
Armónicos	Se deben a las características no lineales de los equipos y cargas en la microrred [24]	Provocan sobrecalentamiento de máquinas rotativas y estáticas como motores y transformadores. Además, provocan una ruptura prematura y situaciones de resonancia armónica [24]
Transitorio	Generalmente son causados por eventos de conmutación [25]	Afectan la degradación o ruptura dieléctrica instantánea en todo tipo de equipo. Provocan fallas de aislamiento en aparatos como máquinas eléctricas, transformadores de potencia, condensadores, cables y relés [25].

3.2 Descomposición de modo empírico.

El algoritmo de descomposición de modo empírico (Empirical Mode Decomposition, EMD) es una técnica utilizada para analizar y descomponer señales complejas en una serie de funciones intrínsecas de modo empírico (Intrinsic Mode Functions, IMF). Fue desarrollado por Huang et al. en la década de 1990 y se ha convertido en una herramienta ampliamente utilizada en el campo del procesamiento de señales [26].

La EMD es una técnica adaptativa y no lineal que no requiere suposiciones a priori sobre la forma o estructura de la señal analizada. Se basa en el concepto de que cualquier señal compleja puede descomponerse en una combinación de componentes más simples y localmente oscilantes. Estos componentes más simples son las IMF, que representan diferentes escalas de tiempo y amplitudes de la señal original [27], el algoritmo de EMD es el siguiente:

1. Dado un conjunto de datos $X(t)$, donde t representa el tiempo.
2. Definir el número de modos N en los que deseas descomponer los datos.
3. Inicializar $X_1(t) = X(t)$.
4. Para i desde 1 hasta N :
 - (a) Calcular la media local $M_i(t)$ de $X_i(t)$ utilizando, por ejemplo, un promedio móvil.
 - (b) Calcular la función residual $R_i(t) = X_i(t) - M_i(t)$.
 - (c) Si $R_i(t)$ satisface un criterio de parada predefinido, detener la descomposición y considerar $R_i(t)$ como el último modo.
 - (d) De lo contrario, incrementar i en 1 y asignar $X_{i+1}(t) = R_i(t)$.
5. El último modo obtenido, $R_N(t)$, se considera como el último residuo.

Como se muestra el proceso inicia cuando dado un conjunto de datos, se identifican los máximos locales y mínimos locales en la señal, estos puntos se conocen como extremos. A partir de los extremos, se generan envolventes superior e inferior suaves y continuas, que son interpolaciones cúbicas de los puntos máximos y mínimos. La media de estas envolventes superior e inferior se calcula y se denomina como función promedio. Se resta la función promedio de la señal original para obtener la primera IMF. Se repiten los pasos anteriores en la IMF obtenida hasta que se cumplan ciertos criterios de parada, como la presencia de un número fijo de extrema o la amplitud de los extrema es menor que un umbral predefinido. La última IMF obtenida se considera como el residuo de la señal original después de la eliminación de las IMF anteriores.

En resumen, el algoritmo de descomposición de modo empírico (EMD) es una técnica poderosa y flexible para descomponer señales complejas en sus componentes intrínsecos. Ha encontrado aplicaciones en diversas áreas, como el análisis de señales biomédicas, el procesamiento de imágenes y la predicción de series temporales. Su capacidad para adaptarse a la naturaleza no lineal de las señales lo hace especialmente útil en escenarios donde otros métodos pueden ser menos efectivos.

3.3 Redes Neuronales Artificiales Profundas.

El libro "Inteligencia Artificial: Un enfoque moderno" (título original: "Artificial Intelligence: A Modern Approach") define la inteligencia artificial (IA) como: **"El estudio de cómo hacer que las computadoras realicen tareas que, hasta ahora, los humanos hacen mejor"**.

En este contexto, la IA se refiere a la creación de programas y sistemas informáticos capaces de realizar actividades que requieren inteligencia humana, como el razonamiento, la planificación, el aprendizaje, la percepción, el reconocimiento de voz, la comprensión del lenguaje natural y la toma de decisiones.

Deep Learning o aprendizaje profundo se basa en el funcionamiento de las redes neuronales artificiales, que son estructuras computacionales diseñadas para imitar el comportamiento del cerebro humano [28]. Sin embargo, a diferencia de las redes neuronales tradicionales, las redes neuronales profundas tienen múltiples capas ocultas que les permiten extraer características complejas y realizar aprendizaje automático a gran escala. El aprendizaje profundo o Deep Learning es un subcampo específico de la IA. Representa un nuevo intento por aprender representaciones idóneas de conjuntos de datos poniendo énfasis en el aprendizaje de dichas representaciones de manera sucesiva mediante las que se denominan capas [29]. El término "Profundo" no hace ninguna referencia a algún tipo de entendimiento profundo alcanzado mediante la utilización de este tipo de enfoque, en vez de ello, el término representa la idea de la representación sucesiva y jerarquizada de los datos por medio de capas [30]. En este sentido, la cantidad de capas que contribuyen a un modelo es denominada la "profundidad del modelo". Modelos de aprendizaje profundo modernos normalmente involucran decenas o cientos de capas sucesivas de representación, y todos los parámetros que ellas contienen son aprendidos automáticamente mediante la exposición de dichos modelos a los denominados datos de entrenamiento [31]. Por otro lado, otros enfoques en el aprendizaje automático tienden a enfocarse en el aprendizaje utilizando sólo una o dos capas de representación para sus datos, por lo tanto, este tipo de enfoques son denominados modelos de aprendizaje superficial, lo contrario al aprendizaje profundo [32]. En los modelos de aprendizaje profundo, las representaciones por capas son casi siempre realizadas mediante Redes Neuronales Artificiales (RNA), las cuales están literalmente estructurados en capas apiladas una después de la otra. En la figura 3.1 se puede observar la diferencia entre los esquemas de aprendizaje automático y aprendizaje profundo.

En la figura 3.1 podemos observar como el número de capas de las redes neuronales repercute en ámbitos como el consumo computacional, el porcentaje de precisión y hasta el procesamiento de los datos. En el aprendizaje profundo, el consumo computacional aumenta de manera notoria, es mayor que en el área de aprendizaje automático sin embargo existe una precisión mayor que en el aprendizaje automático. Además, en la figura podemos notar que, a diferencia del aprendizaje profundo, el aprendizaje automático tiene una fase extra, el preprocesamiento de los datos. En el aprendizaje automático esta fase es necesaria para obtener una mejor calidad en la respuesta de salida, es por eso por lo que este tipo de "filtro" es necesario. En el aprendizaje profundo esta fase está incluida dentro de las metodologías; por lo tanto, no es necesario agregar fases extras.

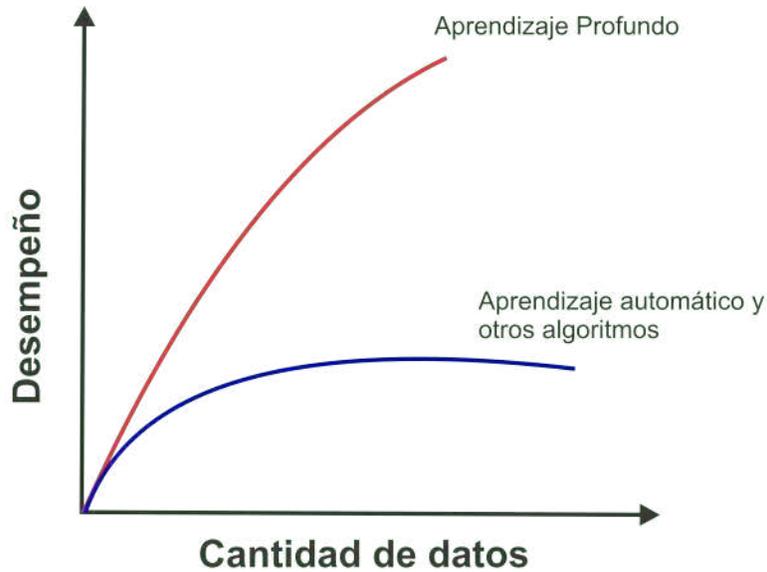


Figure 3.1: Diferencias entre Deep learning y Machine learning.

3.3.1 Arquitectura de las Redes neuronales Artificial Profundas

La unidad más pequeña en las Redes Neuronales Artificiales (RNA) es el perceptrón, el cual representa solo una neurona, como la que la podemos observar en la figura 3.2. Al igual que en el sistema nervioso, la neurona tiene la función de procesar y transmitir de manera continua la información hacia otras neuronas, para generar un aprendizaje determinado.

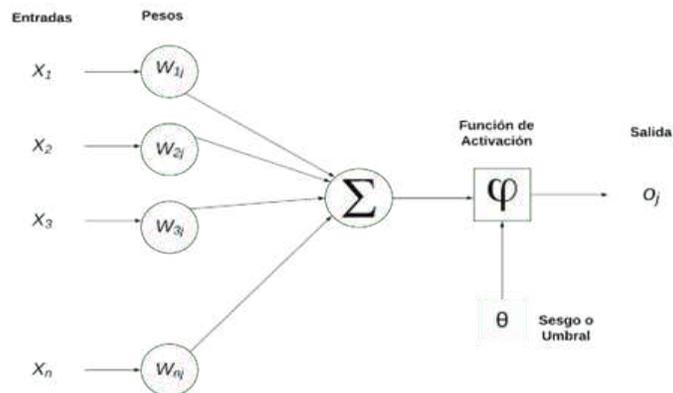


Figure 3.2: Neurona: Unidad básica de RNA.

Apartir de esta neurona inicia la construcción de arquitecturas de RNA. La arquitectura de una red neuronal artificial (RNA) se refiere a la estructura y organización de las capas y conexiones que componen la red. Aquí te presento los componentes fundamentales de una arquitectura de red neuronal artificial:

- Capas de entrada (Input layer): Es la capa inicial de la red y se encarga de recibir los datos

de entrada. Cada neurona en esta capa representa una característica o variable de entrada y se conecta con las neuronas de la siguiente capa.

- Capas ocultas (Hidden layers): Son capas intermedias entre la capa de entrada y la capa de salida. Estas capas realizan cálculos y transformaciones no lineales en los datos de entrada mediante neuronas artificiales. Cuantas más capas ocultas tenga una red, más profunda se considera la arquitectura y mayor capacidad de aprendizaje puede tener la red.
- Capa de salida (Output layer): Es la capa final de la red y produce los resultados o predicciones. Cada neurona en esta capa representa una salida deseada o clasificación. La cantidad de neuronas en esta capa depende del tipo de problema que se esté abordando.
- Pesos (Weights): Los pesos son parámetros ajustables que determinan la fuerza y la influencia de las conexiones entre las neuronas de diferentes capas. Estos pesos son inicializados aleatoriamente y se van ajustando durante el entrenamiento de la red para minimizar el error y mejorar el rendimiento.
- Funciones de activación (Activation functions): Son funciones aplicadas a las salidas de las neuronas para introducir no linealidad en la red. Algunas funciones de activación comunes son la función sigmoide, la función ReLU (Rectified Linear Unit) y la función softmax.
- Conexiones (Connections): Las conexiones representan las interconexiones entre las neuronas de diferentes capas. Cada conexión está asociada con un peso que determina la influencia de la neurona de una capa sobre la neurona de la capa siguiente.
- Función de pérdida (Loss function): Es una función que mide la discrepancia entre las salidas predichas por la red y las salidas reales. La función de pérdida es utilizada durante el entrenamiento para ajustar los pesos de la red.

La arquitectura de una red neuronal artificial puede variar ampliamente según la naturaleza del problema y los requisitos específicos. Pueden existir diferentes tipos de capas ocultas, conexiones adicionales (como conexiones recurrentes en redes neuronales recurrentes) y técnicas avanzadas como la regularización y el dropout para mejorar el rendimiento y prevenir el sobreajuste. La arquitectura de una red neuronal artificial es la disposición de las capas, las conexiones y los parámetros que determinan el funcionamiento y la capacidad de aprendizaje de la red. Cada componente cumple un papel importante en el procesamiento y la transformación de los datos de entrada para producir resultados deseados. En la figura 3.3 se muestra de manera gráfica los elementos que se acaban de definir en los puntos anteriores.

Las arquitecturas dentro de deep learning se generan apartir de la a arquitectura básica. En la década de 1980 y 1990, surgieron importantes avances en el campo del aprendizaje profundo. El investigador Geoff Hinton y su equipo desarrollaron algoritmos de aprendizaje basados en el concepto de redes neuronales profundas, utilizando múltiples capas ocultas. Estos avances incluyeron la técnica de "aprendizaje profundo jerárquico" y el algoritmo de "retropropagación del error" para entrenar redes neuronales profundas de manera más eficiente. Aunque estos avances sentaron las bases del Deep Learning, la falta de grandes conjuntos de datos etiquetados y el poder computacional limitado en ese momento limitaron su aplicación práctica.

Existen varios tipos de redes neuronales profundas, cada una diseñada para abordar diferentes problemas y datos específicos. A continuación, se presentan algunos de los tipos más comunes de redes neuronales profundas:

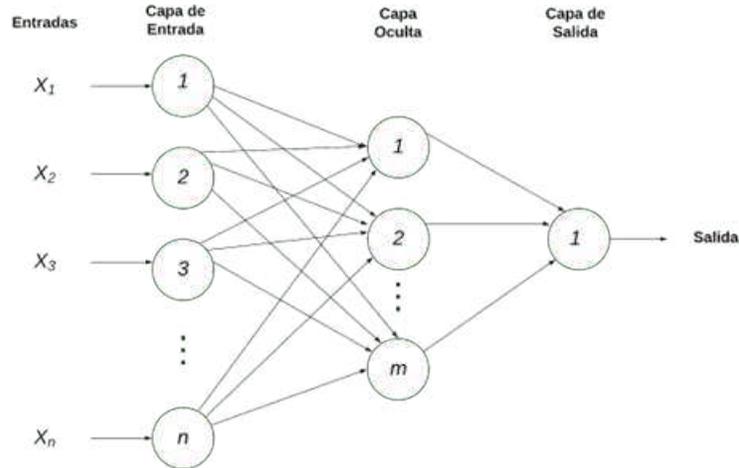


Figure 3.3: Arquitectura básica de una Red Neuronal Artificial.

- **Redes Neuronales Convolucionales (Convolutional Neural Networks, CNN):** Son ampliamente utilizadas en el procesamiento de imágenes y visión por computadora. Estas redes están diseñadas para reconocer patrones y características en imágenes, utilizando capas convolucionales para extraer características locales y capas de agrupación para reducir la dimensionalidad. Las CNN han demostrado un rendimiento excepcional en tareas como la clasificación de imágenes, la detección de objetos y el reconocimiento facial.
- **Redes Neuronales Recurrentes (Recurrent Neural Networks, RNN):** Son adecuadas para procesar datos secuenciales, como texto o series de tiempo. A diferencia de las redes neuronales tradicionales, las RNN tienen conexiones recurrentes que les permiten mantener una memoria interna y considerar el contexto temporal. Esto las hace efectivas en tareas como el procesamiento del lenguaje natural, la traducción automática, el reconocimiento de voz y la generación de texto.
- **Redes Neuronales Generativas Adversariales (Generative Adversarial Networks, GAN):** Consisten en un generador y un discriminador que se entrenan de manera adversarial. El generador intenta generar muestras que sean indistinguibles de los datos reales, mientras que el discriminador intenta distinguir entre las muestras generadas y los datos reales. Las GAN se utilizan para la generación de imágenes y otros tipos de datos sintéticos, y han demostrado ser muy efectivas en la generación de contenido realista.
- **Redes Neuronales de Memoria a Corto Plazo (Long Short-Term Memory Networks, LSTM):** Son una variante de las RNN diseñadas para superar el problema del desvanecimiento del gradiente y capturar dependencias a largo plazo en secuencias. Las LSTM tienen una arquitectura especializada con unidades de memoria que permiten mantener y actualizar información durante un período de tiempo más largo. Se utilizan en tareas como el modelado del lenguaje, la traducción automática y la generación de texto coherente.
- **Redes Neuronales Transformer:** Son una arquitectura basada en atención que ha ganado popularidad en el procesamiento del lenguaje natural. Los Transformers se basan en mecanismos

de atención para capturar relaciones entre palabras o elementos en una secuencia. Han demostrado excelentes resultados en tareas de traducción automática, generación de texto y resumen automático.

Estos son solo algunos ejemplos de las redes neuronales profundas más utilizadas. Además, existen otras arquitecturas y variantes, como las Redes Neuronales Residuales (Residual Neural Networks, ResNet), las Redes Neuronales Siamesas (Siamese Neural Networks) y las Redes Neuronales Autoencoders (Autoencoder Neural Networks), entre otras. La elección de la arquitectura adecuada depende del tipo de problema que se esté abordando y los datos disponibles.

