

**CLASIFICACIÓN DE FALLAS ELÉCTRICAS APLICANDO REDES NEURONALES  
ARTIFICIALES A LA PROTECCIÓN DE DISTANCIA DE LÍNEAS DE  
TRANSMISIÓN BASADA EN EL ALGORITMO DE LEVENBERG-MARQUARDT**





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

**CLASIFICACIÓN DE FALLAS ELÉCTRICAS  
APLICANDO REDES NEURONALES  
ARTIFICIALES A LA PROTECCIÓN DE  
DISTANCIA DE LÍNEAS DE TRANSMISIÓN  
BASADA EN EL ALGORITMO DE  
LEVENBERG-MARQUARDT**

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

**AUTOR: DIEGO STALIN LIQUINCHANA SAGUANO  
TUTOR: MILTON GONZALO RUIZ MALDONADO**

Quito -Ecuador  
2022

Diego Stalin Liquinchana Saguno

**CLASIFICACIÓN DE FALLAS ELÉCTRICAS APLICANDO REDES NEURONALES ARTIFICIALES A LA PROTECCIÓN DE DISTANCIA DE LÍNEAS DE TRANSMISIÓN BASADA EN EL ALGORITMO DE LEVENBERG-MARQUARDT**

Universidad Politécnica Salesiana, Quito – Ecuador 2022

Carrera de Electricidad

Breve reseña histórica e información de contacto.



**Diego Stalin Liquinchana Saguno** (Y'1994 – M'06). Realizó sus estudios secundarios en el Colegio Tecnológico Superior Central Técnico en la ciudad de Quito. Estudiante de la Carrera de Ingeniería Eléctrica de la Universidad Politécnica Salesiana. Su trabajo se basa en clasificación de fallas eléctricas aplicando redes neuronales artificiales a la protección de distancia de líneas de transmisión basada en el algoritmo de levenberg-marquardt. [dliquinchana@est.ups.edu.ec](mailto:dliquinchana@est.ups.edu.ec)

*Dirigido por:*



**Milton Gonzalo Ruiz Maldonado** (Y'1987-M'01), se graduó de la Universidad Politécnica Salesiana en 2012 como Ingeniero Electrónico y en 2015 como Ingeniero Eléctrico; Recibió su MSc. en Redes de Comunicaciones en la Pontificia Universidad Católica del Ecuador; Sus intereses de investigación están en comunicaciones verdes, infraestructura de medición avanzada, red inteligente, redes inalámbricas, gestión de energía. Es profesor de la Universidad Politécnica Salesiana, Ecuador y parte del Grupo de Investigación GIREI. [mruizm@ups.edu.ec](mailto:mruizm@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

©2022 Universidad Politécnica Salesiana

QUITO - ECUADOR

## CERTIFICADO DE RESPONSABILIDAD Y AUTORÍA DEL TRABAJO DE TITULACIÓN

Yo, Diego Stalin Liquinchana Saguno con documento de identificación 1721629150 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, 12 de septiembre del año 2022

Atentamente,



Diego Stalin Liquinchana Saguno

1721629150

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

Yo, Diego Stalin Liquinchana Saguno con documento de identificación 1721629150, 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 de fallas eléctricas aplicando redes neuronales artificiales a la protección de distancia de líneas de transmisión basada en el algoritmo de levenberg-marquardt”, 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, 12 de septiembre del año 2022

Atentamente,



Diego Stalin Liquinchana Saguno

1721629150

## CERTIFICADO DE DIRECCIÓN DEL TRABAJO DE TITULACIÓN

Yo, Milton Gonzalo Ruiz Maldonado con documento de identificación 1714409065, docente de la Universidad Politécnica Salesiana, declaro que bajo mi tutoría fue desarrollado el trabajo de titulación: CLASIFICACIÓN DE FALLAS ELÉCTRICAS APLICANDO REDES NEURONALES ARTIFICIALES A LA PROTECCIÓN DE DISTANCIA DE LÍNEAS DE TRANSMISIÓN BASADA EN EL ALGORITMO DE LEVENBERG-MARQUARDT, realizado por Diego Stalin Liquinchana Saguano con documento de identificación 1721629150, obteniendo como resultado final el trabajo de titulación bajo la opción Artículo Académico que cumple con todos los requisitos determinados por la Universidad Politécnica Salesiana.

Quito, 12 de septiembre del año 2022

Atentamente,



Ing. Milton Gonzalo Ruiz Maldonado, MSc  
1714409065

## ÍNDICE GENERAL

1	Introducción .....	2
2	Fallas en el sistema de energía.....	4
3	Red Neuronal Artificial (ANN) .....	4
3.1	Red neuronal de propagación inversa (BP).....	5
3.2	Clasificación de fallas por ANN.....	7
3.3	Clasificación de fallas por ANN.....	7
4	Formulación del problema.....	8
4.1	Obtención y preprocesamiento de datos de voltaje y corriente .....	8
5	Análisis de resultados.....	10
5.1	Clasificación de fallas en sistema IEEE 9 barras .....	11
5.2	Clasificación de fallas en sistema IEEE 14 barras .....	13
6	Conclusiones .....	14
6.1	Trabajos futuros.....	15
7	Referencias.....	15
7.1	Matriz de Estado del Arte.....	18
7.2	Resumen de Indicadores.....	21



## ÍNDICE DE FIGURAS

Figura 1. Proceso lógico para clasificar fallas [autor].	7
Figura 2. Distribución de capas de la ANN [autor].	9
Figura 3. Sistema de prueba IEEE 9 barras [autor].	9
Figura 4. Sistema de prueba IEEE 14 barras [autor].	9
Figura 5. Precisión del sistema de clasificación de fallas, sistema IEEE 9 barras.	10
Figura 6. Precisión del sistema de clasificación de fallas, sistema IEEE 14 barras.	11
Figura 7. Voltajes RMS, fase a, b y c.	12
Figura 8. Corrientes RMS, fase a, b y c.	12
Figura 9. Respuesta de sistema de clasificación de fallas en base a ANN.	12
Figura 10. Voltajes RMS, fase a, b y c, sistema IEEE 14 barras.	13
Figura 11. Corrientes RMS, fase a, b y c, sistema IEEE 14 barras.	13
Figura 12. Respuesta de sistema de clasificación de fallas en base a ANN, IEEE 14 barras.	13
Figura 13. Resumen e indicador de la temática - Estado del arte.	21
Figura 14. Indicador de formulación del problema - Estado del arte.	22
Figura 15. Indicador de solución - Estado del arte.	23

## ÍNDICE DE TABLAS

Tabla 1. Rango de operación de centrales de GD según su tamaño.	8
Tabla 2. Parámetros para obtención de datos.	9
Tabla 3. Escenarios de prueba.	11
Tabla 4. Resultados de casos de estudio, IEEE 9 barras.	12
Tabla 5. Resultados de casos de estudio, IEEE 14 barras.	13
Tabla 6. Resultados de casos de estudio, IEEE 14 barras.	14
Tabla 7: Matriz de estado del arte.	18

# CLASIFICACIÓN DE FALLAS ELÉCTRICAS APLICANDO REDES NEURONALES ARTIFICIALES A LA PROTECCIÓN DE DISTANCIA DE LÍNEAS DE TRANSMISIÓN BASADA EN EL ALGORITMO DE LEVENBERG-MARQUARDT

## Resumen

Este estudio presenta un sistema de clasificación de fallas basado en redes neuronales artificiales (ANN). En este sentido, los tipos de fallas contempladas para la clasificación son: fase a tierra, fase a fase, trifásicas y fallas de doble línea a tierra. Desde otra perspectiva, para el entrenamiento de la ANN se edifica un conjunto de datos, que contiene valores RMS de voltajes, corrientes de falla y de secuencia cero, bajo diferentes parámetros de impedancia y localización de la falla. Estos datos se obtienen de estudios de cortocircuito y sirven para la extracción de características de los voltajes y corrientes de cada fase en condiciones normales y de falla. Por lo que, se aplica el algoritmo de Levenberg-Marquardt durante la fase de entrenamiento de la ANN.

Para la validación de resultados se comprueba el clasificador de fallas mediante los sistemas de ensayo IEEE de 9 y 14 barras. De las pruebas ejecutadas se obtuvo una precisión promedio del 97% de clasificación de fallas para cada sistema.

**Palabras Clave:** Red neuronal artificial, clasificación, fallas, Levenberg-Marquardt, Propagación inversa.

## Abstract

This study presents a fault classification system based on artificial neural networks (ANN). In this sense, the types of faults considered for classification are phase-to-earth, phase-to-phase, three-phase and double line-to-earth faults. From another perspective, for ANN training, a data set is constructed, containing RMS values of voltages, fault currents and zero sequence currents, under different impedance and fault location parameters. These data are obtained from short-circuit studies and are used to extract the characteristics of the voltages and currents of each phase under normal and fault conditions. Therefore, the Levenberg-Marquardt algorithm is applied during the training phase of the ANN.

For the validation of results, the fault classifier is tested using the IEEE 9 and 14 busbar test systems. From the tests performed, an average fault classification accuracy of 97% was obtained for each system.

