

**CLASIFICACIÓN Y UBICACIÓN DE FALLAS  
EN LÍNEAS DE TRANSMISIÓN UTILIZANDO  
EL ALGORITMO DE RETRO-PROPAGACIÓN  
DEL CLASIFICADOR.**





**UNIVERSIDAD POLITÉCNICA SALESIANA  
SEDE QUITO  
CARRERA DE ELECTRICIDAD**

**CLASIFICACIÓN Y UBICACIÓN DE FALLAS  
EN LÍNEAS DE TRANSMISIÓN UTILIZANDO  
EL ALGORITMO DE RETRO-PROPAGACIÓN  
DEL CLASIFICADOR.**

Trabajo de titulación previo a la obtención del  
Título de Ingeniero Eléctrico

AUTOR: FERNANDO JOSÉ MERA LÓPEZ  
TUTOR: JORGE PAÚL MUÑOZ PILCO

Quito -Ecuador  
2023

Fernando José Mera López

**CLASIFICACION Y UBICACIÓN DE FALLAS EL LÍNEAS DE TRANSMISIÓN UTILIZANDO EL ALGORITMO DE RETRO-PROPAGACION DEL CLASIFICADOR**

Universidad Politécnica Salesiana, Quito – Ecuador 2023

Carrera de Electricidad

Breve reseña histórica e información de contacto.



**Fernando José Mera López** (Y'2000). Realizó sus estudios de nivel secundario en la Unidad Educativa La Salle de Conocoto. Egresado de Ingeniería Eléctrica de la Universidad Politécnica Salesiana. Su trabajo consiste en clasificar y ubicar fallas que se presenta en líneas de transmisión utilizando el algoritmo de retro-propagación.  
[fmeral@est.ups.edu.ec](mailto:fmeral@est.ups.edu.ec)

*Dirigido por:*



**Jorge Paúl Muñoz Pilco** (Y'1989). Realizó sus estudios superiores en la Escuela Politécnica Nacional, Quito –Ecuador, 2014, obteniendo el título de Ingeniero Eléctrico. Además, cursó estudios de posgrado como becario de Fundación Carolina en la Universidad Pública de Navarra, Pamplona –España, 2017, obteniendo el título de Máster en Energías Renovables: Generación Eléctrica. Actualmente es profesor ocasional a tiempo completo en la Universidad Politécnica Salesiana.

[jmunoz@ups.edu.ec](mailto:jmunoz@ups.edu.ec)

Todos los derechos reservados:

Queda prohibida, salvo excepción prevista en la ley, cualquier forma de reproducción, distribución, comunicación pública y transformación de esta obra para fines comerciales, sin contar con la autorización de los titulares de propiedad intelectual. La infracción de los derechos mencionados puede ser constitutiva de delito contra la propiedad intelectual. Se permite la libre difusión de este texto con fines académicos o investigativos por cualquier medio, con la debida notificación a los autores.

**DERECHOS RESERVADOS**

©2023 Universidad Politécnica Salesiana

QUITO - ECUADOR

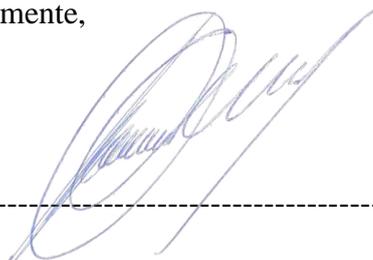
## **CERTIFICADO DE RESPONSABILIDAD Y AUTORÍA DEL TRABAJO DE TITULACIÓN**

Yo, Fernando José Mera López con documento de identificación N° 1727423707 manifiesto que:

Soy el autor y responsable del presente trabajo; y, autorizo a que sin fines de lucro la Universidad Politécnica Salesiana pueda usar, difundir, reproducir o publicar de manera total o parcial el presente trabajo de titulación.

Quito, 4 de mayo del año 2023

Atentamente,



Fernando José Mera López

1727423707

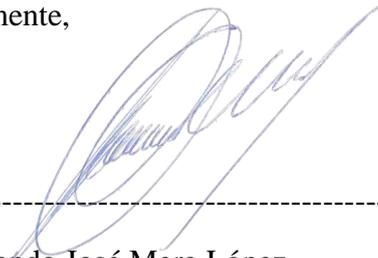
## **CERTIFICADO DE CESIÓN DE DERECHOS DE AUTOR DEL TRABAJO DE TITULACIÓN A LA UNIVERSIDAD POLITÉCNICA SALESIANA**

Yo, Fernando José Mera López con documento de identificación No. 1727423707, expreso mi voluntad y por medio del presente documento cedo a la Universidad Politécnica Salesiana la titularidad sobre los derechos patrimoniales en virtud de que soy autor del Artículo Académico: “Clasificación y ubicación de fallas en líneas de transmisión utilizando el algoritmo de retro-propagación del clasificador”, el cual ha sido desarrollado para optar por el título de: Ingeniero Eléctrico, en la Universidad Politécnica Salesiana, quedando la Universidad facultada para ejercer plenamente los derechos cedidos anteriormente.

En concordancia con lo manifestado, suscribo este documento en el momento que hago la entrega del trabajo final en formato digital a la Biblioteca de la Universidad Politécnica Salesiana.

Quito, 4 de mayo del año 2023

Atentamente,



Fernando José Mera López

1727423707

## CERTIFICADO DE DIRECCIÓN DEL TRABAJO DE TITULACIÓN

Yo, Jorge Paúl Muñoz Pilco con documento de identificación N° 1719006189, docente de la Universidad Politécnica Salesiana, declaro que bajo mi tutoría fue desarrollado el trabajo de titulación: CLASIFICACIÓN Y UBICACIÓN DE FALLAS EN LÍNEAS DE TRANSMISIÓN UTILIZANDO EL ALGORITMO DE RETRO-PROPAGACIÓN DEL CLASIFICADOR, realizado por Fernando José Mera López con documento de identificación N° 1727423707, obteniendo como resultado final el trabajo de titulación bajo la opción Académico que cumple con todos los requisitos determinados por la Universidad Politécnica Salesiana.

Quito, 4 de mayo del año 2023

Atentamente,



Ing. Jorge Paúl Muñoz Pilco, MSc  
1719006189

## ÍNDICE GENERAL

1. Introducción .....	2
2. Marco teórico .....	4
2.1 Sistema de transmisión eléctrica.....	4
2.2 Fallas en SET .....	5
2.3 Redes neuronales ANN .....	6
2.4 Topologías de redes neurales .....	6
2.5 Modelos de aprendizaje para redes neuronales.....	6
2.5.1 ANN con aprendizaje supervisado .....	6
2.5.2 ANN con aprendizaje no supervisado.....	7
2.5.3 ANN con aprendizaje por retro-propagación del error .....	7
2.6 Metodologías para la ubicación y clasificación de fallas en SET .....	7
2.7 Algoritmo de retro-propagación .....	7
3. Planteamiento del problema .....	8
3.1 Modelo propuesto .....	8
3.2 Estudio aplicado.....	9
4 Análisis de resultados .....	10
4.1 Caso de estudio1 .....	10
4.2 Caso de estudio 2 .....	11
5 Conclusiones.....	14
6. Trabajos futuros.....	14
7. Referencias .....	14
8. Anexos .....	18
9 Matriz de Estado del Arte .....	24
9.1 Resumen de Indicadores.....	27

## ÍNDICE DE FIGURAS

Figura 1. Esquema de la metodología para detectar ubicar fallas en la red de transmisión [autor]. .....	2
Figura 2. Conexión al sistema de transmisión.....	5
Figura 3. Falla monofásica de línea a tierra. ....	5
Figura 4. Falla bifásica o línea a línea.....	6
Figura 5. Falla trifásica o simétrica. ....	6
Figura 6. Topología monocapa de una red neural artificial. ....	6
Figura 7. Topología Multicapa de una red neural artificial.....	6
Figura 8. Estructura de retro propagación de una ANN.....	7
Figura 9. Esquema del IEEE 9 nodos.....	8
Figura 10. Esquema de la red neural utilizada en Matlab. ....	9
Figura 11. Convergencia obtenida en el software Matlab de la red neural. ....	10
Figura 12. Convergencia obtenida en el software Matlab de la red neural. ....	10
Figura 13. Validación de fallas Estado de entrenamiento de la red neural de 9 barras IEEE 48 épocas. (a) Gradiente de error, (b) Factor de aprendizaje, (c) Validación de fallas.....	11
Figura 14. Histograma de errores de la red neural de 9 barras IEEE para 48 épocas. ....	11
Figura 15. Ajuste de regresión de salidas contra objetivos de la red neural de 9 barras IEEE para 48 épocas. ....	11
Figura 16. Validación del entrenamiento de la red neural y error cuadrático medio de la red para 9 épocas. ....	12
Figura 17. Validación de fallas Estado de entrenamiento de la red neural de 9 barras IEEE para 9 épocas. (a) Gradiente de error, (b) Factor de aprendizaje, (c) Validación de fallas.....	12
Figura 18. Histograma de errores de la red neural de 9 barras IEEE para 9 épocas. ....	12
Figura 19. Ajuste de regresión de salidas contra objetivos de la red neural de 9 barras IEEE para 9 épocas. ....	12
Figura 20. Muestreo de fallas muy cercanas en la barra 5-4.....	13
Figura 21. Muestreo de fallas cercanas en la barra 7-8.....	13
Figura 22. Muestreo de fallas medianamente cercanas barra 8-9. ....	13
Figura 23. Muestreo de fallas medianamente lejanas en la barra 9-6. ....	13
Figura 24. Muestreo de fallas lejanas en la barra 6-4.....	13
Figura 25. Muestreo de fallas lejanas.....	14
Figura 26. Resumen e indicador de la temática - Estado del arte. ....	27
Figura 27. Indicador de formulación del problema - Estado del arte.....	27
Figura 28. Indicador de solución - Estado del arte.....	27

## ÍNDICE DE TABLAS

Tabla 1. Tipos de fallas consideradas en el estudio. ....	9
Tabla 2. Rango para la ubicación de fallas que se ha llevado a cabo en el estudio. ....	9
Tabla 3. Resultados obtenidos de la ubicación y clasificación de fallas en líneas de transmisión del modelo IEEE de 9 barras. ....	18
Tabla 4: Matriz de estado del arte .....	24

# CLASIFICACIÓN Y UBICACIÓN DE FALLAS EN LÍNEAS DE TRANSMISIÓN UTILIZANDO EL ALGORITMO DE RETRO-PROPAGACIÓN DEL CLASIFICADOR

## Resumen

La investigación desarrollada se basa en diseñar y entrenar una red neural artificial (ANN), para ubicar y clasificar fallas en sistemas eléctricos de transmisión (SET) ya que están construidas para cubrir largos tramos, por lo cual están expuestas a condiciones adversas las cuales provocan fallos eléctricos. Por lo expresado, el documento investigativo propone el diseñar una red neuronal en el software Matlab – Simulink, utilizando el algoritmo de retro-propagación. Se realizó un estudio estático para la obtención de datos mediante software PowerFactory y considerar en la red neuronal, posteriormente a la simulación se ha obtenido los datos de corriente de cortocircuito y el ángulo de cortocircuito, se generó alrededor de doscientas cincuenta fallas en el sistema de nueve barras para de esta forma generar una matriz de números binarios, para que al momento de ser ingresados realicen la acción de ubicar y clasificar.

Se realizó la comparativa con método de censo comprimido teniendo una eficacia del 96% y donde el método de redes neuronales ha llegado a una eficacia del 95% el cual muestra que el uso de redes neuronales en la actualidad es un método viable, el cual mediante un constante entrenamiento llega a una mayor eficacia y confiabilidad el modelo de ANN.

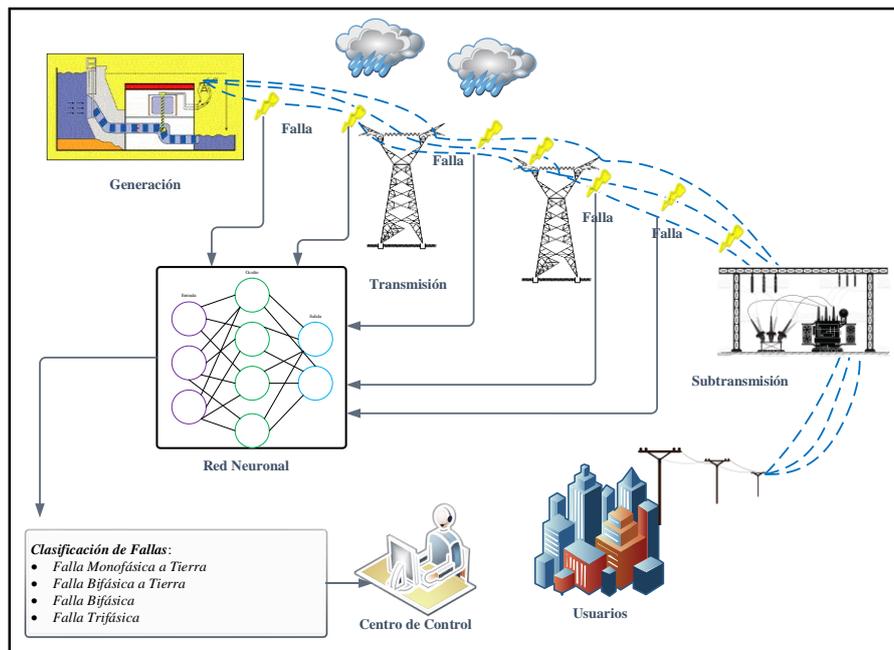
**Palabras Clave:** Clasificación, Corriente, Cortocircuito, Fallas, Red neuronal, Transmisión.