Estas arquitecturas tienen diferentes tipos de capas las cuales son utilizadas para resolver problemas de regresión o clasificación. Algunos ejemplos de capas utilizadas en las arquitecturas de Deep Learning son:

- Capa de entrada (Input layer): Es la capa inicial de la red y se encarga de recibir los datos de entrada. No realiza ningún cálculo y simplemente transmite los datos a la siguiente capa.
- Capa totalmente conectada (Fully Connected layer): También conocida como capa densamente conectada o capa de salida, esta capa tiene todas sus neuronas conectadas con las neuronas de la capa anterior. Cada neurona en esta capa está conectada con todas las neuronas de la capa anterior y calcula una combinación lineal de las entradas ponderadas por sus pesos respectivos.
- Capa convolucional (Convolutional layer): Es una capa especializada para procesar datos en forma de imágenes o mapas de características. Utiliza filtros convolucionales para extraer características locales de la entrada mediante operaciones de convolución. Estas capas son especialmente útiles para la visión por computadora y el procesamiento de imágenes.
- Capa de agrupación (Pooling layer): También conocida como capa de submuestreo, esta capa reduce la dimensionalidad espacial de la salida de la capa anterior. Se utiliza para reducir el costo computacional y la cantidad de parámetros, así como para generar características invariantes a la traslación y escala.
- Capa de activación (Activation layer): Introduce no linealidad en la red mediante una función de activación aplicada a las salidas de las neuronas. Algunas funciones de activación comunes incluyen la función sigmoide, la función ReLU (Rectified Linear Unit), la función tanh (tangente hiperbólica) y la función softmax.
- Capa de regularización (Regularization layer): Se utiliza para evitar el sobreajuste y mejorar la generalización del modelo. Algunas técnicas de regularización comunes incluyen la regularización L1 y L2, el dropout y la normalización por lotes (batch normalization).
- Capa de salida (Output layer): Es la capa final de la red y produce los resultados o predicciones. La estructura y la función de esta capa dependen del tipo de problema que se esté abordando. Por ejemplo, en problemas de clasificación binaria se puede utilizar una función de activación sigmoide, mientras que en problemas de clasificación multiclase se suele utilizar la función softmax.

El aprendizaje multitareas en redes neuronales ha surgido como un enfoque prometedor en el campo del aprendizaje automático. A medida que los sistemas y las aplicaciones se vuelven cada vez más

complejos, la capacidad de abordar múltiples tareas de manera eficiente se ha vuelto fundamental. En este ensayo, exploraremos el concepto de aprendizaje multitareas en redes neuronales, sus beneficios y cómo puede mejorar la eficiencia y el rendimiento del aprendizaje automático.

El aprendizaje multitareas en redes neuronales se refiere a la capacidad de una red neuronal para abordar y aprender múltiples tareas relacionadas simultáneamente. En lugar de entrenar redes neuronales separadas para cada tarea individual, el aprendizaje multitareas busca aprovechar las relaciones y las similitudes entre las tareas para mejorar el rendimiento general, en la figura 3.4 se muestra la diferencias entre una arquitectura neuronal tradicional y la arquitectura multilearning.

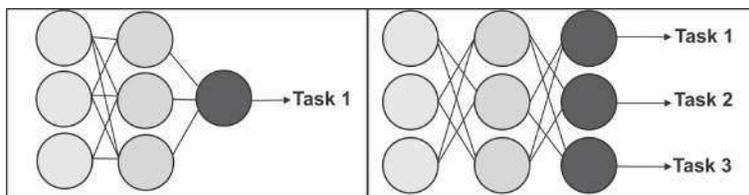


Figure 3.4: Diferencias entre redes neuronales tradicionales y multitareas.

Un beneficio clave del aprendizaje multitareas es la eficiencia en el uso de los datos de entrenamiento. Al compartir y reutilizar información a través de las tareas, las redes neuronales pueden aprender de manera más rápida y efectiva. Esto es especialmente útil cuando los conjuntos de datos de cada tarea son limitados o costosos de recopilar, ya que el aprendizaje multitareas permite aprovechar al máximo los datos disponibles. Además, el aprendizaje multitareas puede mejorar el rendimiento general del modelo al capturar características y conocimientos comunes entre las tareas. Al aprender conjuntamente, la red neuronal puede adquirir representaciones más robustas y generales, lo que conduce a un mejor rendimiento en todas las tareas. Esto se conoce como aprendizaje de transferencia, donde el conocimiento adquirido en una tarea puede beneficiar el rendimiento en otras tareas relacionadas. Otro beneficio del aprendizaje multitareas es la capacidad de abordar problemas de desequilibrio de datos. En algunas tareas, los conjuntos de datos pueden estar desequilibrados, con menos ejemplos de ciertas clases. Al aprender multitareas, las redes neuronales pueden beneficiarse del conocimiento compartido para mejorar la capacidad de generalización en todas las tareas, incluso en aquellas con datos desequilibrados.

3.4 Métricas de evaluación.

Las métricas de evaluación en redes neuronales se utilizan para medir el rendimiento y la calidad de un modelo de red neuronal. Estas métricas permiten cuantificar cómo de bien está funcionando el modelo y proporcionan una forma objetiva de evaluar su desempeño. Algunas de las métricas comunes utilizadas en la evaluación de redes neuronales se presentan en la tabla 3.4.

Para la tarea de clasificar las múltiples perturbaciones eléctricas por etiquetas se utilizaron índices, los cuales se ayudan de la matriz de confusión que se muestra en la Figura 3.5. Una matriz de confusión es una tabla que evalúa el rendimiento de un algoritmo de clasificación para un problema de clasificación. Compara las etiquetas de clase pronosticadas con las etiquetas de clase reales de un conjunto de datos.

Las filas de la matriz de confusión representan las etiquetas de clase reales, mientras que las columnas representan las etiquetas de clase predichas. La diagonal principal de la matriz representa

Table 3.4: Métricas de evaluación.

Nombre	Fórmula	
Error de porcentaje medio absoluto (MAPE, por sus siglas en inglés)	$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \left \frac{y_i - \hat{y}_i}{y_i} \right \times 100$	n es el número de observaciones y_i es el valor real de la observación i \hat{y}_i es el valor predicho
Error cuadrático medio (MSE, por sus siglas en inglés)	$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$	n es el número de observaciones y_i es el valor real de la observación i \hat{y}_i es el valor predicho

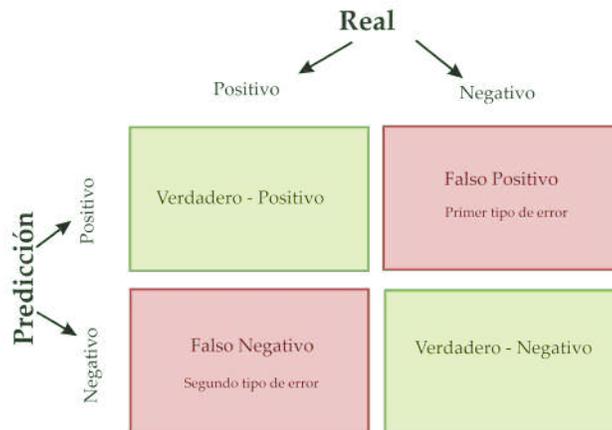


Figure 3.5: Matriz de confusión

las muestras correctamente clasificadas, mientras que los elementos fuera de la diagonal representan las muestras mal clasificadas. Una matriz de confusión normalmente tiene cuatro entradas:

- Verdaderos positivos (TP): el número de muestras predichas correctamente como positivas.
- Falsos Positivos (FP): El número de muestras predichas incorrectamente como positivas.
- Verdaderos negativos (TN): El número de muestras predichas correctamente como negativas.
- Falsos Negativos (FN): El número de muestras predichas incorrectamente como negativas.

La matriz de confusión proporciona información valiosa para evaluar el rendimiento de un algoritmo de clasificación, como Accuracy, Specificity, recall y F1-Score. Estas métricas ayudan a determinar qué tan bien funciona el algoritmo para cada clase.

Metodología

En esta sección se presenta la metodología de desarrollo de la presente tesis. Se tuvieron diversas fases de desarrollo las cuales van anidadas es decir, una sienta las bases de la otra. Las fases son las siguientes:

- Desarrollo en software
- Desarrollo y pruebas en simulaciones en tiempo real
- Desarrollo y pruebas con sistemas monofásicos

En las siguiente secciones describen la importancia y el proceso metodológico de cada uno de las fase de desarrollo. Pero de manera inicial se describe la metodología general de desarrollo.

4.1 Metodología de desarrollo general

En la figura 4.1 se muestra la metodología general utilizada para el desarrollo de la presente investigación.

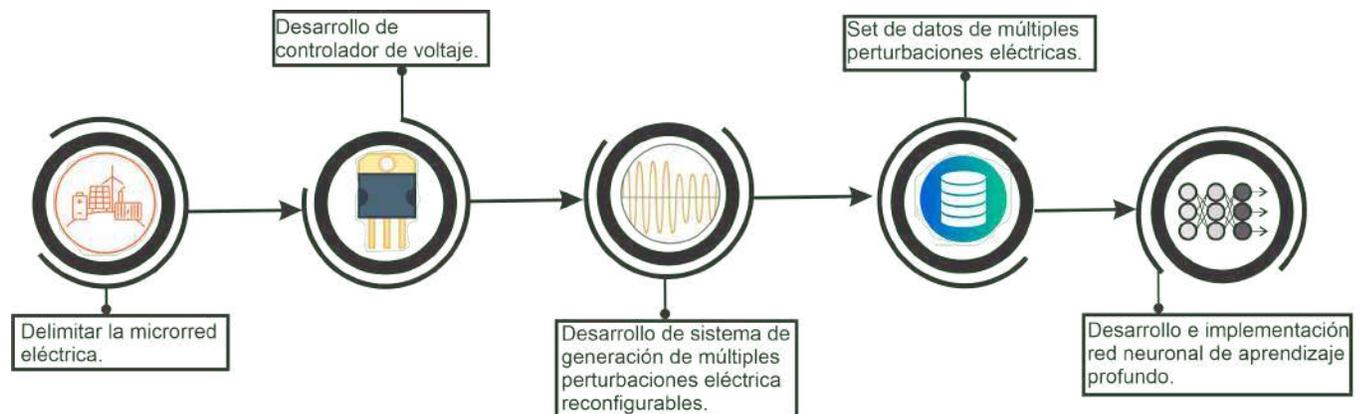


Figure 4.1: Metodología de desarrollo general.

Cada uno de estos puntos sientan las bases de este proyecto y además sirven de base uno de otro. Cada uno de estos puntos son:

1. Definir la microrred eléctrica y sus elementos básicos que lo conforman como generadores de energía, inversor, cargas, controlador de voltaje, entre otros. También es importante definir el modo de operación de la microrred.
2. El punto número dos de la metodología, el cual es importante en una microrred con generadores renovables. Un controlador de voltaje en generadores distribuidos renovables es un componente esencial para garantizar la estabilidad y la calidad del voltaje en un sistema de generación de energía distribuida. Su función principal es mantener el voltaje en un rango óptimo, asegurando que los generadores renovables operen de manera eficiente y segura.
3. desarrollo un generador de inyección de perturbaciones el cual en secciones futuras se discutirá de manera profunda. Pero de manera general este inyector y generador se desarrolló utilizando el lenguaje de programación de matlab y las formulas de perturbaciones eléctricas presentadas en el apéndice 1. En secciones futuras se profundizará en esta parte.
4. El punto cuatro es el desarrollo de un set de datos diverso y multivariado con el objetivo de estudiar, analizar y definir las estrategias a seguir para el sistema de clasificación y análisis. En secciones futuras se profundizará en esta parte.
5. Finalmente, el desarrollo de la red neuronal profunda y las diversas pruebas de desempeño en sistema de simulación en tiempo real y en sistema monofásico.

En las secciones siguientes se presentará el desarrollo de los casos de estudio para analizar el desempeño de la metodología y además la adaptación diversa del modelo en distintos ámbitos como de software, simulaciones y sistemas monofásicos.

4.2 Generador de múltiples perturbaciones eléctricas

Para el desarrollo de el generador de perturbaciones eléctricas se utilizo el software de Matlab 2021-b y la aplicación de App Designer en conjunto claro con los modelos matemáticos de las perturbaciones eléctricas encontradas en el apendice 1. De manera general el pseudocódigo de síntesis de perturbaciones eléctricas el siguiente:

Algorithm 1: Síntesis de perturbaciones eléctricas

[1] Síntesis de perturbaciones eléctricas f frecuencia, A , $A \leftarrow$ amplitud $f \leftarrow$ frecuencia
 $PP \leftarrow$ vector parámetros de perturbación $t \leftarrow$ tiempo total $t_1 \leftarrow$ tiempo de inicio $t_2 \leftarrow$
tiempo de término $fs \leftarrow$ frecuencia de muestreo $unitstep(t_1, t_2) \leftarrow$ función escalón unitario
 $ModeloMatemático(t, unitstep, A)$ **return** perturbación

En la figura 4.2 se muestra la interfaz principal del generador de perturbaciones eléctricas. Apartir de esto podemos ver como el sistema se divide en:

- **Perturbaciones individuales:** es decir perturbaciones que afectan o amplitud o frecuencia.
- **Perturbaciones con dos fenómenos:** en la onda senoidal con un voltaje pico de 180 volts y una frecuencia de 60 hertz, se presentan dos fenomenos electromagneticos simultáneos que afectan la calidad de energía eléctrica.
- **Perturbaciones con tres fenómenos:** se presentan hasta 3 fenómenos electromágneticos que afectan la calidad de energía eléctricas.
- **Perturbaciones con cuatro fenómenos:** se presentan hasta 4 fenómenos electromágneticos que afectan la calidad de energía eléctricas, de manera simultanea.

Al elegir una de las opciones, las cuales son las diferentes perturbaciones eléctricas presentadas en el apéndice 1. Cuando se elige una de éstas opciones nos da una interfaz de amigable la cual se presenta en la figura 4.3. Podemos observar como la interfaz pide algunas parámetros como lo son la frecuencia en Hertz (Hz), tiempo de generación en segundos (s), ruido en la señal en decibeles (dB), tiempo de duración de las perturbación eléctrica y parámetros de síntesis de las perturbaciones eléctricas propias de las fórmulas dentro del apéndice 1. El único parámetro predefinido es el voltaje pico el cual tiene un valor de 180 volts. Es importante mencionar que la onda senoidal normal o de buena calidad es la definida por el código de red de la Comisión General de Electricidad. El cual tiene una descripción de 60 hertz y 180 volts pico con una variabilidad de 10%.

Es importante mencionar que se tiene al final cuatro botones con opciones diferentes:

- **Synthesize:** El cual al presionarlo realiza la síntesis de la señal con los parámetros que predifinimos y lanza una vista como el mostrado en la figura 4.4.
- **Synthesize Random Signal:** El cual al sistema sintetiza una señal completamente aleatoria en caso de que el usuario no quiera rellenar los campos mencionados anteriormente, y lanza una vista como el presentado en la figura 4.4.
- **Save:** El cual guarda en un archivo con extensión **.mat** la perturbación eléctrica con las características que predifinimos en los parámetros.



Figure 4.2: Menú principal del generador de perturbaciones.

- **Save Random Signal:** Esta opción sintetiza y guarda en un archivo con extensión **.mat** una perturbación con valores aleatorios en caso que el usuario no llene los parámetros de síntesis.

Y al final tenemos el botón de **Main Menu** el cual nos regresa al menú principal es decir al mismo de la figura 4.3.

La figura 4.4 es la síntesis de manera gráfica de las perturbación eléctrica que generamos apartir, se muestra el modelo matematico, el ruido en la señal y la imagen de las perturbación eléctrica.

De está manera con este software se generaron varias muestras de diversas perturbaciones eléctricas para el entrenamiento de la red neuronal.

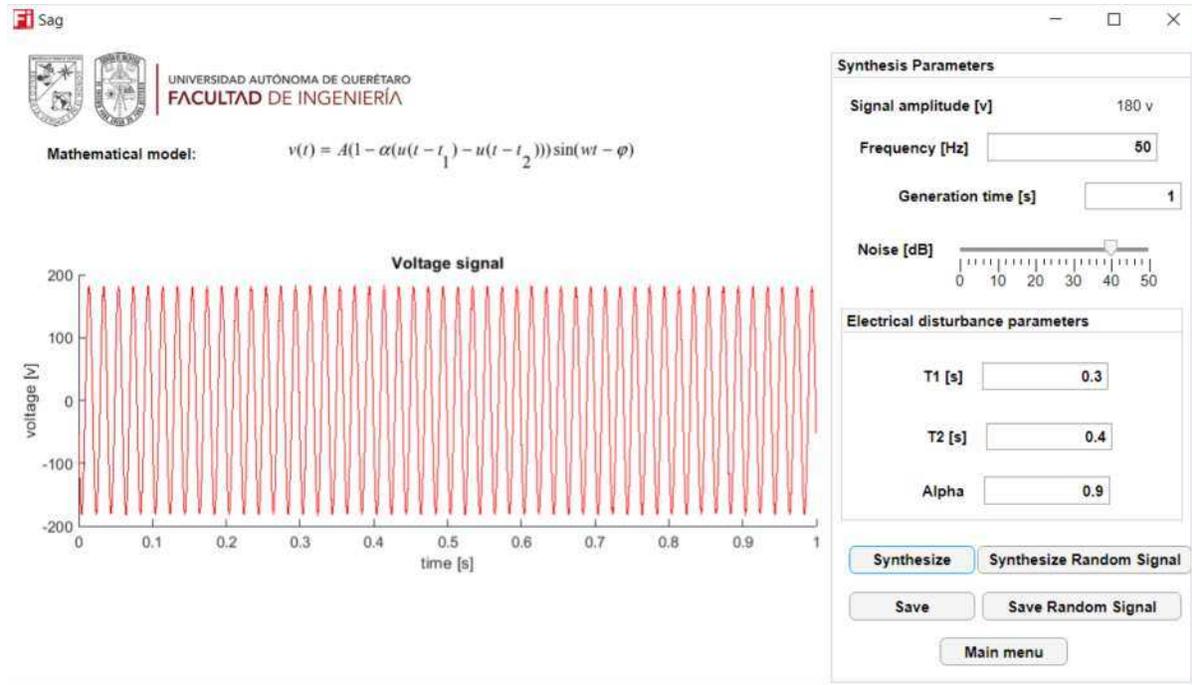


Figure 4.3: Menú principal del generador de perturbaciones.

