

**Detección de sobretensiones en sistemas eléctricos de potencia utilizando
machine learning**

**Iván Fernando Garnica Palencia
Brayam Alexis Quiroz Vásquez**

Asesores

**Carlos David Zuluaga Ríos, PhD
Joseph Sosapanta Salas, MSc**

**Institución Universitaria Pascual Bravo
Facultad de ingeniería
Medellín
2023**

Resumen

En este trabajo, se desarrollan modelos de aprendizaje automático basados en redes neuronales convolucionales (RNC) y Perceptrón Multicapa para la clasificación de eventos en una red eléctrica de baja tensión. Estos eventos incluyen sobretensiones, caídas de voltaje e interrupciones, que suelen estar relacionados con fallos en el sistema eléctrico, como maniobras de conmutación, descargas atmosféricas y el mal funcionamiento de dispositivos como variadores de frecuencia ajustable y condensadores de corrección del factor de potencia. Para abordar este desafío, se generaron datos sintéticos aleatoriamente dentro de un rango específico para representar diversas formas de series temporales asociadas con estos eventos eléctricos, los cuales se emplearon para desarrollar las etapas siguientes del modelo: generación la creación de la base de datos, división de datos, escalado de atributos y el entrenamiento de dos modelos neuronales: el Perceptrón Multicapa y el modelo RNC; con las cuales se obtuvo tasas de precisión del 70% y 71%.

Palabras clave: Aprendizaje automático, Aprendizaje supervisado, base de datos, caídas de voltaje, clasificación, datos sintéticos, descargas atmosféricas, eventos eléctricos, interrupciones de voltaje, modelos neuronales, perceptrón multicapa, precisión, redes neuronales convolucionales (RNC), sobretensiones, sistema eléctrico, series temporales.

Abstract

In this work, several machine learning models based on Convolutional Neural Networks (CNN) and Multilayer Perceptron are addressed for the classification of events in a low-voltage electrical network. These events include overvoltages, voltage drops, and interruptions, which are typically related to failures in the electrical system, such as switching maneuvers, atmospheric discharges, and the malfunction of devices such as adjustable frequency drives and power factor correction capacitors. To tackle this challenge, synthetic data was randomly generated within a specific range to represent various forms of time series associated with these electrical events. The supervised learning approach was structured into four essential stages: data generation and database creation, data splitting, attribute scaling, and the training of two neural models: the Multilayer Perceptron and the CNN model. The results yielded accuracy rates of 70% and 71%.

Keywords: Accuracy, atmospheric discharges, classification, Convolutional Neural Networks (CNN), database, electrical events, electrical system, machine learning, multilayer Perceptron, neural models, overvoltages, supervised learning, synthetic data, time series, voltage drops, voltage interruptions.

Lista de contenido

Introducción	5
Planteamiento del problema.....	6
Justificación	8
Objetivo	9
Objetivo general	9
Objetivos específicos.....	9
Metodología	10
Revisión de la Literatura:.....	10
Implementación del Modelo de Machine Learning:	10
Experimentación y Evaluación:	10
Documentación y Conclusiones:	10
Referentes teóricos	11
Técnicas Machine learning	14
Machine learning.....	14
Redes neuronales.....	14
Red neuronal convolucional	17
Ventajas y desventajas de las redes neuronales convolucionales en la inteligencia artificial	18
Python.....	18
Librería NumPy.....	18
Librería MinMaxScaler	18
Librería Tensorflow.....	18
Capa Conv1D.....	19
Capa de MaxPooling	19
Media	19
Mediana	20
Kurtosis.....	20
Skewness.....	21
THD.....	21
Transformada de Fourier	22

Sistemas eléctricos de baja tensión	23
Clasificación de los niveles de tensión	24
Sobretensiones.....	24
Voltaje nominal	25
Caída de voltaje.....	26
Aumento de voltaje.....	27
Interrupción de voltaje.....	28
Resultados de la propuesta.....	29
Discusión de resultados	33
Conclusiones	34
Bibliografía	35

Lista de ilustraciones

Ilustración 1. Estructura de una red neuronal artificial.	15
Ilustración 2. Red neuronal convolucional (RNC).....	17
Ilustración 3. Unifilar	23
Ilustración 4. Sobretensiones	25
Ilustración 5. Voltaje nominal.....	26
Ilustración 6. Caída de tensión.....	27
Ilustración 7. Sobretensión.....	28
Ilustración 8. Interrupción de voltaje.....	29
Ilustración 9. Gráfica serie de Fourier	30

Lista de tablas

Tabla 1. Eventos eléctricos simulados.....	32
Tabla 2. Evaluación de los modelos.....	32

Introducción

La detección de sobretensiones en sistemas eléctricos de potencia es de vital importancia para salvaguardar la seguridad y la integridad de estos sistemas, así como del personal encargado de su operación. En la actualidad, el crecimiento exponencial en la cantidad de dispositivos conectados a las redes eléctricas ha generado una mayor demanda de energía de alta calidad. A medida que la tecnología avanza y los dispositivos electrónicos se vuelven más sofisticados, se requiere un suministro eléctrico estable y constante. En este contexto, asegurar la provisión de energía ininterrumpida y de calidad se ha convertido en una estrategia comercial fundamental para las empresas del sector energético, lo que ha dado lugar a un mercado energético altamente competitivo (Strack, 2019).

En el marco de este proyecto, se ha llevado a cabo la implementación de métodos de machine learning que han proporcionado una solución en la predicción de sobretensiones. Con el objetivo primordial de lograr detectar sobretensiones, se optó por emplear redes neuronales, las cuales han desempeñado un papel fundamental al anticipar el comportamiento de la red. Estas redes neuronales se nutrieron con datos simulados de eventos eléctricos de voltajes previamente registrados en el sistema, lo que ha permitido realizar un análisis exhaustivo basado en patrones generados.

Planteamiento del problema

Una sobretensión se refiere a una situación en la que el valor de la tensión eléctrica supera el valor nominal en un momento determinado. Esta sobretensión puede tener diversas causas, como una falla en el sistema eléctrico, una maniobra de conmutación en el circuito, o incluso una descarga atmosférica, como un rayo (Posso,2022). Las sobretensiones, con el tiempo, provocan desgastes de los componentes de la red y circuitos electrónicos, reduciendo notablemente su vida útil dejándolos inutilizables e incrementando el riesgo de incendio (TotalEnergies,2022).

Existen diferentes técnicas y dispositivos para la detección de sobretensiones. Uno de los más comunes es el uso de supresores de sobretensión (DPS), que protegen los equipos y sistemas eléctricos de los efectos de los rayos, pueden instalarse en la entrada de la alimentación eléctrica para limitar la magnitud de la sobretensión. Además, la protección de equipos individuales puede incorporar su propio sistema de protección. Estos dispositivos, como los protectores de línea o los filtros de sobretensión, se instalan directamente en los equipos para reducir el impacto de las sobretensiones (SAP, 2022).

Es importante destacar que la detección de sobretensiones no solo es importante para proteger los equipos y sistemas eléctricos, sino también para garantizar la seguridad de las personas. Las sobretensiones pueden generar chispas y arcos eléctricos que pueden ser peligrosos para los trabajadores que manipulan equipos eléctricos. Por lo tanto, es esencial contar con un sistema de detección de sobretensiones eficaz para garantizar la seguridad en el lugar de trabajo.

En la actualidad, surgen nuevos modelos de detección, y uno de los más prometedores es el machine learning. El machine learning, junto con sus componentes de aprendizaje profundo y redes neuronales, se incorpora de manera interconectada en el campo de la inteligencia artificial (IA). A través del procesamiento de datos, la IA se esfuerza por efectuar decisiones y llevar a cabo pronósticos. Los algoritmos de aprendizaje automático permiten que la inteligencia artificial no solo manipule datos, sino que los utilice para aprender y mejorar su capacidad de entrenamiento (SAP, 2022).

Sin embargo, para desarrollar un modelo eficaz y preciso de machine learning para la detección de sobretensiones se presentan varios retos técnicos que deben abordarse adecuadamente para garantizar su eficacia y precisión y uno de ellos es recopilar datos o ejemplos de calidad que sean representativos del problema que se desea resolver. El objetivo es encontrar patrones en esos datos y utilizarlos para tomar decisiones más acertadas (Romero Tello, 2019).

En el caso de la detección de sobretensiones, es fundamental contar con conjuntos de datos lo suficientemente representativos y completos que abarquen una amplia gama de situaciones de sobretensión. La disponibilidad y calidad de estos datos pueden ser un desafío, especialmente si se trata de eventos raros o difíciles de capturar (Pérez, 2022).

Por otro lado, las sobretensiones pueden manifestarse de diferentes formas y tener diversas causas, lo que dificulta su detección precisa. Además, las características de las sobretensiones pueden variar en función de la ubicación, la configuración de la red eléctrica y otros factores. Esto requiere el desarrollo de algoritmos de machine learning que sean capaces de capturar y adaptarse a esta variabilidad y complejidad.