**Keywords:** Artificial neural network, classification, faults, Levenberg-Marquardt, Back propagation.

# 1 Introducción

El sistema de energía eléctrica se compone de varios elementos que interactúan entre sí, dinámicos y complejos, como, líneas de transmisión, generadores y transformadores, que son propensos a sufrir fallas eléctricas o perturbaciones. En este contexto, el uso de centrales eléctricas de alta capacidad, así como, el concepto de redes sincronizadas y desplazadas geográficamente requiere la identificación de fallas en el menor tiempo posible. Esto es necesario para que los equipos de protección se accionen en tiempo oportuno con el fin de mantener al Sistema Eléctrico de Potencia (SEP) en estado estable [1], [2].

Por otro lado, el sistema de transmisión es un componente del SEP que se expone a condiciones atmosféricas, por lo que, la probabilidad de falla en líneas de transmisión es más frecuente, a comparación del componente de generación. En este sentido, una falla se refiere a cualquier evento o perturbación que afecte al funcionamiento normal del SEP [3].

Las fallas se clasifican en dos tipos, fallas en serie y cortocircuito. Las primeras se identifican de forma rápida al monitorear el voltaje de cada fase. No obstante, este tipo de fallas no son muy comunes y se subclasifican en fallas de un conductor abierto y falla de dos conductores abiertos. Por otro lado, las fallas en derivación se identifican por medio del monitoreo de la corriente de fase, puesto que, la corriente aumenta de forma significativa [4], [5].

Las fallas de cortocircuito se dividen en dos tipos, fallas simétricas y fallas asimétricas. Las fallas asimétricas son, línea a tierra (LG), doble línea a tierra (LL) y línea a línea (LL), mientras que, las fallas simétricas son, triple línea (LLL) y triple línea a tierra (LLLG) [6].

Las fallas eléctricas en un sistema de transmisión o distribución ocurren de forma aleatoria y su severidad dependen del tipo de falla. En este sentido la falla más severa

es la falla de línea a tierra (L-G), seguido de la bifásica (L-L) y la falla trifásica (L-L-L). Por lo tanto, el diagnóstico de fallas en un sistema de transmisión es esencial para mitigar los efectos que puedan producir estas sobre el SEP [7].

Para detectar y aislar las fallas se debe proporcionar de un sistema de protección bien coordinado, con el fin de minimizar el daño y la interrupción causados, que puedan ocasionar las fallas, al sistema de energía. Por lo anterior, existen dispositivos de protección que se encargan de salvaguardar los elementos sensibles del SEP, por ejemplo, las líneas están protegidas por relés de protección, que se instalan al final y al comienzo de esta. La función de estos es detectar fallas eléctricas y desconectar las líneas lo más rápido posible [8].

En el centro de control del SEP, la tarea del operador es analizar las alarmas recibidas, no obstante, esta tarea puede ser difícil debido a que se requiere un diagnóstico preciso. En este sentido, existen momentos, como en condiciones meteorológicas tormentosas, en los que la actividad de la alarma es muy alta. Esto supera la capacidad humana para hacer frente al gran volumen de información [7].

En este sentido pueden ocurrir múltiples fallas junto con problemas imprevistos en los mecanismos de protección. Estos pueden reducir gravemente la velocidad de diagnóstico y la eficiencia global del SEP. En estas circunstancias, existe una aparente necesidad de un sistema automático computarizado que sirva como herramienta para ayudar al operador del sistema. El sistema necesita procesar las señales provenientes de los dispositivos de medición PMU desplegados en diferentes puntos del SEP, para detectar y clasificar el tipo de falla que ocurre sobre este [9], [10].

En este contexto, existen varios estudios que abordan la problemática de clasificación de fallas, para lo cual, aplican varias tácticas, que están detalladas de la siguiente forma.

En la investigación descrita en [11] se presenta una técnica que procede con la detección y clasificación de fallas eléctricas en la red de transmisión de energía, que se denomina Detector de Fallas (GFD). El GFD emplea las magnitudes de voltaje y corriente para el cálculo de los ángulos de fase instantáneos (IPA). En este sentido, estos se asocian por medio del método de Transformada Discreta de Fourier. El IPA sirve para calcular el Índice Medio de Fase Derivado (DPMI), así como, el Índice medio de fase (PMI). En este sentido, el índice de fallas se calcula a partir del PMI, mismo que sirve para la detección y clasificación de fallas.

El estudio propuesto en [12] presenta un algoritmo para la ubicación y clasificación de fallas en micro redes. El algoritmo emplea datos de voltaje y corriente, que se recopilan mediante Unidades de medición de Fasores (PMU) ubicadas en cada terminal del sistema. Una vez que se cuantifican las magnitudes de los fasores de corriente y voltaje, se resuelve un conjunto de 33 ecuaciones de manera simultánea. Las variables que incluyen las ecuaciones son, el voltaje en el punto de falla de las tres secuencias (positiva, negativa y cero), además, de las condiciones de contorno de la falla.

En la investigación descrita en [13] se presenta un método basado en la formación no examinada para el proceso de detección y clasificación de fallas en el SEP. El método emplea la Red de Capsulas con Filtrado Disperso (CNSF) que aprende de forma progresiva las características de cada falla. En consecuencia, el rendimiento de la técnica mejora de manera progresiva y disminuye el aumento de datos requeridos para el entrenamiento. Las señales trifásicas post falla de medio ciclo se cuantifican y se codifican en una sola imagen, estas sirven como entrada del modelo CNSF.

En [14] se presenta tres modelos de aprendizaje profundo para la detección, clasificación y predicción de fallas en líneas

de transmisión. El primero es un modelo de Memoria a Corto Plazo (LSTM), el cual, se encarga de la detección de fallas en una región específica del SEP. El segundo es el método LSTM que se emplea como un clasificador profundo, que clasifica la falla según el tipo y la región de ocurrencia de la falla. El tercero es un modelo de regresión LSTM que se aplica para determinar la distancia exacta de la falla, que ocurre dentro de una región específica.

En [15] se propone una arquitectura basada en inteligencia artificial, que se denomina Aprendizaje de extremo a extremo. Esta emplea una técnica LSTM que se encarga de la detección y clasificación de fallas. Los datos de entrada, necesarios para el entrenamiento, se obtienen mediante la ejecución de fallas de forma repetitiva variando los ubicación y resistencia de falla. El autor menciona que el método propuesto es simple y robusto frente a condiciones de operación, impedancia de falla, parámetros de la línea de transmisión, ruido y condiciones transitorias.

En [16] se presenta un esquema de protección adaptativa para solventar los problemas que representan los relés de distancia convencionales al momento de proteger a líneas de transmisión. El problema principal surge del acoplamiento mutuo entre dos circuitos bajo diferentes condiciones de falla, pues este acoplamiento es de naturaleza no lineal. El esquema que se propone es una Red Neuronal Artificial (ANN), esta tiene la capacidad de clasificar la relación no lineal entre las señales cuantificadas que se asocia a diferentes patrones de la señal analizada. Un aspecto importante del estudio es que se utilizan señales de corriente medidas en el extremo local de la falla.

En [17] se presenta una ANN para la detección de fallas en el SEP, donde, las corrientes trifásicas de un extremo de la línea se toman como entrada para aplicar la ANN. La red neuronal se entrena con un

conjunto de datos obtenidos de ejecuciones simultáneas de cálculos de cortocircuito, donde se varían parámetros como: tipo de falla, ubicación de la falla y resistencia de falla.

En este estudio se muestra un método para clasificar fallas eléctricas aplicando redes neuronales artificiales a la protección a distancia de líneas de transmisión, basada en el algoritmo de Levenberg-Marquardt. Para lo cual, se simulan varios estudios de cortocircuito variando parámetros como: distancia, tipo de falla y resistencia de falla, sobre los sistemas de prueba IEEE de 9 y 14 barras. Esto es necesario para generar una base de datos, donde se cuantifique los voltajes, corrientes y tipo de falla. Esta parte será el ingreso para el entrenamiento, validación y ensayos de la ANN.

A partir de este punto, el estudio se organiza de la siguiente manera, en la unidad 2 se presentan los fundamentos de las ANN y de las redes neuronales de retropropagación. En la unidad 4 se describe la formulación del problema, así como, el caso de estudio. En la unidad 5 se muestran los resultados, que se obtuvieron en la investigación. Finalmente, en las unidades 6 y 7 se muestran las conclusiones y trabajos futuros correspondientemente.

## **2 Fallas en el sistema de energía**

La falla eléctrica del sistema es una condición no deseada de cortocircuito, que sucede cuando alguno de las fases falla o se juntan entre sí. De esta manera, el cortocircuito es el tipo de defecto que mayor riesgo influye, debido a que, el flujo de corriente puede causar sobrecalentamiento o crear fuerzas mecánicas que pueden dañar los equipos y otros elementos del SEP [18]. Por otro lado, las fallas se clasifican en tres tipos, fallas simétricas, fallas asimétricas y fallas de circuito abierto.