## Abstract

The research developed is based on designing and training an artificial neural network (ANN) to locate and classify faults in electrical transmission systems (SET), since they are built to cover long stretches, and therefore are exposed to adverse conditions which cause electrical failures. Therefore, the research paper proposes the design of a neural network in Matlab - Simulink software, using the back propagation algorithm. A static study was carried out to obtain data using PowerFactory software and to consider in the neural network, after the simulation the data of short-circuit current and short-circuit angle were obtained, about two hundred and fifty faults were generated in the nine-bar system to generate a matrix of binary numbers, so that when they are entered they perform the action of locating and classifying.

A comparison was made with the compressed census method with an efficiency of 96% and where the neural network method has reached an efficiency of 95%, which shows that the use of neural networks is currently a viable method, which through constant training achieves greater efficiency and reliability of the ANN model.

**Keywords:** Classification, Current, Short circuit, Faults, Neural network, Transmission.



**Figura 1.** Esquema de la metodología para detectar ubicar fallas en la red de transmisión [autor].

## 1. Introducción

El sistema eléctrico de potencia (SEP) está comprendido por tres etapas que son: generación, transmisión y distribución de energía eléctrica [1]. El análisis de este trabajo se centra en el área de transmisión, específicamente en las líneas de transmisión para ubicar y clasificar las fallas que se suscitan en líneas aéreas [2].

Las líneas de transmisión eléctricas están construidas para transportar energía desde la generación hasta los grandes centros de carga, por lo cual están expuestas a condiciones adversas las cuales provocan fallos eléctricos, lo cual para realizar la detección y ubicación se utiliza una red neuronal artificial [3].

En la actualidad se ha presentado algoritmos que usan la transformada de Wavelet y Fourier, también métodos estadísticos y de inteligencia artificial ya que son métodos prometedores y robustos al momento de ubicar fallas [4].

Las fallas o averías que se suscitan en líneas de transmisión están asociados a diversos fenómenos tanto naturales como físicos como por ejemplo el viento, descargas atmosféricas, envejecimiento de conductores entre otros [5].

Estas fallas provocan consecuencias como, cortes de suministro eléctrico para los usuarios residenciales, comerciales y los grandes centros de carga como las industrias, que se ven envueltos en grandes pérdidas económicas y productivas [6].

En la actualidad existen métodos de detección de fallas eléctricas mediante, inteligencia artificial, la cual en la actualidad se ha convertido en una herramienta conveniente en el diagnóstico y detección de las fallas que suceden en el sistema de transmisión [7].

La ANN, se justifica en características propias del cerebro de los seres humanos, porque la misma cuenta con la capacidad de memorizar y asociar sucesos como es el caso de la investigación que se está realizando sobre la detección de fallas utilizando, redes neurales que brindan un modelo el cual tienen la capacidad para poder aprender a partir de datos, la cual brinda una auto-organización y adaptabilidad [8].

En la actualidad, el uso de la inteligencia artificial es beneficioso e interesante dentro de la ingeniería. Ya que la aplicación de ANN ha aumentado enormemente en estos últimos años, impulsada por los éxitos teóricos y de aplicación en una variedad de

disciplinas, incluido en el sistema eléctrico de potencia. Aquí, en este artículo, se han indicado las aplicaciones de las ANN para detectar y clasificar fallas en SET [6].

El algoritmo de retro-propagación en conjunto, a la red neuronal (ANN) tienen la ventaja de que obtiene la relación entre los parámetros que se pueden medir y las decisiones que se deben tomar para lograr soluciones más factibles en menor tiempo sin perder la calidad de energía.

En [9] se propone un algoritmo innovador y realiza nuevas propuestas las cuales no requieren de que exista la alineación de señales y lo más interesante es que no depende de la clasificación de fallas para la localización, al momento de analizar los resultados se pueden comprobar que el algoritmo funciona de manera precisa y confiable.

En [10] se presenta un porcentaje muy bajo tanto de efectividad y precisión en la localización de fallas en el sistema eléctrico de transmisión, y esto genera grandes problemas al momento de suministrar energía, por esto se ha realizado un aumento de cobertura de la unidad de medición fasorial (PMU), que aplica un modelo de alta precisión que se apoya en la medición sincrónica del fasor, y propone un algoritmo iterativo y de alta precisión, que se caracteriza por integrar tanto las características del fasor de tensión y a la vez la comprobación de los saltos que sucede en el ángulo. Indica que es un algoritmo con gran viabilidad y eficiencia para lograr la localización de las fallas.

En [11] para la ubicación de fallas en SET, propone un modelo el cual usa la combinación de doble extremo basado en la discrepancia media máxima (MMD), el cual se apoya en combinar la red neural convolucional (CNN). En cual la discrepancia media máxima realiza la clasificación y la red convolucional es la encargada de la construcción del modelo, para la obtención de datos de las averías que se suscitan de extremo a extremo.

En [12] propone un nuevo algoritmo basado en onda viajera para líneas de

transmisión. Este método está basado en uno ya aplicado años atrás, el cual es de onda viajera para la localización de fallas. Este algoritmo se basa por el cálculo de tres terminales o la relación que sucede entre velocidades de la onda que esto ayuda a poder determinar donde se encuentra la avería si es tanto en un ramal o no.

En [13] presenta el método para la localización de fallas en sistema eléctrico de transmisión compensadas en serie utilizando un sistema de inferencia difuso y sus bases son las redes adaptivas y la estimación obtenida por mínimos cuadrados a partir de valores de corriente y tensión en un solo terminal de la línea. Para eso se ha implementado una red que actúa para ubicar fallas en toda una línea o en un segmento en específico, para mayor eficacia se ha tomado características del algoritmo de Relief.

En [14] desarrolla un estudio híbrido para cumplir con la ubicación, identificación y clasificación de fallas, la cual se basa en un método de aprendizaje automático ML con el uso de la transformada de Wavelet que extrae los valores de corriente, tensión o ambos. Se lo aplica usando el modelo GoogLENet que clasifica la falla y utiliza una red neural para la localización.

En [15] se presenta un procedimiento para clasificar fallas por medio del uso de componentes superpuestos de señales de corriente, usando el clasificador como una referencia para detectar los diversos tipos de fallos y se desarrolle la clasificación de manera lógica. Para esto se usan datos de corriente, de esta manera se determina el tipo de falla y las fases que se encuentren afectadas, de esta manera realiza un estudio de la impedancia de falla, la ubicación de la falla, el ángulo de inicio de la falla y la variación del ángulo.

En [16] se propone el método que utiliza las mediciones obtenidas a partir de los sincrofasores que son dispositivos que miden las ondas eléctricas en la red, durante una falla que se suscite en las líneas de transmisión y de esta manera comparar con

señales, que se encuentran en condiciones ideales y a partir de esta comparación ubicar y clasificar la falla.

En [17] se analiza y se plantea varias técnicas para ubicar y clasificar fallas en el SET, como la técnica de procesamiento de señales, el método de medición basado en la impedancia, además el método basado en el fenómeno de onda viajera y por último el método utilizando inteligencia artificial, para comprender diversas técnicas y modelos.

En [18] propone un algoritmo el cual mediante el cálculo de índices de coeficiente de regresión lineal de las señales de corriente trifásicas, indica que la regla de este algoritmo cuando el sistema se encuentre en condiciones normales los coeficientes de regresión lineal sean cero y cuando se encuentre en falla el sistema, los coeficientes de regresión lineal sean mayores a cero y de esta manera se observa diferentes escenarios como el tiempo de inicio, las impedancias de falla y las diferentes ubicaciones.

En [19] se presenta el estudio de señales basadas en ondículas discretas para la identificación y clasificación de fallas, para esto, se utiliza la transformada de Wavelet discreta, que mediante sus índices y la onda de corriente de las señales de falla, servirá para identificar y clasificar las fallas en las líneas de transmisión, este método ha sido propuesto en Matlab.

En [20] se utiliza la técnica de perceptrón multicapa (MLP), para localizar y detectar las fallas de transmisión, para realizar el mismo se ejecutó en una línea de 600 km de distancia y se usó Matlab. Con esto se logró obtener un 98% de predicción para detectar el tipo de falla y un 78% para la localización de fallas, con esto se obtiene que los resultados son de alta precisión para lograr la predicción de una falla como es en este caso.

El artículo se lo realiza con el objetivo de clasificar y ubicar fallas en líneas de transmisión mediante el algoritmo de retro propagación (Backpropagation), utilizando una red neural artificial. El algoritmo

permitirá encontrar y conocer de manera más rápida y eficaz la falla a partir de registros de variables eléctricas como voltajes y corrientes de la operación de un sistema eléctrico de potencia que formarán la entrada y datos de entrenamiento en la red neural.

Bajo lo expresado, el trabajo se encuentra segmentado en cinco partes. La primera parte describe el marco conceptual, la segunda parte sustenta la investigación del trabajo propuesto, la tercera describe el planteamiento del problema de investigación, la cuarta parte describe los resultados obtenidos y la quinta parte detalla las conclusiones a las que se llegó con el trabajo realizado.

## **2. Marco teórico**

A continuación, se describe los fundamentos teóricos que sustentan el desarrollo del presente estudio, los temas generales a desarrollarse sobre el sistema eléctrico de transmisión (SET), fallas en líneas de transmisión, ANN y seguidamente se presentan sus conceptos, tipos y fundamentos.

### **2.1 Sistema de transmisión eléctrica**

El SET está conformado por las líneas, torres, soportes entre los principales ya que estos están encargados del transporte de energía ya que abarca una gran extensión de terreno para de esta manera llegar a los puntos de distribución de energía eléctrica y de esta manera abastecer un consumo eléctrico de calidad al usuario final [21].

La transmisión está referida al transporte de energía eléctrica que va desde los puntos de generación que están ubicados a largas distancias, que tienen como finalidad llegar a las subestaciones, las cuales se encuentran en puntos más próximos de demanda eléctrica [22].

El SET es sencillo de identificar ya sea por sus líneas de transmisión o torres, ya que estas son muy vistosas.

El sistema de transmisión es la conexión entre punto de generación y el punto de

distribución, porque la transmisión tiene la función de transportar la energía que está siendo producida por la parte de generación, para después pasar al punto de distribución el cual se encarga de brindar suministro eléctrico a los usuarios finales [23].

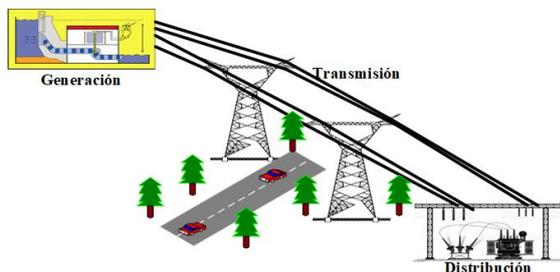


Figura 2. Conexión al sistema de transmisión.

Al referirse al SET se debe de tomar en cuenta que se tiene de dos tipos de sistemas que es el HVDC (High Voltage Direct Current), y el HVAC (High Voltage Alternating Current) a continuación se detallara un poco más de estos sistemas [24].

Los sistemas HVDC, están diseñados para transportar energía a largas distancias, ya que la misma no genera pérdidas de potencia reactiva. El sistema puede ser tanto en radial como en paralelo y cuenta con dos topologías que son la monopolar y la bipolar [24].

La ventaja del uso del sistema HVDC, es que logra transportar grandes cantidades de potencia a largas distancias y de esta manera también mantiene la estabilidad transitoria y dinámica en el sistema [25].

Los sistemas HVAC, están diseñados para transportar energía en pequeñas distancias, este sistema utiliza subestaciones intermediarias para realizar una compensación en el sistema, cabe aclarar que el control de energía es de manera lenta y compleja en este sistema [25].

En la actualidad el sistema HVDC es uno de los más ocupados por encima del HVAC, esto se debe tanto por aspectos técnicos, económicos y también de fiabilidad.

Cabe mencionar que la transmisión eléctrica no únicamente se la hace de manera aérea sino también se la puede

realizar de forma soterrada pero los valores de inversión son mucho más elevados que el de los sistemas aéreos que son más realizados [1].

## 2.2 Fallas en SET

Las fallas están relacionadas principalmente con fenómenos naturales y mecánicos, esto provoca que se generen fallas en el sistema, como por ejemplo algunos de estos fenómenos son el viento, las descargas atmosféricas, las lluvias [26] entre otros; presentándose fallas del tipo asimétricas y simétricas [27].