4.3 Algoritmo de detección de perturbaciones

El algoritmo basado en la distancia al cuadrado de Euler es una técnica de procesamiento de señales o análisis de datos que se utiliza para medir la similitud o distancia entre dos señales o conjuntos de datos. La distancia al cuadrado de Euler se define como la suma de las diferencias al cuadrado entre las muestras correspondientes de dos señales. En la red monofásica es bien sabido que un conjunto de eventos nominales con diferentes fases forma un círculo en un espacio N-dimensional debido al comportamiento fasor de la señal de voltaje. En base a esto, el detector implementado utiliza el centro del espacio N-dimensional, c , como referencia para las señales de voltaje monitoreadas. Se define como: $\mathbf{c} = [0, 0, 0, 0, N]$ donde N es el número de muestras de la ventana de señal monitoreada.

A partir de esto se demuestra que todas las señales de tensión monitorizadas sin perturbación (señales nominales) presentan el mismo valor de distancia (el cuadrado de la distancia euclidiana) medidas desde ellas al centro, como lo muestra la siguiente fórmula $D(v, c) = E|v - c|^2$ Donde: D es la distancia euclidiana al cuadrado c y c son los vectores de la señal monitoreada y el centro, respectivamente. La metodología se compone de calcular la distancia euclidiana al cuadrado desde la señal de voltaje monitoreada hasta el centro (punto multidimensional c) y verificar si el valor de distancia obtenido está dentro del rango definido por un par de límites (superior e inferior) los cuales se determinan a partir del código de red que rige la Comisión Federal de Electricidad, que menciona límites del ± 10 [*]. Para la detección de perturbaciones en frecuencia se utilizó un filtro digital pasa bandas con los límites en frecuencia en ± 10 como lo dicta la normativa nacional en el código de red. En la tabla 6 se muestra el pseudocódigo para la detección de perturbaciones en frecuencia y amplitud.

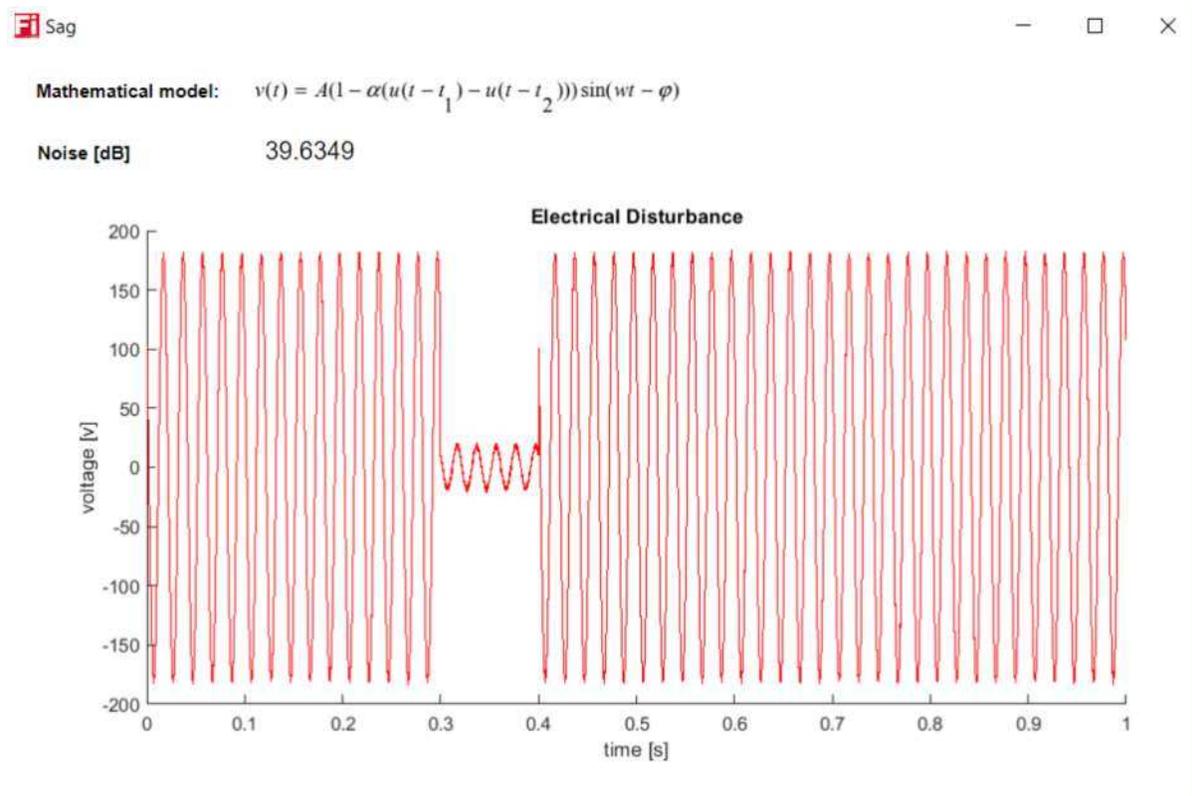


Figure 4.4: Vista secundaria de síntesis de perturbaciones eléctricas.

4.4 Diseño y desarrollo de Red Neuronal Profunda

4.4.1 Base de datos no relacional.

El segmento de datos es de las cosas más importantes para el diseño y desarrollo de redes neuronales, a partir de esto la conformación de la base o segmento de datos se compone de diversas fuentes:

- La base de datos [33] el cual está formada por 1000 instancias. La variable de salida (clase) consta de dos categorías: "stable" (estable) e "unstable" (inestable), que indican el estado de la red eléctrica en función de los atributos proporcionados.
- Power Quality Classification Dataset-1 tiene 11998 instancias con 7 clasificaciones diferentes.
- Set de datos sintetizado mediante aplicación desarrollada este set tiene cerca de 10000 instancias y 23 clasificaciones diferentes.

Al juntar estas tres fuentes de señales eléctricas se obtuvo un set diverso con las siguientes características:

- Contiene 22,998 registros
- 23 clasificaciones diferentes
- Algunos registros contienen ruido de entre 10 dB y 55 dB

Algorithm 2: `distanciaEuclidianaCuadradaConFiltroPasabajas(datos1, datos2, factorDeCorte)`

Data: `datos1, datos2, factorDeCorte`
Result: `distanciaEuclidianaCuadrada`
`datos1Filtrados = aplicarFiltroPasabajas(datos1, factorDeCorte);`
`datos2Filtrados = aplicarFiltroPasabajas(datos2, factorDeCorte);`
`sumaCuadradosDiferencia = 0;`
for *cada índice de 1 a longitud(datos1Filtrados)* **do**
 `diferencia = datos1Filtrados[i] - datos2Filtrados[i];`
 `_sumaCuadradosDiferencia += diferencia × diferencia`
return `sumaCuadradosDiferencia;`

- Diversidad en severidad de perturbaciones eléctricas
- Perturbaciones eléctricas múltiples con hasta 4 fenomenos electromagneticos en la onda

4.4.2 Diseño y desarrollo de Red Neuronal Profunda.

Para el entrenamiento de la red neuronal se realizó con la metodología de validación cruzada o k-fold. La validación cruzada, también conocida como cross-validation en inglés, es una técnica utilizada en el aprendizaje automático y la estadística para evaluar y validar modelos predictivos. La idea principal detrás de la validación cruzada es dividir los datos disponibles en un conjunto de entrenamiento y un conjunto de prueba de manera repetida y sistemática. Esto se hace para tener una estimación más precisa del rendimiento del modelo en datos no vistos y para evitar problemas como el sobreajuste (overfitting). El proceso de validación cruzada se realiza con los siguientes pasos y además se muestra en la figura 4.5.

- División de los datos: El conjunto de datos se divide en k subconjuntos más pequeños, llamados folds o pliegues. Cada fold actúa como un conjunto de prueba en una iteración y los demás folds se utilizan como conjunto de entrenamiento.
- Iteraciones: Se repite el proceso k veces, donde en cada iteración se elige un fold diferente como conjunto de prueba y los demás folds se utilizan como conjunto de entrenamiento.
- Evaluación del modelo: En cada iteración, se entrena el modelo utilizando el conjunto de entrenamiento y se evalúa su rendimiento utilizando el conjunto de prueba. Se registra una métrica de evaluación, como precisión, exactitud o error cuadrático medio.
- Promedio de resultados: Una vez que se han completado todas las iteraciones, se promedian los resultados obtenidos en cada una para obtener una medida general del rendimiento del modelo.

La validación cruzada proporciona una estimación más confiable del rendimiento del modelo al utilizar diferentes combinaciones de datos de entrenamiento y prueba en cada iteración. Esto permite detectar problemas como el sobreajuste y tener una idea más realista de cómo se comportará el modelo en datos no vistos. La validación cruzada es una técnica utilizada para evaluar y validar modelos predictivos y clasificatorios. Dividiendo los datos en conjuntos de entrenamiento y prueba

de manera sistemática, proporciona una estimación más precisa del rendimiento del modelo en datos no vistos y ayuda a evitar el sobreajuste. Es una herramienta esencial en el proceso de desarrollo y evaluación de modelos de aprendizaje automático.

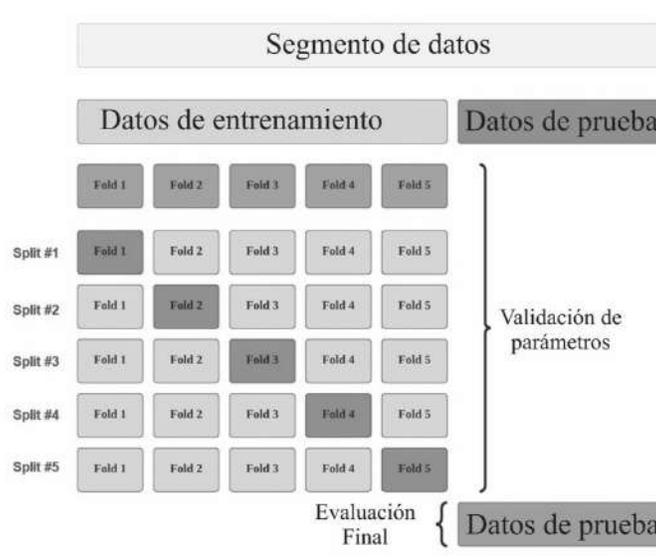


Figure 4.5: Validación cruda K-Fold.

La validación cruzada ofrece varias ventajas, como una evaluación más precisa del rendimiento del modelo y una reducción del riesgo de sobreajuste, ya que se evalúa en múltiples conjuntos de datos de prueba. Además de la validación cruzada en K-fold, existen otras variantes, como la validación cruzada Leave-One-Out (LOO), donde se utiliza un solo dato como conjunto de prueba en cada iteración, y la validación cruzada estratificada, que mantiene una distribución similar de clases en los conjuntos de prueba y entrenamiento.

4.5 Banco de pruebas

La Figura 4.6 muestra la metodología utilizada para analizar y clasificar los diferentes niveles de complejidad de las perturbaciones eléctricas en un ambiente simulado.

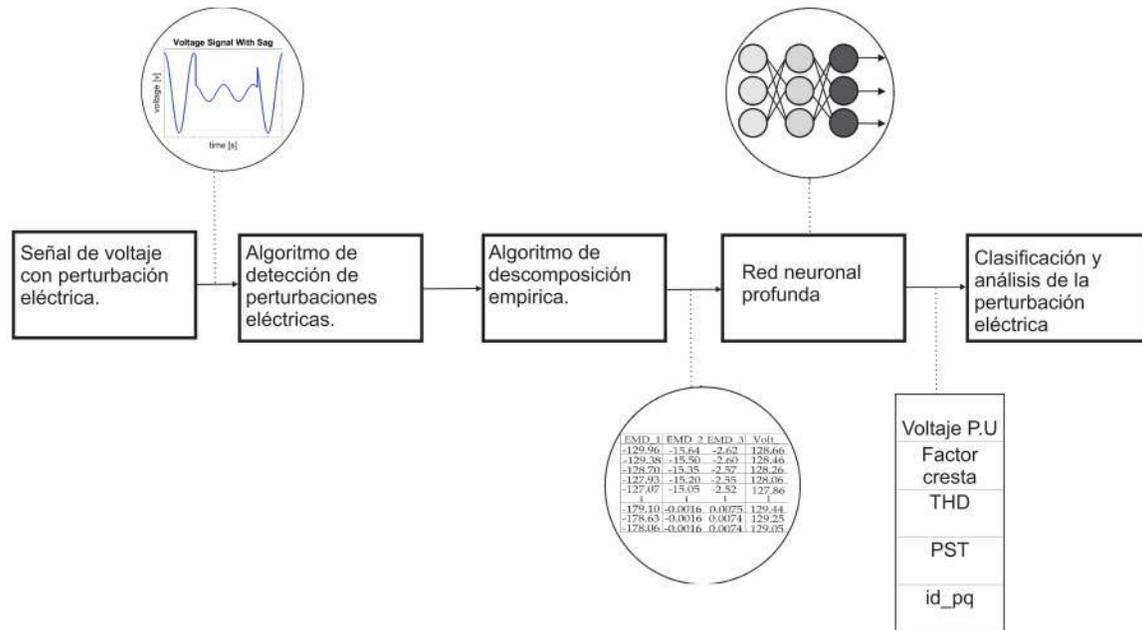


Figure 4.6: Validación cruda K-Fold.

En primer lugar, se encuentra el bloque de generación de perturbaciones eléctricas. En apartados posteriores se describirán con más detalle la naturaleza y propiedades de las diferentes perturbaciones eléctricas a lo largo de la propuesta de este artículo. El segundo bloque corresponde a la fase de extracción de las características de las diferentes perturbaciones eléctricas con el algoritmo de descomposición empírica, que se descompone en Funciones de Modo Intrínseco (IMF). Se recomiendan los tres primeros FMI para perturbaciones eléctricas ya que tienen información más relevante. Los dos primeros componentes contienen altas frecuencias y el tercero es información relacionada con perturbaciones en el componente fundamental. Además, esto se implementa para reducir el tiempo de consumo computacional y una respuesta rápida. Además de estos valores, se suma el valor de tensión de la perturbación eléctrica. Estos valores forman una matriz que comprende las tres columnas IMF y el valor de voltaje de la señal, que son los valores de entrada del sistema Multitasking Deep Neural Network.

Posteriormente, al introducir estos valores a la arquitectura de la Red Neural Multitarea, esta los procesa. En secciones posteriores, se analizará con más detalle la arquitectura y los componentes de esta red neuronal profunda multitarea. La salida de la arquitectura neuronal presenta un vector que se compone de dos grupos de campos. El primero es un identificador numérico del tipo de perturbación que va del 1 al 29; Las secciones posteriores explicarán qué asignación tiene cada uno de estos números. El otro grupo de valores es un elemento esencial para el análisis y cuantificación de la calidad de la energía eléctrica, es decir, evaluar la calidad en amplitud y frecuencia. Estos elementos incluyen voltaje por unidad, factor de cresta, distorsión armónica total (THD), percep-

tibilidad de parpadeo a corto plazo (Pst), área de muesca y profundidad.

El modelo de microrred utilizado es una red tipo isla con un sistema fotovoltaico desarrollado en el entorno Matlab 2021b con las herramientas Simulink y AppDesigner e introduce diferentes perturbaciones eléctricas con diferentes niveles de complejidad, como se muestra en el apartado anterior. Un sistema fotovoltaico integra principalmente la configuración del modelo de microrred tipo isla que se muestra en la Figura 1. Un usuario puede manipular las variables de temperatura e irradiación solar a través de una interfaz desarrollada en App Designer.

Los componentes del sistema incluyen: Generadores distribuidos: Un sistema solar fotovoltaico genera una potencia máxima de 250 kW en STC (temperatura de celda de 25 °C con irradiancia solar de 1000 Wm² Controlador de voltaje para generadores distribuidos: Controlador de carga tipo DC-DC Boost y un inversor de fuente de voltaje DC-AC (VSI). Inversor de voltaje: Para el inversor de fuente de voltaje (VSI), un inversor de puente completo funciona con una conmutación de 1000 Hz. Metodología de control para el controlador de voltaje: El sistema también tiene un controlador integrado de seguimiento del punto de máxima potencia (MPPT) con un controlador de voltaje tipo refuerzo DC-DC. El control MPPT ayuda a generar el voltaje adecuado extrayendo la máxima potencia y ajustando el ciclo de trabajo para evitar problemas de rendimiento debido a cambios de temperatura e irradiancia solar que se simulan en el sistema. Si bien se utilizó este modelo de microrred, es importante mencionar que la metodología está diseñada para ser implementada en diversas arquitecturas. Esto se debe a que sólo se utilizan señales de voltaje para clasificar y analizar múltiples perturbaciones eléctrica.