Otro aspecto para tener en cuenta es la detección de sobretensiones debe realizarse en tiempo real para poder tomar acciones preventivas o correctivas de manera oportuna. Dado que un modelo de aprendizaje profundo tiene la capacidad de ejecutar miles de tareas repetitivas y rutinarias en un intervalo de tiempo significativamente menor en comparación con el tiempo que requeriría un ser humano (Pérez, 2022), se hace evidente la necesidad de algoritmos de machine learning eficientes y de baja latencia. Estos algoritmos son fundamentales para procesar volúmenes masivos de datos en tiempo real, sin experimentar demoras significativas.

¿Cómo desarrollar un modelo de detección de sobretensiones en sistemas eléctricos de potencia de baja tensión, utilizando métodos de machine learning, considerando diferentes condiciones operativas?

Justificación

Según la Electrical Safety Foundation International (ESFI) (2021), ¿en su artículo What are Power Surges?, las sobretensiones son picos breves de sobretensión o perturbaciones en una forma de onda de energía que pueden dañar, degradar o destruir equipos electrónicos en cualquier hogar, edificio comercial o instalaciones industriales y de fabricación.

Nuestra sociedad actual depende en gran medida de la electricidad y la creciente sensibilidad de los dispositivos electrónicos hace que la disponibilidad de energía confiable sea de vital importancia. A pesar de ello, las interrupciones en el suministro eléctrico son eventos que pueden ocurrir. De hecho, se estima que los problemas relacionados con la alimentación eléctrica generan pérdidas que superan los 80.000 millones de dólares anuales para las empresas en Estados Unidos. Además, se calcula que aproximadamente el 63% de las sobretensiones que afectan a las instalaciones se originan internamente, debido a situaciones como el arranque y parada de motores, cambios bruscos en la carga de maquinaria industrial, o conmutaciones en paneles de distribución eléctrica, entre otros. El 37% restante de las sobretensiones proviene de fuentes externas a la instalación, estas sobretensiones son causadas por eventos externos tales como rayos, conmutación de la red eléctrica, conmutación de bancos de condensadores, Accidentes, etc. Los daños provocados por estos eventos tienen un doble impacto en términos de costos: por un lado, los gastos asociados a la reparación o sustitución de equipos dañados pueden igualar o incluso superar los costos de implementar sistemas de protección contra sobretensiones; por otro lado, el tiempo de inactividad resultante de estas interrupciones puede tener un costo económico significativo, llegando a alcanzar millones de dólares por hora o incluso por minuto. (Colsein, 2021).

Por esta razón, se destaca la relevancia de llevar a cabo la presente investigación, la cual posibilitará la creación de un modelo de detección de sobretensiones en sistemas eléctricos de potencia de baja tensión mediante el empleo de métodos de machine learning. Este modelo puede prever posibles fluctuaciones en la tensión del sistema eléctrico y, al mismo tiempo, puede establecer un punto de partida valioso para investigaciones futuras que empleen esta metodología, que permitan prevenir fallos en equipos y sistemas eléctricos, reduciendo los riesgos para la seguridad del personal y la comunidad.

Objetivo

Objetivo general

Desarrollar un modelo de detección de sobretensiones en sistemas eléctricos de potencia de baja tensión utilizando métodos de machine learning, considerando diferentes condiciones operativas, el cual pueda servir de apoyo para la toma de decisiones en sistemas eléctricos.

Objetivos específicos

- Revisar la literatura científica sobre la detección de sobretensiones en sistemas eléctricos de potencia y los métodos de machine learning, específicamente RNC y Perceptrón Multicapa, utilizados en la detección de sobretensiones.
- Adaptar y emplear técnicas de machine learning, específicamente redes neuronales, para la detección efectiva de sobretensiones en sistemas de baja tensión, con el objetivo de fortalecer la seguridad y la gestión de sistemas eléctricos bajo diversas circunstancias operativas.
- Validar experimentalmente el método propuesto para la detección de sobretensiones utilizando datos históricos y simulados en sistemas de baja tensión.

Metodología

La metodología propuesta se centra en abordar la detección de sobretensiones en sistemas eléctricos de baja tensión mediante la implementación de técnicas de machine learning basadas en redes neuronales. La metodología se divide en los siguientes pasos:

Revisión de la Literatura:

- Realizar una búsqueda de documentación para identificar información relacionada con la detección de sobretensiones en sistemas eléctricos y el uso de machine learning, RNC y Perceptrón Multicapa.
- Analizar los artículos seleccionados para identificar las fortalezas y debilidades de los diferentes enfoques utilizados en la detección de sobretensiones mediante redes neuronales.

Implementación del Modelo de Machine Learning:

- Estudiar en profundidad los modelos teóricos seleccionados para el machine learning basado en redes neuronales utilizados en la detección de sobretensiones en sistemas de baja tensión.
- Configurar la red neuronal de acuerdo con los modelos teóricos estudiados para la detección de sobretensiones, teniendo en consideración las diferentes condiciones operativas.

Experimentación y Evaluación:

- Recopilar datos de sobretensiones en sistemas eléctricos de baja tensión, incluyendo diversas condiciones operativas, para entrenar y probar el modelo de machine learning.
- Implementar experimentos con el modelo configurado utilizando conjuntos de datos reales y evaluar su desempeño en la detección de sobretensiones.
- Realizar análisis detallados de los resultados obtenidos, identificando la eficacia y posibles áreas de mejora del modelo.

Documentación y Conclusiones:

- Documentar todo el proceso de investigación y desarrollo, incluyendo los hallazgos clave y los detalles técnicos de la metodología.
- Generar conclusiones basadas en los resultados de los experimentos y ofrecer recomendaciones para futuros trabajos en este campo.

Esta metodología proporciona un marco sólido para abordar la detección de sobretensiones en sistemas eléctricos de baja tensión a través de enfoques de machine learning basados en redes neuronales, asegurando una investigación completa y una implementación efectiva del modelo.

Referentes teóricos

Estado del arte

En esta sección se exponen diversas investigaciones a nivel nacional e internacional que abordan el problema de detección de sobretensiones utilizando técnicas de Machine Learning.

En el estudio realizado por Mahela et al. (2014), se aborda la problemática vinculada a la calidad de la energía que surge de las variaciones en voltaje, corriente y frecuencia. Para abordar esta temática, se emplea como metodología investigativa el análisis exhaustivo y revisión de la literatura existente en estas áreas, buscando proporcionar una visión más completa de las técnicas y enfoques utilizados en la detección y clasificación de eventos relacionados con la calidad de la energía, en los cuales se abordan diversos métodos, tales como la transformada de Hilbert-Huang, la transformada de Fourier y la transformada de Wavelet. Asimismo, se realiza un análisis comparativo de técnicas de detección de eventos relacionados con la calidad de la energía en términos de potencia activa y reactiva (PQ). Además, se exploran estrategias de clasificación de IA, como la clasificación basada en redes neuronales, máquinas de soporte vectorial (SVM) y algoritmos genéticos. Este enfoque se complementa con un estudio comparativo de las técnicas de clasificación aplicadas a eventos de calidad de la energía PQ. El documento resalta las ventajas de estas técnicas, como su alta eficiencia, mejora en la toma de decisiones, capacidad de automatización y aprendizaje continuo. Así mismo, subraya que la IA puede adaptarse a las preferencias y necesidades individuales. Sin embargo, identifica desventajas como las limitaciones en la toma de decisiones, baja seguridad y la fuerte dependencia de los datos de entrenamiento. Los resultados obtenidos en la investigación evidencian que el ruido tiene un impacto significativo en la precisión de la clasificación de eventos relacionados con la calidad de energía, y este impacto varía en función del tipo de perturbación.

Además, en el estudio realizado por de Yong (2016), se destaca la importancia de la eficiencia energética, que ha evolucionado para convertirse en una fuente crucial de energía. Esto se alinea con las inversiones tanto en fuentes tradicionales como en renovables. Sin embargo, aún persisten desafíos en la calidad de la energía, especialmente en sistemas eléctricos complejos, lo que ha impulsado el desarrollo de algoritmos y herramientas de simulación. A pesar de las notables ventajas que ofrecen estas soluciones, como la capacidad para gestionar perturbaciones complejas y la generación de bases de datos diversificadas, también se enfrentan a desafíos, como la precisa clasificación de señales complejas. Por lo tanto, se enfatiza la necesidad de llevar a cabo una investigación más exhaustiva en este campo. En el estudio, el algoritmo de localización demostró una eficacia del 100% en la clasificación y localización de la línea de falla en diversos escenarios, característica fundamental que permite obtener resultados rápidos en cualquier línea de sistemas radiales de pequeñas dimensiones. Esto, a su vez, simplifica la instalación de sistemas de medición.

Por su parte Basumallik (2019) desarrolló un estudio en donde destaca que la degradación en la calidad de la energía surge principalmente debido al aumento en la utilización de cargas no lineales, capacitores y eventos de conmutación de cargas. Para abordar este problema, propone identificar las causas y efectos de dicha degradación mediante la clasificación de eventos asociados, utilizando una RNC.