En gran parte las fallas que se suscitan en el sistema de transmisión son del tipo asimétricas. En un gran porcentaje son las más frecuentes en el sistema Nórdico Europeo, como un ejemplo genérico que se lo considera [28].

Se ha registrado que las averías o fallas en líneas de transmisión tienen mucho que ver con su extensión y corresponde a un 85% del total de las fallas que se suscitan en el sistema de transmisión de energía eléctrica [26].

Al contrario, un 85% son cortocircuitos fugaces, mientras tanto un 5% y 10% representan a fallas de lenta desaparición, las cuales son las que tiene un tiempo mayor de desconexión de la línea y afecta al suministro eléctrico [29].

La Falla monofásica a tierra sucede cuando una de las fases hace un contacto con tierra, en un punto de contacto en el cual se llamará F, como en [30] se toma la fórmula para la misma.

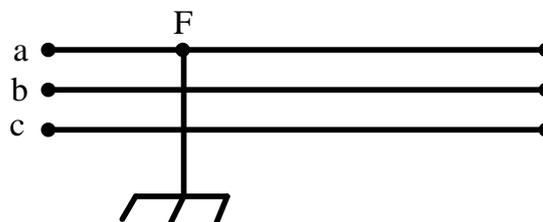


Figura 3. Falla monofásica de línea a tierra.

La falla bifásica se produce cuando dos de las fases se interconectan en un punto de falla denominado F, como en [30] se toma la fórmula para la misma.

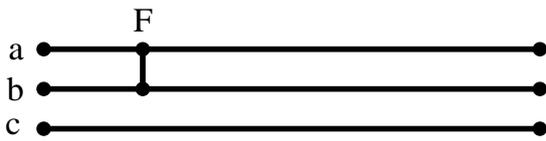


Figura 4. Falla bifásica o línea a línea.

La falla trifásica o simétrica esta se produce cuando todas las fases hacen contacto en un mismo punto denominado F, como en [30] se toma la fórmula para la misma.

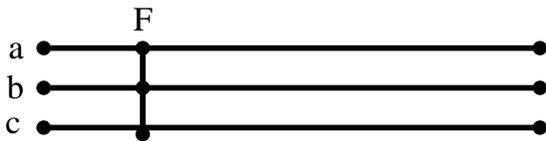


Figura 5. Falla trifásica o simétrica.

### 2.3 Redes neuronales ANN

La Red Neural Artificial (ANN), son de uso común para realizar la identificación y evaluación de fallas ya que resuelve de manera eficaz, confiable tanto problemas lineales como no lineales[31],[30].

Para que resuelva de manera satisfactoria un problema, se ha tomado en cuenta dos técnicas esenciales que son el modelo de regresión del proceso y el otro que modela la salida de datos de forma directa tanto para condiciones favorables y no favorable [32].

El sistema eléctrico está expuesto a cambios cada que suceda una falla, por lo mismo la red neural tiene la capacidad de incorporar el cambio dentro del sistema.

El modelo de red neuronal cuenta con una capa de entrada donde ingresa información. Para después pasar a una capa oculta, en el cual se lleva a cabo distintas operaciones con los datos ingresados en la capa de entrada, de esta manera finalizar con la obtención de resultados en la capa de salida de la red neuronal artificial.

### 2.4 Topologías de redes neuronales

Para las topologías de redes neuronales se considera, dos tipos las cuales son: la topología monocapa y la topología multicapa [33].

La topología monocapa es la cual realiza las conexiones dentro de una misma capa, de manera más resumida esta topología realiza una conexión automática, como se describe en la figura 6:

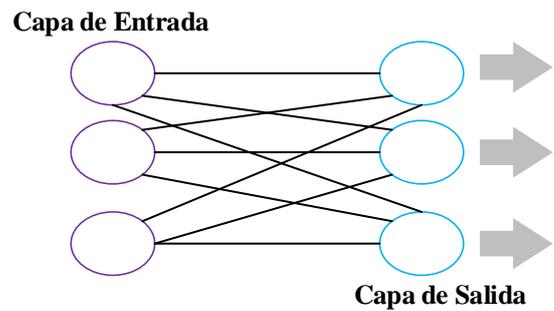


Figura 6. Topología monocapa de una red neural artificial.

La topología multicapa a diferencia, de la topología monocapa, está conformada por un conjunto de capas que están compuestas por distintas neuronas que estas van a servir para lograr diferenciar el nivel en el que esta cada una de ellas, esta topología hace un análisis el cual se basa en la revisión de datos que se ingresa en la capa de entrada, para después obtener el resultado en la capa de salida de la ANN. Tal como se describe en la figura 7:

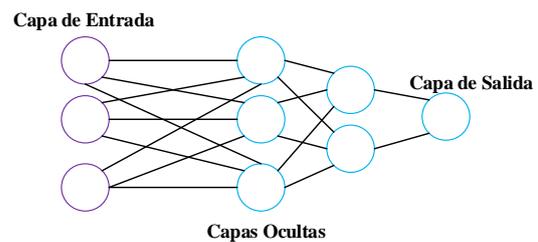


Figura 7. Topología Multicapa de una red neural artificial.

### 2.5 Modelos de aprendizaje para redes neuronales

Las ANN tiene tres modelos de aprendizaje importantes que son: modelo de aprendizaje supervisado, no supervisado y por retro- propagación del error [34].

#### 2.5.1 ANN con aprendizaje supervisado

Las ANN con aprendizaje del tipo supervisado, como lo dice su nombre necesita de la supervisión de un agente externo. El cual el agente conoce el vector de entrada con la respuesta correcta, ante cada vector de entrada y con la respuesta real de la red se va a generar un vector error que esto hará que se retroalimente la red. Y a partir de esto va a generar que los pesos se

actualicen y de esta forma desaparezca el error. De esta forma la red va a converger, provocando que las respuestas sean las deseadas y más exactas.

Este aprendizaje también es aplicado en el modelo de perceptrón, como en el modelo Adeline [35].

### 2.5.2 ANN con aprendizaje no supervisado

Las ANN con aprendizaje del tipo no supervisado, como su nombre lo dice no necesita de un agente externo, ya que utiliza los datos de enteramiento de la red, que no están etiquetados. Los datos de entrenamiento son presentados a la red y comprime los datos de entrada para de esta manera obtener un resultado que conforma niveles de clasificación. Este tipo de aprendizaje es utilizado mayor mente en redes de Kohonen [36].

### 2.5.3 ANN con aprendizaje por retro-propagación del error

Existe una desventaja dentro de los algoritmos de aprendizaje ya que los mismos, no se los puede utilizar cuando existe más de una capa de pesos que se los debe de ajustar. En el año de 1986 Rumelhart, Hilton & Williams introdujeron, el algoritmo de retro propagación, que permite ajustar los pesos de las capas que se encuentran interconectadas, con la diferencia que la salida era la real y la esperada [30].

## 2.6 Metodologías para la ubicación y clasificación de fallas en SET

A continuación, se presenta los siguientes métodos que se usan para ubicar y clasificar las fallas en el SET.

El algoritmo de Prony [37] se basa en extraer información de una señal, para realizar un proceso, combinatorio lineal el cual va ir construyendo, funciones exponenciales tanto complejas como sinusoidales.

El algoritmo de Relief [38] se caracteriza porque es un método eficaz el cual se basa en la selección de características de problemas que necesitan de clasificación y regresión son utilizados en la etapa conocida como la de pre-procesamiento.

Este algoritmo fue propuesto por primera vez en 1992 por Kira and Rendell que años después tuvo variaciones.

## 2.7 Algoritmo de retro-propagación

El algoritmo de retro propagación es un método el cual utiliza un periodo de propagación. Una vez que se aplica el patrón de entrada de la red, este pasa a propagarse en la primera capa a través de las demás capas para con esto, generar una salida [1],[30].

La razón principal para usar el algoritmo de propagación hacia atrás es para poder eliminar una de las restricciones dentro de la ANN de dos capas con esto se va a obtener entradas similares que conllevan a una salida similar [30].

En la figura 8 se describe la estructura de retro propagación de ANN y de esta manera comprender el concepto del algoritmo de retro-propagación de una red neural BPNN.

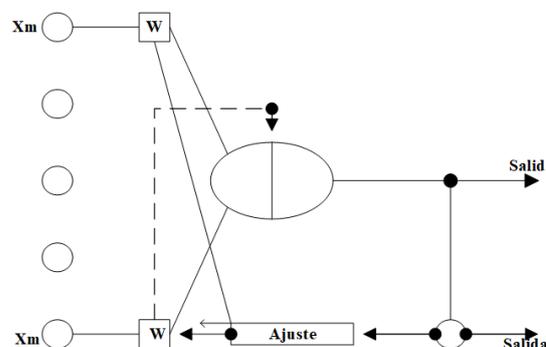


Figura 8. Estructura de retro propagación de una ANN.

### Algoritmo de Retro propagación (Back Propagation)

#### Paso 1:

##### Entrada

Activación de las neuronas de la primera capa, con la entrada.

#### Paso 2:

##### Propagación

Propagación hacia adelante:

$$a_j = \sum_I^{metro} \omega_{yo\_I}^{(1)} X_I$$

$$z_j = f(a_j)$$

$$y_j = \sum_I^{METRO} \omega_k^{(2)} z_j$$

#### Paso 3:

---

**Cálculo de errores de la capa de salida.**

Diferencia de salida:

$$d_j = y_k - t_k$$

**Paso 4: Propagación hacia atrás o re- propagación del error.**

Propagación hacia atrás para capas ocultas

$$d_j = (1 - z_j^2) \sum_{k=1}^k \omega_{jk} d_k$$

**Paso 5: Salida.**El gradiente de la función

---

Donde:

**$a_j$  y  $\omega_{yo}$**  Son los pesos de suma de entradas y asociados a las conexiones.

**XI; yI** Son los datos para la capa de entrada y la salida respectivamente.

**Zj** Esta es la unidad de activación de la entrada que es conectada a la unidad j.

**Yk** Está en cambio es la salida de activación que corresponderá a la unidad k.

**dk** Esta es la derivada del error.

**dj** Está en cambio es la derivada del error con respecto a la variable  $w_r$ .

### 3. Planteamiento del problema

Las fallas en el sistema eléctrico de transmisión, tiene relación con fenómenos naturales y mecánicos en este caso puede generar fallas que terminan en una interrupción de algunos milisegundos como también, afectar directamente al suministro de energía eléctrica. Para realizar el análisis correspondiente de estas fallas se ha implementado el algoritmo de retro-propagación junto con una red neural con la cual se va a clasificar y detectar.

A la vez se tiene la opción la cual permite cargar diferentes datos de prueba, y de esta manera la programación de forma automática empezara a mostrar la ubicación y el tipo de falla que corresponde.

Para el caso de estudio se trabajó en las líneas de transmisión del modelo IEEE de 9 barras y de esta manera utilizar los datos de prueba y se proceda a realizar la detección y clasificación del mismo mediante la ANN.

La estructura de la red neuronal se llevó a cabo a partir de los datos obtenidos en la simulación que fueron de alrededor de 250 fallas, que se realizó en el sistema IEEE y de esta manera la red detecte y clasifique la falla.

#### 3.1 Modelo propuesto

Para el estudio realizado sobre la ubicación y clasificación de fallas se lo realizo en el modelo de prueba IEEE de 9 barras que se presenta en la figura 9 a continuación:

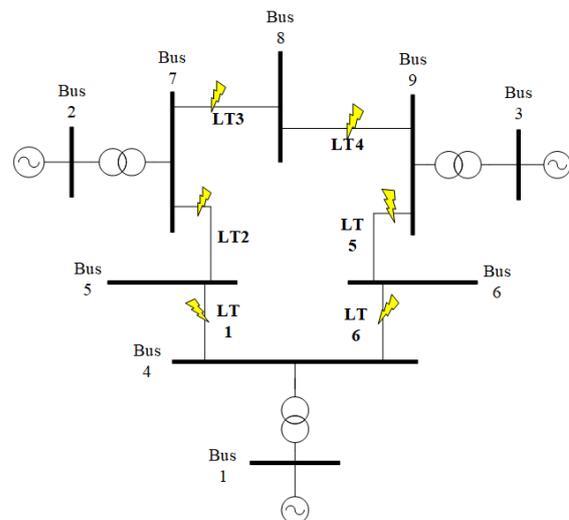


Figura 9. Esquema del IEEE 9 nodos.

Donde se procederá a realizar el análisis en líneas del sistema de nueve barras, mediante el software PowerFactory-DIGSILENT en el cual se ha simulado 250 fallas, realizando un análisis estático para obtener fallas de tipo trifásica, bifásica monofásica a tierra y bifásica a tierra.

Se ha considerado para la ubicación de fallas los siguientes casos: muy cercanas, cercanas, medianamente lejanas, lejanas y muy lejanas, a la vez tomado en cuenta la

barra del sistema de prueba IEEE. Para después obtener éstos datos e ingresar en la red neuronal.