Bibliography

- [1] M. Gayatri, A. Parimi, and A. Pavan Kumar, “A review of reactive power compensation techniques in microgrids,” *Renewable and Sustainable Energy Reviews*, vol. 81, pp. 1030–1036, 2018.
- [2] M. A. Hossain, H. R. Pota, W. Issa, and M. J. Hossain, “Overview of ac microgrid controls with inverter-interfaced generations,” *Energies*, vol. 10, no. 9, 2017.
- [3] R. Kuceba, M. Zawada, M. Szajt, and J. Kowalik vol. 164, p. 012003, jun 2018.
- [4] Z. Luo, H. Geng, and G. Zhu, “Cooperative control for dc microgrid with large power disturbance,” in *2018 IEEE International Power Electronics and Application Conference and Exposition (PEAC)*, pp. 1–5, 2018.
- [5] H. Moussa, A. Shahin, J.-P. Martin, B. Nahid-Mobarakeh, S. Pierfederici, and N. Moubayed, “Harmonic power sharing with voltage distortion compensation of droop controlled islanded microgrids,” *IEEE Transactions on Smart Grid*, vol. 9, no. 5, pp. 5335–5347, 2018.
- [6] Y. Yoldaş, A. Önen, S. Muyeen, A. V. Vasilakos, and İrfan Alan, “Enhancing smart grid with microgrids: Challenges and opportunities,” *Renewable and Sustainable Energy Reviews*, vol. 72, pp. 205–214, 2017.
- [7] A. R. Devidas and M. V. Ramesh, “Cost optimal hybrid communication model for smart distribution grid,” *IEEE Transactions on Smart Grid*, vol. 13, no. 6, pp. 4931–4942, 2022.
- [8] “Current challenges and future trends in the field of communication architectures for microgrids,” *Renewable and Sustainable Energy Reviews*, vol. 82, pp. 3610–3622, 2018.
- [9] G. Abdunnasser, A. Ali, M. F. Shaaban, and E. E. Mohamed, “Stochastic multi-objectives optimal scheduling of energy hubs with responsive demands in smart microgrids,” *Journal of Energy Storage*, vol. 55, p. 105536, 2022.
- [10] E. G. Ribeiro, T. M. Mendes, G. L. Dias, E. R. Faria, F. M. Viana, B. H. Barbosa, and D. D. Ferreira, “Real-time system for automatic detection and classification of single and multiple power quality disturbances,” *Measurement*, vol. 128, pp. 276–283, 2018.
- [11] K. Cai, T. Hu, W. Cao, and G. Li, “Classifying power quality disturbances based on phase space reconstruction and a convolutional neural network,” *Applied Sciences*, vol. 9, no. 18, 2019.

- [12] N. Huang, H. Peng, G. Cai, and J. Chen, "Power quality disturbances feature selection and recognition using optimal multi-resolution fast s-transform and cart algorithm," *Energies*, vol. 9, no. 11, 2016.
- [13] S. Wang and H. Chen, "A novel deep learning method for the classification of power quality disturbances using deep convolutional neural network," *Applied Energy*, vol. 235, pp. 1126–1140, 2019.
- [14] R. Gong and T. Ruan, "A new convolutional network structure for power quality disturbance identification and classification in micro-grids," *IEEE Access*, vol. 8, pp. 88801–88814, 2020.
- [15] H. Xue, A. Chen, D. Zhang, and C. Zhang, "A novel deep convolution neural network and spectrogram based microgrid power quality disturbances classification method," in *2020 IEEE Applied Power Electronics Conference and Exposition (APEC)*, pp. 2303–2307, 2020.
- [16] S. Suganthi, A. Vinayagam, V. Veerasamy, A. Deepa, M. Abouhawwash, and M. Thirumeni, "Detection and classification of multiple power quality disturbances in microgrid network using probabilistic based intelligent classifier," *Sustainable Energy Technologies and Assessments*, vol. 47, p. 101470, 2021.
- [17] S. Chamchuen, A. Siritaratiwat, P. Fuangfoo, P. Suthisopapan, and P. Khunkitti, "Adaptive salp swarm algorithm as optimal feature selection for power quality disturbance classification," *Applied Sciences*, vol. 11, no. 12, 2021.
- [18] A. Saxena, A. M. Alshamrani, A. F. Alrasheedi, K. A. Alnowibet, and A. W. Mohamed, "A hybrid approach based on principal component analysis for power quality event classification using support vector machines," *Mathematics*, vol. 10, no. 15, 2022.
- [19] S. Banerjee and P. S. Bhowmik, "A machine learning approach based on decision tree algorithm for classification of transient events in microgrid," *Electrical Engineering*, pp. 1–11, 2023.
- [20] G. Bayrak, A. Küçüker, and A. Yılmaz, "Deep learning-based multi-model ensemble method for classification of pqds in a hydrogen energy-based microgrid using modified weighted majority algorithm," *International Journal of Hydrogen Energy*, vol. 48, no. 18, pp. 6824–6836, 2023.
- [21] R. Igual and C. Medrano, "Research challenges in real-time classification of power quality disturbances applicable to microgrids: A systematic review," *Renewable and Sustainable Energy Reviews*, vol. 132, p. 110050, 2020.
- [22] A. Kaur, J. Kaushal, and P. Basak, "A review on microgrid central controller," *Renewable and Sustainable Energy Reviews*, vol. 55, pp. 338–345, 2016.
- [23] G. Van den Broeck, J. Stuyts, and J. Driesen, "A critical review of power quality standards and definitions applied to dc microgrids," *Applied energy*, vol. 229, pp. 281–288, 2018.
- [24] Y. Naderi, S. H. Hosseini, S. G. Zadeh, B. Mohammadi-Ivatloo, M. Savaghebi, and J. M. Guerrero, "An optimized direct control method applied to multilevel inverter for microgrid power quality enhancement," *International Journal of Electrical Power & Energy Systems*, vol. 107, pp. 496–506, 2019.

- [25] D. Y. Yamashita, I. Vechiu, and J.-P. Gaubert, “A review of hierarchical control for building microgrids,” *Renewable and Sustainable Energy Reviews*, vol. 118, p. 109523, 2020.
- [26] J. Sun, W. Chen, J. Yao, Z. Tian, and L. Gao, “Research on the roundness approximation search algorithm of si3n4 ceramic balls based on least square and emd methods,” *Materials*, vol. 16, no. 6, p. 2351, 2023.
- [27] A. Cuculić, L. Drašćić, I. Panić, and J. Čelić, “Classification of electrical power disturbances on hybrid-electric ferries using wavelet transform and neural network,” *Journal of marine science and engineering*, vol. 10, no. 9, p. 1190, 2022.
- [28] J. Lu, R. Xiong, J. Tian, C. Wang, C.-W. Hsu, N.-T. Tsou, F. Sun, and J. Li, “Battery degradation prediction against uncertain future conditions with recurrent neural network enabled deep learning,” *Energy Storage Materials*, 2022.
- [29] P. Celard, E. Iglesias, J. Sorribes-Fdez, R. Romero, A. S. Vieira, and L. Borrajo, “A survey on deep learning applied to medical images: from simple artificial neural networks to generative models,” *Neural Computing and Applications*, vol. 35, no. 3, pp. 2291–2323, 2023.
- [30] F. Sun, J. Sun, and Q. Zhao, “A deep learning method for predicting metabolite–disease associations via graph neural network,” *Briefings in Bioinformatics*, vol. 23, no. 4, p. bbac266, 2022.
- [31] R. Hu, J. Chen, and L. Zhou, “A transformer-based deep neural network for arrhythmia detection using continuous ecg signals,” *Computers in Biology and Medicine*, vol. 144, p. 105325, 2022.
- [32] G. Xu, X. Shen, S. Chen, Y. Zong, C. Zhang, H. Yue, M. Liu, F. Chen, and W. Che, “A deep transfer convolutional neural network framework for eeg signal classification,” *IEEE Access*, vol. 7, pp. 112767–112776, 2019.
- [33] V. Arzamasov, “Electrical Grid Stability Simulated Data .” UCI Machine Learning Repository, 2018. DOI: <https://doi.org/10.24432/C5PG66>.

Resultados

En las siguientes secciones se muestran los diferentes resultados obtenidos de la presente investigación.

5.1 Análisis de características de múltiples perturbaciones eléctricas.

La Extracción de Características mediante la Descomposición Empírica de Modos (EMD) es una técnica poderosa y versátil en el campo del procesamiento de señales que se utiliza para descomponer señales complejas en sus componentes intrínsecos llamados "modos". Estos modos representan las diferentes escalas temporales y características inherentes presentes en la señal original. Una vez que se ha realizado la descomposición, es posible extraer una variedad de características útiles de cada modo para analizar y comprender mejor la señal en cuestión.

En esta sección, exploraremos los resultados de la extracción de características de una señal utilizando EMD. Discutiremos cómo esta técnica permite descomponer la señal en sus componentes subyacentes y cómo las características derivadas de cada modo pueden proporcionar información valiosa para las distintas perturbaciones eléctricas múltiples que se estudiaron a lo largo de esta investigación.

En la 5.1 podemos observar la extracción de características de una perturbación en amplitud. En el inciso a) podemos ver la extracción sin ruido y el inciso b) es la misma perturbación, pero con 20 dB de ruido.

En la figura 5.2 podemos observar la extracción de características de Oscilatorio transitorio una perturbación peculiar debido a su naturaleza. Los osciladores transitorios se refieren a oscilaciones temporales o transitorias en una señal de corriente o voltaje que fluctúan antes de estabilizarse en un estado estacionario. En el inciso a) podemos ver la extracción sin ruido y el inciso b) es la misma perturbación, pero con 50 dB de ruido.

Es importante mencionar que las estrategias de extracción de características tradicionales las cuales discutiremos más adelante, funcionan bien con todas las perturbaciones individuales cuando la complejidad aumenta es debido a las perturbaciones múltiples. En la figura * vemos la combinación de 3 perturbaciones en un solo fenómeno:

- Sag (Hundimiento de Tensión): Un "sag" o "hundimiento de tensión" es una disminución

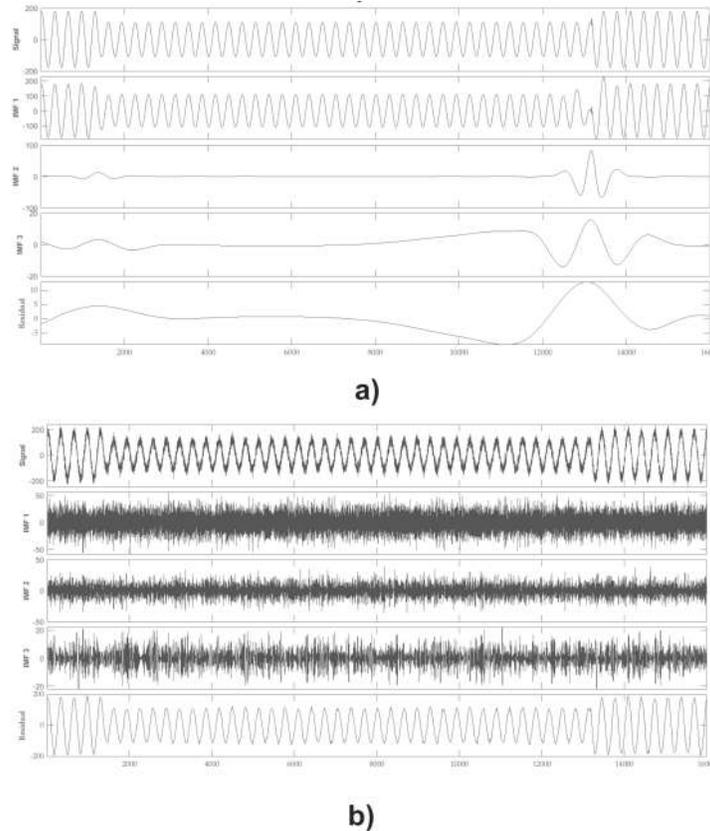


Figure 5.1: Extracción de características con EMD en perturbación en amplitud tipo sag: **a)** perturbación sin ruido. **b)** Perturbación con ruido

temporal de la tensión eléctrica por debajo de su valor nominal. Esto puede ocurrir debido a una variedad de razones, como el arranque de motores grandes o cortocircuitos en la red eléctrica. Los sags pueden causar problemas en equipos electrónicos sensibles y, a veces, se miden y cuantifican para evaluar la calidad de la energía eléctrica.

- **Harmonics (Armónicos):** Los "armónicos" son componentes de frecuencia no fundamental en una señal eléctrica, y generalmente son múltiplos de la frecuencia fundamental de la red eléctrica (por ejemplo, 60 Hz en América del Norte). Los armónicos pueden ser causados por cargas no lineales, como computadoras, equipos de soldadura y sistemas de alimentación conmutada, y pueden degradar la calidad de la energía eléctrica.
- **Flicker (Parpadeo):** El "flicker" se refiere a las variaciones rápidas y repetitivas en la luminosidad de las lámparas o dispositivos de iluminación debido a fluctuaciones en la tensión de la red eléctrica. El flicker puede ser causado por cambios rápidos en la carga de la red eléctrica y puede ser percibido incómodamente por los usuarios.

En la señal limpia a simple vista apenas podemos detectar todas las perturbaciones y en la señal con ruido se complica más. Sin embargo es importante mencionar cómo el algoritmo EMD detecta los puntos de inicio y término de la perturbación así como los puntos donde las demás perturbaciones se presentan.

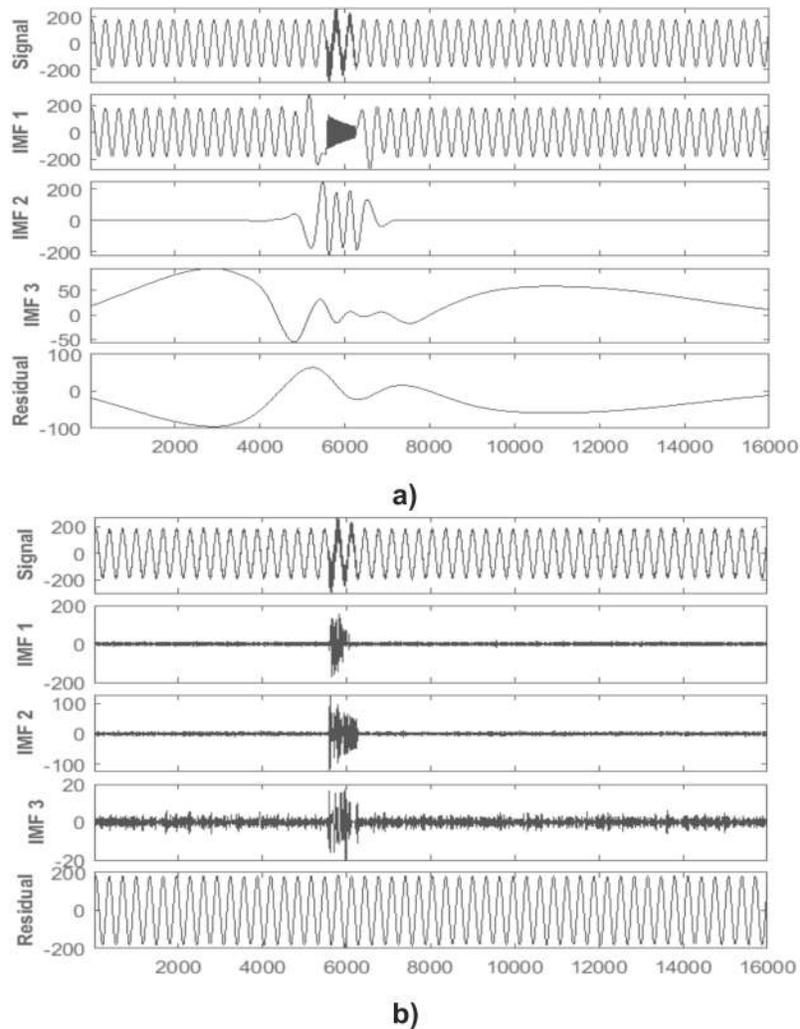


Figure 5.2: Extracción de características con EMD en perturbación en amplitud transitorio oscilatorio: **a)** perturbación sin ruido. **b)** Perturbación con ruido

En la siguiente figura podemos observar una perturbación múltiple con dos eventos: una elevación de tensión y un oscilatorio transitorio con una duración de 5 segundos. Podemos observar lo caótico que es esta perturbación, sin embargo, se detecta y separa de manera correcta la perturbación la parte de elevación y la parte del oscilatorio transitorio.

Un caso importante son las perturbaciones en frecuencia las cuales son la raíz del porque hay distintas metodologías de extracción de características y la complejidad aumenta por el ruido del sistema eléctrico monofásico. En la figura 5.4 podemos observar una de las perturbaciones más complejas de detectar un pico, espiga o "spike" eléctrico. En el contexto de sistemas eléctricos monofásicos, un "spike" se refiere a una breve y brusca sobretensión en la corriente o el voltaje eléctrico. Estos picos pueden ser causados por varias razones, y pueden tener un impacto negativo en los dispositivos eléctricos y electrónicos sensibles. Usualmente las razones pueden ser conmutación de cargas inductivas, condiciones de carga cambiantes o descargas eléctricas. En la figura ?? inciso b podemos observar como el algoritmo EMD de extracción de características, detecta de manera

adecuada la presencia de picos eléctricos. En la misma figura inciso b) podemos observar y aún con ruido detecta la presencia de este tipo de perturbaciones complejas.

En la figura 5.5 se muestra el mismo comportamiento, pero con muescas, otras perturbaciones complejas de procesar. En la misma figura inciso b) podemos observar el mismo fenómeno

Finalmente se muestra la extracción de características de parpadeo o flickers eléctricos. En la figura 5.6 se muestra en el inciso a) la perturbación sin ruido y el inciso b) perturbación con ruido.