El estudio presenta ventajas como la diversidad de datos utilizados y la aplicación de técnicas. Estas técnicas abarcan tanto técnicas tradicionales, como la Transformada de Fourier, la Transformada de Fourier de Tiempo Corto, la Transformada de Gabor, la Transformada S de Stockwell, la Transformada de Ondeleta y el Filtro de Kalman, así como enfoques más contemporáneos de aprendizaje automático, tales como las MSV y las RNA para prevenir el sobreajuste, pero carece de detalles específicos sobre la metodología de clasificación y el impacto del ruido en las señales. Además, se destacan los excelentes resultados obtenidos de la RNC, los cuales revelaron una precisión notable del 99.83% en la clasificación de eventos en la calidad de la energía utilizando RNC, superando a muchos enfoques tradicionales en el análisis de calidad de energía.

De igual manera, Carpio y Daga (2019) realizan un trabajo donde se aborda la problemática de las fluctuaciones y pérdidas técnicas en sistemas de potencia, las cuales impactan tanto a consumidores como a distribuidoras eléctricas. La gestión de estas variaciones es crucial para minimizar su impacto y generar ahorros económicos. La metodología empleada se enfoca en el uso de una red neuronal artificial para optimizar sistemas de distribución de bajo voltaje y evaluar su rentabilidad mediante un análisis económico. Los resultados subrayan la importancia de equilibrar el número de capas y neuronas en la arquitectura de la red neuronal perceptrón multicapa (MLP) para evitar el sobreajuste, lo cual puede perjudicar su capacidad predictiva. Se encontró que incrementar el número de capas incrementa el error cuadrático, mientras que aumentar las neuronas con la arquitectura mencionada apenas afecta este error.

Rozo Puentes (2022) en su investigación resalta la importancia del monitoreo y garantía de la calidad en sistemas eléctricos, particularmente en relación con los fenómenos de calidad de la potencia. La metodología utilizada involucra el procesamiento de señales mediante la transformada de wavelet, la transformada de Hilbert y la transformada de Fourier, junto con técnicas de machine learning, como el perceptrón multicapa, y el software simulador de señales eléctricas, Typhoon HIL. El autor enfatiza que los algoritmos de machine learning ofrecen la capacidad de predecir o clasificar resultados automáticamente y adaptarse a diferentes sistemas y condiciones, lo que los hace versátiles en diversas aplicaciones. Aunque el estudio evidencia que la transformada de Hilbert-Huang permite visualizar con alta sensibilidad los cambios y perturbaciones en la señal a lo largo del tiempo, se destaca que su precisión es menor que la obtenida con la transformada de wavelet. Se recomienda una mayor profundización en el entrenamiento de los clasificadores para mejorar la precisión de los resultados en futuras investigaciones.

Guevara Gómez (2023) en su se centra en la implementación y optimización de las redes eléctricas inteligentes, particularmente en la integración de micro-redes y la detección de anomalías en estas estructuras. La metodología utilizada involucra la transformada de wavelet, la transformada de Hilbert, la transformada de Fourier y el uso de RNC para el procesamiento de datos. Se destaca la capacidad de las micro-redes para ofrecer alta calidad de energía, así como la eficacia de las RNA en la detección de fallos. Además, se resalta la efectividad de la IA y el aprendizaje automático en la detección de eventos de calidad de energía en la industria eléctrica. Estas ventajas representan avances significativos en la eficiencia, sostenibilidad y confiabilidad de los sistemas eléctricos. Los resultados

del estudio mostraron una tasa de precisión del 84 % en la identificación del tipo de fallo y del 95 % en la ubicación de este.

Técnicas Machine learning

Machine learning

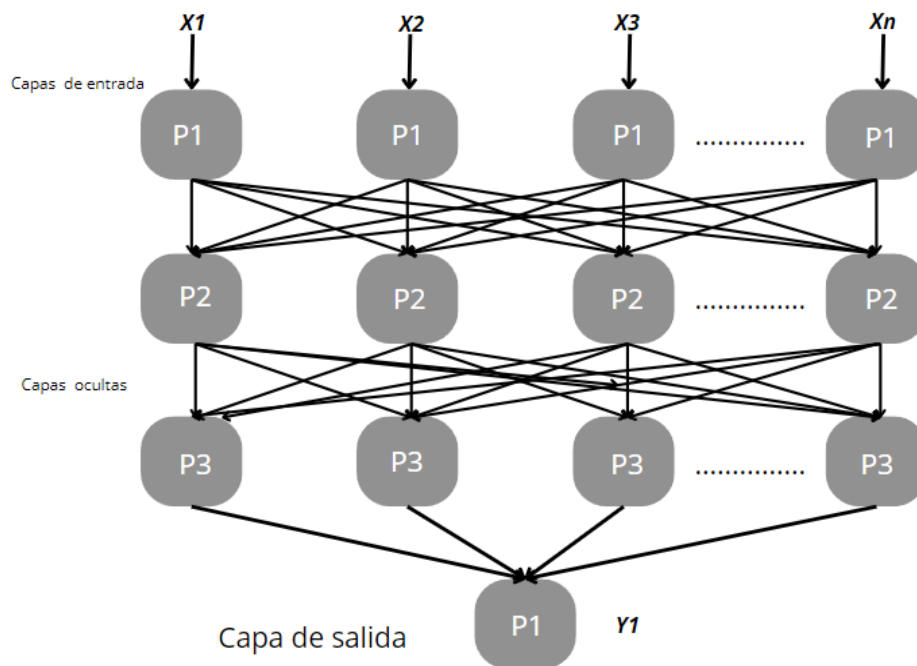
El concepto de Machine Learning o “aprendizaje automático” se originó a mediados del siglo XX y fue definido por Arthur Lee Samuel en 1959 pionero en el ámbito de los videojuegos y la inteligencia artificial. Machine Learning es una rama de la IA que utiliza técnicas estadísticas y algoritmos computacionales para permitir que las computadoras “aprendan” y mejoren sus resultados en una tarea específica al procesar una cantidad suficiente de datos sin instrucciones explícitas externas (y por lo tanto potencialmente sesgadas) (Reiz et al, 2019)

Machine learning es una rama de la inteligencia artificial que entrena a las computadoras para aprender de los datos y mejorar su rendimiento a través de la experiencia. Los algoritmos de machine learning descubren patrones y correlaciones en grandes conjuntos de datos, lo que les permite tomar decisiones y hacer predicciones precisas. A medida que se utilizan más datos, las aplicaciones de machine learning mejoran su desempeño y aumentan su precisión. En otras palabras, el machine learning enseña a las computadoras a aprender de los datos, identificar patrones y tomar decisiones con poca intervención humana (SAP, 2022).

Redes neuronales

Las redes neuronales artificiales son un enfoque computacional que posibilita emular el funcionamiento del cerebro humano, permitiendo a las máquinas aprender de manera análoga a nuestro cerebro. Estas redes consisten en nodos o unidades interconectadas, cuyas conexiones se caracterizan por valores numéricos ajustables. Estos nodos efectúan el procesamiento y la transmisión de señales de entrada y salida mediante algoritmos de aprendizaje, los cuales pueden ajustarse para adaptarse a información novedosa (UNIR, 2021).

Ilustración 1. Estructura de una red neuronal artificial.



Fuente: Propia.

En la ilustración 1 se muestra la estructura de una red neuronal.

Las capas de una red neuronal se forman por unidades de procesamiento. Por lo general, una red neuronal se compone de tres partes: una capa de entrada que contiene unidades que representan los campos de entrada, una o varias capas ocultas, y una capa de salida que consta de una unidad o varias unidades que representan el campo o los campos de destino. Las unidades de procesamiento están interconectadas mediante fuerzas de conexión que varían en su ponderación. Los datos de entrada se introducen en la primera capa y se propagan desde cada neurona a todas las neuronas de la capa siguiente. Finalmente, se envía un resultado desde la capa de salida.

La red aprende examinando registros individuales y ajustando las ponderaciones cuando realiza una predicción incorrecta. Este proceso se repite muchas veces y la red sigue mejorando sus predicciones hasta alcanzar uno o varios criterios de parada. Al principio, todas las ponderaciones son aleatorias y las respuestas pueden ser disparatadas. La red aprende a través del entrenamiento, presentándole ejemplos para los que se conoce el resultado y comparando sus respuestas con los resultados conocidos. A medida que progresa el entrenamiento, la red se va haciendo cada vez más precisa (IBM.2021).