### 3.2 Estudio aplicado

Para la realización de este estudio se ha realizado la simulación y obtención de datos mediante el software PowerFactory-DIGSILENT, después en Matlab se procederá a emplear las apps para la red neural, y de esta manera cumplir el objetivo de la ubicación y clasificación de fallas en el modelo de prueba del IEEE de 9 barras.

Para el trabajo se ha utilizado, el algoritmo de retro-propagación y a la vez una topología de red neuronal la cual tiene 3 entradas las mismas fueron determinada por los tres datos que ingresan a la red, 10 capas ocultas las cuales se determina por la convergencia de la red y la rapidez de respuesta y 12 salidas que es la respuesta para la clasificación y ubicación de fallas que ocurren en las líneas.

En el modelo IEEE de 9 barras se realizó un total de 250 simulaciones para poder realizar el entrenamiento de la red y de esta forma se las ha dividido de la siguiente manera: Un 70% para los datos del entrenamiento, un 15% para validar y el otro 15% para prueba de la red neural. En el software de Matlab se usó el algoritmo Levenberg - Marquardt Backpropagation, en la red neural y a la vez para obtener una mejor respuesta se utilizó la función de filtrado. A continuación, se muestra el esquema de la red neural en la figura 10:

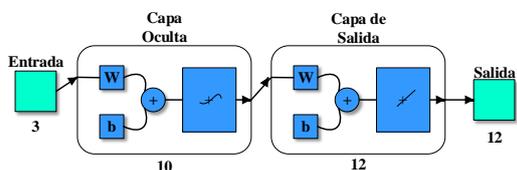


Figura 10. Esquema de la red neural utilizada en Matlab.

Para detectar y la clasificar las fallas en líneas de transmisión se utilizó una capa de salida la cual corresponde a datos binarios que indican qué tipo de falla es y si incluye o no falla a tierra como se muestra en la siguiente tabla a continuación.

Falla	A	B	C	Tierra
Sin Falla	0	0	0	0
Falla Trifásica	1	1	1	0
Falla Bifásica	1	1	0	0
Falla Monofásica a Tierra	1	0	0	1
Falla Bifásica a Tierra	1	1	0	1

Tabla 1. Tipos de fallas consideradas en el estudio.

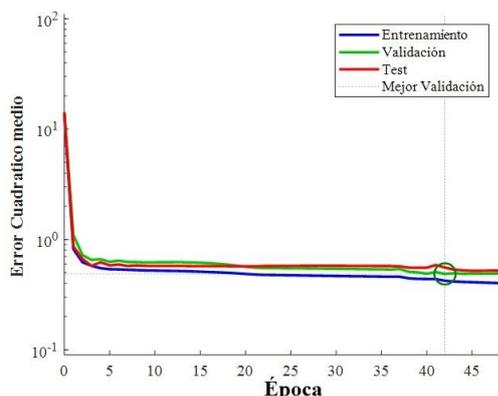
Para ubicar las fallas en las líneas de transmisión, se lo ha realizado con un rango de longitud (L), a cumplir como se muestra en la tabla 5.

Ubicación de fallas
Muy cercanas $L < 10\%$
Cercanas $10\% < L \leq 30\%$
Medianamente cercanas $30\% < L \leq 50\%$ ,
Medianamente lejanas $50\% < L \leq 70\%$ ,
Lejanas $70\% < L \leq 90\%$
Muy lejanas $90\% < L \leq 100\%$ .

Tabla 2. Rango para la ubicación de fallas que se ha llevado a cabo en el estudio.

Para realizar este estudio se ha considerado las fallas que se nombran en la tabla 1, ya que en el modelo de prueba IEEE 9 barras, no cuenta con neutro ya que es un sistema estable, de esta manera si no existe el neutro, no se va a tener el valor de impedancia del neutro por lo tanto será cero.

En la figura 11, a continuación, se muestra la convergencia de la ANN donde se puede visualizar el funcionamiento de la red neuronal, y de esta manera observar la mejor validación del sistema con respecto a los datos de entrenamiento, validación y prueba.



**Figura 11.** Convergencia obtenida en el software Matlab de la red neural.

A continuación, se explica el programa realizado en el software Matlab, paso a paso de cómo se lo debe de realizar mediante la siguiente tabla.

---

**Algoritmo para la detección y clasificación de fallas en líneas de transmisión**

---

**Paso 1:**  
**Inicio.**

Parametrización del SET.

**Paso 2:**

**Simulación del flujo de potencia.**

Obtención del flujo de potencia.

**Paso 3:**

**Simulación de fallas.**

3Ø, 2Ø, 1Ø a tierra, 2Ø a tierra.

**Paso 4:**

**Ingreso de datos obtenidos.**

Ingreso de datos e información.

**Paso 5:**

**Retro propagación.**

$$a_j = \sum_l^{metro} \omega_{y_o_l}^{(1)} X_l$$

$$z_j = f(a_j)$$

$$y_j = \sum_l^{metro} \omega_{k_j}^{(2)} z_l$$

Diferencia de salida:

$$d_j = y_k - t_k$$

Propagación hacia atrás para capas ocultas.

$$d_j = (1 - z_j^2) \sum_{k=1}^k \omega_{k_j} d_k$$

**Paso 6:**

**Ubicación de fallas.**

Falla= 3Ø, 2Ø, 1Ø a tierra, 2Ø a tierra.

**Paso 7:**

**Mostrar resultados.**

Detección y clasificación.

**Paso 8:**

**Fin**

---

## 4 Análisis de resultados

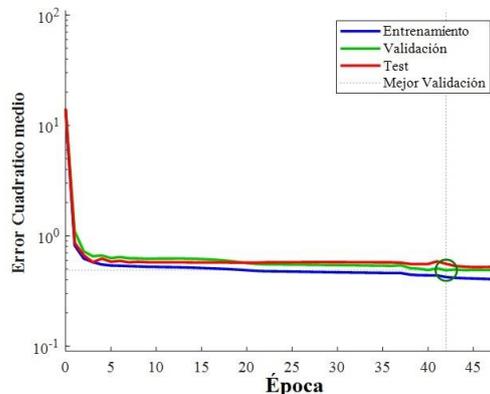
A continuación, se presenta los resultados obtenidos para el caso de estudio con el modelo de prueba IEEE de 9 barras, el cual se utilizó para realizar el estudio de fallas en líneas de transmisión y de esta manera mediante redes neuronales clasificar, ubicar y saber en qué tramo de la línea se sitúa la falla.

Para esto se ha tomado en cuenta los parámetros a considerar como es la efectividad del entrenamiento de la red neural, la mejor validación de datos, el error cuadrático medio, entre los principales que se deben de considerar en la red neuronal. A la vez la época o iteración que el algoritmo toma en cuenta para obtener los resultados con mayor exactitud, porque la época influye en el error del gradiente.

### 4.1 Caso de estudio1

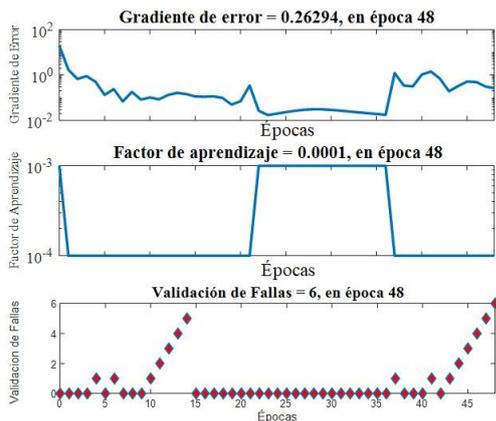
El caso 1 es una falla bifásica a tierra que se suscita a una distancia de  $30\% < L \leq 50\%$ , en las barras 8-9 que corresponde a la línea 4 del modelo IEEE de 9 barras. A continuación, se puede observar las figuras obtenidas de la red neuronal al momento de realizar la clasificación y ubicación de esta falla.

En la figura 12 se determina el valor del gradiente del error es  $1.00e-07$  en la iteración 48, esto quiere decir que error del gradiente no llegó hasta el valor máximo el cual es de  $1.00e+10$ , los valores ya mencionados se validaron en la iteración 48, por que el error del gradiente va decreciendo.



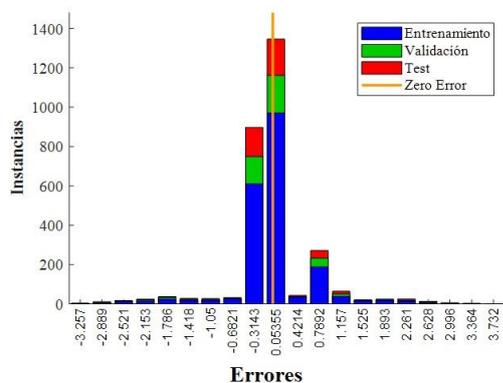
**Figura 12.** Convergencia obtenida en el software Matlab de la red neural.

En la figura 13 (a) se puede observar el error del gradiente medio es un valor de 0.26294, en época 48, de igual manera se puede observar en figura 13 (b) que el factor de aprendizaje es de 0.0001 en época 48, y en la figura 13 (c) la validación en la iteración 6, en la época 48, ya que en las demás iteraciones el error se incrementa paulatinamente, lo cual no es favorable para los resultados que se espera obtener.



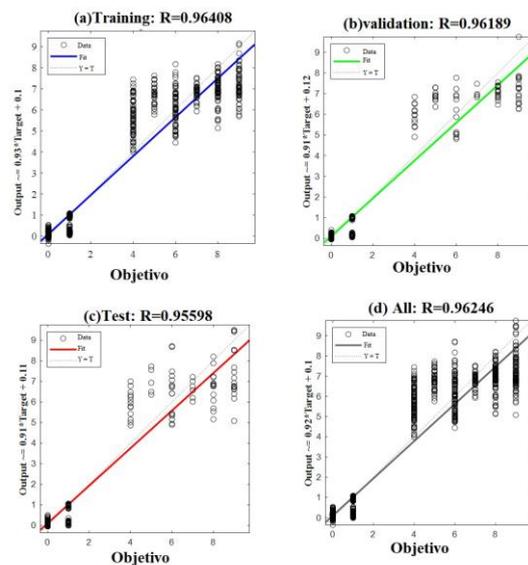
**Figura 13.** Validación de fallas Estado de entrenamiento de la red neural de 9 barras IEEE 48 épocas. (a) Gradiente de error, (b) Factor de aprendizaje, (c) Validación de fallas.

En la figura 14 se puede observar el resumen mediante el histograma de errores que se ha tomado en cuenta 20 intervalos, con el rango de instancias que se ha considerado, de esta manera se puede observar cómo se trabajó la red tanto en entrenamiento, en validación y en prueba para llegar a estos resultados que se observan a continuación.



**Figura 14.** Histograma de errores de la red neural de 9 barras IEEE para 48 épocas.

En la figura 15 que se presenta a continuación se observa el ajuste de regresión de las salidas contra los objetivos de la red. El coeficiente 'R' que se muestra en la gráfica es una medida en la cual se demuestra que tan correctos son los objetivos de la red neuronal, en la figura 15 (a) el coeficiente 'R' de los datos de entrenamiento es de 0.96408, en la figura 15 (b) el coeficiente 'R' de los datos de validación es de 0.96189, la figura 15 (c) el coeficiente 'R' de los datos de prueba es de 0.95598 con esto se quiere concluir que mediante esta gráfica se puede determinar si existe una correlación o no, pero en este caso se ha encontrado un coeficiente correlación 0.96246, lo que muestra una buena correlación.



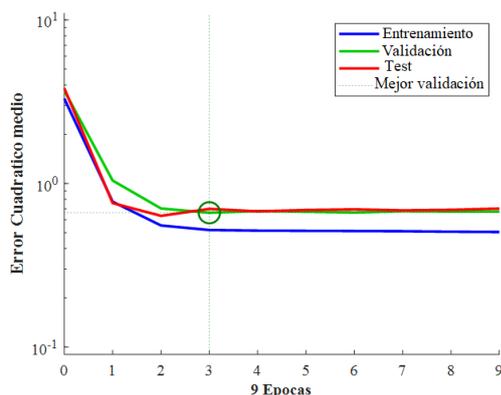
**Figura 15.** Ajuste de regresión de salidas contra objetivos de la red neural de 9 barras IEEE para 48 épocas.

## 4.2 Caso de estudio 2

El caso 2 es una falla trifásica que se suscita a una distancia de  $90\% < L \leq 100\%$ , en las barras 6-4 que corresponde a la línea 6 del modelo IEEE de 9 barras. A continuación, se puede observar las figuras obtenidas de la red neuronal al momento de realizar la clasificación y ubicación de esta falla.