5.2 Desarrollo de Red neuronal Profunda.

Los conceptos de parámetros e hiper parámetros dentro de los modelos de inteligencia artificial son confundidos muy a menudo. El concepto de parámetro se refiere a las variables que se estiman durante el proceso de entrenamiento con los conjuntos de datos. Los parámetros son la parte más importante en los modelos de inteligencia artificial como en redes neuronales los pesos sinápticos. Por otro lado, los hiperparámetros son los valores de las configuraciones utilizadas durante el proceso de entrenamiento. Por lo que se tiene que utilizar valores genéricos, reglas genéricas, los valores que han funcionado anteriormente en problemas similares o buscar la mejor opción mediante prueba y error. Siendo una buena opción buscar los hiperparámetros la validación cruzada. En esta sección se muestran estos dos elementos descriptivos y la arquitectura de la red neuronal final la cual se muestra en la figura 5.7.

Como podemos observar tenemos diferentes tipos de capas en las capas de entrada, en la capa oculta y en la capa de salida cada una de ellas tiene un propósito en específico en la tabla 5.1 se muestra la descripción y propósito de cada una de estas capas.

En la tabla 5.2 se muestran hiperparámetros utilizados para el desarrollo de la red neuronal artificial de aprendizaje múltiple.

En la figura 5.8 se muestran las curvas de entrenamiento del modelo para la tarea de clasificación. En la figura 5.9 se muestran las curvas de entrenamiento del modelo para la tarea de predicción de datos o análisis.

Por otro lado, al utilizarse la metodología de validación cruzada para el entrenamiento y la validación del modelo se obtuvo distintos valores de cuantificación en cada uno de los folds o iteraciones. En la figura 5.10 se muestran los resultados de la precisión en cada una de las iteraciones de validación cruzada.

5.3 Desempeño en banco de pruebas.

En esta sección se muestra los resultados de las pruebas de desempeño con la microrred eléctrica, primero se presenta el desempeño con red neuronal y después con un modelo de aprendizaje automático esto para hacer un estudio comparativo.

5.3.1 Desempeño con red neuronal profunda

En la figura 5.11 se presenta la matriz de correlación de la clasificación de perturbación eléctrica, de los primeros 16 niveles de perturbaciones eléctricas. En la figura 37 nos muestra la matriz de confusión de los demás niveles.

Table 5.1: Descripción de capas en red neuronal profunda.

Capas	Descripción
Capa Batch Normalization	En esta capa se normalizan las activaciones de la capa para que tenga una mediana cercana a cero los datos y una desviación estándar cercana a uno. Esto ayuda a estabilizar y acelerar el entrenamiento al mitigar los problemas asociados con el cambio de covariables internas (covariate shift) y proporcionar una normalización de los gradientes durante el retroceso.
Conv	La capa convolucional o Conv es un componente principal en redes neuronales dentro del campo de aprendizaje profundo. Extrae características importantes de la señal.
Pooling	La capa pooling o capa de agrupación tiene como función principal reducir la dimensionalidad espacial de las feature maps (mapas de características) obtenidas después de las capas de convolución. Esto ayuda a disminuir la carga computacional y el número de parámetros en la red, además de proporcionar cierta invariancia a la traslación y escalado en las características aprendidas.
Dropout	La idea detrás de esta capa es apagar de manera aleatoria un conjunto de unidades básicas o neuronas artificiales
Flatten	Es el proceso de convertir los datos multidimensionales (a menudo un tensor 3D) en un vector unidimensional, que luego se puede utilizar como entrada para una capa completamente conectada.
Max pool	La idea básica detrás de la capa de agrupación máxima es reducir la dimensionalidad espacial de la representación y, al mismo tiempo, retener las características más importantes.
SoftMax	La capa de activación softmax es utilizada comúnmente en la capa de salida de una red neuronal, especialmente en problemas de clasificación multiclase. Softmax toma un vector de números reales como entrada y los normaliza en un vector de probabilidades, donde la suma de todas las probabilidades es igual a 1.
Full connection	El término "fully connected layer" o "capa completamente conectada" para describir una capa donde cada neurona o unidad está conectada a todas las neuronas de la capa anterior

Table 5.2: Hiperparámetros en red neuronal profunda.

Hiperparámetros	Descripción	Configuración
Tasa de aprendizaje	Determina cuánto ajustamos los pesos de las conexiones entre las neuronas en cada iteración durante el entrenamiento. Si la tasa de aprendizaje es demasiado pequeña, el modelo puede tardar mucho tiempo en converger o puede quedarse atascado en un mínimo local. Si la tasa de aprendizaje es demasiado grande, el modelo puede oscilar y no converger.	0.03
Número de épocas	Una época o epoch se refiere a un ciclo completo a través de todo el conjunto de datos de entrenamiento. Una época se completa cuando el modelo ha visto y se ha entrenado con cada muestra en el conjunto de entrenamiento una vez.	150
Tamaño del lote (Batch Size)	Este parámetro define el número de ejemplos de entrenamiento que se utilizan en una iteración para actualizar los pesos del modelo durante el proceso de optimización.	
Función de pérdida	función de costo o función objetivo, es una medida que cuantifica cuán bien el modelo de aprendizaje automático está realizando en términos de predicciones en comparación con los valores reales.	Categorical Crossentropy
Optimizador	Ajustan los pesos de la red durante el entrenamiento para minimizar la función de pérdida.	adam

Por otro lado en la figura 5.11 y 5.12 se muestran los resultados del análisis de la perturbación en voltaje por unidad. Esto también es una salida de la red neuronal, como podemos observar nota de manera clara la presencia de perturbaciones en amplitud aunque exista un alto nivel de ruido en la señal.

En la figura 5.14 se muestra el análisis del factor de cresta, el cual es un factor para cuantificar el impacto en frecuencia, el valor normal es de 1 si este baja o sube de este valor estamos en presencia de una perturbación en frecuencia grave la cual puede afectar los aparatos electricos y electronicos de la arquitectura de la microrred.

5.3.2 Desempeño en tiempo real con aprendizaje automático

Para poder realizar una comparativa del estudio se utilizó aprendizaje máquina, de manera más concreta máquina de soporte vectorial. Una Máquina de Soporte Vectorial (SVM, por sus siglas en inglés, Support Vector Machine) es un modelo de aprendizaje supervisado que se utiliza tanto para clasificación como para regresión. Su objetivo principal es encontrar el hiperplano que mejor divide un conjunto de datos en clases o que mejor se ajusta a los datos en el caso de la regresión. Este modelo se desarrolló e implementó para pruebas en el banco de datos para tener una comparativa de metodologías, este modelo solo trabaja para clasificar perturbaciones eléctricas no hace un análisis cuantitativo para evaluar el impacto de las perturbaciones en el sistema, es decir es una metodología tradicional. En la figura 41 se muestra la matriz de confusión para ver de manera tangible la precisión, el cual es del 85%.

5.4 Discusiones

La clasificación de perturbaciones múltiples mediante el uso de redes neuronales representa un avance significativo en la comprensión y detección de eventos complejos en una amplia gama de campos, desde la geofísica hasta la medicina. Esta tesis se sumerge en el emocionante mundo de la clasificación de perturbaciones múltiples y ofrece una contribución sustancial a la literatura científica en este dominio. A lo largo de este trabajo de investigación, se han aplicado técnicas de aprendizaje profundo, específicamente redes neuronales, para abordar el desafío de identificar y caracterizar perturbaciones múltiples en datos heterogéneos y ruidosos. En esta sección se analizarán en detalle los hallazgos más significativos, las limitaciones del enfoque y las perspectivas para investigaciones futuras en el emocionante campo de la clasificación de perturbaciones múltiples utilizando redes neuronales. La extracción de características de señales es un proceso fundamental en el análisis de datos en una amplia gama de campos, desde el procesamiento de señales digitales hasta el aprendizaje automático y la visión por computadora. La elección de la estrategia de extracción de características adecuada es un factor crítico que puede tener un impacto significativo en la calidad de los resultados de análisis y las aplicaciones finales. En esta discusión, exploraremos diversas estrategias de extracción de características de señales, examinando cómo cada enfoque aborda de manera única los desafíos y los objetivos de análisis de señales. Desde el enfoque clásico de la transformación de Fourier hasta las técnicas más avanzadas basadas en redes neuronales, existen numerosas formas de extraer información relevante de señales en términos de características. Cada estrategia tiene sus propias ventajas y limitaciones, y la elección adecuada dependerá de la naturaleza de los datos y los objetivos de análisis. En esta discusión, exploraremos cómo estas estrategias pueden ser aplicadas en una variedad de dominios, como el procesamiento de señales de audio, imágenes médicas, datos geofísicos y mucho más. Además, examinaremos la evolución de

las estrategias de extracción de características a lo largo del tiempo, teniendo en cuenta los avances tecnológicos y la creciente disponibilidad de datos. También consideraremos cómo el aprendizaje automático y las técnicas de inteligencia artificial han influido en la forma en que se abordan las características de las señales, permitiendo enfoques más automatizados y robustos. En última instancia, esta discusión tiene como objetivo proporcionar una visión general de las estrategias de extracción de características de señales, destacando sus aplicaciones, ventajas y desafíos, con el fin de ayudar a los investigadores y profesionales a tomar decisiones informadas al abordar sus propios proyectos de análisis de señales. En la tabla 5.3 se muestra una comparativa de las diferentes estrategias de extracción de características esto con el objetivo de mostrar un panorama más completo de las ventajas y desventajas para la extracción de las señales eléctricas.

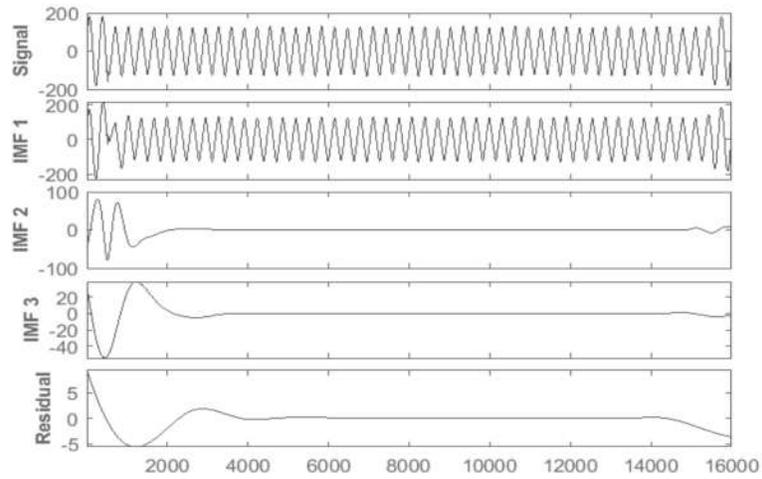
Existe una alta diversidad en metodologías de extracción de características, esto debido a que extracción de las características de las señales es un tema matemáticamente con un alto nivel de generación de conocimiento, la diversidad de señales y aplicaciones en campos como la ingeniería, la electrónica, la medicina, la geofísica, entre otros. Para la clasificación y análisis de las perturbaciones eléctricas múltiples el trabajo de identificar características es relevante sobre todo en perturbaciones ultrarrápidas y con niveles de ruido significativos como 20 dB o 30 dB. Debido a que puede afectar en las tareas de clasificar y analizar las perturbaciones eléctricas. Esto lo observamos en los resultados de las pruebas mismas que se discutirán más adelante. En la sección 5 podemos observar como el algoritmo de descomposición de modo empírica al adaptarse a señales no estacionarios se adapta y detecta perturbaciones ultrarrápidas como lo son las espigas eléctricas. Además, como podemos observar en la misma sección las perturbaciones múltiples, conforme aumenta el nivel o el número de perturbaciones y el ruido en la señal, el algoritmo extrae y detecta las perturbaciones eléctricas bajo este nivel de dificultad.

Table 5.3: Tabla comparativa de metodologías de extracción de características de señales.

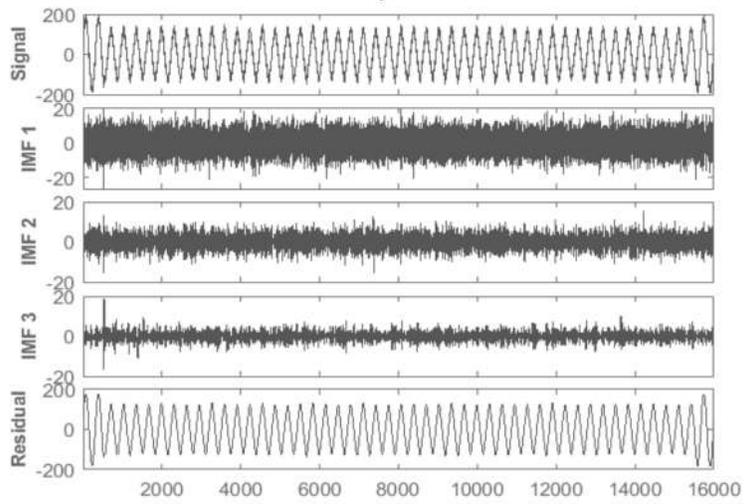
Metodología	Ventaja	Desventaja
Transformada de Fourier (FT)	Muestra el espectro en frecuencia de la perturbación eléctrica.	Limitaciones en la detección y análisis de señales con frecuencias que varían en el tiempo.
Transformada de Fourier de tiempo corto (STFT)	Capaz de rastrear adecuadamente las señales dinámicas debido a las limitaciones en su ancho de ventana de tiempo fijo.	La incapacidad para detectar y analizar bajas frecuencias y la resolución temporal incorrecta de eventos de alta frecuencia.
Transforma de Wavelet (WT)	Computacionalmente hablando es más rápida en comparación a FT. Además, proporciona un mejor ajuste a los datos con menos coeficientes.	Es sensible al ruido y esto pudiera afectar el análisis de la señal
Filtro Kalman	Buena estimación de la relación de cambio de frecuencia, amplitud y armónicos. Alta relación señal/ruido.	Diverge en algunas condiciones iniciales mal elegidas. La inestabilidad puede resultar en una estimación falsa del componente fundamental y armónico. Descomposición en los dominios de tiempo y frecuencia no presente.
Transformada Park	Bueno para el control orientado al campo (FOC) de motores. Conversión de cantidades de CA trifásicas a dos cantidades de CC.	No apto para monofásico
HOSA	Robustez al ruido, detecta transitorios de manera efectiva	Resolución limitada Difícil de analizar
PA	Robustez al ruido, detecta transitorios de manera efectiva	Este método da una estimación incorrecta en caso de que el modelo no coincida.
Transformada TT	Bueno para el control orientado al campo (FOC) de motores. Conversión de cantidades de CA trifásicas a dos cantidades de CC	No apto para sistemas monofásico
GT	Alta relación señal/ruido y buena resolución tiempo-frecuencia	Uso limitado a altas frecuencias, la complejidad computacional está directamente asociada con la frecuencia de muestreo
HHT (Hilbert and Hilbert-Huang Transform, por sus siglas en inglés)	Extrae con éxito las características de la señal distorsionada. La evaluación de la fase y la magnitud es bastante fácil.	Alto consumo computacional por extracción de características

Table 5.4: Tabla comparativa de metodologías de extracción de características de señales.