Para llevar a cabo la detección de sobretensiones es necesario entrenar la red neuronal con estas capas de entrada, capas ocultas y capas de salida:

- Capa de entrada: esta capa recibe las entradas de las lecturas de voltaje y corriente en tiempo real en diferentes puntos del sistema eléctrico, las características del sistema eléctrico y los datos históricos.
- Primera capa oculta: esta capa procesa la información de entrada y genera una representación intermedia de la información.
- Segunda capa oculta: esta capa procesa la información generada por la capa anterior y genera una representación aún más compleja de la información.
- Capa de salida: esta capa genera las salidas de la detección de sobretensiones, indicando si se ha producido o no una sobretensión en el sistema eléctrico en función de las lecturas de voltaje y corriente.
- La magnitud y la ubicación donde se produjo la sobretensión ya sea en los conductores, el tablero de distribución o en algún dispositivo eléctrico conectado al sistema, así como también conocer la magnitud de dicha sobretensión. Esto implica indicar con precisión la cantidad de aumento de tensión que se experimentó en el sistema eléctrico y especificar el punto exacto dentro del sistema donde se produjo.
- Durante el entrenamiento, la red ajusta los pesos de las conexiones entre las neuronas para minimizar el error entre la salida de la red y la salida deseada. Además, la cantidad de neuronas en cada capa y la cantidad de capas ocultas pueden ser ajustadas y optimizadas durante el entrenamiento de la red para mejorar el desempeño de la red para la detección de sobretensiones en sistemas eléctricos (IBM.2021).

Red neuronal convolucional

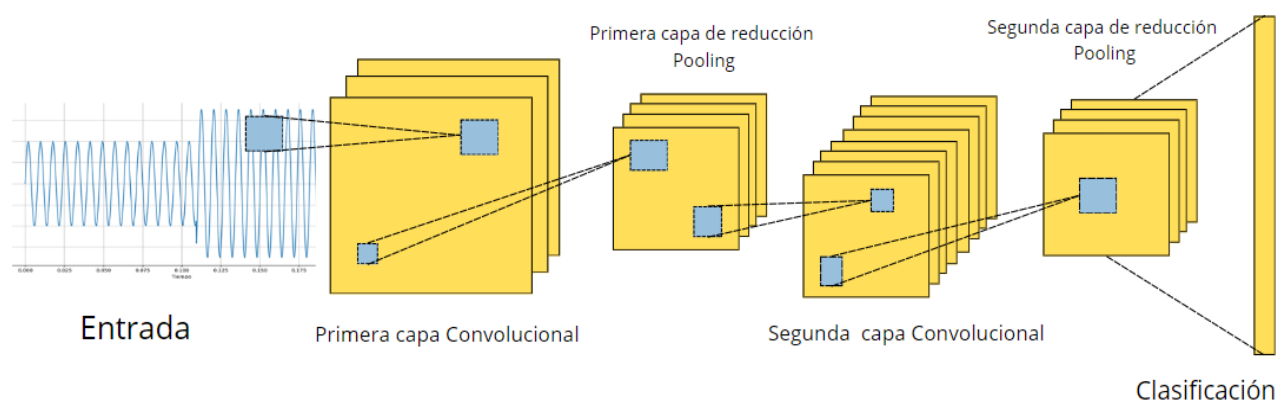
Una RNC se define como una red neuronal artificial diseñada específicamente para permitir a las computadoras procesar imágenes. En esencia, estas redes están modeladas para imitar la estructura de las redes neuronales del cerebro humano, especialmente en el proceso de visión. Las RNCs son ampliamente utilizadas en inteligencia artificial y aprendizaje profundo, con un enfoque particular en el procesamiento de imágenes.

Estas redes se caracterizan por su arquitectura de múltiples capas que trabajan en tres dimensiones: ancho, altura y profundidad, junto con capas de color para detectar las componentes roja, verde y azul. Esto significa que pueden aprender a reconocer características visuales a través de operaciones de convolución en conjuntos de datos.

Para que una RNC funcione con eficacia, generalmente se estructura en al menos tres tipos de capas: una capa de entrada, capas de extracción de características y una capa final de clasificación. Esto las hace extremadamente útiles en aplicaciones de procesamiento de imágenes, permitiendo a las computadoras identificar objetos.

En el proceso, la computadora emplea filtros o lentes específicos que actúan como ventanas deslizantes para escanear y analizar imágenes en busca de características relevantes. Estos filtros se mueven por la imagen, escaneándola y, finalmente, permiten definir y clasificar lo que se encuentra en la imagen (Quiroa, 2023)

Ilustración 2. Red neuronal convolucional (RNC)



Fuente: fuente propia.

En la ilustración 2 se explica de forma resumida como es una red neuronal y su proceso.

Ventajas y desventajas de las redes neuronales convolucionales en la inteligencia artificial

Las RNCs, se destacan en inteligencia artificial debido a ventajas clave, como su eficacia en la identificación de patrones visuales, la capacidad de procesar grandes volúmenes de datos visuales y su habilidad para aprender y mejorar con el tiempo. No obstante, enfrentan desafíos, como la necesidad de conjuntos de datos extensos y el tiempo y recursos requeridos para el entrenamiento y optimización (Quiroa, 2023).

Python

Python es un lenguaje de programación de código abierto que fue concebido por Guido van Rossum en 1991. Se destaca por ser un lenguaje orientado a objetos, reconocido por su facilidad de interpretación y una sintaxis que se asemeja mucho a la lengua inglesa, lo que facilita su comprensión. En su funcionamiento, Python es un lenguaje interpretado, lo que implica que el código de programación se traduce en bytecode y se ejecuta mediante el intérprete, en este caso, la máquina virtual de Python. (blog.hubspot, 2023).

Librería NumPy

NumPy es una biblioteca de Python altamente especializada en el procesamiento numérico y el análisis de datos, diseñada especialmente para su aplicación en conjuntos de datos extensos (Aprendeconalf ,2022).

Librería MinMaxScaler

Este procedimiento de normalización ajusta los valores de una distribución para que se encuentren dentro de un intervalo de 0 a 1 (aunque se puede elegir otro intervalo, el más común es 0 a 1). Su principal beneficio radica en que, al incorporar la desviación estándar junto con los valores mínimo y máximo, conserva la proporción relativa de los datos dentro del intervalo definido (Rubiales,2020).

Librería Tensorflow

En TensorFlow, el proceso comienza con la recopilación de datos, seguido de la selección o creación de un modelo que sea adecuado para el procesamiento de grandes conjuntos de datos. Luego, se procede a ajustar los datos recopilados al modelo y realizar la primera predicción. Posteriormente, se

evalúa la precisión del modelo, se continúa iterando y experimentando para perfeccionarlo y, finalmente, se almacena el modelo para su uso futuro y para continuar mejorando su eficacia (keepcoding, 2023).

Capa Conv1D

La capa Conv1D se destaca por su capacidad para analizar datos unidimensionales y extraer características locales y patrones secuenciales de manera efectiva. En aplicaciones de procesamiento de señales, esta capa resulta útil para identificar características en series temporales de datos, lo que abarca la detección de cambios en señales de sonido o en valores de sensores, fortaleciendo su utilidad en tareas continuas de análisis y procesamiento de datos. (Álvaro González, 2023)

Capa de MaxPooling

El proceso de pooling consiste en analizar segmentos de una imagen para extraer su información más significativa. El max-pooling, en particular, tiene la finalidad de reducir la cantidad de datos entre capas de una red neuronal, lo que agiliza tanto el procesamiento de imágenes como el entrenamiento de la red. Al mismo tiempo, se asegura de mantener la información más destacada. En el max-pooling, la imagen se divide en regiones de tamaño uniforme, y para cada región, se selecciona simplemente el valor más alto, que se corresponderá con un píxel en la imagen resultante (Sotaquirá, 2019).

Media

La media aritmética se determina mediante la función "mean," que requiere una lista de valores como entrada para calcular la tendencia central. La media se obtiene al sumar todos los valores y dividirlos por la cantidad de valores presentes. Este valor es un indicador del punto medio de la distribución y se encuentra entre las medidas estadísticas más comunes. Sin embargo, es importante señalar que esta medida puede ser distorsionada por valores extremos, lo que puede hacerla inexacta como representante de la centralidad de los valores (Navarro, 2023).

La ecuación para la media aritmética se puede expresar como:

$$Media = \frac{a_1 + a_2 + \dots + a_n}{n} \quad (1)$$

Donde los valores a_1, a_2, \dots, a_n representan los datos, y n es la cantidad total de datos presentes en la muestra.

Mediana

La mediana es el valor que se halla en el centro de un conjunto de datos previamente ordenados, y se emplea para representar un valor "normal" de una población específica. Desde una perspectiva de programación, podemos describir la mediana como el valor que divide una secuencia en dos partes iguales: la mitad inferior y la mitad superior (Díaz, 2023).

La ecuación para la mediana aritmética se puede expresar como:

$$Md = \frac{x_{n+1}}{2} \quad \text{Si } n \text{ es impar} \quad (2)$$

$$Md = \frac{\frac{x_n + x_{\frac{n}{2}+1}}{2}}{2} \quad \text{Si } n \text{ es par} \quad (3)$$

Donde x es el valor del conjunto de datos y n es el número total de observaciones o datos.