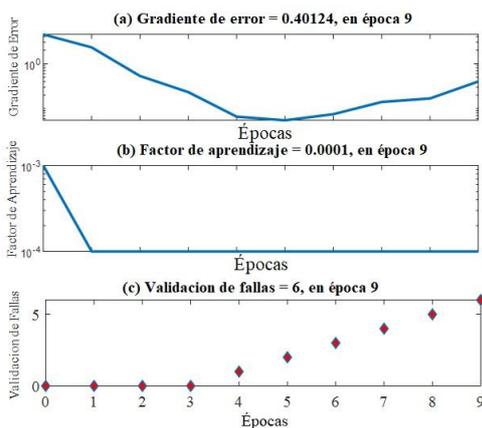
Para este caso se ha presentado con una época o iteración para 9 con la cual se ha

Llegado a obtener las siguientes figuras y los resultados que se muestran a continuación.



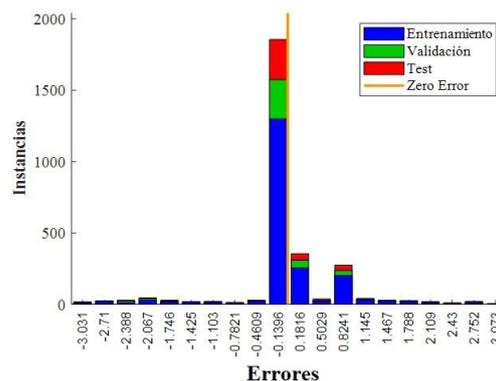
**Figura 16.** Validación del entrenamiento de la red neural y error cuadrático medio de la red para 9 épocas.

En la figura 16 se muestra el enteraamiento de la red, mediante la figura se observa que el entrenamiento de la red es el adecuado, el error cuadrático que se llega a obtener es de 0.66258, en la época 3.



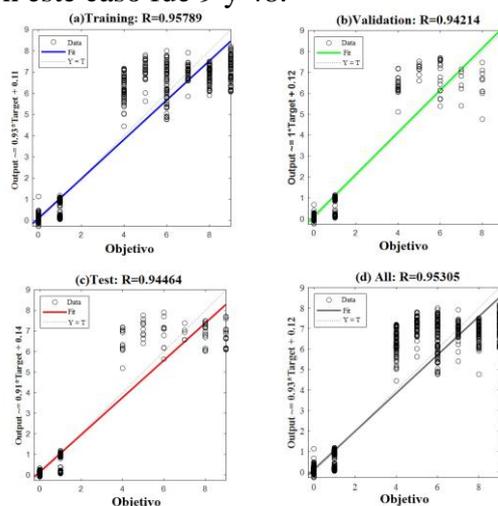
**Figura 17.** Validación de fallas Estado de entrenamiento de la red neural de 9 barras IEEE para 9 épocas. (a) Gradiente de error, (b) Factor de aprendizaje, (c) Validación de fallas

En la figura 17 (a) se observar la gráfica del error del gradiente medio que tiene un valor de 0.40124, en época 9, de igual manera se puede observar, en la figura 17 (b) que el factor de aprendizaje es de 0.0001 en época 9, y en la figura 17 (c) la validación es en la iteración 6, en la época 9, ya que en las demás iteraciones el error crece según la red.



**Figura 18.** Histograma de errores de la red neural de 9 barras IEEE para 9 épocas.

Como se puede realizar una comparación con la figura 18 podemos observar que el rango de instancias es de 2000 para 9 iteraciones en cambio con 48 su rango solo era de 1400, también en el eje de objetivos resultados llega a cambiar esto se debe por la época o iteración que se considera como en este caso fue 9 y 48.

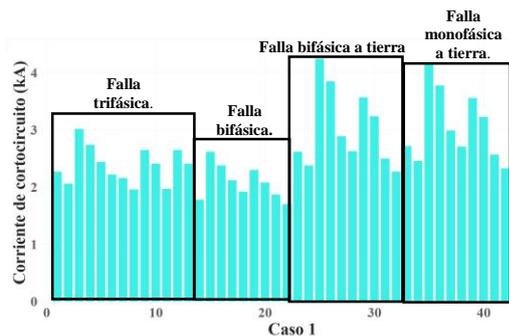


**Figura 19.** Ajuste de regresión de salidas contra objetivos de la red neural de 9 barras IEEE para 9 épocas.

En la figura 19, el coeficiente 'R' que se muestra en la gráfica es una medida en la cual se demuestra qué tan correctos son los objetivos de la red neuronal, en la figura 19 (a) el coeficiente 'R' de los datos de entrenamiento es de 0.95789, en la figura 19 (b) el coeficiente 'R' de los datos de validación es de 0.94214, la figura 19 (c) el coeficiente 'R' de los datos de prueba es de 0.94464, con esto se quiere concluir que mediante esta gráfica se puede determinar si

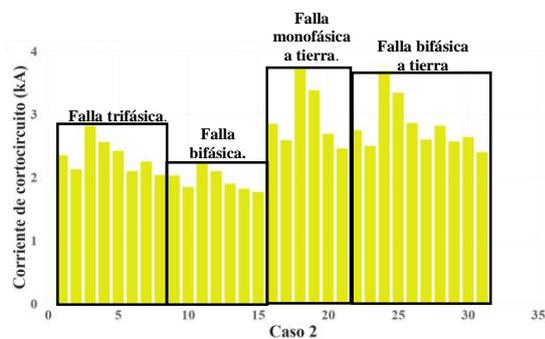
existe una correlación o no, pero en este caso como se muestra en la figura 19 (d) se ha encontrado un coeficiente correlación 0.95205, lo que muestra una correcta correlación con la red neural.

En las siguientes figuras se puede observar mediante el diagrama de barras realizado las fallas que se suscitan en las líneas de transmisión tomando en cuenta la barra de entrada como la barra de salida para de esta manera realizar una ubicación de la falla de manera óptima.



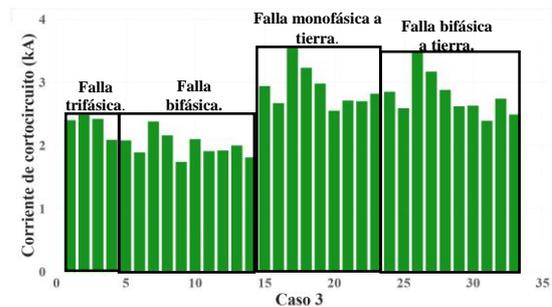
**Figura 20.** Muestreo de fallas muy cercanas en la barra 5-4.

En la figura 20, se presenta el muestreo realizado para la ubicación y clasificación de fallas en las líneas de transmisión muy cercanas correspondiente a la longitud  $L < 10\%$ , entre las barras 5-4 correspondiente a la línea 1.



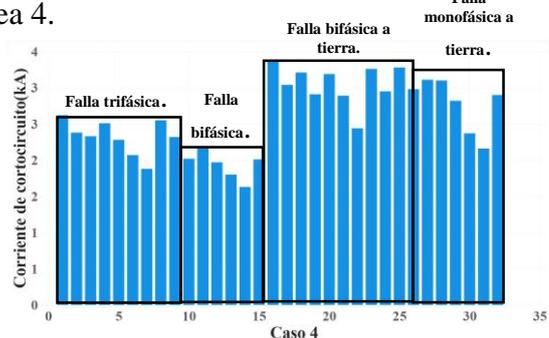
**Figura 21.** Muestreo de fallas cercanas en la barra 7-8.

En la figura 21, se presenta el muestreo realizado para la ubicación y clasificación de fallas en las líneas de transmisión cercanas  $10\% < L \leq 30\%$ , entre las barras 7-8 correspondiente a la línea 3.



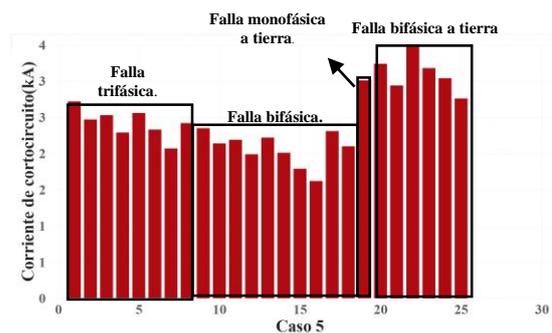
**Figura 22.** Muestreo de fallas medianamente cercanas barra 8-9.

En la figura 22, se presenta el muestreo realizado para la ubicación y clasificación de fallas en las líneas de transmisión medianamente cercanas  $30\% < L \leq 50\%$ , entre las barras 8-9 correspondiente a la línea 4.



**Figura 23.** Muestreo de fallas medianamente lejanas en la barra 9-6.

En la figura 23, se presenta el muestreo realizado para la ubicación y clasificación de fallas en las líneas de transmisión medianamente lejanas  $50\% < L \leq 70\%$ , entre las barras 9-6 correspondiente a la línea 5.



**Figura 24.** Muestreo de fallas lejanas en la barra 6-4

En la figura 24, se presenta el muestreo realizado para la ubicación y clasificación de fallas en las líneas de transmisión lejanas  $70\% < L \leq 90\%$ , entre las barras 6-4 correspondiente a la línea 6.

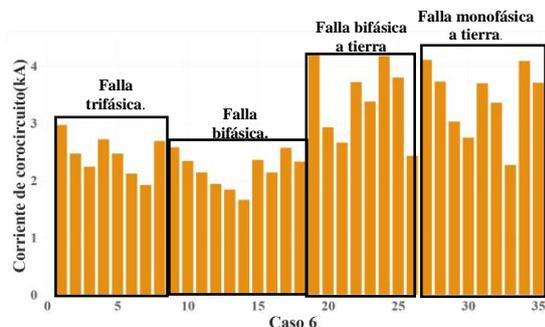


Figura 25. Muestreo de fallas lejanas.

En la figura 25, se presenta el muestreo realizado para la ubicación y clasificación de fallas en las líneas de transmisión lejanas  $90\% < L \leq 100\%$ , entre las barras 7-8 correspondiente a la línea 3.

En la tabla 3, que se encuentra en la sección ocho de anexos se puede observar los resultados obtenidos de la ubicación y clasificación de fallas en el modelo IEEE 9 barras, que se realizó mediante software Matlab y sus aplicaciones realizando el diseño de una red neural.

Haciendo la comparativa de este trabajo de investigación con [39], método de censado comprimido presenta un porcentaje de eficacia del 96 %, en comparación con el método utilizado obtenemos una eficacia del 95 % de la red neuronal.

## 5 Conclusiones

En este artículo se ha llegado a realizar la modelación y simulación de la ANN en el software Matlab, se ha llevado a cabo un estudio estático de las fallas en el modelo de prueba del IEEE de 9 barras en el cual se ha desarrollado la clasificación y ubicación de fallas del tipo monofásica a tierra, bifásica a tierra, trifásica y bifásica.

En el artículo se ha comprobado mediante los valores obtenidos de salida en la simulación de la ANN se aplica tanto para fallas asimétricas y simétricas, para el modelo propuesto, de tal manera que se cumple con la clasificación y ubicación de fallas en líneas de transmisión del modelo IEEE de 9 barras.

Se ha demostrado en la investigación que el uso de inteligencia artificial en la actualidad es un método viable y eficaz con la comparación realizada con el método de Wavelet para la detección de fallos en SET,

dando como resultado una correlación correcta entre datos de entrenamiento, validación y prueba de la ANN.

## 6. Trabajos futuros

Dado el alcance del estudio realizado, se puede plantear distintas propuestas las cuales se pueda analizar en un futuro, entre las que se puede sugerir:

El método propuesto se lo puede extender a la red de distribución del sistema eléctrico.