Metodología	Ventaja	Desventaja
EMD	Una de las mayores ventajas del algoritmo EMD es su capacidad para adaptarse y descomponer señales no estacionarias en Modos Intrínsecos (IMFs) que representan componentes locales de frecuencia y amplitud. Esto lo hace especialmente útil en situaciones donde las propiedades de la señal pueden cambiar con el tiempo	Alto consumo computacional por extracción de características

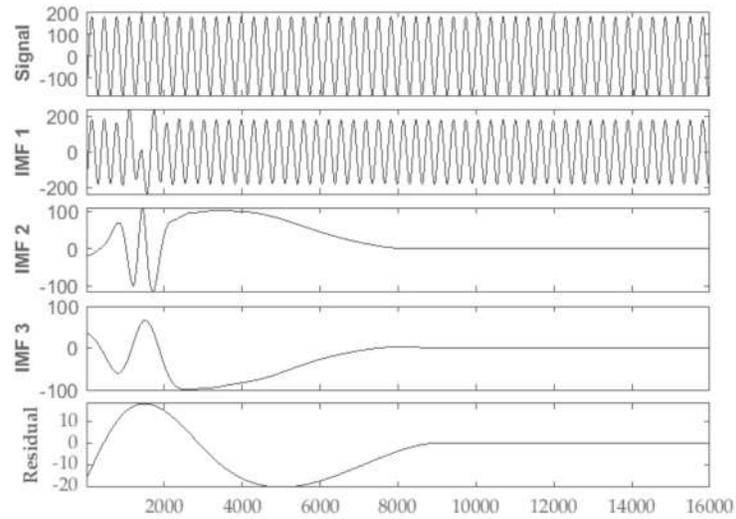


a)

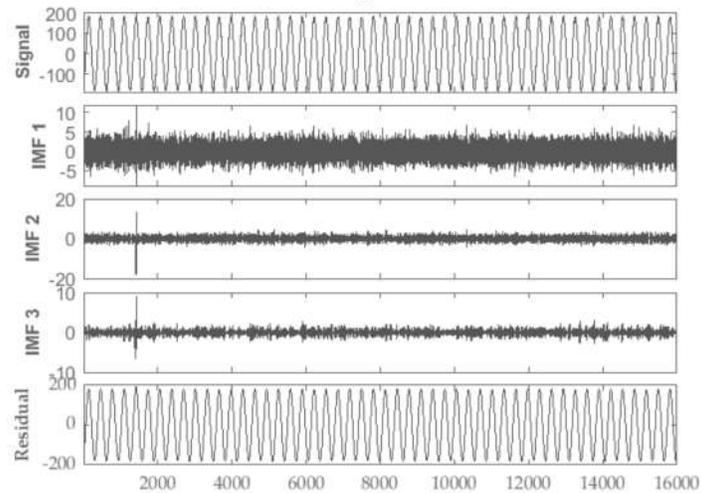


b)

Figure 5.3: Extracción de características con EMD en perturbación en amplitud transitorio oscilatorio: **a)** perturbación sin ruido. **b)** Perturbación con ruido

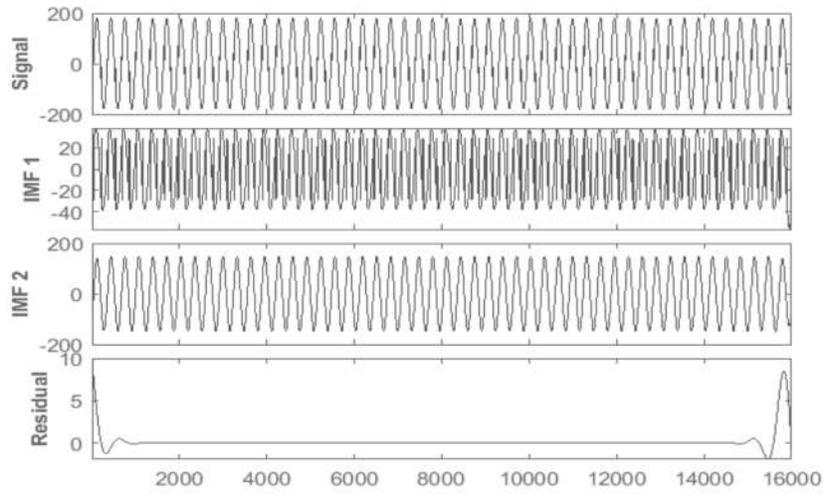


a)

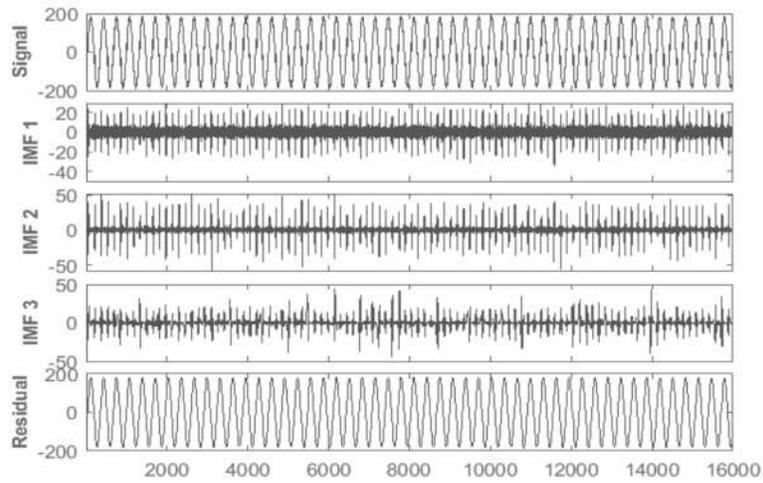


b)

Figure 5.4: Extracción de características con EMD en perturbación tipo espiga: a) perturbación sin ruido. b) Perturbación con ruido

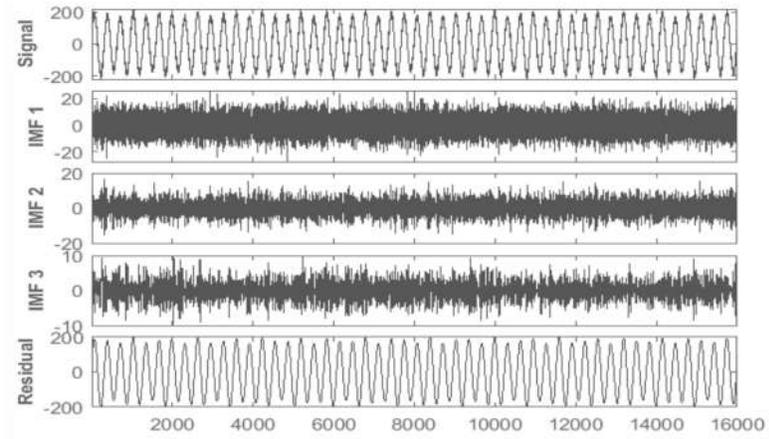


a)

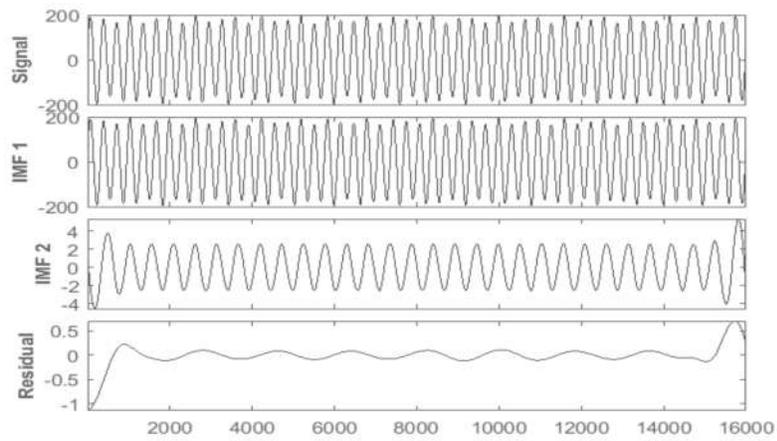


b)

Figure 5.5: Extracción de características con EMD en perturbación muesca o notch: **a)** perturbación sin ruido. **b)** Perturbación con ruido



a)



b)

Figure 5.6: Extracción de características con EMD en perturbación flicker o parpadeo: **a)** perturbación sin ruido. **b)** Perturbación con ruido

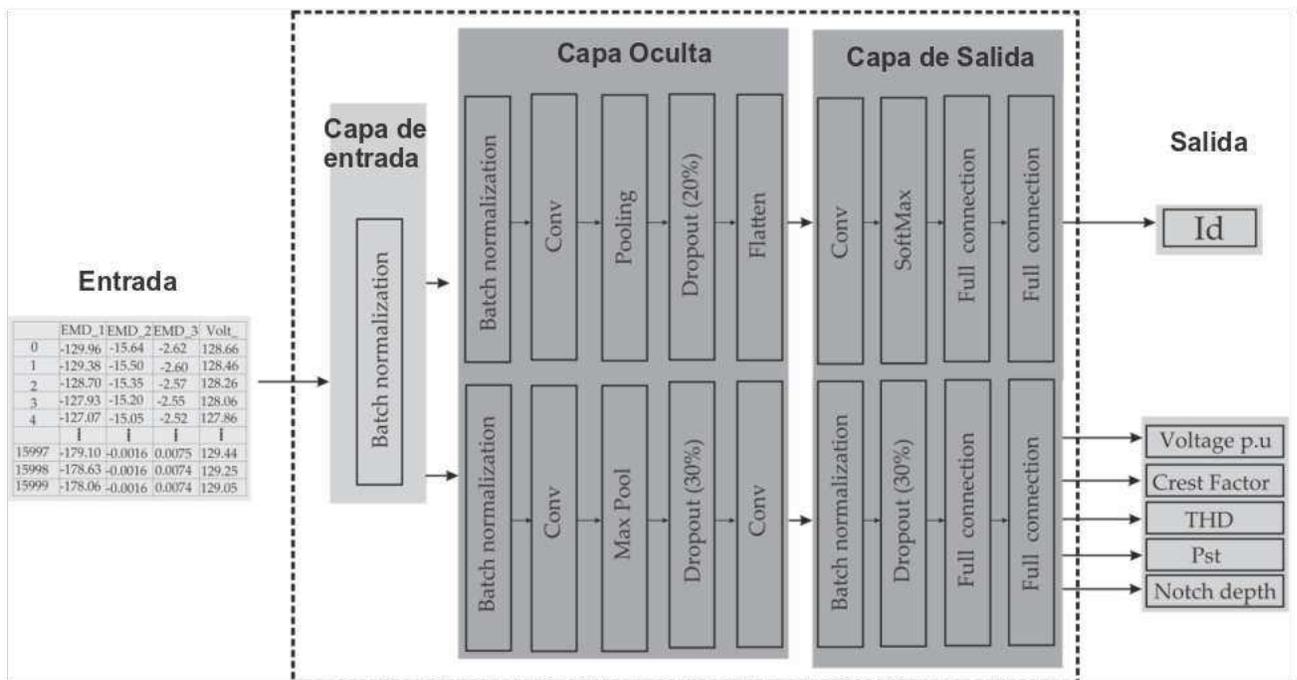


Figure 5.7: Arquitectura de red neuronal multitareas

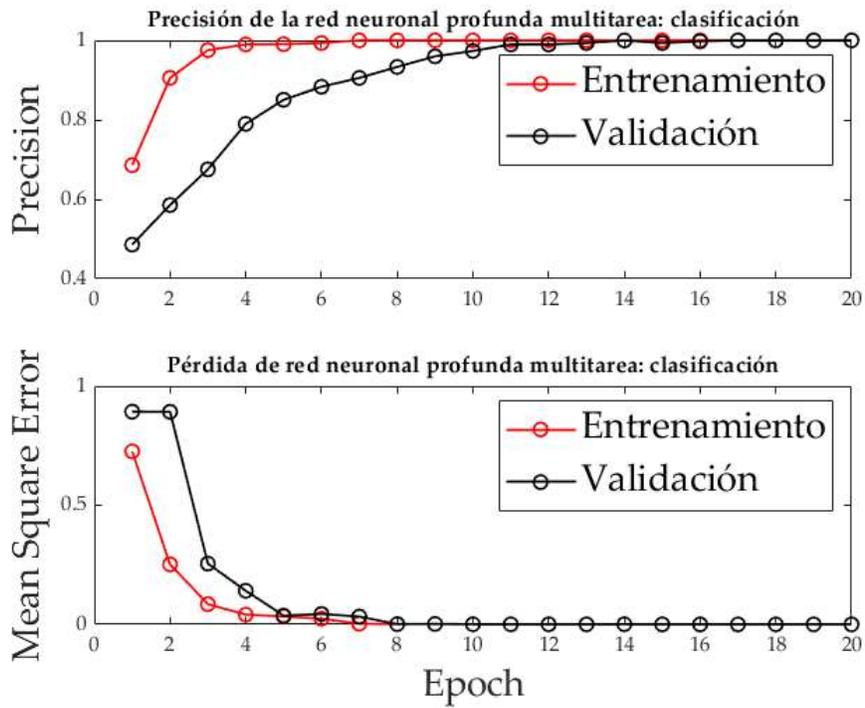


Figure 5.8: curvas de entrenamiento del modelo para la tarea de clasificación..

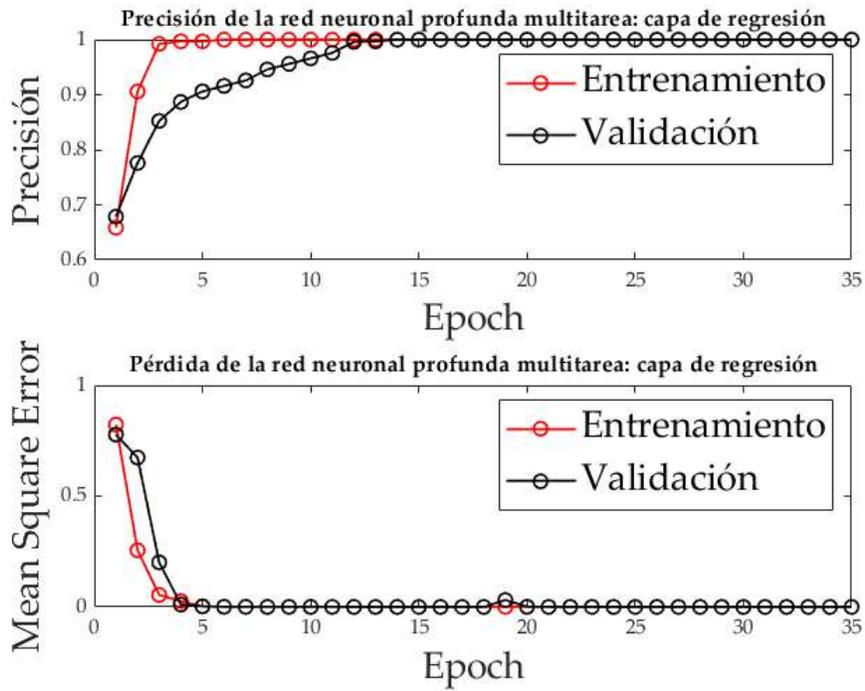


Figure 5.9: curvas de entrenamiento del modelo para la tarea de predicción de datos o análisis..

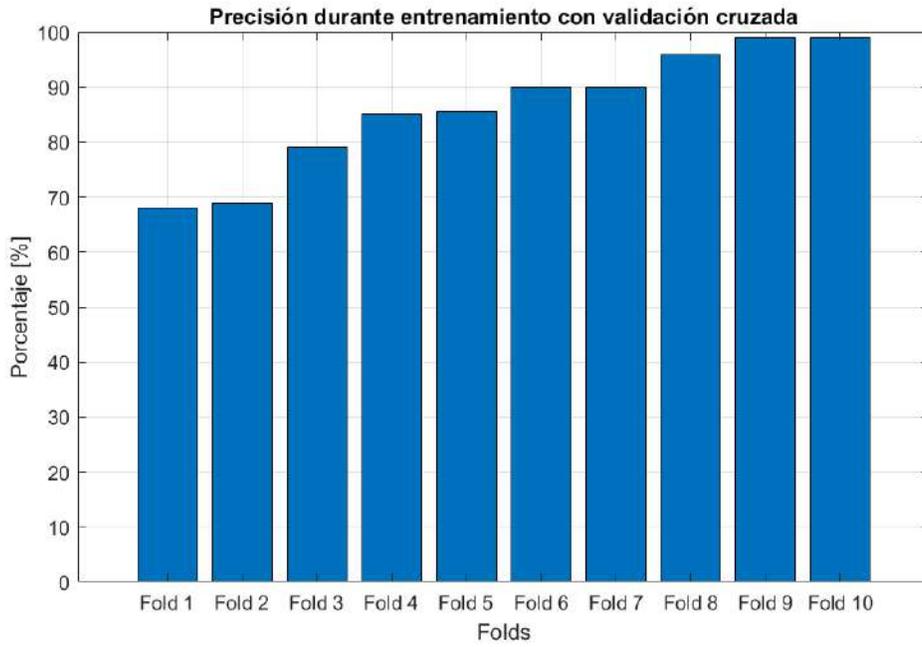


Figure 5.10: Iteraciones de entrenamiento utilizando validación cruzada.

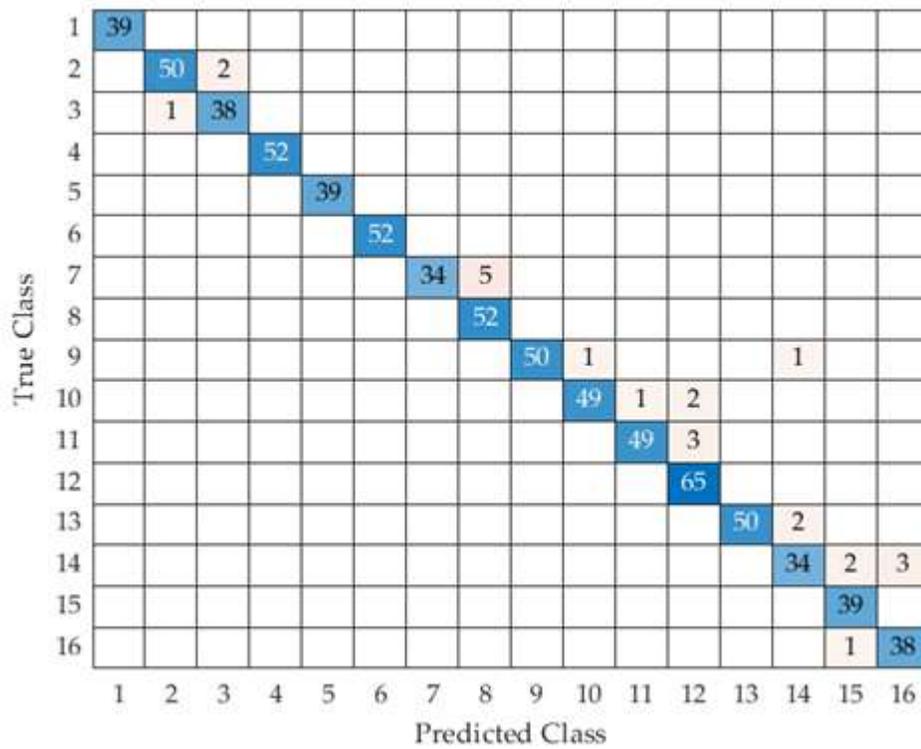


Figure 5.11: matriz de confusión en red neuronal - Parte 1.