Las fallas simétricas producen corrientes elevadas, de hasta 120 veces su valor nominal, un ejemplo de esto es una falla trifásica, donde las tres fases se cortocircuitan sin involucrar la referencia. Por otro lado, las fallas asimétricas son, monofásicas a tierra, dos fases a tierra y fase a fase.

La falla monofásica a tierra (LG) se puede producir por un aislamiento entre el conductor de fase y tierra, o por la rotura y caída del conductor de fase a tierra. Asimismo, la prevalencia de este tipo de fallas es del 70% al 80% [19].

Las fallas de dos fases a tierra ocurren cuando se cortocircuita dos fases cualesquiera con tierra, la prevalencia de este tipo de fallas es del 10% al 17%. La falla de fase a fase ocurre cuando dos fases cualesquiera se unen, la prevalencia de este tipo de fallas es del 8% al 10% [19].

Sin embargo, los defectos de circuito abierto suceden cuando una o más fases del conductor se rompen, en la ubicación de la torre de transmisión, de una línea aérea. Esto puede ocurrir cuando los disyuntores o aisladores se abren, pero no se logran cerrar en una o más fases. Durante el circuito abierto de una de las dos fases, fluye corriente desequilibrada en el sistema, esto provoca un recalentamiento de las máquinas rotativas [20].

## **3 Red Neuronal Artificial (ANN)**

La ANN se puede aplicar a la detección y clasificación de fallas de forma efectiva, debido a que, esta es una técnica de programación capaz de resolver problemas lineales de forma fácil. Asimismo, es efectiva para la resolución de problemas donde se dispone información de forma masiva. Además, las ANN tienen la capacidad de aprender con nuevas experiencias [7]. Por otro lado, las ANN son ampliamente utilizadas e investigadas para el problema de detección y clasificación de

fallas, debido a las características que se presentan a continuación.

- Posibilidad de configurar el número de líneas de transmisión, es decir, se puede configurar desde una línea de transmisión de circuito único de longitud corta, hasta líneas de transmisión de circuito doble.
- Es posible emplear varios métodos, para la resolución de la red, con diferentes condiciones del sistema de energía de una forma rápida y confiable.
- Una red neuronal puede incorporar los cambios dinámicos que sufre el SEP. Esto es muy importante debido a que las condiciones del sistema de energía cambian posterior a una perturbación.
- La salida de la ANN es muy rápida, debido a que converge muy rápido, por lo que, se convierte en una técnica confiable y precisa, esto depende del entrenamiento puesto que su funcionamiento se ve influido por una serie de operaciones simples.

El algoritmo que emplea la programación de la ANN brinda diversas ventajas, pero también adolece de varias desventajas, que son de naturaleza muy compleja. Algunos de los factores importantes son: el tipo de red, arquitectura de la red, selección de número de capas, número de neuronas, tipo de función de activación y las cuantificaciones del algoritmo de entrenamiento. Asimismo, existen parámetros necesarios, como los valores de las tensiones, corrientes previas y posteriores a la falla de las tres fases respectivas en estado estable, que son necesarias para la detección y clasificación de fallas [21].

Los valores de tensión y corriente, antes y después de la falla de las tres fases, son diferentes y se rigen por el tipo de falla. Por lo tanto, el método de clasificación de fallas requiere una red neuronal que le permita determinar el tipo de falla, a partir de los patrones de tensiones y corrientes previas y posteriores a la falla, que se generan a partir

de los valores medidos desde una línea de transmisión trifásica, de un sistema de energía eléctrica. La clasificación de fallas mediante la red neuronal se basa en seis entradas, que corresponden a los voltajes y corrientes de cada fase. Por otro lado, el número total de salidas, de la red neuronal, son cuatro, que corresponden a las tres fases A, B, C y tierra, de la línea de transmisión trifásica [22].

### 3.1 Red neuronal de propagación inversa (BP)

Las redes neuronales multicapa se aplican con éxito para resolver problemas difíciles, mediante el empleo de varios procedimientos de aprendizaje supervisado, entre los cuales el algoritmo de aprendizaje de retro propagación de error (BP) es el más popular. Este es un algoritmo iterativo basado en el gradiente, que se propone para minimizar el error generado entre el vector de salida existente y el querido. El término retro propagación hace referencia al cálculo del gradiente para las redes neuronales multicapas no lineales. La salida total se obtiene de la propagación de los patrones de entrenamiento mediante la red, para lo cual se define una matriz  $O^\ell$ , donde, las entradas de  $A^{\ell+1}$ , para todas las capas ( $\ell = 1, 2, \dots, L - 1$ ), se evalúan con (2) [2].

$$O^\ell = A^\ell W^\ell \quad (1)$$

$$a_{p,j}^{\ell+1} = f(O_{p,j}^\ell) \quad (2)$$

Donde,  $p = 1, \dots, P$  y  $j = 1, 2, \dots, n_{\ell+1}$ . Asimismo, se requiere un algoritmo debido a que se debe acoplar los pesos, de modo que la red aprenda a asignar los patrones de entrada a los patrones de salida. El algoritmo más usado para el proceso de entrenamiento de la ANN es el algoritmo BP. El aprendizaje se logra ajustando los pesos de manera que la salida de la red,  $A^L$ , sea lo más cercana posible al objetivo,  $T^L$ .

En este sentido el error se calcula mediante (3).

$$E = \frac{1}{2P} \sum_{p=1}^P \sum_{j=1}^{n_L} (t_{p,j} - a_{p,j}^L)^2 \quad (3)$$

Por lo que, se necesita minimizar el error  $E$ , con respecto a los cambios de peso  $W_{i,j}$ . De igual forma, se emplea la regla delta para incorporar la tasa de aprendizaje  $\eta$  junto con las técnicas del algoritmo de descenso de gradiente, para definir el cambio de peso. Los cambios de pesos son proporcionales al gradiente del error.

$$\Delta W_{i,j}^\ell = -\eta \frac{\partial E}{\partial W_{ij}}; \quad 0 < \eta \leq 1 \quad (4)$$

Si el gradiente  $\frac{\partial E}{\partial W_{ij}}$  es positivo, el cambio de peso debería ser negativo y viceversa. Por lo tanto, se agrega un signo negativo en el lado derecho de (4). De esta forma, los cambios de peso  $\Delta W_{i,j}^{L-1}$  para los pesos que se conectan a la capa final se obtienen mediante (5).

$$\begin{aligned} \Delta W_{i,j}^{L-1} &= -\frac{\eta}{2P} \sum_{p=1}^P \sum_{j=1}^{n_L} \frac{\partial}{\partial W_{i,j}^{L-1}} (t_{p,j} \\ &\quad - a_{p,j}^L)^2 \end{aligned} \quad (5)$$

Para cada  $j$ , solo un valor de  $a_{p,j}^L$  tiene relación con  $W_{i,j}^{L-1}$ , por lo que se obtiene (6).

$$\begin{aligned} \Delta W_{i,j}^{L-1} &= -\frac{\eta}{P} \sum_{p=1}^P (t_{p,j} \\ &\quad - a_{p,j}^L) \frac{\partial a_{p,j}^L}{\partial W_{i,j}^{L-1}} \end{aligned} \quad (6)$$

La derivada parcial  $\frac{\partial a_{p,j}^L}{\partial W_{i,j}^{L-1}}$  se puede evaluar con la regla de la cadena como en (7).

$$\begin{aligned} \Delta W_{i,j}^{L-1} &= -\frac{\eta}{P} \sum_{p=1}^P (t_{p,j} \\ &\quad - a_{p,j}^L) f'(O_{p,j}^{L-1}) a_{p,i}^{L-1} \\ &= \frac{\eta}{P} \sum_{p=1}^P \delta_{p,j}^{L-1} a_{p,i}^{L-1} \end{aligned} \quad (7)$$

Donde,  $\delta_{p,j}^{L-1} = (t_{p,j} - a_{p,j}^L) f'(O_{p,j}^{L-1})$  y  $f'(O_{p,j}^{L-1}) = \frac{\partial a_{p,j}^L}{\partial O_{p,j}^{L-1}}$ . En este sentido, los pesos cambian en capas inferiores, además, se calculan mediante (8) y (9).

$$\begin{aligned} \Delta W_{i,j}^\ell &= -\frac{\eta}{P} \sum_{p=1}^P (\delta_{p,j}^\ell a_{p,i}^\ell); \quad \ell \\ &= 1, \dots, L-1 \end{aligned} \quad (7)$$

$$\begin{aligned} \delta_{p,j}^\ell &= \sum_{k=1}^{n_{\ell+1}} (\delta_{p,k}^{\ell+1} w_{j,k}^{\ell+1}) f'(O_{p,j}^\ell); \quad \ell \\ &= 1, \dots, L-1 \end{aligned} \quad (8)$$

Por lo tanto, el procedimiento de aprendizaje consiste en que la red comience con un conjunto aleatorio de valores de peso, elija uno de los patrones de entrenamiento y evalúe las salidas utilizando dicho patrón como entrada de una manera anticipada. De tal modo que, usando el procedimiento de BP, se evalúan todos los cambios de peso para ese patrón. Este procedimiento se repite para cada

parámetro del conjunto de entrenamiento, es decir, para todos los pesos  $\Delta w_{i,j}$  [2].