## 7. Referencias

- [1] M. Jamil, S. K. Sharma, and R. Singh, "Fault detection and classification in electrical power transmission system using artificial neural network," *Springerplus*, vol. 4, no. 1, 2015, doi: 10.1186/s40064-015-1080-x.
- [2] L. L. Hurtado-Cortés, E. Villarreal-López, and L. Villarreal-López, "Fault detection and diagnosis through artificial intelligence techniques, a state of art," *DYNA*, vol. 83, no. 199, 2016, doi: 10.15446/dyna.v83n199.55612.
- [3] C. Asbery and Y. Liao, "Fault Identification on Electrical Transmission Lines Using Artificial Neural Networks," *Electr. Power Components Syst.*, 2022, doi: 10.1080/15325008.2022.2049659.
- [4] G. T. Alencar, R. C. Santos, and A. Neves, "Euclidean Distance-Based Method for Fault Detection and Classification in Transmission Lines," *J. Control. Autom. Electr. Syst.*, 2022, doi: 10.1007/s40313-022-00918-x.
- [5] M. A. M. Nasrin, A. M. S. Omar, S. S. M. Ramli, A. R. Ahmad, N. F. Jamaludin, and M. K. Osman, "Deep Learning Approach for Transmission Line Fault Classification," *Proc. - 2021 11th IEEE Int. Conf. Control Syst. Comput. Eng. ICCSCE 2021*, no. August, pp. 164–169, 2021, doi:

- 10.1109/ICCSCE52189.2021.9530747.
- [6] S. K. Padhy, B. K. Panigrahi, P. K. Ray, A. K. Satpathy, R. P. Nanda, and A. Nayak, "Classification of Faults in a Transmission Line using Artificial Neural Network," *Proc. - 2018 Int. Conf. Inf. Technol. ICIT 2018*, pp. 239–243, 2018, doi: 10.1109/ICIT.2018.00056.
- [7] T. Hubana, "Transmission lines fault location estimation based on artificial neural networks and power quality monitoring data," *Proc. - 2018 IEEE PES Innov. Smart Grid Technol. Conf. Eur. ISGT-Europe 2018*, pp. 1–6, 2018, doi: 10.1109/ISGTEurope.2018.8571744.
- [8] J. Amrutha and A. S. Remya Ajai, "Performance analysis of backpropagation algorithm of artificial neural networks in verilog," *2018 3rd IEEE Int. Conf. Recent Trends Electron. Inf. Commun. Technol. RTEICT 2018 - Proc.*, pp. 1547–1550, 2018, doi: 10.1109/RTEICT42901.2018.9012614.
- [9] K. Kalita, S. Anand, and S. K. Parida, "A Novel Non-Iterative Fault Location Algorithm for Transmission Line with Unsynchronized Terminal," *IEEE Trans. Power Deliv.*, vol. 36, no. 3, pp. 1917–1920, 2021, doi: 10.1109/TPWRD.2021.3054235.
- [10] J. Xie, G. Jin, Y. Wang, X. Ni, and X. Liu, "New Algorithm for 2-terminal Transmission Line Fault Location Integrating Voltage Phasor Feature and Phase Angle Jump Checking," *Electr. Power Syst. Res.*, vol. 209, 2022, doi: 10.1016/j.epsr.2022.107971.
- [11] X. Wang, P. Zhou, X. Peng, Z. Wu, and H. Yuan, "Fault location of transmission line based on CNN-LSTM double-ended combined model," *Energy Reports*, vol. 8, pp. 781–791, 2022, doi: 10.1016/j.egy.2022.02.275.
- [12] X. Chen, Y. Zhu, X. Zhao, L. Zhao, and X. Guo, "Traveling wave fault location for T-shaped transmission line considering change of line length," *Dianwang Jishu/Power Syst. Technol.*, vol. 39, no. 5, pp. 1438–1443, 2015, doi: 10.13335/j.1000-3673.pst.2015.05.040.
- [13] M. Tabari and J. Sadeh, "Fault location in series-compensated transmission lines using adaptive network-based fuzzy inference system," *Electr. Power Syst. Res.*, vol. 208, 2022, doi: 10.1016/j.epsr.2022.107800.
- [14] N. N. Bon and L. Van Dai, "Fault Identification, Classification, and Location on Transmission Lines Using Combined Machine Learning Methods," *Int. J. Eng. Technol. Innov.*, vol. 12, no. 2, pp. 91–109, 2022, doi: 10.46604/IJETI.2022.7571.
- [15] P. R. Pattanaik, B. K. Panigrahi, S. Pati, S. K. Sanyal, and J. J. Mahakud, "Transmission Line Fault Classification Using Superimposed Components," in *Proceedings of the 3rd International Conference on I-SMAC IoT in Social, Mobile, Analytics and Cloud, I-SMAC 2019*, 2019, pp. 391–395. doi: 10.1109/I-SMAC47947.2019.9032706.
- [16] S. A. Kumar and D. Chandramohan, "Fault test analysis in transmission lines throughout interfering synchrophasor signals," *ICT Express*, vol. 5, no. 4, pp. 266–270, 2019, doi: 10.1016/j.icte.2018.03.003.
- [17] D. P. Mishra and P. Ray, "Fault detection, location and classification of a transmission line," *Neural Comput. Appl.*, vol. 30, no. 5, pp. 1377–1424, 2018, doi: 10.1007/s00521-017-3295-y.
- [18] M. H. H. Musa, Z. He, L. Fu, and Y.

- Deng, "Linear regression index-based method for fault detection and classification in power transmission line," *IEEJ Trans. Electr. Electron. Eng.*, vol. 13, no. 7, pp. 979–987, 2018, doi: 10.1002/tee.22654.
- [19] S. Kirubadevi and S. Sutha, "Wavelet based transmission line fault identification and classification," in *6th International Conference on Computation of Power, Energy, Information and Communication, ICCPEIC 2017*, 2018, vol. 2018-Janua, pp. 737–741. doi: 10.1109/ICCPEIC.2017.8290461.
- [20] P. S. Pouabe Eboule, A. N. Hasan, and B. Twala, *The use of multilayer perceptron to classify and locate power transmission line faults*, vol. 668. 2018. doi: 10.1007/978-981-10-7868-2\_5.
- [21] E. Development and P. G. Committee, *IEEE Standards IEEE Guide for the Application of*, vol. 2020, no. June. 2004.
- [22] T. Alquthami, M. K. Alghamdi, B. S. Almajnuni, and O. M. Alarbidi, "Forecasting Transmission System Outages Using Artificial Neural Networks," *22nd Int. Middle East Power Syst. Conf. MEPCON 2021 - Proc.*, pp. 654–658, 2021, doi: 10.1109/MEPCON50283.2021.9686292.
- [23] E. B. Fisher, R. P. O'Neill, and M. C. Ferris, "Optimal transmission switching," *IEEE Trans. Power Syst.*, vol. 23, no. 3, pp. 1346–1355, 2008, doi: 10.1109/TPWRS.2008.922256.
- [24] J. Deng *et al.*, "System topologies, key operation and control technologies for offshore wind power transmission based on HVDC," pp. 767–774, 2022, doi: 10.1049/icp.2022.1286.
- [25] S. Salman, A. Xin, A. Shahzad, A. Masood, and S. Iqbal, "Composite E-HVAC and CSC-HVDC system: control and its fault analysis," *Electr. Eng.*, vol. 103, no. 2, pp. 1265–1277, 2021, doi: 10.1007/s00202-020-01139-8.
- [26] P. L. Vianna and G. M. Junior, "Time-domain distance protection of transmission lines based on the conic section general equation," *Electr. Power Syst. Res.*, vol. 205, 2022, doi: 10.1016/j.epsr.2021.107740.
- [27] G. Panda and R. T. N. Sukumar, *Sustainable Energy and Technological Advancements*. 2022. doi: 978-981-16-9032-7.
- [28] ENTSOE, "Nordic and Baltic Grid Disturbance Statistics 2019," pp. 1–89, 2020.
- [29] D. P. Mishra and P. Ray, *Fault detection, location and classification of a transmission line*, vol. 30, no. 5. Springer London, 2018. doi: 10.1007/s00521-017-3295-y.
- [30] O. Navya Teja, M. Siva Ramakrishna, G. B. Bhavana, and K. Sireesha, "Fault Detection and Classification in Power Transmission Lines using Back Propagation Neural Networks," *Proc. - Int. Conf. Smart Electron. Commun. ICOSEC 2020*, no. Icosec, pp. 1150–1156, 2020, doi: 10.1109/ICOSEC49089.2020.9215253.
- [31] M. R. Bishal, S. Ahmed, N. M. Molla, K. M. Mamun, A. Rahman, and M. A. Al Hysam, "ANN Based Fault Detection Classification in Power System Transmission line," *2021 Int. Conf. Sci. Contemp. Technol. ICSCT 2021*, pp. 7–10, 2021, doi: 10.1109/ICSCT53883.2021.9642410.
- [32] A. Bhuyan, B. K. Panigrahi, K. Pal, and S. Pati, "Convolutional Neural Network Based Fault Detection for Transmission Line," *2022 Int. Conf. Intell. Controll. Comput. Smart Power, ICICCSPP 2022*, pp. 40–43, 2022, doi:

- 10.1109/ICICCSP53532.2022.9862446.
- [33] R. Jercic, I. Pavic, and I. Damjanovic, "New algorithm for identifying network topology based on artificial neural networks," *2019 2nd Int. Colloq. Smart Grid Metrol. SMAGRIMET 2019 - Proc.*, 2019, doi: 10.23919/SMAGRIMET.2019.8720364.
- [34] H. Tong, R. C. Qiu, D. Zhang, H. Yang, Q. Ding, and X. Shi, "Detection and classification of transmission line transient faults based on graph convolutional neural network," *CSEE J. Power Energy Syst.*, vol. 7, no. 3, pp. 456–471, 2021, doi: 10.17775/CSEEJPES.2020.04970.
- [35] E. Alamilla-Jiménez, A. Bolívar-Cimé, and E. Nájera, "Neural Networks and Their Application in the Classification of Patterns," *Rev. la Fac. Ciencias*, vol. 11, no. 1, pp. 78–97, 2022, doi: 10.15446/rev.fac.cienc.v11n1.99173.
- [36] R. Resmi, V. Vanitha, E. Aravind, B. R. Sundaram, C. A. Raj, and S. Harithaa, "Detection, Classification and Zone Location of Fault in Transmission Line using Artificial Neural Network," *Proc. 2019 3rd IEEE Int. Conf. Electr. Comput. Commun. Technol. ICECCT 2019*, 2019, doi: 10.1109/ICECCT.2019.8868990.
- [37] M. Pan *et al.*, *Fault Transient Signal Analysis of UHV Transmission Line Based on Wavelet Transform and Prony Algorithm*, vol. 1303. Springer Singapore, 2021. doi: 10.1007/978-981-33-4572-0\_42.
- [38] C. Wang, X. Zhang, J. Chen, Y. Mao, S. Li, and Y. Lin, "OFHR: Online Streaming Feature Selection With Hierarchical Structure Based on Relief," *Proc. - 11th Int. Conf. Inf. Technol. Med. Educ. ITME 2021*, pp. 140–145, 2021, doi: 10.1109/ITME53901.2021.00038.
- [39] J. Cedeño, M. Zambrano, and C. Medina, "Wireless networks of efficient sensors for agro-industry," *Prism. Tecnológico*, vol. 5, no. 1, pp. 22–25, 2014, doi: 2076-8133.

## 8. Anexos.

**Tabla 3.** Resultados obtenidos de la ubicación y clasificación de fallas en líneas de transmisión del modelo IEEE de 9 barras.

Sk''(MVA)	Ik''(kA/kA)	Ángulo (Grados)	A	B	C	Tierra	MUY CERCANAS L<10%	CERCANAS 10%<L<=30%	MEDIANAMEN TE CERCANAS 30%<L<=50%	MEDIANAMEN TE LEJANAS 50%<L<=70%	LEJANAS 70%<L<=90%	LEJANAS 90%<L<=100%	Barra de Entrada	Barra de Salida
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
904,61	2,27	-84,74	1	1	1	0	1	0	0	0	0	0	5	4
935,6	2,35	-84,97	1	1	1	0	0	1	0	0	0	0	5	4
956,09	2,4	-85,09	1	1	1	0	0	0	1	0	0	0	5	4
1042,99	2,62	-85,52	1	1	1	0	0	0	0	1	0	0	5	4
1082,71	2,72	-85,69	1	1	1	0	0	0	0	0	1	0	5	4
1184,75	2,97	-86,1	1	1	1	0	0	0	0	0	0	1	5	4
820,36	2,06	-83,67	1	1	1	0	1	0	0	0	0	0	5	4
848,56	2,13	-83,96	1	1	1	0	0	1	0	0	0	0	5	4
867,2	2,18	-84,13	1	1	1	0	0	0	1	0	0	0	5	4
946,13	2,38	-84,69	1	1	1	0	0	0	0	1	0	0	5	4
982,2	2,47	-84,92	1	1	1	0	0	0	0	0	1	0	5	4
1074,8	2,7	-85,46	1	1	1	0	0	0	0	0	0	1	5	4
261,26	1,97	-175,11	1	1	0	0	1	0	0	0	0	0	5	4
270,2	2,03	-175,37	1	1	0	0	0	1	0	0	0	0	5	4
276,11	2,08	-175,51	1	1	0	0	0	0	1	0	0	0	5	4
301,19	2,27	-176,01	1	1	0	0	0	0	0	1	0	0	5	4
312,65	2,35	-176,21	1	1	0	0	0	0	0	0	1	0	5	4
342,09	2,58	-176,69	1	1	0	0	0	0	0	0	0	1	5	4
236,94	1,78	-174,04	1	1	0	0	1	0	0	0	0	0	5	4
245,08	1,85	-174,36	1	1	0	0	0	1	0	0	0	0	5	4
250,46	1,89	-174,54	1	1	0	0	0	0	1	0	0	0	5	4
273,23	2,06	-175,18	1	1	0	0	0	0	0	1	0	0	5	4
283,64	2,14	-175,44	1	1	0	0	0	0	0	0	1	0	5	4
310,35	2,34	-176,05	1	1	0	0	0	0	0	0	0	1	5	4
360,6	2,72	-84,61	1	0	0	1	1	0	0	0	0	0	5	4
378,7	2,85	-84,94	1	0	0	1	0	1	0	0	0	0	5	4
390,95	2,94	-85,12	1	0	0	1	0	0	1	0	0	0	5	4
445,61	3,36	-85,78	1	0	0	1	0	0	0	1	0	0	5	4
472,23	3,56	-86,05	1	0	0	1	0	0	0	0	1	0	5	4
545,87	4,11	-86,75	1	0	0	1	0	0	0	0	0	1	5	4
326,89	2,46	-83,4	1	0	0	1	1	0	0	0	0	0	5	4
343,38	2,59	-83,82	1	0	0	1	0	1	0	0	0	0	5	4
354,52	2,67	-84,05	1	0	0	1	0	0	1	0	0	0	5	4
404,2	3,04	-84,88	1	0	0	1	0	0	0	1	0	0	5	4
428,38	3,23	-85,23	1	0	0	1	0	0	0	0	1	0	5	4
495,23	3,73	-86,12	1	0	0	1	0	0	0	0	0	1	5	4
348,3	2,62	145,07	1	1	0	1	1	0	0	0	0	0	5	4
365,83	2,75	143,7	1	1	0	1	0	1	0	0	0	0	5	4