17	40	2	2											
18	1	52	2											
19		2	52	1										
20				53	2									
21					53	2								
22					3	52								
23							51	4						
24						1	1	42						
25									44					
26									2	42				
27									1	2	41			
28											1	43		
29											4	4	36	
	17	18	19	20	21	22	23	24	25	26	27	28	29	
														Predicted Class

Figure 5.12: matriz de confusión en red neuronal - Parte 1.

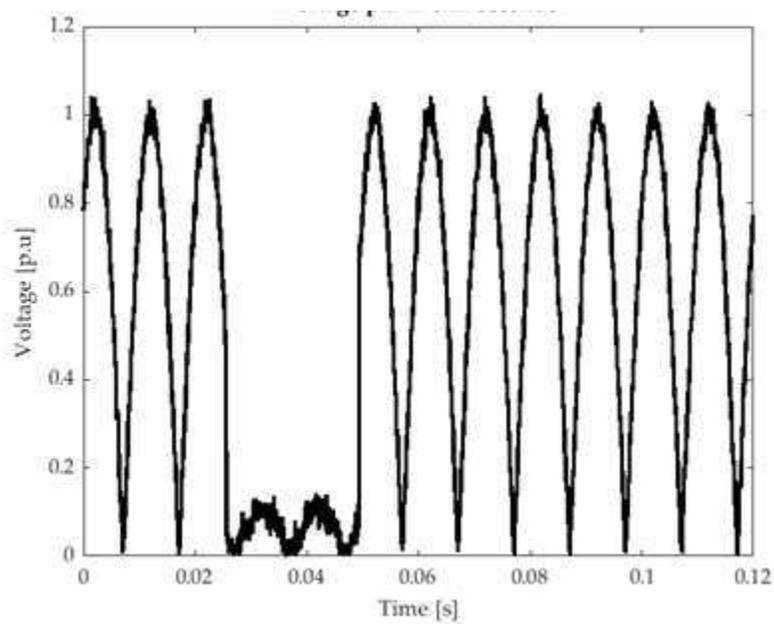


Figure 5.13: Análisis con factor cresta.

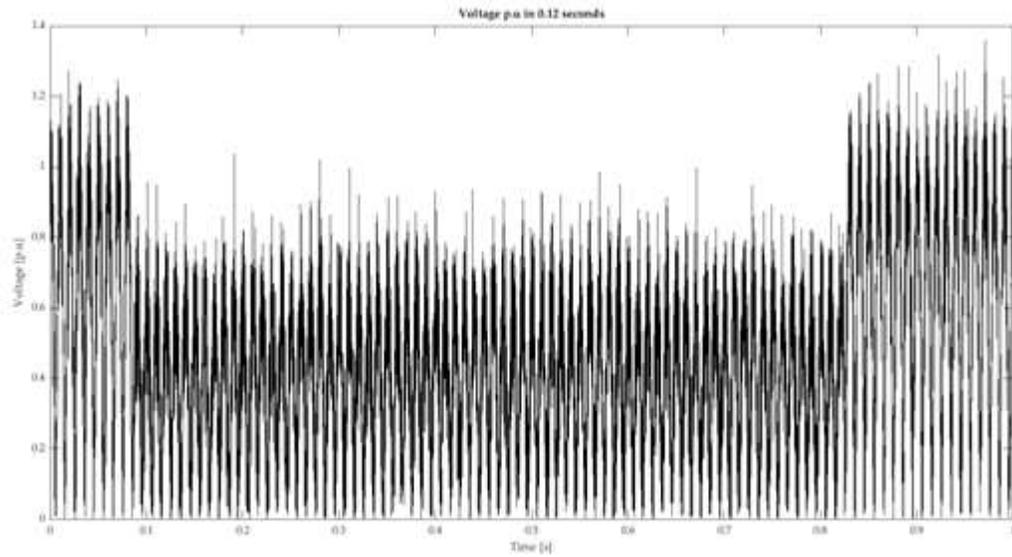


Figure 5.14: Análisis en voltaje por unidad (p.u).

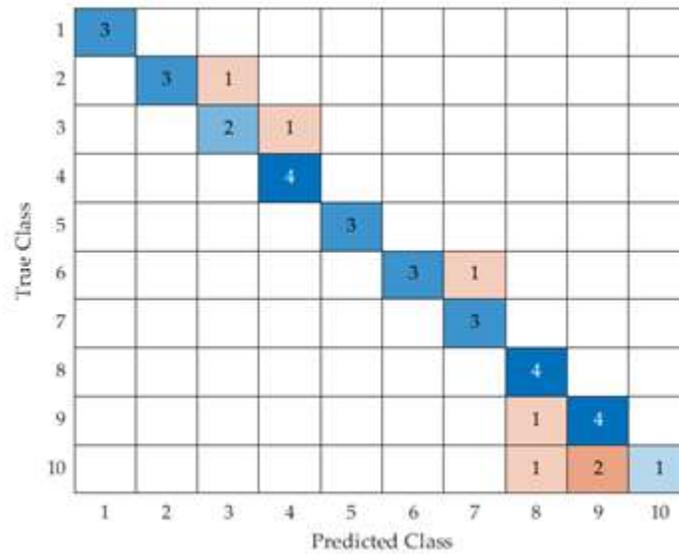


Figure 5.15: Matriz de confusión parte 1- Máquina de soporte vectorial.

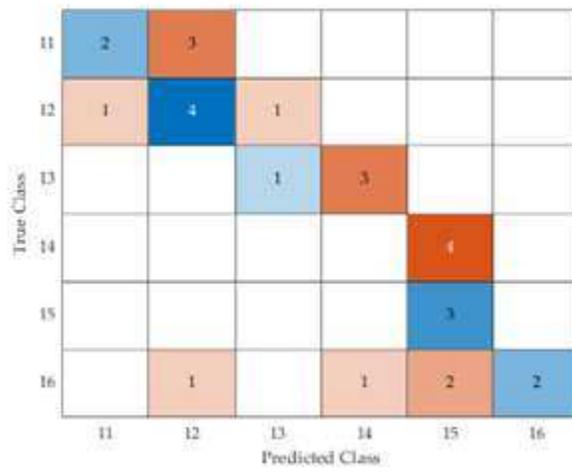


Figure 5.16: Matriz de confusión parte 2- Máquina de soporte vectorial.

Conclusión

Dentro de esta investigación hay alegatos finales para resaltar como lo son:

- Las perturbaciones eléctricas tienen una naturaleza aleatoria en tiempo y duración, haciendo que su estudio y análisis tenga un grado de complejidad elevado. Debido a esto ciertas metodologías basadas en probabilidad pudieran no funcionar de manera adecuada al ser aplicadas en ambientes reales. En otras palabras debido a la naturaleza intrínseca de las perturbaciones eléctricas metodologías basadas en aprendizaje automático no siempre son adecuados en todos los escenarios de los esquemas de generación de energía.
- Extraer las características de una señal es una fase primaria para la correcta clasificación de las perturbaciones eléctricas. Solo analizar y procesar las características que definen las propiedades de una perturbación reduce consumo computacional y aumenta porcentaje de precisión.
- El consumo computacional en este tipo de sistemas colaborativos es importante para poder trabajar en tiempo real sobretodo por la naturaleza del problema.
- Clasificar a veces no contiene la información necesaria para tomar acciones o para cuantificar en este caso perturbaciones eléctricas. Es necesario analizar y calcular en las métricas primarias de las señales eléctricas para tener información significativa y cuantificar la calidad de la onda.
- Apartir de la cuantificación de las perturbaciones eléctricas se tiene una optimización importante en cuando a control en sistemas de generación eléctrica.
- Además integramos ciencia de datos para los diferentes reportes de energía de calidad eléctrica, monofásico o trifásico. De esta manera visualmente podemos observar el comportamiento y la calidad de energía eléctrica.

En esta investigación se inicia y marca una línea de investigación de la aplicación de la inteligencia artificial en esquemas de generación de energía eléctrica. Como pudimos mostrar las áreas de investigación y desarrollo de inteligencia artificial en las microrredes eléctricas son diversas y las metodologías aún más. El rol de la inteligencia artificial se enfrenta a diferentes retos, oportunidades, retos y debilidades sobretodo por la evolución tecnológica y las necesidades de calidad de energía eléctrica. Apartir de esta investigación se deja claramente un camino trazado para iniciar en los demás ámbitos los estudios de las microrredes eléctricas inteligentes con inteligencia artificial.

Bibliography

- [1] M. Gayatri, A. Parimi, and A. Pavan Kumar, “A review of reactive power compensation techniques in microgrids,” *Renewable and Sustainable Energy Reviews*, vol. 81, pp. 1030–1036, 2018.
- [2] M. A. Hossain, H. R. Pota, W. Issa, and M. J. Hossain, “Overview of ac microgrid controls with inverter-interfaced generations,” *Energies*, vol. 10, no. 9, 2017.
- [3] R. Kuceba, M. Zawada, M. Szajt, and J. Kowalik vol. 164, p. 012003, jun 2018.
- [4] Z. Luo, H. Geng, and G. Zhu, “Cooperative control for dc microgrid with large power disturbance,” in *2018 IEEE International Power Electronics and Application Conference and Exposition (PEAC)*, pp. 1–5, 2018.
- [5] H. Moussa, A. Shahin, J.-P. Martin, B. Nahid-Mobarakeh, S. Pierfederici, and N. Moubayed, “Harmonic power sharing with voltage distortion compensation of droop controlled islanded microgrids,” *IEEE Transactions on Smart Grid*, vol. 9, no. 5, pp. 5335–5347, 2018.
- [6] Y. Yoldaş, A. Önen, S. Muyeen, A. V. Vasilakos, and İrfan Alan, “Enhancing smart grid with microgrids: Challenges and opportunities,” *Renewable and Sustainable Energy Reviews*, vol. 72, pp. 205–214, 2017.
- [7] A. R. Devidas and M. V. Ramesh, “Cost optimal hybrid communication model for smart distribution grid,” *IEEE Transactions on Smart Grid*, vol. 13, no. 6, pp. 4931–4942, 2022.
- [8] “Current challenges and future trends in the field of communication architectures for microgrids,” *Renewable and Sustainable Energy Reviews*, vol. 82, pp. 3610–3622, 2018.
- [9] G. Abdunnasser, A. Ali, M. F. Shaaban, and E. E. Mohamed, “Stochastic multi-objectives optimal scheduling of energy hubs with responsive demands in smart microgrids,” *Journal of Energy Storage*, vol. 55, p. 105536, 2022.
- [10] E. G. Ribeiro, T. M. Mendes, G. L. Dias, E. R. Faria, F. M. Viana, B. H. Barbosa, and D. D. Ferreira, “Real-time system for automatic detection and classification of single and multiple power quality disturbances,” *Measurement*, vol. 128, pp. 276–283, 2018.
- [11] K. Cai, T. Hu, W. Cao, and G. Li, “Classifying power quality disturbances based on phase space reconstruction and a convolutional neural network,” *Applied Sciences*, vol. 9, no. 18, 2019.

- [12] N. Huang, H. Peng, G. Cai, and J. Chen, "Power quality disturbances feature selection and recognition using optimal multi-resolution fast s-transform and cart algorithm," *Energies*, vol. 9, no. 11, 2016.
- [13] S. Wang and H. Chen, "A novel deep learning method for the classification of power quality disturbances using deep convolutional neural network," *Applied Energy*, vol. 235, pp. 1126–1140, 2019.
- [14] R. Gong and T. Ruan, "A new convolutional network structure for power quality disturbance identification and classification in micro-grids," *IEEE Access*, vol. 8, pp. 88801–88814, 2020.
- [15] H. Xue, A. Chen, D. Zhang, and C. Zhang, "A novel deep convolution neural network and spectrogram based microgrid power quality disturbances classification method," in *2020 IEEE Applied Power Electronics Conference and Exposition (APEC)*, pp. 2303–2307, 2020.
- [16] S. Suganthi, A. Vinayagam, V. Veerasamy, A. Deepa, M. Abouhawwash, and M. Thirumeni, "Detection and classification of multiple power quality disturbances in microgrid network using probabilistic based intelligent classifier," *Sustainable Energy Technologies and Assessments*, vol. 47, p. 101470, 2021.
- [17] S. Chamchuen, A. Siritaratiwat, P. Fuangfoo, P. Suthisopapan, and P. Khunkitti, "Adaptive salp swarm algorithm as optimal feature selection for power quality disturbance classification," *Applied Sciences*, vol. 11, no. 12, 2021.
- [18] A. Saxena, A. M. Alshamrani, A. F. Alrasheedi, K. A. Alnowibet, and A. W. Mohamed, "A hybrid approach based on principal component analysis for power quality event classification using support vector machines," *Mathematics*, vol. 10, no. 15, 2022.
- [19] S. Banerjee and P. S. Bhowmik, "A machine learning approach based on decision tree algorithm for classification of transient events in microgrid," *Electrical Engineering*, pp. 1–11, 2023.
- [20] G. Bayrak, A. Küçüker, and A. Yılmaz, "Deep learning-based multi-model ensemble method for classification of pqds in a hydrogen energy-based microgrid using modified weighted majority algorithm," *International Journal of Hydrogen Energy*, vol. 48, no. 18, pp. 6824–6836, 2023.
- [21] R. Igual and C. Medrano, "Research challenges in real-time classification of power quality disturbances applicable to microgrids: A systematic review," *Renewable and Sustainable Energy Reviews*, vol. 132, p. 110050, 2020.
- [22] A. Kaur, J. Kaushal, and P. Basak, "A review on microgrid central controller," *Renewable and Sustainable Energy Reviews*, vol. 55, pp. 338–345, 2016.
- [23] G. Van den Broeck, J. Stuyts, and J. Driesen, "A critical review of power quality standards and definitions applied to dc microgrids," *Applied energy*, vol. 229, pp. 281–288, 2018.
- [24] Y. Naderi, S. H. Hosseini, S. G. Zadeh, B. Mohammadi-Ivatloo, M. Savaghebi, and J. M. Guerrero, "An optimized direct control method applied to multilevel inverter for microgrid power quality enhancement," *International Journal of Electrical Power & Energy Systems*, vol. 107, pp. 496–506, 2019.

- [25] D. Y. Yamashita, I. Vechiu, and J.-P. Gaubert, “A review of hierarchical control for building microgrids,” *Renewable and Sustainable Energy Reviews*, vol. 118, p. 109523, 2020.
- [26] J. Sun, W. Chen, J. Yao, Z. Tian, and L. Gao, “Research on the roundness approximation search algorithm of si3n4 ceramic balls based on least square and emd methods,” *Materials*, vol. 16, no. 6, p. 2351, 2023.
- [27] A. Cuculić, L. Drašćić, I. Panić, and J. Čelić, “Classification of electrical power disturbances on hybrid-electric ferries using wavelet transform and neural network,” *Journal of marine science and engineering*, vol. 10, no. 9, p. 1190, 2022.
- [28] J. Lu, R. Xiong, J. Tian, C. Wang, C.-W. Hsu, N.-T. Tsou, F. Sun, and J. Li, “Battery degradation prediction against uncertain future conditions with recurrent neural network enabled deep learning,” *Energy Storage Materials*, 2022.
- [29] P. Celard, E. Iglesias, J. Sorribes-Fdez, R. Romero, A. S. Vieira, and L. Borrajo, “A survey on deep learning applied to medical images: from simple artificial neural networks to generative models,” *Neural Computing and Applications*, vol. 35, no. 3, pp. 2291–2323, 2023.
- [30] F. Sun, J. Sun, and Q. Zhao, “A deep learning method for predicting metabolite–disease associations via graph neural network,” *Briefings in Bioinformatics*, vol. 23, no. 4, p. bbac266, 2022.
- [31] R. Hu, J. Chen, and L. Zhou, “A transformer-based deep neural network for arrhythmia detection using continuous ecg signals,” *Computers in Biology and Medicine*, vol. 144, p. 105325, 2022.
- [32] G. Xu, X. Shen, S. Chen, Y. Zong, C. Zhang, H. Yue, M. Liu, F. Chen, and W. Che, “A deep transfer convolutional neural network framework for eeg signal classification,” *IEEE Access*, vol. 7, pp. 112767–112776, 2019.
- [33] V. Arzamasov, “Electrical Grid Stability Simulated Data .” UCI Machine Learning Repository, 2018. DOI: <https://doi.org/10.24432/C5PG66>.