### 3.2 Clasificación de fallas por ANN

Aunque el concepto básico de los relés sigue siendo el mismo, la tecnología digital ha tenido una influencia significativa en la forma en que operan los relés y ha ofrecido varias mejoras sobre los relés electromecánicos tradicionales. En el método basado en ANN, todos los datos que se recopilan se subdividen en tres vínculos, estos son, los vínculos de datos de aprendizaje, comprobación y prueba. El primer avance del procedimiento es la detección de fallas, una vez que se sabe que ha ocurrido una falla en la línea de transmisión, el siguiente paso es clasificar la falla en las diferentes categorías en función de las fases que presentan la falla. En el diagrama de la Figura 1 se explica el procedimiento básico que se emplea para la detección y clasificación de fallas basada en ANN en la línea de transmisión de alta tensión [17].

### 3.3 Clasificación de fallas por ANN

El LMA también conocido como el método Damped Lower Squares (DLS), se utiliza en matemáticas y computación para resolver problemas no lineales de cuadrados menores, fundamentalmente para la nivelación de curvas de mínimos cuadrados. El LMA es manejado para solucionar dificultades genéricas de nivelación de curvas en diversos estudios de software, en virtud a que, descubre un mínimo local, como ocurre con muchos algoritmos apropiados, que no es obligatoriamente el mínimo total.




Figura 1. Proceso lógico para clasificar fallas [autor].

El LMA intercala el algoritmo de Gauss Newton (GNA) con la técnica de descenso de gradiente, esto permite que, el LMA sea más firme que el GNA, esto conlleva a que encuentra una solución en muchos casos, aunque este muy lejos del mínimo final. Además, el LMA alarga a que sea lo más lento a comparación del GNA, para tareas con buen procedimiento y cuantificaciones de inicio sensibles [23].



La implementación trascendental del LMA se localiza en el inconveniente de nivelación de las curvas de mínimos cuadrados dado una agrupación de pares de datos empíricos de variables autónomas y dependientes  $(x_i, y_i)$ . Pues, los parámetros  $\beta$  de la curva del modelo  $f(x, \beta)$  se deben adecuar para limitar el aumento de cuadrados de desviación  $S(\beta)$  [24].

$$S(\beta) = \underset{\beta}{\operatorname{argmin}} \sum_{i=1}^m \operatorname{sqr}t[(y_i - f(x_i, \beta))^2]; \quad \bar{\beta} \in \underset{\beta}{\operatorname{argmin}} \quad (9)$$

## 4 Formulación del problema

La mayor amenaza para la continuidad del suministro eléctrico son las fallas del sistema, las cuales son un problema inevitable. Por lo tanto, se necesita un sistema bien coordinado de protecciones, para detectar y asilar fallas de forma rápida, con el fin de minimizar el daño y las interrupciones causados al sistema eléctrico. Sin embargo, al existir una gran cantidad de tipos de fallas es necesario aplicar un método que permita identificar el tipo de falla de forma rápida, para que los operadores del sistema actúen de forma rápida para la mitigación de esta.

En contraste, en esta investigación se propone una red neuronal artificial (ANN) que se utiliza como método para la detección de fallas del SEP. La red propuesta consta de ocho entradas y cuatro salidas. Las entradas son las tensiones, corrientes de falla y secuencia cero, mientras que, la salida son cuatro variables binarias, una por cada fase y tierra. De esta forma se generaliza la representación de todas las permutaciones posibles, que involucra la combinación de fases.

La red neuronal propuesta es capaz de clasificar las fases específicas que se involucran en el escenario de falla, es decir,

que para la clasificación se considera nueve categorías diferentes, las cuales se presentan en la Tabla 1. Por otra parte, la edificación de la ANN está constituida de 8, 100 y 4 neuronas, distribuidas en la capa de entrada, oculta y salida respectivamente, como se representa en la Figura 2.

Tabla 1. Rango de operación de centrales de GD según su tamaño.

Tipo de falla	Salida de la ANN			
	A	B	C	G
A-G	1	0	0	1
B-G	0	1	0	1
C-G	0	0	1	1
A-B	1	1	0	0
B-C	0	1	1	0
C-A	1	0	1	0
A-B-G	1	1	0	1
B-C-G	0	1	1	1
C-A-G	1	0	1	1

### 4.1 Obtención y preprocesamiento de datos de voltaje y corriente

En el modelo de práctica de la IEEE de 9 y 14 como se indica en la (Figura 3 y 4) se implementa a manera de compilación de las cifras, debido a lo cual son obligatorios para ensayar a la ANN.

Además, se hace uso del software MATLAB/Simulink y Power Factory, para los cálculos de flujos de potencia y estudios de cortocircuito, bajo diferentes parámetros de ubicación y resistencia de falla acorde con la Tabla 2.

La ubicación de la falla se modela 19 veces para los 11 tipos, por lo tanto, el total de simulaciones son 209 (19\*11). De la misma forma, para las resistencias de falla se modela 20 veces para los 11 tipos de fallas, es decir el total de simulaciones es de 220 (20\*11). Además, se presenta el

algoritmo 1 para la construcción de la base de datos de fallas, el algoritmo 2 para el entrenamiento de la red neuronal y, por último, el algoritmo 3 para el procedimiento de clasificación de fallas.

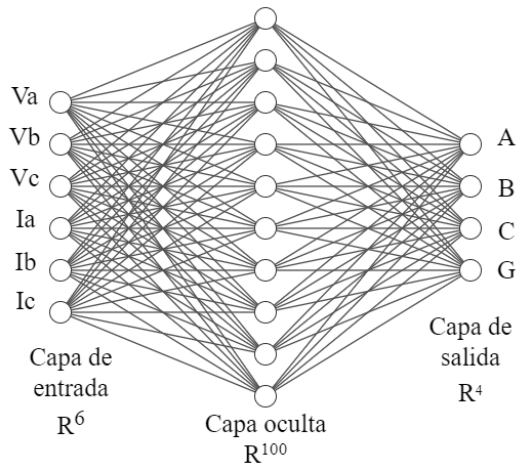


Figura 2. Distribución de capas de la ANN [autor].

Tabla 2. Parámetros para obtención de datos.

Parámetros	Variación de valores
Resistencia de falla ( $\Omega$ )	0.001, 5, 10, 15, 20, 25, 30, 35, 40, 45, 50, 55, 60, 65, 70, 75, 80, 85, 90, 95
Localización de la falla (km)	10, 20, 30, 40, 50, 60, 70, 80, 90, 100, 110, 120, 130, 140, 150, 160, 170, 180, 190




Figura 3. Sistema de prueba IEEE 9 barras [autor].




Figura 4. Sistema de prueba IEEE 14 barras [autor].

**Algoritmo 1. Construcción de la base de datos de fallas**

- Paso 1: Ingresar parámetros de falla.  
Tipo de falla, tiempo, resistencia de falla y distancia.
- Paso 2: Ejecutar estudio de cortocircuito
- Paso 3: Iniciar medición de variables eléctricas  
Voltajes y corrientes.
- Paso 4: Almacenar resultados de voltajes y corrientes trifásicas en la base de datos.
- Paso 5: Regresar al paso 1

$$\delta_{p,j}^{\ell} = \sum_{k=1}^{n_{\ell+1}} (\delta_{p,k}^{\ell+1} w_{j,k}^{\ell+1}) f'(O_{p,j}^{\ell})$$

- Paso 5: Graficar resultados del tipo de falla
- Paso 6: Regresar al paso 1

**Algoritmo 2. Entrenamiento de ANN para clasificación de fallas**

- Paso 1: Ingresar base de datos de tipos de fallas.
- Paso 2: Iniciar la aplicación Neural Fitting tool de MATLAB.
- Paso 3: Seleccionar los datos de entrada  
Entradas (Voltajes y corrientes de fase) y salidas (salida binaria por cada línea)
- Paso 4: Dividir los datos de entrada  
El 70% son de entrenamiento  
El 15% corresponden a datos de validación.  
El 15% son datos de prueba.
- Paso 5: Definir la arquitectura de la red  
8 neuronas en la entrada  
100 neuronas para la capa oculta  
4 neuronas sobre la capa de salida
- Paso 6: Iniciar el proceso de entramiento con el algoritmo de Levenberg Marquardt  
Hacer para todo  $\beta$ 

$$S(\beta) = \operatorname{argmin}_{\beta} \sum_{i=1}^m \operatorname{sqr}t[(y_i - f(x_i, \beta))]^2$$
- Paso 7: Verificar las métricas de entrenamiento  
Rendimiento  
Estado de entrenamiento  
Error

**Algoritmo 3. Clasificación de fallas**

- Paso 1: Ingresar parámetros de falla.  
Tipo de falla, tiempo, resistencia de falla y distancia.
- Paso 2: Iniciar medición de variables eléctricas  
Voltajes y corrientes
- Paso 3: Ingresar mediciones a la ANN  
Voltajes y corrientes.
- Paso 4: Aplicar la lógica de la ANN  
Hacer para todo  $\ell$

## 5 Análisis de resultados

El análisis de resultados se basa en el entrenamiento, validación y prueba del clasificador de fallas basado en la ANN, tanto para el sistema de pruebas de 9 y 14 barras de la IEEE. Para lo cual, el conjunto de datos obtenidos del cálculo de corto circuito, ante la variación de parámetros de resistencia, ubicación y tipo de falla, se dividen en tres conjuntos, 70% para entrenamiento, 15% para validación y 15 % para pruebas, como se presenta en la Figura 5.