377,98	2,85	142,81	1	1	0	1	0	0	1	0	0	0	5	4
435,25	3,28	138,89	1	1	0	1	0	0	0	1	0	0	5	4
465,25	3,5	136,97	1	1	0	1	0	0	0	0	1	0	5	4
558,2	4,2	131,49	1	1	0	1	0	0	0	0	0	1	5	4
316,59	2,38	146,32	1	1	0	1	1	0	0	0	0	0	5	4
332,5	2,5	144,86	1	1	0	1	0	1	0	0	0	0	5	4
343,52	2,59	143,93	1	1	0	1	0	0	1	0	0	0	5	4
395,43	2,98	139,83	1	1	0	1	0	0	0	1	0	0	5	4
422,56	3,18	137,83	1	1	0	1	0	0	0	0	1	0	5	4
506,39	3,81	132,11	1	1	0	1	0	0	0	0	0	1	5	4
1203,61	3,02	-86,96	1	1	1	0	1	0	0	0	0	0	7	8
1124,49	2,82	-86,62	1	1	1	0	0	1	0	0	0	0	7	8
1093,02	2,74	-86,48	1	1	1	0	0	0	1	0	0	0	7	8
1023,35	2,57	-86,15	1	1	1	0	0	0	0	1	0	0	7	8
1006,94	2,53	-86,07	1	1	1	0	0	0	0	0	1	0	7	8
982,63	2,47	-85,94	1	1	1	0	0	0	0	0	0	1	7	8
1092,71	2,74	-86,45	1	1	1	0	1	0	0	0	0	0	7	8
1020,88	2,56	-86,01	1	1	1	0	0	1	0	0	0	0	7	8
992,3	2,49	-85,84	1	1	1	0	0	0	1	0	0	0	7	8
929	2,33	-85,43	1	1	1	0	0	0	0	1	0	0	7	8
914,08	2,29	-85,32	1	1	1	0	0	0	0	0	1	0	7	8
891,97	2,24	-85,16	1	1	1	0	0	0	0	0	0	1	7	8
347,57	2,62	-177,4	1	1	0	0	1	0	0	0	0	0	7	8
324,73	2,45	-177,03	1	1	0	0	0	1	0	0	0	0	7	8
315,65	2,38	-176,88	1	1	0	0	0	0	1	0	0	0	7	8
295,53	2,23	-176,54	1	1	0	0	0	0	0	1	0	0	7	8
290,8	2,19	-176,46	1	1	0	0	0	0	0	0	1	0	7	8
283,77	2,14	-176,33	1	1	0	0	0	0	0	0	0	1	7	8
315,56	2,38	-176,88	1	1	0	0	1	0	0	0	0	0	7	8
294,83	2,22	-176,42	1	1	0	0	0	1	0	0	0	0	7	8
286,58	2,16	-176,24	1	1	0	0	0	0	1	0	0	0	7	8
268,31	2,02	-175,82	1	1	0	0	0	0	0	1	0	0	7	8
264	1,99	-175,71	1	1	0	0	0	0	0	0	1	0	7	8
257,61	1,94	-175,55	1	1	0	0	0	0	0	0	0	1	7	8
552,91	4,16	-87,44	1	0	0	1	1	0	0	0	0	0	7	8
493,79	3,72	-86,87	1	0	0	1	0	1	0	0	0	0	7	8
471,86	3,55	-86,65	1	0	0	1	0	0	1	0	0	0	7	8
426,43	3,21	-86,21	1	0	0	1	0	0	0	1	0	0	7	8
416,42	3,14	-86,1	1	0	0	1	0	0	0	0	1	0	7	8
402,29	3,03	-85,96	1	0	0	1	0	0	0	0	0	1	7	8
502	3,78	-86,92	1	0	0	1	1	0	0	0	0	0	7	8
448,3	3,38	-86,21	1	0	0	1	0	1	0	0	0	0	7	8
428,37	3,23	-85,94	1	0	0	1	0	0	1	0	0	0	7	8
387,08	2,91	-85,38	1	0	0	1	0	0	0	1	0	0	7	8
377,98	2,85	-85,25	1	0	0	1	0	0	0	0	1	0	7	8
365,13	2,75	-85,07	1	0	0	1	0	0	0	0	0	1	7	8
563,82	4,25	130,96	1	1	0	1	1	0	0	0	0	0	7	8
488,36	3,68	135,52	1	1	0	1	0	1	0	0	0	0	7	8

462,94	3,49	137,14	1	1	0	1	0	0	1	0	0	0	7	8
413,64	3,11	140,32	1	1	0	1	0	0	0	1	0	0	7	8
403,27	3,04	140,98	1	1	0	1	0	0	0	0	1	0	7	8
388,88	2,93	141,86	1	1	0	1	0	0	0	0	0	1	7	8
511,87	3,85	131,47	1	1	0	1	1	0	0	0	0	0	7	8
443,89	3,34	136,22	1	1	0	1	0	1	0	0	0	0	7	8
420,92	3,17	137,89	1	1	0	1	0	0	1	0	0	0	7	8
376,25	2,83	141,19	1	1	0	1	0	0	0	1	0	0	7	8
366,83	2,76	141,87	1	1	0	1	0	0	0	0	1	0	7	8
353,74	2,66	142,78	1	1	0	1	0	0	0	0	0	1	7	8
972,98	2,44	-85,88	1	1	1	0	1	0	0	0	0	0	8	9
963,63	2,42	-85,78	1	1	1	0	0	1	0	0	0	0	8	9
965,63	2,42	-85,75	1	1	1	0	0	0	1	0	0	0	8	9
999,36	2,51	-85,75	1	1	1	0	0	0	0	1	0	0	8	9
1020,95	2,56	-85,78	1	1	1	0	0	0	0	0	1	0	8	9
1083,54	2,72	-85,9	1	1	1	0	0	0	0	0	0	1	8	9
883,18	2,22	-85,09	1	1	1	0	1	0	0	0	0	0	8	9
874,63	2,2	-84,97	1	1	1	0	0	1	0	0	0	0	8	9
876,4	2,2	-84,95	1	1	1	0	0	0	1	0	0	0	8	9
906,89	2,28	-84,98	1	1	1	0	0	0	0	1	0	0	8	9
926,43	2,33	-85,04	1	1	1	0	0	0	0	0	1	0	8	9
983,08	2,47	-85,22	1	1	1	0	0	0	0	0	0	1	8	9
280,99	2,12	-176,27	1	1	0	0	1	0	0	0	0	0	8	9
278,28	2,1	-176,19	1	1	0	0	0	1	0	0	0	0	8	9
278,86	2,1	-176,18	1	1	0	0	0	0	1	0	0	0	8	9
288,59	2,17	-176,25	1	1	0	0	0	0	0	1	0	0	8	9
294,81	2,22	-176,31	1	1	0	0	0	0	0	0	1	0	8	9
312,86	2,36	-176,51	1	1	0	0	0	0	0	0	0	1	8	9
255,07	1,92	-175,48	1	1	0	0	1	0	0	0	0	0	8	9
252,6	1,9	-175,39	1	1	0	0	0	1	0	0	0	0	8	9
253,11	1,91	-175,38	1	1	0	0	0	0	1	0	0	0	8	9
261,89	1,97	-175,48	1	1	0	0	0	0	0	1	0	0	8	9
267,53	2,01	-175,56	1	1	0	0	0	0	0	0	1	0	8	9
283,86	2,14	-175,83	1	1	0	0	0	0	0	0	0	1	8	9
397,11	2,99	-85,9	1	0	0	1	1	0	0	0	0	0	8	9
393,56	2,96	-85,84	1	0	0	1	0	1	0	0	0	0	8	9
396,14	2,98	-85,85	1	0	0	1	0	0	1	0	0	0	8	9
423,09	3,19	-86,05	1	0	0	1	0	0	0	1	0	0	8	9
439,97	3,31	-86,18	1	0	0	1	0	0	0	0	1	0	8	9
491,17	3,7	-86,6	1	0	0	1	0	0	0	0	0	1	8	9
360,42	2,71	-85	1	0	0	1	1	0	0	0	0	0	8	9
357,17	2,69	-84,93	1	0	0	1	0	1	0	0	0	0	8	9
359,49	2,71	-84,95	1	0	0	1	0	0	1	0	0	0	8	9
383,92	2,89	-85,21	1	0	0	1	0	0	0	1	0	0	8	9
399,22	3,01	-85,39	1	0	0	1	0	0	0	0	1	0	8	9
445,65	3,36	-85,93	1	0	0	1	0	0	0	0	0	1	8	9
383,66	2,89	142,15	1	1	0	1	1	0	0	0	0	0	8	9
380,14	2,86	142,16	1	1	0	1	0	1	0	0	0	0	8	9

382,78	2,88	141,84	1	1	0	1	0	0	1	0	0	0	8	9
411,45	3,1	139,32	1	1	0	1	0	0	0	1	0	0	8	9
430,46	3,24	137,79	1	1	0	1	0	0	0	0	1	0	8	9
494,36	3,72	133,06	1	1	0	1	0	0	0	0	0	1	8	9
348,98	2,63	143,08	1	1	0	1	1	0	0	0	0	0	8	9
345,72	2,6	143,1	1	1	0	1	0	1	0	0	0	0	8	9
348,08	2,62	142,77	1	1	0	1	0	0	1	0	0	0	8	9
373,9	2,82	140,18	1	1	0	1	0	0	0	1	0	0	8	9
391,03	2,94	138,61	1	1	0	1	0	0	0	0	1	0	8	9
448,44	3,38	133,72	1	1	0	1	0	0	0	0	0	1	8	9
1056,21	2,65	-85,4	1	1	1	0	1	0	0	0	0	0	9	6
924,29	2,32	-83,91	1	1	1	0	0	1	0	0	0	0	9	6
883,41	2,22	-83,45	1	1	1	0	0	0	1	0	0	0	9	6
825,46	2,07	-82,84	1	1	1	0	0	0	0	1	0	0	9	6
823,53	2,07	-82,84	1	1	1	0	0	0	0	0	1	0	9	6
844,28	2,12	-83,14	1	1	1	0	0	0	0	0	0	1	9	6
958,1	2,41	-84,59	1	1	1	0	1	0	0	0	0	0	9	6
837,82	2,1	-82,69	1	1	1	0	0	1	0	0	0	0	9	6
800,51	2,01	-82,11	1	1	1	0	0	0	1	0	0	0	9	6
747,62	1,88	-81,33	1	1	1	0	0	0	0	1	0	0	9	6
745,86	1,87	-81,33	1	1	1	0	0	0	0	0	1	0	9	6
764,78	1,92	-81,7	1	1	1	0	0	0	0	0	0	1	9	6
305,01	2,3	-175,99	1	1	0	0	1	0	0	0	0	0	9	6
266,98	2,01	-174,38	1	1	0	0	0	1	0	0	0	0	9	6
255,19	1,92	-173,89	1	1	0	0	0	0	1	0	0	0	9	6
238,46	1,8	-173,23	1	1	0	0	0	0	0	1	0	0	9	6
237,91	1,79	-173,22	1	1	0	0	0	0	0	0	1	0	9	6
243,89	1,84	-173,53	1	1	0	0	0	0	0	0	0	1	9	6
276,68	2,08	-175,18	1	1	0	0	1	0	0	0	0	0	9	6
242,03	1,82	-173,17	1	1	0	0	0	1	0	0	0	0	9	6
231,27	1,74	-172,55	1	1	0	0	0	0	1	0	0	0	9	6
216,01	1,63	-171,72	1	1	0	0	0	0	0	1	0	0	9	6
215,5	1,62	-171,71	1	1	0	0	0	0	0	0	1	0	9	6
220,96	1,66	-172,09	1	1	0	0	0	0	0	0	0	1	9	6
473,2	3,56	-85,86	1	0	0	1	1	0	0	0	0	0	9	6
383,95	2,89	-83,69	1	0	0	1	0	1	0	0	0	0	9	6
358,67	2,7	-83,08	1	0	0	1	0	0	1	0	0	0	9	6
323,9	2,44	-82,32	1	0	0	1	0	0	0	1	0	0	9	6
322,28	2,43	-82,33	1	0	0	1	0	0	0	0	1	0	9	6
332,47	2,5	-82,69	1	0	0	1	0	0	0	0	0	1	9	6
429,22	3,23	-85,01	1	0	0	1	1	0	0	0	0	0	9	6
347,84	2,62	-82,29	1	0	0	1	0	1	0	0	0	0	9	6
324,78	2,45	-81,54	1	0	0	1	0	0	1	0	0	0	9	6
293,09	2,21	-80,59	1	0	0	1	0	0	0	1	0	0	9	6
291,61	2,2	-80,59	1	0	0	1	0	0	0	0	1	0	9	6
300,93	2,27	-81,04	1	0	0	1	0	0	0	0	0	1	9	6
474,33	3,57	134,98	1	1	0	1	1	0	0	0	0	0	9	6
375,11	2,82	143,25	1	1	0	1	0	1	0	0	0	0	9	6