Modelos matemáticos de múltiples perturbaciones eléctricas

Perturbación Eléctrica	Identificador	Modelo Matemático	Parámetros
Señal Normal	1	$v(t) = 180 \sin(\omega t - \phi)$	<i>Frecuencia = 60Hertz</i> <i>Amplitude = 180V</i> $\omega = 2\pi * 60 \frac{rad}{s}$
Sag	2	$v(t) = 180(1 - \alpha(u(t - t_1) - u(t - t_2))) \sin(\omega t - \phi)$	$0.1 \leq \alpha \leq 0.9$
Swell	3	$v(t) = 180(1 + \beta(u(t - t_1) - u(t - t_2))) \sin(\omega t - \phi)$	$0.1 \leq \beta \leq 0.9$
Interrupción	4	$v(t) = 180(1 + \rho(u(t - t_1) - u(t - t_2))) \sin(\omega t - \phi)$	$0.9 \leq \rho \leq 1$
Spikes, impulsos transitorios	5	$v(t) = 180 [\sin(\omega t - \phi) - \psi (e^{-750(t-t_a)} - e^{-344(t-t_a)}) (u(t-t_a) - u(t-t_b))]$	$0.222 \leq \psi \leq 1.11$

Perturbación Eléctrica	Identificador	Modelo Matemático	Parámetros
Transitorios oscilatorios	6	$v(t) = 180 [\sin(\omega t - \phi) + \beta e^{-\frac{t-t_I}{\tau}} \sin(\omega_n(t - t_I) - \theta) (u(t-t_I) - u(t - t_I))]$	$300 \leq f_n \leq 900$ $8 \text{ ms} \leq \tau \leq 40 \text{ ms}$ $0.1 \leq \beta \leq 0.9$
armónicos	7	$v(t) = 180 [\sin(\omega t - \phi) + \sum_{n=3}^7 \alpha_n \sin(n\omega t + \theta_n)]$	$0.05 \leq \alpha_5 \leq 0.15$ $0.05 \leq \alpha_7 \leq 0.15$
armónicos con sag	8	$v(t) = 180(1 - \alpha(u(t - t_1) - u(t - t_2))) [\sin(\omega t - \phi) + \sum_{n=3}^5 \alpha_n \sin(n\omega t + \theta_n)]$	$0.05 \leq \alpha_5 \leq 0.15$ $0.05 \leq \alpha_7 \leq 0.15$
armónicos con swell	9	$v(t) = 180(1 + \beta(u(t - t_1) - u(t-t_2))) [\sin(\omega t - \phi) + \sum_{n=3}^5 \alpha_n \sin(n\omega t + \theta_n)]$	$0.05 \leq \alpha_5 \leq 0.15$ $0.05 \leq \alpha_7 \leq 0.15$
Flicker	10	$v(t) = 180(1 + \lambda \sin(\omega_f t)) \sin(\omega t - \phi)$	$0.05 \leq \lambda \leq 0.1$ $8 \leq f \leq 25$
Flicker con sag	11	$v(t) = 180(1 + \lambda \sin(\omega_f t) - \alpha(u(t - t_1) - u(t - t_2))) \sin(\omega t - \phi)$	$0.05 \leq \lambda \leq 0.1$ $8 \leq f \leq 25$ $0.1 \leq \alpha \leq 0.9$
Flicker con swell	12	$v(t) = 180(1 + \lambda \sin(\omega_f t) - \beta(u(t - t_1) - u(t - t_2))) \sin(\omega t - \phi)$	$0.05 \leq \lambda \leq 0.1$ $8 \leq f \leq 25$ $0.1 \leq \alpha \leq 0.9$
Sag con transitorios oscilatorios	13	$v(t) = 180[\sin(\omega t - \phi) (1 - \alpha(u(t - t_1) - u(t - t_2))) + \beta e^{-\frac{t-t_I}{\tau}} \sin(\omega_n(t - t_I) - \theta) (u(t-t_I) - u(t - t_I))]$	$0.1 \leq \alpha \leq 0.9\theta$ $300 \leq f_n \leq 900$ $8 \text{ ms} \leq \tau \leq 40 \text{ ms}$ $0.1 \leq \beta \leq 0.9$
Swell con transitorios oscilatorios	14	$v(t) = 180[\sin(\omega t - \phi)\beta (u(t-t_1) - u(t - t_2)) + \beta e^{-\frac{t-t_I}{\tau}} \sin(\omega_n(t - t_I) - \theta) (u(t-t_I) - u(t - t_I))]$	$0.1 \leq \alpha \leq 0.9\theta$ $300 \leq f_n \leq 900$ $8 \text{ ms} \leq \tau \leq 40 \text{ ms}$ $0.1 \leq \beta \leq 0.9$
Sag con armónicos	15	$v(t) = 180 [\sin(\omega t + \theta_1) + (-\alpha(u(t - t_1) - u(t - t_2))) \sum_{n=3}^5 \alpha_n \sin(n\omega t + \theta_n)]$	$0.1 \leq \alpha \leq 0.9\alpha_3$
Swell con armónicos	16	$v(t) = 180 [\sin(\omega t + \theta_1) + \beta(u(t - t_1) - u(t - t_2))] \sum_{n=3}^5 \alpha_n \sin(n\omega t + \theta_n)$	$0.1 \leq \beta \leq 0.9\alpha_3$ $0.05 \leq \alpha_5 \leq 0.15$ $0.05 \leq \alpha_7 \leq 0.15$
Notch o muescas	17	$v(t) = 180(1 + \lambda \sin(\omega_f t)) [\sin(\omega t - \phi) + \sum_{n=3}^5 \alpha_n \sin(n\omega t + \theta_n) (1 - \alpha(u(t - t_1) - u(t - t_2)))]$	$0.1 \leq \alpha \leq 0.9\alpha_3$ $0.05 \leq \alpha_5 \leq 0.15$ $0.05 \leq \alpha_7 \leq 0.15$ $0.05 \leq \lambda \leq 0.1$ $8 \leq f \leq 25$
armónicos con sag con flicker	18	$v(t) = 180 [\sin(\omega t - \phi) - \sin(\omega t - \phi) \sum_{n=0}^{N-c-1} k(u(t - (t_c + s \cdot n)) - u) (t - (t_d + s \cdot n))]$	$c = 1, 2, 4, 6$

Perturbación Eléctrica	Identificador	Modelo Matemático	Parámetros
armónicos con swell con flicker	19	$v(t) = 180(1 + \lambda \sin(\omega_f t))$ $[\sin(\omega t - \phi) +$ $\sum_{n=3}^5 \alpha_n \sin(n\omega t + \theta_n)$ $(1 + \beta(u(t - t_1) - u(t - t_2)))]$	$0.1 \leq \beta \leq 0.9\alpha_3$ $0.05 \leq \alpha_5 \leq 0.15$ $0.05 \leq \alpha_7 \leq 0.15$ $0.05 \leq \lambda \leq 0.1$ $8 \leq f \leq 25$
Sag con armónicos con flicker	20	$v(t) = 180(\sin(\omega t + \theta_1)$ $+ (1 + \lambda \sin(\omega_f t)(-\alpha(u(t - t_1) -$ $u(t - t_2)) \sum_{n''}^5 \alpha_{n''}$ $\sin(n''\omega t + \theta_{n''}))$	$a.0.1 \leq \alpha \leq 0.9\alpha_3$ $0.05 \leq \alpha_5 \leq 0.15$ $0.05 \leq \alpha_7 \leq 0.15$ $0.05 \leq \lambda \leq 0.1$ $8 \leq f \leq 25$
Swell con armónicos con flicker	21	$v(t) = 180(\sin(\omega t + \theta_1)$ $+ (1 + \lambda \sin(\omega_f t)$ $(\beta(u(t - t_1) - u(t - t_2))$ $\sum_{n''}^5 \alpha_{n''} \sin(n''\omega t + \theta_{n''}))$	$0.1 \leq \beta \leq 0.9\alpha_3$ $0.05 \leq \alpha_5 \leq 0.15$ $0.05 \leq \alpha_7 \leq 0.15$ $0.05 \leq \lambda \leq 0.1$ $8 \leq f \leq 25$
Sag con armónicos con transitorios oscilatorios	22	$v(t) = 180[\sin(\omega t + \theta_1)$ $+ (-\alpha(u(t - t_1) - u(t - t_2))$ $\sum_{n''}^5 \alpha_{n''}$ $\sin(n''\omega t + \theta_{n''})$ $+ \beta e^{-\frac{t-t_I}{\tau}}$ $\sin(\omega_n(t - t_I)$ $- \theta)(u(t - t_{II}) - u(t - t_I))$	$0.1 \leq \alpha \leq 0.9\alpha_3$ $0.05 \leq \alpha_5 \leq 0.15$ $0.05 \leq \alpha_7 \leq 0.15$ $300 \leq f_n \leq 900$ $8 \text{ ms} \leq \tau \leq 40 \text{ ms}$ $0.1 \leq \beta \leq 0.9$
Swell con armónicos con transitorios oscilatorios	23	$v(t) = 180[\sin(\omega t + \theta_1) +$ $(\beta(u(t - t_1) - u(t - t_2))$ $\sum_{n''}^5 \alpha_{n''} \sin(n''\omega t + \theta_{n''})$ $+ \beta e^{-\frac{t-t_I}{\tau}}$ $\sin(\omega_n(t - t_I) - \theta)$ $(u(t - t_{II}) - u(t - t_I))$	$0.1 \leq \alpha \leq 0.9\alpha_3$ $0.05 \leq \alpha_5 \leq 0.15$ $0.05 \leq \alpha_7 \leq 0.15$ $300 \leq f_n \leq 900$ $8 \text{ ms} \leq \tau \leq 40 \text{ ms}$ $0.1 \leq \beta \leq 0.9$
armónicos con sag con transitorios oscilatorios	24	$v(t) = 180[1 -$ $\alpha(u(t - t_1) - u(t - t_2)) \sum_{n''}^5 \alpha_{n''}$ $\sin(n''\omega t + \theta_{n''})$ $+ \beta e^{-\frac{t-t_I}{\tau}}$ $\sin(\omega_n(t - t_I) - \theta)$ $(u(t - t_{II}) - u(t - t_I))$	$0.1 \leq \alpha \leq 0.9\alpha_3$ $0.05 \leq \alpha_5 \leq 0.15$ $0.05 \leq \alpha_7 \leq 0.15$ $300 \leq f_n \leq 900$ $8 \text{ ms} \leq \tau \leq 40 \text{ ms}$ $0.1 \leq \beta \leq 0.9$
armónicos con swell con oscilatorios transitorios	25	$v(t) = 180[1 + \beta(u(t - t_1)$ $- u(t - t_2)) \sum_{n''}^5 \alpha_{n''}$ $\sin(n''\omega t + \theta_{n''})$ $+$ $\beta e^{-\frac{t-t_I}{\tau}}$ $\sin(\omega_n(t - t_I) - \theta)$ $(u(t - t_{II}) - u(t - t_I))$	$0.1 \leq \beta \leq 0.9\alpha_3$ $0.05 \leq \alpha_5 \leq 0.15$ $0.05 \leq \alpha_7 \leq 0.15$ $300 \leq f_n \leq 900$ $8 \text{ ms} \leq \tau \leq 40 \text{ ms}$ $0.1 \leq \beta \leq 0.9$

Perturbación Eléctrica	Identificador	Modelo Matemático	Parámetros
armónicos con sag con flicker con oscilatorios transitorios	26	$v(t)=180[1-\alpha(u(t-t_1)-u(t-t_2))\sum_{n''}^5 \alpha_{n''}\sin(n''\omega t + \theta_{n''}) + \beta e^{-\frac{t-t_I}{\tau}}\sin(\omega_n(t-t_I) - \theta)(u(t-t_{II}) - u(t-t_I)1 + \lambda \sin(\omega_f t))$	$0.1 \leq \beta \leq 0.9\alpha_3$ $0.05 \leq \alpha_5 \leq 0.15$ $0.05 \leq \alpha_7 \leq 0.15$ $300 \leq f_n \leq 900$ $8 \text{ ms} \leq \tau \leq 40 \text{ ms}$ $0.1 \leq \beta \leq 0.9$
armónicos con swell con flicker con oscilatorios transitorios	27	$v(t)=180[1+\beta(u(t-t_1) - u(t-t_2))\sum_{n''}^5 \alpha_{n''}\sin(n''\omega t + \theta_{n''}) + \beta e^{-\frac{t-t_I}{\tau}}\sin(\omega_n(t-t_I) - \theta)(u(t-t_{II}) - u(t-t_I)1 + \lambda \sin(\omega_f t))$	$0.05 \leq \alpha_3 \leq 0.15$ $0.05 \leq \alpha_5 \leq 0.15$ $0.05 \leq \alpha_7 \leq 0.15$ $0.1 \leq \beta \leq 0.9\lambda$ $0.05 \leq \lambda \leq 0.1$ $8 \leq f \leq 25\theta$ $300 \leq f_n \leq 900$ $8 \text{ ms} \leq \tau \leq 40 \text{ ms}$ $0.1 \leq \beta \leq 0.9$
armónicos con swell con flicker con oscilatorios transitorios	28	$v(t)=180[\sin(\omega t + \theta_1) + \alpha(u(t-t_1) - u(t-t_2))\sum_{n''}^5 \alpha_{n''}\sin(n''\omega t + \theta_{n''}) + \beta e^{-\frac{t-t_I}{\tau}}\sin(\omega(t-t_I) - \theta)(u(t-t_{II}) - u(t-t_I)1 + \lambda \sin(\omega_f t))$	$0.1 \leq \alpha \leq 0.9\alpha_3$ $0.05 \leq \alpha_3 \leq 0.15$ $0.05 \leq \alpha_5 \leq 0.15$ $0.05 \leq \alpha_7 \leq 0.15$ $0.05 \leq \lambda \leq 0.1$ $8 \leq f \leq 25\theta$ $300 \leq f_n \leq 900$ $8 \text{ ms} \leq \tau \leq 40 \text{ ms}$ $0.1 \leq \beta \leq 0.9$
armónicos con swell con flicker con oscilatorios transitorios	29	$v(t)=180[\sin(\omega t + \theta_1) + (\beta(u(t-t_1) - u(t-t_2))\sum_{n''}^5 \alpha_{n''}\sin(n''\omega t + \theta_{n''}) + \beta e^{-\frac{t-t_I}{\tau}}\sin(\omega_n(t-t_I) - \theta)(u(t-t_{II}) - u(t-t_I)1 + \lambda \sin(\omega_f \tau))$	$0.05 \leq \alpha_3 \leq 0.15$ $0.05 \leq \alpha_5 \leq 0.15$ $0.05 \leq \alpha_7 \leq 0.15$ $0.05 \leq \lambda \leq 0.1$ $8 \leq f \leq 25\theta$ $300 \leq f_n \leq 900$ $8 \text{ ms} \leq \tau \leq 40 \text{ ms}$ $0.1 \leq \beta \leq 0.9$

Acreditación Inglés

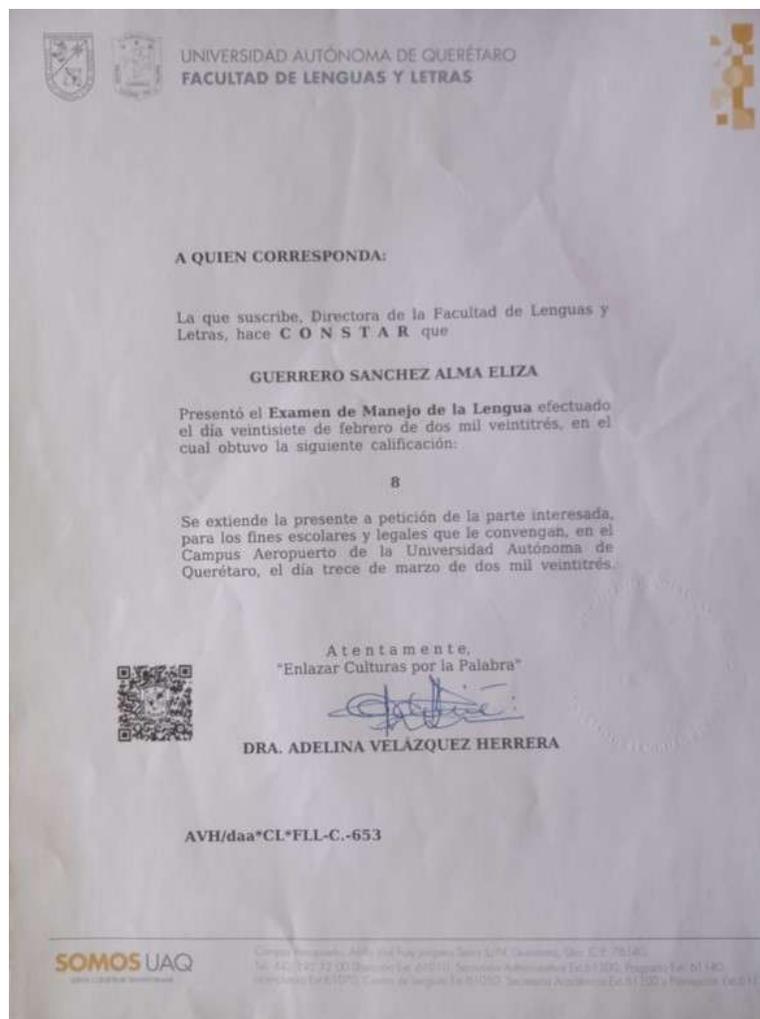


Figure B.1: Acreditación de inglés

Primer Articulo Publicado



Figure C.1: Primer articulo Publicado

Registro de software



Figure D.1: Registro de software.

Segundo Articulo Publicado

Home / Archives / Vol. 54 No. 2 (2024): Latin American Applied Research / Control and Information Processing

Artificial Intelligence Applied for Smart Electric Microgrids: A Literature Review

Alma Eliza Guerrero Sánchez
Master Degree

Edgar Alejandro Rivas Araiza

Mariano Garduño Aparicio

José Luis González-Córdoba

Juvenal Rodríguez Reséndiz

DOI: <https://doi.org/10.52292/ljaar.2024.1952>

Keywords: Artificial intelligence, Energy production schemes, Electrical Microgrid, smart grid, smart control

Abstract

pdf (EUR 35) | html (EUR 35)

Published
2024-03-11

Issue
[Vol. 54 No. 2 \(2024\): Latin American Applied Research](#)

Section
Control and Information Processing

License
Copyright (c) 2024 Latin American Applied

Figure E.1: Segundo articulo Publicado.