Figura 5. Precisión del sistema de clasificación de fallas, sistema IEEE 9 barras.

La precisión del 97% corresponde a los datos de entrenamiento, asimismo, el 96% corresponde a los datos de validación. Además, para los datos de prueba, la precisión del sistema es del 98%. De esta forma, la precisión general del sistema es del 97%, es decir que, la clasificación de las

fallas es exitosa el 97% de los casos, mientras que, el 3% restante corresponde a detecciones erróneas.

En la Figura 6 se presenta la precisión del sistema de clasificación de fallas para el sistema IEEE de 14 barras. En este sentido, la precisión del 97% corresponde a los datos de entrenamiento, asimismo, el 98% se vincula a los datos de validación. Además, para los datos de prueba, la precisión del sistema es del 96%. De esta forma, la precisión general del sistema es del 97%, es decir que, la clasificación de las fallas es exitosa el 97% de los casos, mientras que, el 3% restante corresponde a detecciones erróneas.




Figura 6. Precisión del sistema de clasificación de fallas, sistema IEEE 14 barras.

En otro sentido, para analizar de forma detallada los resultados obtenidos del sistema de clasificación de fallas se plantea 11 casos (Tabla 3).

Tabla 3. Escenarios de prueba

Caso	Rf ( $\Omega$ )	Tipo de falla	Distancia (%)	Duración (seg)
1	2	AG	5	0.2

2	6	BG	15	0.2
3	11	CG	25	0.2
4	21	ABG	35	0.2
5	3	BCG	45	0.2
6	6	ACG	55	0.2
7	12	AB	65	0.2
8	22	BC	75	0.2
9	4	AC	85	0.2
10	8	ABC	5	0.2
11	0.02	ABCG	15	0.2

Los escenarios descritos en la Tabla 3 se aplican a los sistemas de prueba IEEE de 9 y 14 barras. Las variables eléctricas que se analizan son los voltajes, corrientes de falla y secuencia cero.

## 5.1 Clasificación de fallas en sistema IEEE 9 barras

De los casos descritos en la Tabla 3, se elige el caso 5 para realizar el análisis de las ondas rms de voltajes (Figura 7) y corrientes (Figura 8), mientras que, los resultados de todos los casos se detallan en la Tabla 4.

En la Figura 7 se observa que a los 0.1 segundos los voltajes de las fases B y C se reducen de forma significativa, de tal forma que tienden a cero. Este estado se mantiene hasta los 0.2 segundos, ya que, posterior a este tiempo, las ondas de voltaje de las fases B y C incrementan su valor hasta alcanzar su magnitud previo a la falla. Por otro lado, el voltaje de la fase A aumenta ligeramente desde el tiempo 0.1 a 0.22 segundos, ya que posteriormente se despeja la falla.

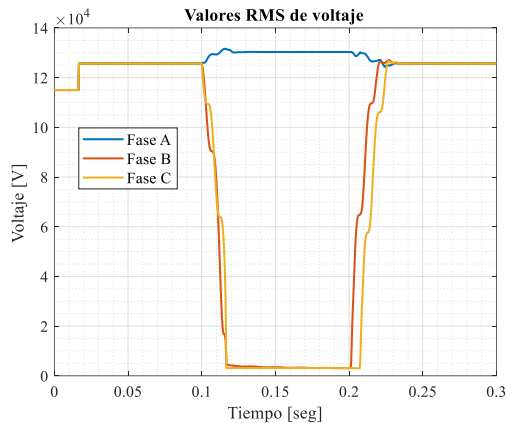


Figura 7. Voltajes RMS, fase a, b y c.

En la Figura 8 se presenta las ondas RMS de corriente. En este sentido, las corrientes de las fases B y C aumentan de forma significativa, la fase B adopta un valor de 1038 A, mientras que, la fase C un valor de 831 A. Asimismo, a partir de los 0.2 segundos, las magnitudes de las fases B y C disminuyen hasta adoptar el valor previo a la falla. Por otro lado, la magnitud de la Fase A se mantiene en el valor nominal previo a la falla.




Figura 8. Corrientes RMS, fase a, b y c.

El comportamiento del sistema de detección de fallas se detalla en la Figura 9. En este se observa que a partir de los 0.1 segundos el tipo de falla BCG cambia su valor de 0 a 1. Este estado se mantiene hasta los 0.22 segundos, lo cual coincide con el tiempo que toma el sistema en retomar sus magnitudes nominales de voltaje y corriente previos a la falla. También, se observa que

existen cambios repentinos de las fallas BC y CG, sin embargo, estos no perduran.

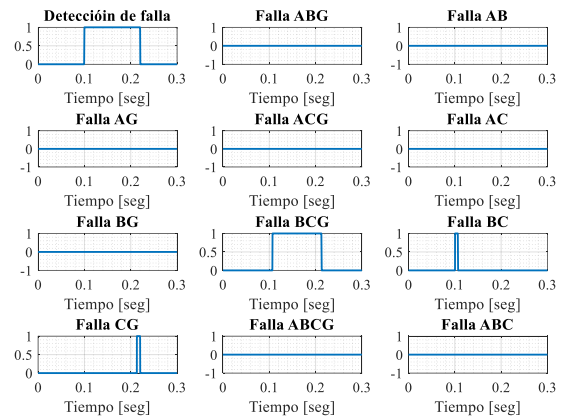


Figura 9. Respuesta de sistema de clasificación de fallas en base a ANN.

Tabla 4. Resultados de casos de estudio, IEEE 9 barras

Caso	Parámetros de falla			Resultado de la ANN			
	R F	Tipo	Distan- cia (%)	A	B	C	G
1	2	AG	5	1	0	0	1
2	6	BG	15	0	1	0	1
3	11	CG	25	0	0	1	1
4	21	ABG	35	1	1	0	1
5	3	BCG	45	0	1	1	1
6	6	ACG	55	1	0	1	1
7	12	ABG	65	1	1	0	1
8	22	BC	75	0	1	1	0
9	4	AC	85	1	0	1	0
10	8	ABC G	5	1	1	1	1
11	5	ABC G	15	1	1	1	1

Los resultados obtenidos por el sistema de clasificación de fallas basado en la ANN se detallan en la Tabla 4. En esta se observa que todas las fallas de prueba fueron clasificadas de forma correcta.

## 5.2 Clasificación de fallas en sistema IEEE 14 barras

De los casos descritos en la Tabla 3, se elige el caso 1 para realizar el análisis de las ondas rms de voltajes (Figura 10) y corrientes (Figura 11), mientras que, los resultados de todos los casos se detallan en la Tabla 5.

En la Figura 10 se observa que a los 0.1 segundos el voltaje de la fase A se reduce de forma significativa, de tal forma que tiende a cero. Este estado se mantiene hasta los 0.2 segundos, ya que, posterior a este tiempo, la onda de la fase A incrementa su valor hasta alcanzar su magnitud previo a la falla. Por otro lado, el voltaje de las fases B y C aumenta ligeramente desde el tiempo 0.1 hasta los 0.22 segundos, ya que posteriormente se despeja la falla.

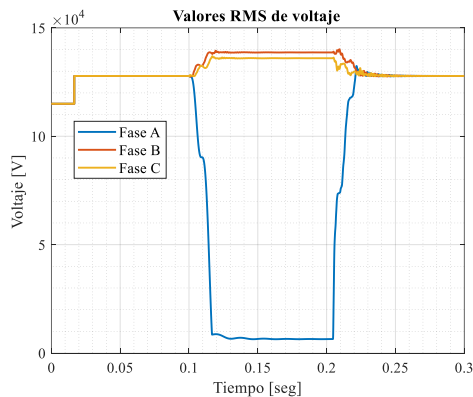


Figura 10. Voltajes RMS, fase a, b y c, sistema IEEE 14 barras.

En la Figura 11 se presenta las ondas RMS de corriente. En este sentido, la corriente de la fase A aumenta de forma significativa, situándose en un valor de 3806 A. Asimismo, a partir de los 0.2 segundos, la magnitud de la fase A disminuye hasta adoptar el valor previo a la falla. Por otro lado, la magnitud de la fase B aumenta ligeramente, mientras que, la magnitud de la fase C disminuye ligeramente a lo largo del tiempo de contingencia de la falla.

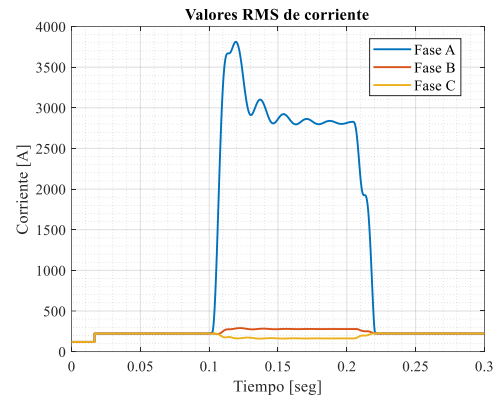


Figura 11. Corrientes RMS, fase a, b y c, sistema IEEE 14 barras.