349,39	2,63	145,45	1	1	0	1	0	0	1	0	0	0	9	6
315,11	2,37	148,44	1	1	0	1	0	0	0	1	0	0	9	6
313,47	2,36	148,61	1	1	0	1	0	0	0	0	1	0	9	6
323,03	2,43	147,84	1	1	0	1	0	0	0	0	0	1	9	6
430,69	3,24	135,87	1	1	0	1	1	0	0	0	0	0	9	6
341,08	2,57	144,75	1	1	0	1	0	1	0	0	0	0	9	6
317,66	2,39	147,09	1	1	0	1	0	0	1	0	0	0	9	6
286,36	2,16	150,25	1	1	0	1	0	0	0	1	0	0	9	6
284,85	2,15	150,41	1	1	0	1	0	0	0	0	1	0	9	6
293,56	2,21	149,56	1	1	0	1	0	0	0	0	0	1	9	6
861,81	2,16	-83,35	1	1	1	0	1	0	0	0	0	0	6	4
897,04	2,25	-83,67	1	1	1	0	0	1	0	0	0	0	6	4
920,09	2,31	-83,87	1	1	1	0	0	0	1	0	0	0	6	4
1017,75	2,55	-84,67	1	1	1	0	0	0	0	1	0	0	6	4
1062,72	2,67	-85,02	1	1	1	0	0	0	0	0	1	0	6	4
1179,69	2,96	-85,93	1	1	1	0	0	0	0	0	0	1	6	4
780,76	1,96	-81,96	1	1	1	0	1	0	0	0	0	0	6	4
812,86	2,04	-82,37	1	1	1	0	0	1	0	0	0	0	6	4
833,86	2,09	-82,62	1	1	1	0	0	0	1	0	0	0	6	4
922,79	2,32	-83,64	1	1	1	0	0	0	0	1	0	0	6	4
963,72	2,42	-84,09	1	1	1	0	0	0	0	0	1	0	6	4
1070,13	2,69	-85,26	1	1	1	0	0	0	0	0	0	1	6	4
248,95	1,87	-173,74	1	1	0	0	1	0	0	0	0	0	6	4
259,12	1,95	-174,09	1	1	0	0	0	1	0	0	0	0	6	4
265,77	2	-174,3	1	1	0	0	0	0	1	0	0	0	6	4
293,95	2,21	-175,16	1	1	0	0	0	0	0	1	0	0	6	4
306,92	2,31	-175,54	1	1	0	0	0	0	0	0	1	0	6	4
340,64	2,57	-176,53	1	1	0	0	0	0	0	0	0	1	6	4
255,57	1,7	-172,36	1	1	0	0	1	0	0	0	0	0	6	4
234,83	1,77	-172,79	1	1	0	0	0	1	0	0	0	0	6	4
240,89	1,81	-173,05	1	1	0	0	0	0	1	0	0	0	6	4
266,54	2,01	-174,13	1	1	0	0	0	0	0	1	0	0	6	4
278,35	2,1	-174,61	1	1	0	0	0	0	0	0	1	0	6	4
309,01	2,33	4,15	1	1	0	0	0	0	0	0	0	1	6	4
341,73	2,57	-82,95	1	0	0	1	1	0	0	0	0	0	6	4
360,98	2,72	-83,35	1	0	0	1	0	1	0	0	0	0	6	4
373,98	2,82	-83,6	1	0	0	1	0	0	1	0	0	0	6	4
432,47	3,26	-84,64	1	0	0	1	0	0	0	1	0	0	6	4
461,33	3,47	-85,14	1	0	0	1	0	0	0	0	1	0	6	4
542,77	4,09	-86,52	1	0	0	1	0	0	0	0	0	1	6	4
309,37	2,33	-81,36	1	0	0	1	1	0	0	0	0	0	6	4
326,91	2,46	-81,86	1	0	0	1	0	1	0	0	0	0	6	4
338,74	2,55	-82,17	1	0	0	1	0	0	1	0	0	0	6	4
392	2,95	-83,48	1	0	0	1	0	0	0	1	0	0	6	4
418,28	3,15	-84,1	1	0	0	1	0	0	0	0	1	0	6	4
492,38	3,71	-85,83	1	0	0	1	0	0	0	0	0	1	6	4
331,87	2,5	147,14	1	1	0	1	1	0	0	0	0	0	6	4
350,66	2,64	145,76	1	1	0	1	0	1	0	0	0	0	6	4

363,56	2,74	144,84	1	1	0	1	0	0	1	0	0	0	6	4
424,14	3,19	140,57	1	1	0	1	0	0	0	1	0	0	6	4
455,95	3,43	138,4	1	1	0	1	0	0	0	0	1	0	6	4
555,35	4,18	131,93	1	1	0	1	0	0	0	0	0	1	6	4
301,61	2,27	148,79	1	1	0	1	1	0	0	0	0	0	6	4
318,74	2,4	147,33	1	1	0	1	0	1	0	0	0	0	6	4
330,5	2,49	146,34	1	1	0	1	0	0	1	0	0	0	6	4
385,58	2,9	141,82	1	1	0	1	0	0	0	1	0	0	6	4
414,41	3,12	139,52	1	1	0	1	0	0	0	0	1	0	6	4
503,98	3,8	132,63	1	1	0	1	0	0	0	0	0	1	6	4

## 9 Matriz de Estado del Arte

Tabla 4: Matriz de estado del arte

CLASIFICACIÓN Y UBICACIÓN DE FALLAS EN LÍNEAS DE TRANSMISIÓN UTILIZANDO EL ALGORITMO DE RETRO-PROPAGACIÓN DEL CLASIFICADOR.																							
DATOS					TEMÁTICA				FORMULACIÓN DEL PROBLEMA FUNCIONES OBJETOS				RESTRICCIONES DEL PROBLEMA			PROPUESTAS PARA RESOLVER EL PROBLEMA			SOLUCIÓN PROPUESTA				
ITEM	AÑO	TÍTULO DEL ARTÍCULO	REFERENCIA	CITAS	Problem: Objetivo	UBICACIÓN Y CLASIFICACIÓN DE FALLAS	ALGORITMO DE RETRO-PROPAGACIÓN	RED NEURAL	LÍNEAS DE TRANSMISIÓN	UBICACIÓN DE FALLAS	REDES NEURAL	LÍNEAS DE TRANSMISIÓN	CLASIFICACION DE FALLAS	FALLAS EN LINEAS DE TRANSMISION	VELOCIDAD DE PROPAGACION	ENRUTAMIENTO	LÍNEA DE TRANSMISION	NUMERO DE NEURONAS	REDES NEURONALES	UBICACIÓN Y CLASIFICACIÓN ÓPTIMA DE FALLAS	RESULTADOS ESPERADOS	ALGORITMO DE RETRO-PROPAGACION	
1	2015	"Fault detection and classification in electrical power transmission system using artificial neural network"	\cite{M. Jamil, S. K. Sharma, and R. Singh2015}	66	Si			X				X											
2	2016	"Fault detection and diagnosis through artificial intelligence techniques, a state of art"	\cite{L. L. Hurtado-Cortés, E. Villarreal-López, and L. Villarreal-López2016}	3	No								X						X				
3	2022	"Fault Identification on Electrical Transmission Lines Using Artificial Neural Networks"	\cite{C. Asbery and Y. Liao2022}	43	Si	X								X									
4	2022	"Euclidean Distance-Based Method for Fault Detection and Classification in Transmission Lines"	\cite{G. T. Alencar, R. C. Santos, and A. Neves2022}	63	No							X					X						
5	2021	"Deep Learning Approach for Transmission Line Fault Classification,"	\cite{M. A. M. Nasrin, A. M. S. Omar, S. S. M. Ramli, A. R. Ahmad, N. F. Jamaludin, and M. K. Osman2021}	10	Si				X					X									
6	2018	"Classification of Faults in a Transmission Line using Artificial Neural Network"	\cite{S. K. Padhy, B. K. Panigrahi, P. K. Ray, A. K. Satpathy, R. P. Nanda, and A. Nayak2018}	6	Si			X												X			
7	2018	"Transmission lines fault location estimation based on artificial neural networks and power quality monitoring data,"	\cite{T. Hubana2018}	7	No								X				X						





## 9.1 Resumen de Indicadores

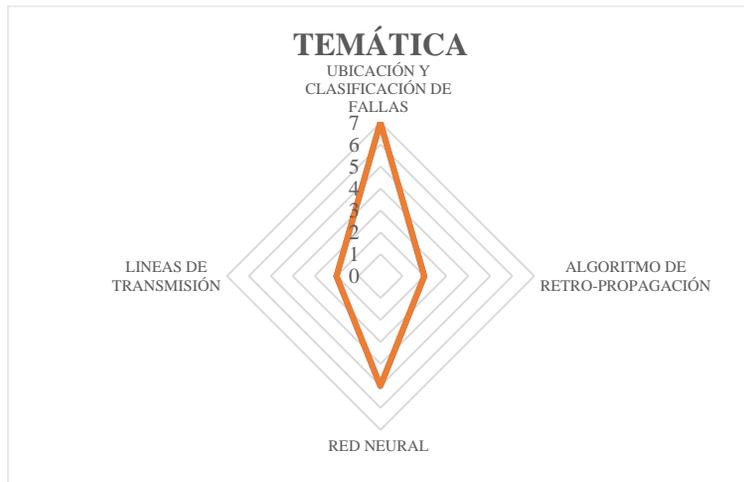


Figura 26. Resumen e indicador de la temática - Estado del arte.

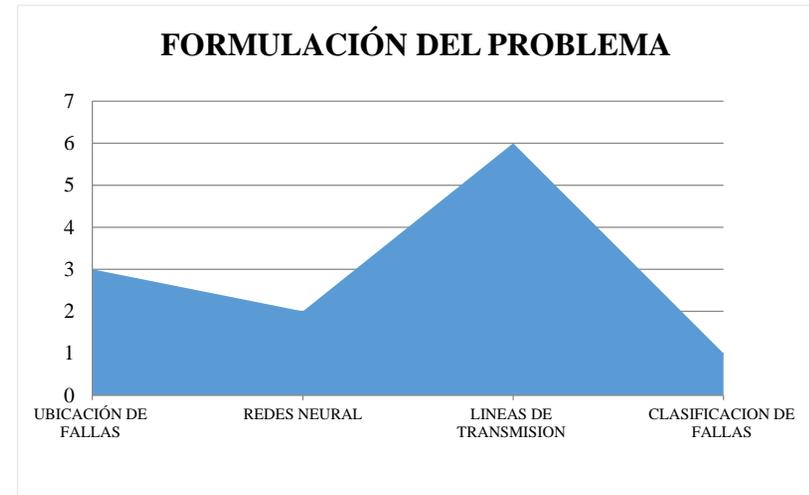


Figura 27. Indicador de formulación del problema - Estado del arte.

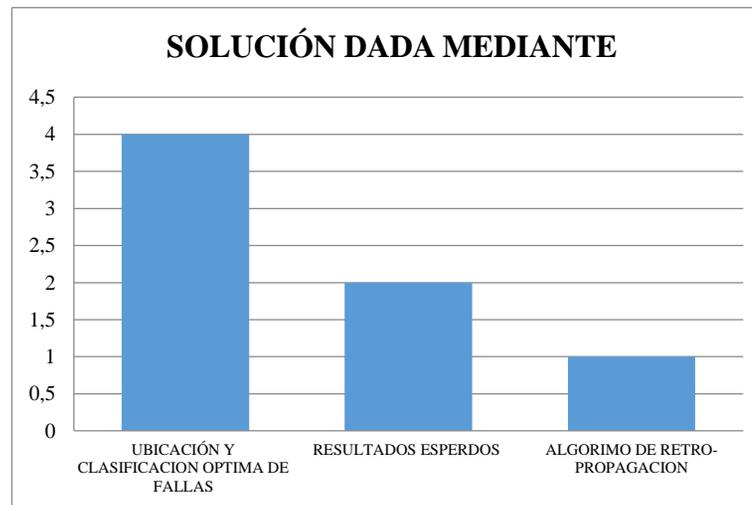


Figura 28. Indicador de solución - Estado del arte