Kurtosis

La kurtosis, o curtosis, se emplea para caracterizar la forma de una distribución. Esta medida utiliza el cuarto momento central estandarizado y ayuda a identificar valores extremos. Cuando existen valores atípicos, la distribución tiende a mostrar una forma más puntiaguda, y por este motivo, la kurtosis se considera una medida que cuantifica el nivel de concentración o apuntalamiento de la distribución. (odiolaestadistica, 2020).

La ecuación para calcular la kurtosis de una muestra de datos se define como:

$$Kurt = \frac{1}{n} \sum_{i=1}^n \left(\frac{x_i - \bar{x}}{s} \right)^4 - 3 \quad (4)$$

En donde n es el total de observaciones de la muestra, x_i representa el valor de la i -ésima observación. En este contexto, \bar{x} simboliza la media de toda la muestra, mientras que s representa la desviación estándar de dicha muestra.

Skewness

La skewness es una medida empleada para evaluar la asimetría de una distribución de datos. Ofrece detalles acerca de si los valores de una variable exhiben una tendencia a concentrarse en mayor medida en uno de los lados (superior o inferior) de la media. En esencia, la skewness representa una herramienta matemática y estadística que contribuye a la comprensión de las propiedades de una distribución de frecuencias, al considerar factores como la inclinación o desviación, como podría ser la variabilidad en los datos (Zhou, 2023).

La fórmula de skewness es:

$$Skewness = \frac{n}{(n-1)(n-2)} \sum_{i=1}^n \left(\frac{x_i - \bar{x}}{s} \right)^3 \quad (5)$$

En donde la variable n simboliza la cantidad de elementos presentes en la muestra y cada valor individual dentro de la muestra es representado por x_i . La \bar{x} corresponde a la media aritmética de todos los datos contenidos en la muestra, mientras que s representa la desviación estándar de la misma.

THD

La Distorsión Armónica Total (THD) es una métrica técnica que mide la distorsión presente en una señal eléctrica o acústica. THD cuantifica la relación entre la potencia total de todas las frecuencias armónicas presentes en la señal y la potencia de la frecuencia fundamental. En términos más sencillos, THD se expresa como un porcentaje que compara la energía de las componentes armónicas de orden superior con la energía de la componente fundamental. Es crucial destacar que un valor elevado de THD puede ser indicativo de una señal de baja calidad con una alta cantidad de distorsión (Schneider, 2020). La ecuación para THD se puede expresar como:

$$THD = \frac{\sqrt{\sum_{i=2}^n v_i^2}}{v_1} \quad (6)$$

Donde v_1 es el valor eficaz de la señal y v_i es el valor eficaz de la i -ésima componente armónica.

Transformada de Fourier

Una serie de Fourier es una representación matemática de una función periódica en términos de una suma infinita de funciones sinusoidales (senos y cosenos) o exponenciales complejas. Fue desarrollada por el matemático francés Jean-Baptiste Joseph Fourier y se utiliza para descomponer una función periódica en sus componentes fundamentales, es decir, las frecuencias sinusoidales que la componen (Zill, 2018).

Sea $f(x)$ una función seccionalmente continua en $[-p, p]$. La serie descrita por la ecuación (6) (Zill, 2018)

$$f(x) = \frac{a_0}{2} + \sum_{n=1}^{\infty} \left(a_n \cos \frac{n\pi x}{P} + b_n \sin \frac{n\pi x}{P} \right) \quad (7)$$

Las fórmulas (7), (8) y (9) que dan los coeficientes de una serie de Fourier se conocen como fórmulas de Euler (Zill, 2018).

Donde:

$$a_0 = \frac{1}{P} \int_{-p}^P f(x) dx \quad (8)$$

$$a_n = \frac{1}{P} \int_{-p}^P f(x) \cos \frac{n\pi x}{P} dx \quad (9)$$

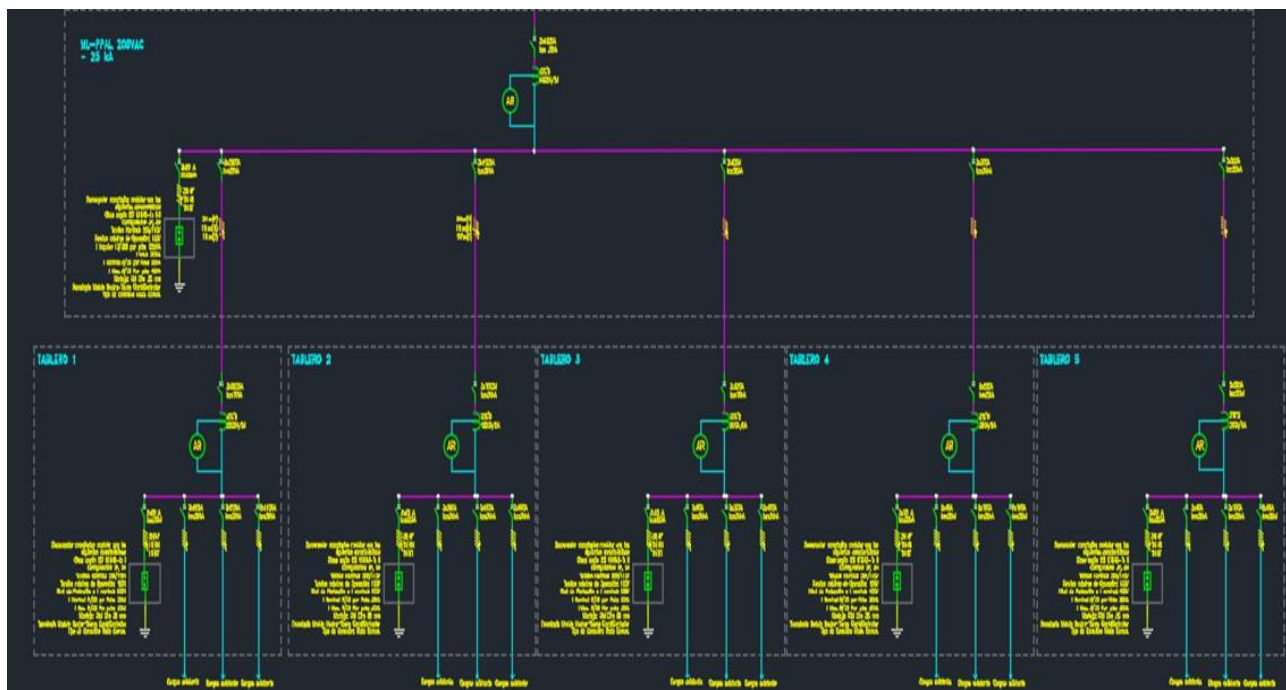
$$b_n = \frac{1}{P} \int_{-p}^P f(x) \sin \frac{n\pi x}{P} dx \quad (10)$$

Sistemas eléctricos de baja tensión

Los sistemas eléctricos consisten en circuitos eléctricos cerrados utilizados para la transferencia de energía eléctrica. Estos sistemas se categorizan en base a su voltaje (alta, media y baja tensión) y su propósito (generación, transporte, transformación y recepción). A pesar de estas diferencias, todos comparten la función fundamental de transportar la energía eléctrica desde los elementos generadores hasta los dispositivos consumidores.

Las instalaciones de baja tensión son aquellas cuya clasificación se aplica a sistemas eléctricos que operan con corriente alterna de 1000 voltios o menos, así como con corriente continua de 1500 voltios o menos (Grupo Turelectric, 2019).

Ilustración 3. Unifilar



Fuente: Propia

En la ilustración 3 se muestra el unifilar típico de un sistema eléctrico de baja tensión que se encuentra bien estructurado y equipado con interruptores, submales, DPS, TC's y analizadores de red. La presencia de estos componentes es fundamental para garantizar el funcionamiento seguro y eficiente del sistema eléctrico, permitiendo un control preciso, protección contra sobretensiones y un monitoreo detallado de su desempeño.

Clasificación de los niveles de tensión

Con fines de cumplimiento del reglamento Técnico de Instalaciones Eléctricas, se establecen los siguientes niveles de tensión para sistemas de corriente alterna, los cuales se toman de la norma NTC 1340:

- Extra alta tensión (EAT): Se refiere a tensiones que superan los 230 kV.
- Alta tensión (AT): Tensiones que son iguales o superiores a 57,5 kV y menores o iguales a 230 kV.
- Media tensión (MT): Aquellas con una tensión nominal superior a 1000 V, pero inferior a 57,5 kV.
- Baja tensión (BT): Aquellas con una tensión nominal igual o superior a 25 V, pero menor o igual a 1000 V.
- Muy baja tensión (MBT): Tensiones por debajo de los 25 V (Energía, 2013).

Sobretensiones

Las sobretensiones, en el contexto eléctrico, se definen como incrementos en el voltaje que exceden los límites máximos permitidos en una instalación. Estas pueden clasificarse en dos categorías: sobretensiones permanentes o sostenidas, que superan el 10% del valor nominal y persisten durante varios días, y sobretensiones transitorias, que elevan brevemente el voltaje por un corto período de tiempo.