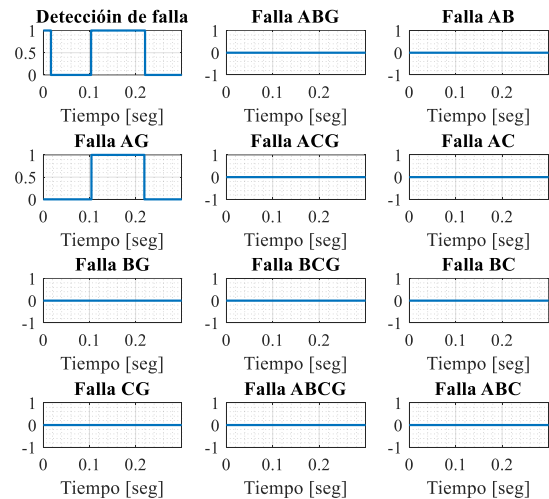


Figura 12. Respuesta de sistema de clasificación de fallas en base a ANN, IEEE 14 barras.

En la Figura 12 se observa que a partir de los 0.1 segundos el tipo de falla AG cambia su valor de 0 a 1. Este estado se mantiene hasta los 0.22 segundos, lo cual coincide con el tiempo que toma el sistema en retomar sus magnitudes nominales de voltaje y corriente previos a la falla.

Los resultados obtenidos por el sistema de clasificación de fallas basado en la ANN se presentan en la Tabla 5. En esta se observa que todas las fallas de prueba fueron clasificadas de forma correcta.

Tabla 5. Resultados de casos de estudio, IEEE 14 barras

Parámetros de falla	Resultado de la ANN
---------------------	---------------------

R F	Tipo	Distan- cia (%)	A	B	C	G	
1	2	AG	5	1	0	0	1
2	6	BG	15	0	1	0	1
3	11	CG	25	0	0	1	1
4	21	ABG	35	1	1	0	1
5	3	BCG	45	0	1	1	1
6	6	ACG	55	1	0	1	1
7	12	ABG	65	1	1	0	1
8	22	BC	75	0	1	1	0
9	4	AC	85	1	0	1	0
10	8	ABC G	5	1	1	1	1
11	5	ABC G	15	1	1	1	1

Por último, en la Tabla 6 se presenta una comparación del sistema de clasificación de fallas basado en una ANN, propuesto en esta investigación, con los resultados obtenidos en el estudio descrito en [17]. Este estudio se basa en el cálculo de la Transformada Wavelet Discreta (DWT) y su energía, para emplear una técnica de reconocimiento de patrones y finalmente obtener la clasificación de fallas.

Se observa que los resultados obtenidos con las técnicas ANN y DWT son iguales, sin embargo, la investigación descrita en [17] no permite una detección en tiempo real, a diferencia del estudio descrito en esta investigación que emplea voltajes, corrientes de falla y secuencia cero, para clasificar la falla en tiempo real. Esto se evidencia en el análisis de la respuesta del sistema de clasificación de fallas analizado en gráficos previos.

Tabla 6. Resultados de casos de estudio, IEEE 14 barras

Caso	Tipo	Resultado con ANN				Resultado con Transformada wavelet discreta			
		A	B	C	G	A	B	C	G
1	2	AG	5	1	0	0	1	1	1
2	6	BG	15	0	1	0	1	0	1
3	11	CG	25	0	0	1	1	1	1
4	21	ABG	35	1	1	0	1	1	1
5	3	BCG	45	0	1	1	1	1	1
6	6	ACG	55	1	0	1	1	1	1
7	12	ABG	65	1	1	0	1	1	1
8	22	BC	75	0	1	1	1	0	0
9	4	AC	85	1	0	1	1	0	0
10	8	ABC G	5	1	1	1	1	1	1
11	5	ABC G	15	1	1	1	1	1	1

1	AG	1	0	0	1	1	0	0	1
2	BG	0	1	0	1	0	1	0	1
3	CG	0	0	1	1	0	0	1	1
4	AB G	1	1	0	1	1	1	0	1
5	BCG	0	1	1	1	0	1	1	1
6	AC G	1	0	1	1	1	0	1	1
7	AB G	1	1	0	1	1	1	0	1
8	BC	0	1	1	0	0	1	1	0
9	AC	1	0	1	0	1	0	1	0
10	ABC	1	1	1	1	1	1	1	1
11	ABC G	1	1	1	1	1	1	1	1

## 6 Conclusiones

El enfoque propuesto en la presente investigación hace uso de una red neuronal artificial para clasificar distintos tipos de fallas como: fallas de fase a tierra, fase a fase, trifásicas y fallas de doble línea a tierra, bajo diferentes parámetros de impedancia y ubicación de la falla.

El método desarrollado emplea los valores RMS de voltaje, corriente y las magnitudes de secuencia cero, que se cuantifican del estudio de cortocircuito. Esto se ejecuta con la intención de conseguir la base de datos de entrada para el entrenamiento, validación y prueba de la ANN.

Por la cantidad de valores producto del cálculo repetitivo de los estudios de cortocircuito bajo diferentes parámetros, la arquitectura de la ANN es la de retro propagación. En este sentido, las capas de entrada de la ANN son 8, mismas que corresponden a los voltajes trifásicos, corrientes trifásicas y de secuencia cero. Las capas ocultas son 10 y las capas de salida son 4 variables binarias, que se asocian a cada fase (A-B-C) y tierra (G).

La ANN clasifica la relación no lineal entre las señales de entrada, mediante la

identificación de patrones durante las condiciones de falla. Esto lo realiza durante la etapa de entrenamiento, para lo cual, se maneja el LMA. En contraste, con el clasificador de fallas, basado en la ANN, se obtiene una precisión general promedio del 97%, para los sistemas IEEE de 9 y 14 barras. Además, este permite clasificar fallas en tiempo real a diferencia de otros métodos que necesitan datos previos, como la DWT de las señales de cada fase, para posteriormente ingresar los datos al algoritmo de reconocimiento de patrones.

Por último, el rendimiento de la ANN depende de su estructura, es decir de las capas de entrada, ocultas y de salida, así como, del algoritmo de aprendizaje seleccionado para la fase de entrenamiento.

### 6.1 Trabajos futuros

El sistema de clasificación de fallas propuesto en la presente investigación posee una precisión general promedio del 97%, no obstante, la resolución de la red neuronal artificial en tiempo real tiene algunas variaciones, es decir existe activaciones repentinas de algunos tipos de fallas antes de la detección final. En este sentido, se propone, como trabajo futuro, la mejora de la técnica propuesta, con el fin de mejorar su precisión y rendimiento. Asimismo, se propone involucrar nuevas funcionalidades como: la ubicación de ocurrencia de la falla, de tal forma, se tendría un sistema completo, que detecte, identifique el lugar de la falla y clasifique el tipo de falla.

## 7 Referencias

- [1] A. Maheshwari, V. Agarwal, S. K. Sharma, and E. Engineering, "Transmission Line Fault Classification Using Artificial Neural Network Based Fault," vol. 9, no. 3, pp. 170–181, 2018.
- [2] B. E. M Tayeb, "Faults Detection in Power Systems Using Artificial Neural Network," *Am. J. Eng. Res.*, vol. 2, no. 6, pp. 69–75, 2013, [Online]. Available: [www.ajer.org](http://www.ajer.org).
- [3] J. Zhang, Z. Y. He, S. Lin, Y. B. Zhang, and Q. Q. Qian, "An ANFIS-based fault classification approach in power distribution system," *Int. J. Electr. Power Energy Syst.*, vol. 49, no. 1, pp. 243–252, 2013, doi: 10.1016/j.ijepes.2012.12.005.
- [4] S. Mishra and A. Baral, "Classification of power system faults using voltage Concordia pattern feature aided PNN," *2016 IEEE 6th Int. Conf. Power Syst. ICPS 2016*, pp. 0–5, 2016, doi: 10.1109/ICPES.2016.7584104.
- [5] K. Saravanababu, P. Balakrishnan, and K. Sathiyasekar, "Transmission Line Faults Detection, Classification, and Location Using Discrete Wavelet Transform," in *International Conference on Power, Energy and Control (ICPEC)*, 2013, pp. 209–216, doi: 10.1201/9781568816692-11.
- [6] M. Jamil, A. Kalam, A. Q. Ansari, and M. Rizwan, "Generalized neural network and wavelet transform based approach for fault location estimation of a transmission line," *Appl. Soft Comput. J.*, vol. 19, pp. 322–332, 2014, doi: 10.1016/j.asoc.2014.02.020.
- [7] 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.
- [8] A. Nag and A. Yadav, "Fault Classification using Artificial Neural Network in Combined Underground