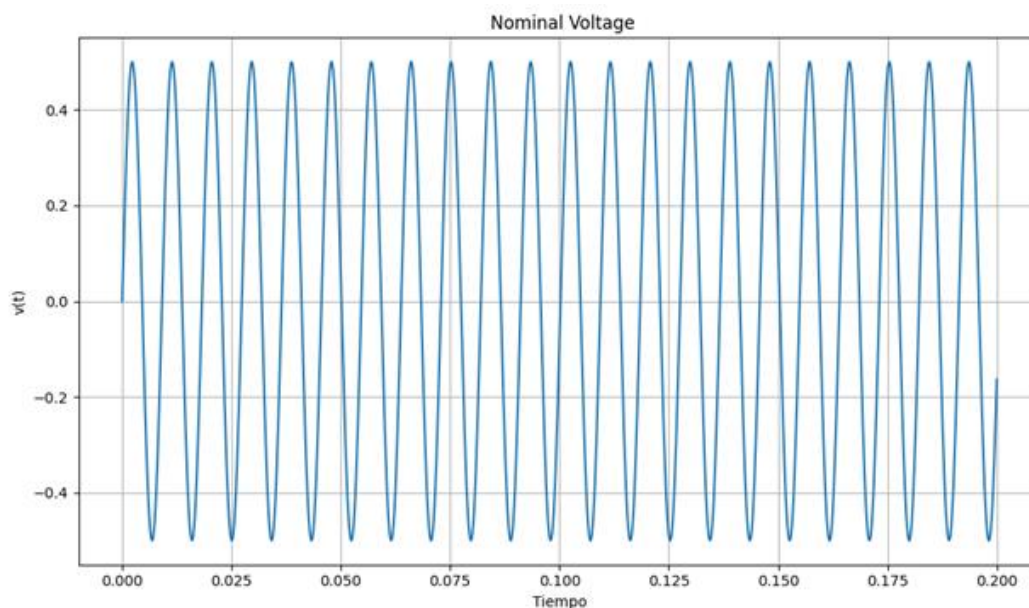
Las sobretensiones en entornos residenciales suelen originarse a partir de eventos como cambios en la red eléctrica o descargas de rayos. Para proteger un hogar de las sobretensiones, se recomienda la instalación de dispositivos de protección conocidos como limitadores de sobretensión o DPS (Dispositivos de Protección contra Sobretensiones). Existen tres tipos principales de DPS utilizados en entornos residenciales: DPS contra sobretensiones transitorias, DPS contra sobretensiones permanentes y DPS combinados que ofrecen protección contra ambos tipos de sobretensiones. Estos dispositivos se encargan de gestionar la energía eléctrica para proteger los dispositivos conectados al suministro eléctrico de posibles daños debidos a sobretensiones (TotalEnergies.2022).

Este voltaje nominal se describe matemáticamente mediante de la siguiente fórmula:

$$v(t) = V \text{ sen}(\omega t + \theta) \quad (11)$$

En donde $v(t)$ denota el voltaje en relación con el tiempo. Además, se representa con V el valor constante del voltaje nominal, ωt es la frecuencia angular del sistema eléctrico, comúnmente considerada una constante y el ángulo de fase es representado con θ .

Ilustración 5. Voltaje nominal



Fuente: propia

En la ilustración 5 se muestra el comportamiento gráfico del voltaje nominal en el cual no tiene contaminaciones en el sistema que pueda hacer variar el voltaje.

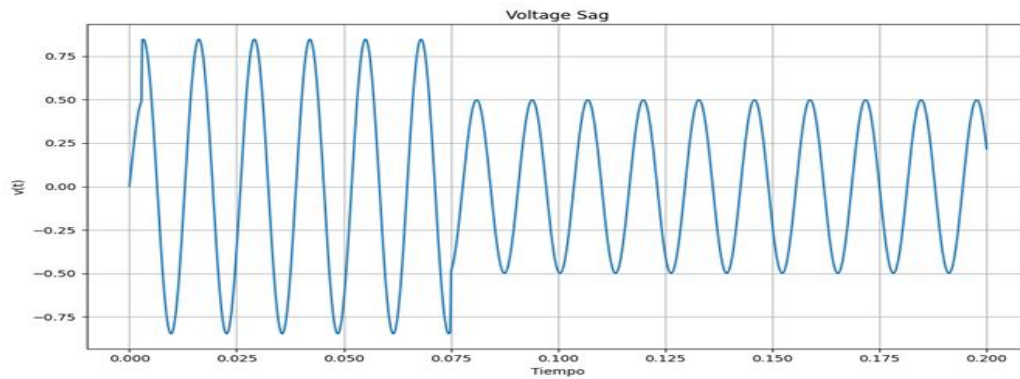
Caída de voltaje

Las caídas de voltaje, que se incluyen en la categoría de "bajo voltaje", ocurren principalmente durante la conmutación de cargas pesadas o fallas del sistema eléctrico. El estándar IEEE 1159 describe esta condición como la disminución del 10% al 90% del voltaje RMS durante un tiempo de entre 0,5 ciclos y 1 min. Las caídas de voltaje también pueden ser causadas como resultado del arranque del motor del inductor, la energización del transformador o el aumento en la impedancia de la fuente. También se denomina 'caída de voltaje' y puede describirse matemáticamente como:

$$v(t) = V [1 - \alpha (u(t - t_1) - u(t - t_2))] \text{sen}(\omega t) \quad (12)$$

En donde α está entre los valores $0.1 \leq \alpha \leq 0.9$. $v(t)$ denota el voltaje en relación con el tiempo y, además, se representa con V el valor constante del voltaje nominal y ωt es la frecuencia angular del sistema eléctrico, comúnmente considerada una constante. (Basumallik, 2019).

Ilustración 6. Caída de tensión



Fuente: Propia.

En la ilustración 6 se muestra el comportamiento grafico de caída de tensión.


Aumento de voltaje

El aumento de voltaje se incluye en la categoría de "sobretensión", que ocurre cuando el voltaje aumenta entre un 10% y un 90% de su valor RMS durante 0,5 ciclos a 1 min. Estos eventos se deben a una reducción repentina de la carga, la conmutación de un banco de condensadores y un aumento temporal de voltaje en una fase sin falla durante una falla de SLG. También se denomina "sobretensión monetaria" y matemáticamente viene dada por:

$$v(t) = V [1 + \alpha (u(t - t_1) - u(t - t_2))] \text{sen}(\omega t) \quad (13)$$

En donde α está entre los valores $0.1 \leq \alpha \leq 0.9$. $v(t)$ denota el voltaje en relación con el tiempo y Además, se representa con V el valor constante del voltaje nominal y ωt es la frecuencia angular del sistema eléctrico, comúnmente considerada una constante. (Basumallik, 2019).

Ilustración 7. Sobretensión



Fuente: Propia.

En la ilustración 7 se muestra el comportamiento grafico de una sobretensión de tensión.

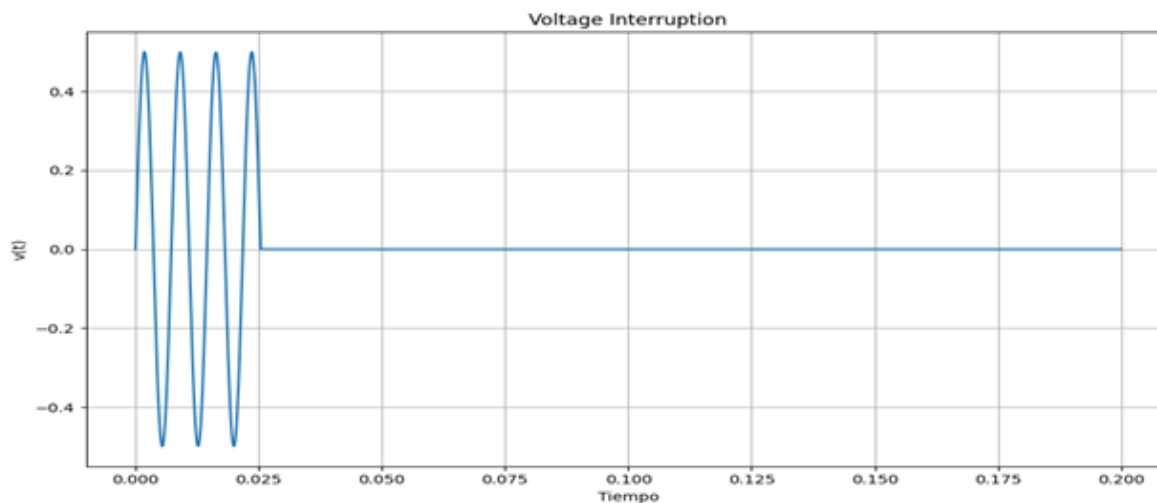
Interrupción de voltaje

Cuando el voltaje RMS cae entre un 90% y un 100% de su valor nominal durante 0,5 ciclos a 1 min, se denomina interrupción de voltaje. Se pueden clasificar en interrupciones de larga duración (≥ 3 min) y de corta duración (≤ 3 min). Estos eventos son causados por fallas, fallas del equipo, mal funcionamiento del control o intervención del operador. A veces, las interrupciones van seguidas de caídas de tensión. Se expresa como:

$$v(t) = V [1 - \alpha(u(t - t1) - u(t - t2))] \text{sen}(\omega t) \quad (14)$$

En donde α está entre los valores $0.1 \leq \alpha \leq 0.9$. $v(t)$ denota el voltaje en relación con el tiempo y Además, se representa con V el valor constante del voltaje nominal y ωt es la frecuencia angular del sistema eléctrico, comúnmente considerada una constante (Basumallik, 2019).