- Cable and Overhead Line,” in *IEEE International Conference on Power Electronics, Intelligent Control and Energy Systems (ICPEICES-2016)*, 2016, pp. 1–4, doi: 10.1109/ICPEICES.2016.7853664.
- [9] I. Farhat, “Fault detection, classification and location in transmission line systems using neural networks.” p. 115, 2003, [Online]. Available: <http://spectrum.library.concordia.ca/1920/>.
- [10] M. Saini, A. A. Mohd Zin, M. W. Mustafa, A. R. Sultan, and R. Nur, “Algorithm for fault location and classification on parallel transmission line using wavelet based on Clarke’s transformation,” *Int. J. Electr. Comput. Eng.*, vol. 8, no. 2, pp. 699–710, 2018, doi: 10.11591/ijece.v8i2.699-710.
- [11] B. R. Kumar, A. Mohapatra, S. Chakrabarti, and A. Kumar, “Phase angle-based fault detection and classification for protection of transmission lines,” *Int. J. Electr. Power Energy Syst.*, vol. 133, no. June, p. 107258, 2021, doi: 10.1016/j.ijepes.2021.107258.
- [12] M. Abasi, A. Rohani, F. Hatami, M. Joorabian, and G. B. Gharehpetian, “Fault location determination in three-terminal transmission lines connected to industrial microgrids without requiring fault classification data and independent of line parameters,” *Int. J. Electr. Power Energy Syst.*, vol. 131, no. July 2020, p. 107044, 2021, doi: 10.1016/j.ijepes.2021.107044.
- [13] S. R. Fahim, S. K. Sarker, S. M. Muyeen, S. K. Das, and I. Kamwa, “A deep learning based intelligent approach in detection and classification of transmission line faults,” *Int. J. Electr. Power Energy Syst.*, vol. 133, no. June, p. 107102, 2021, doi: 10.1016/j.ijepes.2021.107102.
- [14] S. Belagoune, N. Bali, A. Bakdi, B. Baadji, and K. Atif, “Deep learning through LSTM classification and regression for transmission line fault detection, diagnosis and location in large-scale multi-machine power systems,” *Meas. J. Int. Meas. Confed.*, vol. 177, no. December 2020, p. 109330, 2021, doi: 10.1016/j.measurement.2021.109330.
- [15] F. Rafique, L. Fu, and R. Mai, “End to end machine learning for fault detection and classification in power transmission lines,” *Electr. Power Syst. Res.*, vol. 199, no. June, p. 107430, 2021, doi: 10.1016/j.epsr.2021.107430.
- [16] A. Jain, A. Thoke, and R. Patel, “Fault classification of double circuit transmission line using artificial neural network,” *Int. J. Electr. ...*, pp. 1029–1034, 2008, [Online]. Available: <https://waset.org/journals/waset/v22/v22-149.pdf>.
- [17] E. Phyo Thwe, “Fault Detection and Classification for Transmission Line Protection System Using Artificial Neural Network,” *J. Electr. Electron. Eng.*, vol. 4, no. 5, p. 89, 2016, doi: 10.11648/j.jeee.20160405.11.
- [18] A. Yadav and Y. Dash, “An Overview of Transmission Line Protection by Artificial Neural Network: Fault Detection, Fault Classification, Fault Location, and Fault Direction Discrimination,” *Adv. Artif. Neural Syst.*, vol. 2014, pp. 1–20, 2014, doi:

10.1155/2014/230382.

- [19] A. Prasad, J. Belwin Edward, and K. Ravi, “A review on fault classification methodologies in power transmission systems: Part— I,” *J. Electr. Syst. Inf. Technol.*, vol. 5, no. 1, pp. 48–60, 2018, doi: 10.1016/j.jesit.2017.01.004.
- [20] D. Guillen *et al.*, “Fault detection and classification in transmission lines based on a PSD index,” *IET Gener. Transm. Distrib.*, vol. 12, no. 18, pp. 4070–4078, 2018, doi: 10.1049/iet-gtd.2018.5062.
- [21] E. B. M and T. O. A, “Transmission line faults detection, classification and location using artificial neural network,” *Proc. 2011 Int. Conf. Util. Exhib. Power Energy Syst. Issues Prospect. Asia, ICUE 2011*, pp. 1–5, 2012, doi: 10.1109/ICUEPES.2011.6497761.
- [22] S. V Khond and G. A. Dhokane, “Fault Classification Accuracy Measurement for a Distribution System with Artificial Neural Network without using Signal Processing Technique,” *Int. J. Innov. Technol. Explor. Eng.*, vol. 9, no. 3, pp. 1523–1527, 2020, doi: 10.35940/ijitee.c8558.019320.
- [23] T. Anil Kumar and T. Dinesh, “Fault detection and identification using levenberg machine learning algorithm,” *Int. J. Sci. Technol. Res.*, vol. 9, no. 1, pp. 1166–1169, 2020.
- [24] L. Jain, G. Tsihrintzis, and V. Balas, *Data Communication and Networks*, Primera ed. Poland: Springer, 2019.

## 7.1 Matriz de Estado del Arte

Tabla 7: Matriz de estado del arte.

CLASIFICACIÓN DE FALLAS ELÉCTRICAS APLICANDO REDES NEURONALES ARTIFICIALES A LA PROTECCIÓN DE DISTANCIA DE LÍNEAS DE TRANSMISIÓN BASADA EN EL ALGORITMO DE LEVENBERG-MARQUARDT																								
ITEM	DATOS			TEMÁTICA			FORMULACIÓN DEL PROBLEMA FUNCIONES OBJETIVO				RESTRICCIONES DEL PROBLEMA				PROPUESTAS PARA RESOLVER EL PROBLEMA				SOLUCIÓN PROPUESTA					
	AÑO	TÍTULO DEL ARTÍCULO	CITAS	DETECCIÓN DE FALLAS	UBICACIÓN DE LA FALLA	CLASIFICACIÓN DE FALLAS	VOLTAJES	CORRIENTES	VARIABLES BINARIAS	ENERGÍA DWT	TIPOS DE FALLAS	CANTIDAD DE DATOS DE VOLTAJES Y CORRIENTES	NÚMERO DE CAPAS DE ENTRADA	NÚMERO DE CAPAS DE SALIDA	FRECUENCIA	ANN	TRANSFORMADA DISCRETA DE WAVELET	RECONOCIMIENTO DE PATRONES	SISTEMA ADAPTATIVO DIFUSO	ANÁLISIS DE SECUENCIAS	TRANSFORMADA DE CLARKE	CLASIFICACIÓN DE TIPO DE FALLA	IDENTIFICACIÓN DE LA FALLA	UBICACIÓN DEL LUGAR DE LA FALLA
1	2018	Transmission Line Fault Classification Using Artificial Neural Network Based Fault	5	☒	☐	☒	☒	☒	☐	☒	☒	☐	☒	☒	☒	☒	☒	☐	☐	☐	☐	☒	☒	☐
2	2013	Faults Detection in Power Systems Using Artificial Neural Network	45	☒	☐	☒	☒	☒	☒	☐	☒	☐	☒	☒	☐	☒	☐	☐	☐	☐	☐	☒	☒	☐
3	2013	An ANFIS-based fault classification approach in power distribution system	79	☒	☒	☒	☐	☒	☒	☒	☐	☐	☒	☒	☐	☐	☐	☒	☐	☒	☒	☐	☐	
4	2016	Classification of power system faults using voltage Concordia pattern feature aided PNN	3	☒	☐	☒	☒	☒	☐	☐	☒	☒	☒	☐	☐	☐	☐	☒	☐	☐	☐	☒	☒	☐
5	2013	Transmission Line Faults Detection, Classification, and Location Using Discrete Wavelet Transform	48	☒	☐	☒	☒	☒	☐	☒	☒	☐	☒	☒	☒	☒	☒	☐	☐	☐	☐	☒	☒	☐
6	2014	Generalized neural network and wavelet transform based approach for fault location estimation of a transmission line	81	☒	☐	☒	☒	☒	☒	☐	☒	☐	☒	☒	☐	☒	☐	☐	☐	☐	☐	☒	☒	☐
7	2015	Fault detection and classification in electrical power transmission system using artificial neural network	113	☒	☐	☒	☒	☒	☐	☒	☒	☐	☒	☒	☒	☒	☒	☐	☐	☐	☐	☒	☒	☐

## CLASIFICACIÓN DE FALLAS ELÉCTRICAS APLICANDO REDES NEURONALES ARTIFICIALES A LA PROTECCIÓN DE DISTANCIA DE LÍNEAS DE TRANSMISIÓN BASADA EN EL ALGORITMO DE LEVENBERG-MARQUARDT