Ilustración 8. Interrupción de voltaje



Fuente: Propia

En la ilustración 8 se muestra el comportamiento gráfico de una interrupción de tensión.

Resultados de la propuesta

En esta sección, se presenta la aplicación de métodos de aprendizaje, en el que el proyecto abarcó la generación de series temporales de datos eléctricos simulados y la implementación de 3 modelos de redes neuronales, las cuales son una RNC, y dos Perceptrón multicapa, para clasificar estas series temporales en diferentes categorías. El objetivo principal del proyecto fue desarrollar una herramienta que permitiera la detección y clasificación de distintas condiciones eléctricas, como caídas de voltaje, aumentos de voltaje, interrupciones de voltaje y voltaje nominal, en sistemas eléctricos.

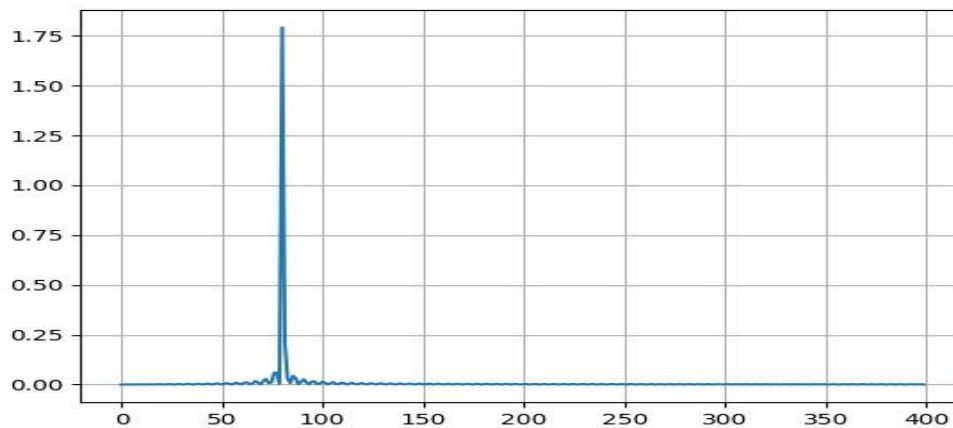
Para los tres diferentes modelos de la red neuronal se desarrolla un código en Python Colab que genera una base de datos simulada de series temporales eléctricas con diferentes condiciones y sus etiquetas, y se importan las siguientes bibliotecas: NumPy para operaciones matemáticas, Matplotlib para graficar, la función `uniform` desde `numpy.random` para generar números aleatorios uniformes y `MinMaxScaler` desde `sklearn.preprocessing` para la posible normalización de datos.

Para la generación de los datos simulados, se utilizan parámetros como V , t_1 , t_2 y `num_repetitions` para controlar la generación de datos. Se crea un arreglo de tiempo (t) que contiene valores espaciados linealmente de 0 a 0.2, con un total de 1000 puntos para representar el tiempo.

Para generar los datos, se crean matrices para almacenar series temporales de eventos eléctricos simulados, las cuales se combinan en una matriz conjunta llamada "resulting_matrix." Además, se crean etiquetas al combinar cuatro matrices de etiquetas individuales en una matriz llamada "labels." Luego, se analizan las características de las señales almacenadas en "resulting_matrix" en los dominios del tiempo y la frecuencia mediante la Transformada de Fourier.

La Transformada de Fourier se aplica a cada fila de la matriz "resulting_matrix," se obtienen estadísticas de la serie temporal, se calcula THD y se calculan estadísticas similares para la Serie de Fourier. Todas estas características se almacenan en una nueva matriz llamada "resulting_characteristic_matrix," que tendrá 10 columnas y un número de filas igual al número de elementos en "resulting_matrix."

Ilustración 9. Gráfica serie de Fourier



Fuente: Propia.

La ilustración 9 muestra la gráfica de serie de Fourier obtenida.

En el desarrollo de diferentes modelos de aprendizaje automático, se aplican varios procesos comunes para la preparación de datos, entrenamiento de modelos y evaluación de su rendimiento. Se realiza la división de los datos en conjuntos de entrenamiento y prueba utilizando la función `train_test_split` de Scikit-Learn, asignando porcentajes específicos a cada conjunto, en este proceso, el 80% de los datos se destina al conjunto de entrenamiento (`X_train` y `y_train``), mientras que el 20% se reserva para el conjunto de pruebas (`X_test` y `y_test``). Luego, se normalizan las características de estos conjuntos utilizando `MinMaxScaler` para asegurar que todas las características tengan la misma escala, lo que es crucial para el funcionamiento óptimo de los algoritmos de aprendizaje automático.

Posteriormente, se procede al entrenamiento de las redes neuronales, para esto se crea un modelo de MSV utilizando la clase `SVC` de Scikit-Learn, la cual obtuvo una precisión del 69%. A continuación, este se entrena con los datos de entrenamiento (`X_train`, `y_train`) anteriormente escalados. Paralelamente, Se crea un primer modelo red Perceptrón Multicapa (MLP) usando la clase `MLPClassifier` de Scikit-Learn, con una estructura que consta de tres capas ocultas, cada una con 250 neuronas, y un límite de 1000 iteraciones de entrenamiento. Posteriormente, la precisión del modelo se evalúa comparando las etiquetas reales con las predichas mediante la función `accuracy_score`, revelando una precisión del 70% para estos modelos.

En un enfoque alternativo, se implementa un segundo modelo Perceptrón Multicapa, sin embargo, se omiten las medidas de dispersión mencionadas en la primera red y se procede directamente al análisis de los datos generados. Se divide el conjunto de datos en conjuntos de entrenamiento y prueba utilizando la función `train_test_split` de Scikit-Learn. El 20% se destina al conjunto de pruebas, mientras que el 80% se utiliza como conjunto de entrenamiento. A continuación se crea el modelo de red neuronal utilizando `tf.keras.Sequential`. La arquitectura comprende varias capas densas con activaciones ReLU en las capas ocultas estas se dividen en 7 capas ocultas y una capa de salida con 4 unidades. Luego para evaluar el rendimiento del modelo, se compila el modelo utilizando `model.compile`, la función de pérdida se establece como `sparse_categorical_crossentropy`, se utiliza el optimizador 'adam', y se registra la métrica de precisión (acc). La función `model.evaluate()` evalúa el modelo en el conjunto de pruebas y proporciona la pérdida y la precisión de este. La precisión alcanzada por este modelo se sitúa en un 71%.

En otro enfoque, se emplea la arquitectura de un modelo RNC, se inicia con la división de los datos en conjuntos de entrenamiento y prueba. Luego, se reformatean los datos para agregar una dimensión adicional. La arquitectura de la red se define, se compila el modelo, se lleva a cabo el entrenamiento y se evalúa, obteniendo una precisión del 70%.

Tabla 1. Eventos eléctricos simulados.

Eventos	Etiqueta	Muestras
Caída de voltaje	1	1000
Sobretensión	2	1000
Interrupción de voltaje	3	1000
Voltaje nominal	0	1000

Fuente: Propia.

En la tabla 1 se muestra los diferentes eventos simulados con la etiqueta y numero de muestras.

Tabla 2. Evaluación de los modelos

Tipo de red	Estructura	Precisión
Perceptrón Multicapa 1	2 capas ,250 x1,	70%
	1 capa 4x1	
Perceptrón Multicapa 2	5 capas, 20x1,	71%
	1capa 4x1	
Convolutacional	1 capa ,400x200	70%

Fuente: Propia.

En la tabla 2 se muestra la precisión obtenida con la implementación de las diferentes redes neuronales.

Discusión de resultados

Después de haber desarrollado y ejecutado los modelos de redes neuronales, tanto el perceptrón multicapa como el convolucional, no se logró alcanzar la precisión deseada de al menos el 92%. La posible falta de precisión podría estar relacionada con la forma en que los modelos procesaron la información, ya que los datos utilizados eran de naturaleza sintética y generados de manera aleatoria, lo cual podría haber influido en que la precisión no alcanzara un nivel óptimo. Esta conclusión se basa en la comparación de nuestros modelos con el utilizado en el trabajo desarrollado por Basumallik (2019), el cual alcanzó una precisión del 99.83 %. No obstante, es importante destacar que en este otro estudio se empleó una base de datos distinta a la que fue utilizada en nuestra investigación.