ITEM	DATOS			TEMÁTICA		FORMULACIÓN DEL PROBLEMA FUNCIONES OBJETIVO				RESTRICCIONES DEL PROBLEMA				PROPUESTAS PARA RESOLVER EL PROBLEMA				SOLUCIÓN PROPUESTA						
	AÑO	TÍTULO DEL ARTÍCULO	CITAS	DETECCIÓN DE FALLAS	UBICACIÓN DE LA FALLA	CLASIFICACIÓN DE FALLAS	VOLTAJES	CORRIENTES	VARIABLES BINARIAS	ENERGÍA DWT	TIPOS DE FALLAS	CANTIDAD DE DATOS DE VOLTAJES Y CORRIENTES	NÚMERO DE CAPAS DE ENTRADA	NÚMERO DE CAPAS DE SALIDA	FRECUENCIA	ANN	TRANSFORMADA DISCRETA DE WAVELET	RECONOCIMIENTO DE PATRONES	SISTEMA ADAPTATIVO DIFUSO	ANÁLISIS DE SECUENCIAS	TRANSFORMADA DE CLARKE	CLASIFICACIÓN DE TIPO DE FALLA	IDENTIFICACIÓN DE LA FALLA	UBICACIÓN DEL LUGAR DE LA FALLA
8	2016	Fault Classification using Artificial Neural Network in Combined Underground Cable and Overhead Line	12	☒	☐	☒	☒	☒	☐	☒	☒	☐	☐	☐	☒	☐	☐	☐	☐	☒	☐	☒	☒	☐
9	2003	Fault detection, classification and location in transmission line systems using neural networks	8	☒	☒	☒	☐	☒	☒	☒	☐	☐	☒	☒	☐	☒	☐	☐	☐	☐	☐	☒	☒	☒
10	2018	Algorithm for fault location and classification on parallel transmission line using wavelet based on Clarke's transformation	14	☒	☒	☒	☒	☒	☒	☐	☒	☐	☐	☐	☒	☐	☒	☐	☐	☐	☒	☒	☒	☒
11	2021	Phase angle-based fault detection and classification for protection of transmission lines	2	☒	☐	☒	☒	☒	☐	☐	☒	☐	☐	☐	☐	☐	☒	☐	☐	☒	☐	☒	☒	☐
12	2021	Fault location determination in three-terminal transmission lines connected to industrial microgrids without requiring fault classification data and independent of line parameters	3	☒	☒	☐	☒	☒	☐	☐	☒	☒	☒	☒	☐	☐	☒	☐	☐	☒	☐	☒	☒	☐
13	2021	A deep learning based intelligent approach in detection and classification of transmission line faults,	6	☒	☐	☒	☒	☒	☐	☐	☒	☐	☐	☐	☐	☐	☒	☐	☐	☒	☐	☒	☒	☐
14	2021	Deep learning through LSTM classification and regression for transmission line fault detection, diagnosis and location in large-scale multi-machine power systems	8	☒	☐	☒	☒	☒	☐	☒	☒	☐	☒	☒	☒	☒	☒	☐	☐	☐	☐	☒	☒	☐
15	2021	End to end machine learning for fault detection and classification in power transmission lines,	2	☒	☐	☒	☒	☒	☐	☐	☒	☐	☐	☐	☐	☐	☒	☐	☐	☒	☐	☒	☒	☐
16	2008	Fault classification of double circuit transmission line using artificial neural network	65	☒	☐	☒	☒	☒	☐	☒	☒	☐	☒	☒	☒	☒	☒	☐	☐	☐	☐	☒	☒	☐

## CLASIFICACIÓN DE FALLAS ELÉCTRICAS APLICANDO REDES NEURONALES ARTIFICIALES A LA PROTECCIÓN DE DISTANCIA DE LÍNEAS DE TRANSMISIÓN BASADA EN EL ALGORITMO DE LEVENBERG-MARQUARDT

ITEM	DATOS			TEMÁTICA		FORMULACIÓN DEL PROBLEMA FUNCIONES OBJETIVO				RESTRICCIONES DEL PROBLEMA				PROPUESTAS PARA RESOLVER EL PROBLEMA				SOLUCIÓN PROPUESTA						
	AÑO	TÍTULO DEL ARTÍCULO	CITAS	DETECCIÓN DE FALLAS	UBICACIÓN DE LA FALLA	CLASIFICACIÓN DE FALLAS	VOLTAJES	CORRIENTES	VARIABLES BINARIAS	ENERGÍA DWT	TIPOS DE FALLAS	CANTIDAD DE DATOS DE VOLTAJES Y CORRIENTES	NÚMERO DE CAPAS DE ENTRADA	NÚMERO DE CAPAS DE SALIDA	FRECUENCIA	ANN	TRANSFORMADA DISCRETA DE WAVELET	RECONOCIMIENTO DE PATRONES	SISTEMA ADAPTATIVO DIFUSO	ANÁLISIS DE SECUENCIAS	TRANSFORMADA DE CLARKE	CLASIFICACIÓN DE TIPO DE FALLA	IDENTIFICACIÓN DE LA FALLA	UBICACIÓN DEL LUGAR DE LA FALLA
17	2016	Fault Detection and Classification for Transmission Line Protection System Using Artificial Neural Network,	24	☒	☐	☒	☒	☒	☐	☒	☐	☒	☒	☐	☒	☐	☐	☐	☐	☐	☐	☒	☒	☐
18	2014	An Overview of Transmission Line Protection by Artificial Neural Network: Fault Detection, Fault Classification, Fault Location, and Fault Direction Discrimination	72	☒	☒	☒	☐	☒	☒	☒	☐	☐	☒	☒	☐	☐	☐	☒	☐	☐	☒	☐	☐	
19	2018	A review on fault classification methodologies in power transmission systems: Part—I	66	☒	☐	☒	☒	☒	☐	☒	☐	☒	☒	☒	☒	☒	☐	☐	☐	☐	☐	☒	☒	☐
20	2018	Fault detection and classification in transmission lines based on a PSD index	18	☒	☐	☒	☒	☒	☐	☒	☐	☒	☒	☐	☒	☐	☐	☐	☐	☐	☐	☒	☒	☐
21	2011	Transmission line faults detection, classification and location using artificial neural network	65	☒	☐	☒	☒	☒	☐	☒	☐	☒	☒	☒	☒	☒	☐	☐	☐	☐	☐	☒	☒	☐
22	2020	Fault Classification Accuracy Measurement for a Distribution System with Artificial Neural Network without using Signal Processing Technique	2	☒	☐	☒	☒	☒	☐	☒	☐	☒	☒	☒	☒	☒	☐	☐	☐	☐	☐	☒	☒	☐
23	2020	Fault detection and identification using levenberg machine learning algorithm	3	☒	☐	☒	☒	☒	☐	☒	☐	☒	☒	☐	☒	☐	☐	☐	☐	☐	☐	☒	☒	☐
24	2019	Fault Classification in a Transmission Line Using Levenberg–Marquardt Algorithm Based Artificial Neural Network	7	☒	☐	☒	☒	☒	☐	☒	☐	☒	☒	☐	☒	☐	☐	☐	☐	☐	☐	☒	☒	☐
<b>CANTIDAD</b>				8	1	8	7	8	5	4	7	0	8	8	3	7	3	0	1	0	1	8	7	0

## 7.2 Resumen de Indicadores




Figura 13. Resumen e indicador de la temática - Estado del arte.

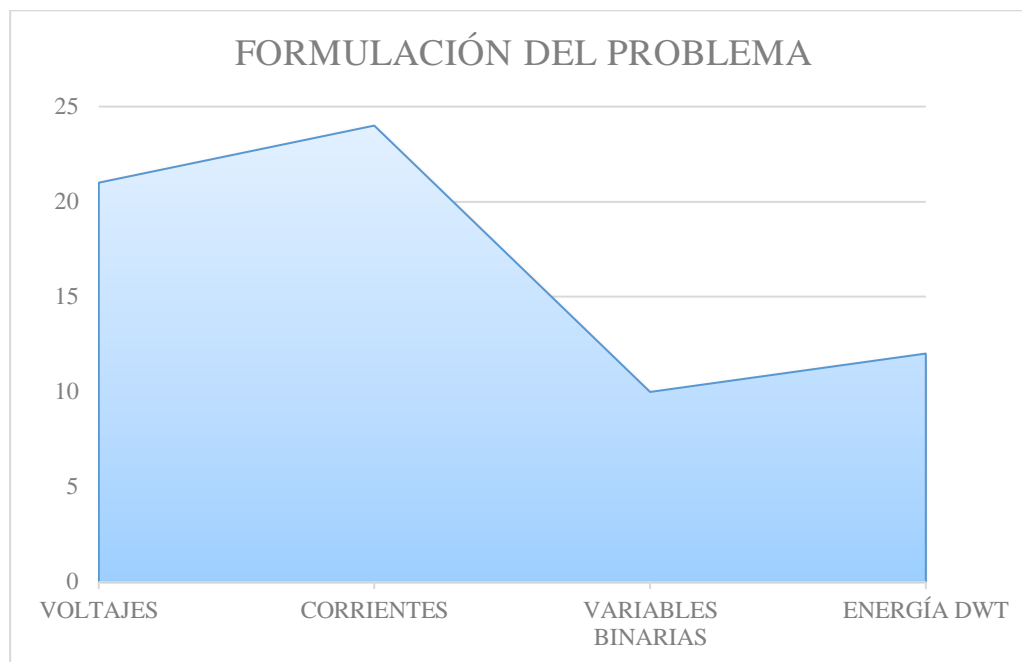


Figura 14. Indicador de formulación del problema - Estado del arte.




Figura 15. Indicador de solución - Estado del arte.