A pesar de ello, se logró obtener una precisión que osciló entre el 70% y el 71% en nuestros modelos, lo cual representa un porcentaje adecuado. Esto establece una sólida base para investigaciones futuras y la mejora continua del sistema de detección de sobretensiones.

Conclusiones

- El proyecto logró sus objetivos al desarrollar un modelo de clasificación capaz de detectar y categorizar diferentes condiciones eléctricas en series temporales de datos eléctricos simulados.
- La variabilidad en los resultados, con un rango de precisión del 70% al 71%, sugiere que los modelos pueden ser sensibles a ciertas condiciones, naturaleza o características de los datos utilizados, las cuales afectan directamente la precisión. La alta aleatoriedad en la generación de los datos simulados sobre eventos de calidad de energía puede complicar la capacidad de las tecnologías de machine learning para distinguir entre distintos fenómenos. Esta aleatoriedad podría introducir ruido, es decir, datos con errores o mal etiquetados, afectando negativamente el aprendizaje de las redes neuronales y resultando en imprecisiones en los resultados. Por esto es debe destacar la importancia de contar con un equilibrio adecuado en esta aleatoriedad para permitir que las tecnologías de machine learning identifiquen patrones de manera efectiva y mejoren la precisión.
- Se recomienda una validación adicional con datos reales y la posibilidad de ajustar la arquitectura del modelo y el preprocesamiento de datos para obtener un rendimiento aún mayor.
- Esta investigación pone de manifiesto la importancia de la calidad y representatividad de los datos en el rendimiento de los modelos de aprendizaje automático. En futuros estudios, la atención a la recopilación y preparación de datos puede ser un factor crítico para mejorar la precisión.
- A pesar de no alcanzar la precisión del 92%, esta investigación revela el potencial de este proyecto en la supervisión y detección de anomalías eléctricas en sistemas de energía. Aunque se ha observado una baja precisión en la predicción de sobretensiones, caídas de tensión e interrupciones de la tensión, esto establece una base sólida para investigaciones futuras en el campo de la detección de eventos eléctricos anómalos.

Bibliografía

Strack, J. L. (2019). Identificación y clasificación automática de eventos de tensión en redes eléctricas inteligentes.

Electrical Safety Foundation International (2021). What are Power Surges:

<https://www.esfi.org/what-are-power-surges/>

Posso Pereira, P. A. (2022). Mejoramiento de la coordinación de aislamiento en subestaciones mediante el estudio y análisis de viabilidad en reproducir la reducción de BIL (Bachelor's thesis).

Romero Tello, P. (2019). Aplicación de herramientas de Machine Learning al comportamiento en la mar.

Pérez, M. (2022). ¿Cómo está cambiando el Deep Learning la forma de analizar datos?:

<https://www.gantabi.com/2022/04/26/como-esta-cambiando-el-deep-learning-la-forma-de-analizar-datos/>

SAP. (2022). ¿Qué es el machine learning?:

<https://www.sap.com/latinamerica/products/artificial-intelligence/what-is-machine-learning.html>

García, J. (2021). Estructura de una red neuronal artificial:

https://www.íeseaíhgate.net/figuie/Figuía-1-Estíuctuía-de-una-íed-neuóonal-aítificial-8_fig1_356119399

IBM. (2021). El modelo de redes neuronales:

<https://www.ibm.com/docs/es/spss-modeler/saas?topic=networks-neural-model>

TotalEnergies. (2022). Sobretensiones: causas, daños y protección:

<https://www.totalenergies.es/es/hogares/blog/mantenimiento-hogares/sobretensiones-causas-danos-proteccion#:~:text=Las%20sobretensiones%20se%20producen%20por,las%20sobretensiones%20permanentes%20o%20mantenidas.>

Grupo Turelectric. (2019). INSTALACIONES ELÉCTRICAS:

<https://grupoturelectric.com/tipos-de-instalaciones-electricas-cuales-son-las-mas-recomendables/#:~:text=Las%20instalaciones%20de%20baja%20tensi%C3%B3n,o%20inferior%20a%201500%20voltios>

Reiz, A. N., de la Hoz, M. A., & García, M. S (2019). Big data analysis y machine learning en medicina intensiva. *Medicina Intensiva*, 43(7), 416-426.

UNIR. (2021). Redes neuronales artificiales: qué son y cuáles son sus usos. *UNIR Revista Digital de Ingeniería y Tecnología*, (28):

<https://www.unir.net/ingenieria/revista/redes-neuronales-artificiales>

Quiroa. (2023). Red neuronal convolucional:

<https://economipedia.com/definiciones/red-neuronal-convolucional.html>

Sagnik, Basumallik. (2019). Voltage Quality Time Series Classification using Convolutional Neural Network.

Aprendeconalf. (2022). La librería Numpy:

<https://aprendeconalf.es/docencia/python/manual/numpy/#:~:text=NumPy%20es%20una%20librer%C3%ADa%20de,un%20gran%20volumen%20de%20datos.>

Hubspot. (2023). Qué es Python:

<https://blog.hubspot.es/website/que-es-python>

Rubiales, A. (2020). MinMaxScaler de sklearn solo con Numpy. <https://es.stackoverflow.com/questions/400007/minmaxscaler-de-sklearn-solo-con-numpy>

keepcoding (2023). ¿Para qué sirve TensorFlow?:

<https://keepcoding.io/blog/para-que-sirve-tensorflow/#:~:text=En%20Tensorflow%20el%20flujo%20de,de%20modelo%2C%20continuar%20experimentando%20para>

González, A. (2023) Trabajo de grado Sistema de Identificación de Emociones Independiente el Hablante Basado en Redes Neuronales Convolucionales:

https://oa.upm.es/75003/1/TFG_ALVARO_GONZALEZ_ALMANSA%20LAREDO.pdf

Sotaquirá, M. (2019). Padding, strides, max-pooling y stacking en las Redes Convolucionales:
<https://www.codificandobits.com/blog/padding-strides-maxpooling-stacking-redes-convolucionales/>

Cabrera Berríos, J. (2023). Voltaje nominal: ¿Qué es? (frente a voltaje operativo y nominal):
<https://telcomplus.org/sistema-de-control-bucle-cerrado-sistema-de-control-bucle-abierto/>

Navarro, A. (2023) Estadística con Python:

<https://juncotic.com/estadistica-con-python/>

Díaz, D. (2023). ¿Cómo hallar la media, la mediana y la moda en Python?:

<https://geekflare.com/es/python-find-mean-median-and-mode/>

Odiolaestadística. (2020). Asimetría y kurtosis:

<https://www.odiolaestadistica.com/estadistica-python/asimetria/>

Zhou. X. (2023). Skewness:

<https://www.rankia.com/diccionario/fondos-inversion/skewness>

Schneider. (2020). Distorsión total armónica. recuperado de Unidad de control MasterPact MTZ MicroLogic X (schneider-electric.com):

https://product-help.schneider-electric.com/ED/MTZ/Micrologic_X_User_Guide/EDMS/DOCA0102ES/DOCA0102xx/MeteringFunctions/MeteringFunctions-12.htm

seabrookewindows. (2023). Cómo Calcular la serie de Fourier en Python:
<https://www.seabrookewindows.com/xW6O6ExPL/>

Zill, D. G (2018). *Differential Equations with Boundary-Value Problems* (Ninth ed.). Boston: Cengage Learning.

Energía. (2013). *REGLAMENTO TÉCNICO DE INSTALACIONES ELÉCTRICAS (RETIE)*: <https://www.minenergia.gov.co/documents/9024/9703.pdf>

Colsein. (2021). *¿POR QUÉ ES NECESARIA LA PROTECCIÓN*: <http://www.colsein.com.co/docs/aplicaciones/PCSAS/phoenixcontact26agosto.pdf>

Mahela, O. P., Shaik, A. G., & Gupta, N. (2015). A critical review of detection and classification of power quality events. *Renewable and Sustainable Energy Reviews*, 41, 495-505.

de Yong, D. M. (2016). *Detección, clasificación y localización de eventos de calidad de energía utilizando técnicas avanzadas de procesamiento de señales e inteligencia artificial*. Repositorio DIGITAL Universidad Nacional de Río Cuarto. Facultad de Ingeniería; Argentina.

Carpio Suárez, G. X., & Daga López, P. A. (2019). *Aplicación de una red neuronal a un sistema eléctrico de distribución mediante el análisis de comportamiento de su carga en bajo voltaje*. Tesis de pregrado, Repositorio Institucional de la Universidad Politécnica Salesiana.

Rozo Puentes, J. D. (2022). *Detección de fenómenos de la calidad de la potencia por medio de algoritmos de machine learning*. Tesis de pregrado, Repositorio Institucional Séneca Universidad de los Andes.

Guevara Gómez, M. L. (2023). *Clasificación de eventos de calidad de energía utilizando redes neuronales convolucionales profundas en el marco de la industria 4.0*. Tesis doctoral, Universidad Tecnológica de Pereira.