

**APLICACIÓN DE LA TRANSFORMADA DE
STOCKWELL PARA LA DETECCIÓN Y
CLASIFICACIÓN DE FALLAS EN LÍNEAS DE
TRANSMISIÓN**



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

**APLICACIÓN DE LA TRANSFORMADA DE
STOCKWELL PARA LA DETECCIÓN Y
CLASIFICACIÓN DE FALLAS EN LÍNEAS DE
TRANSMISIÓN**

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

AUTOR: DAVID ANTONIO AMAGUA TUETA

TUTOR: ROGELIO ALFREDO ORIZONDO MARTÍNEZ

Quito -Ecuador

2023

David Antonio Amagua Tucta

APLICACIÓN DE LA TRANSFORMADA DE STOCKWELL PARA DETECCIÓN Y CLASIFICACIÓN DE FALLAS EN LÍNEAS DE TRANSMISIÓN.

Universidad Politécnica Salesiana, Quito – Ecuador 2023

Carrera de Electricidad

Breve reseña histórica e información de contacto.



David Antonio Amagua Tucta (Y'1993 – M'01). Realizó sus estudios de nivel secundario en el Colegio Nacional “Instituto Tecnológico Superior Central Técnico” de la ciudad de Quito. Egresado de Ingeniería Eléctrica de la Universidad Politécnica Salesiana. Su trabajo de investigación se basa la Aplicación de la transformada de Stockwell para la detección y clasificación de fallas en líneas de transmisión. damagua@est.ups.edu.ec

Dirigido por:



Rogelio Alfredo Orizondo Martínez (Y'1972 – M'1). Nació en Caracas, Venezuela. Recibió su título en Ingeniería Eléctrica por la Universidad Simón Bolívar en 1999 y el MSc. en la Universidad Simón Bolívar en 2006. Actualmente es docente en la Universidad Politécnica Salesiana. Sus áreas de investigación incluyen electrónica de potencia, especialmente FACTS, sistemas de puesta a tierra y protección catódica. rorizondo@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, David Antonio Amagua Tuca con documento de identificación N° 1718811399 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, 27 de octubre del año 2023

Atentamente,

A handwritten signature in blue ink that reads "David Amagua". The signature is written in a cursive style with a horizontal line extending to the right.

David Antonio Amagua Tuca
1718811399

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

Yo, David Antonio Amagua Tucta con documento de identificación No. 1718811399, 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: “Aplicación de la Transformada de Stockwell para Detección y Clasificación de Fallas en Líneas de Transmisión”, la 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, 27 de octubre del año 2023

Atentamente,

A handwritten signature in blue ink that reads "David Amagua". The signature is written in a cursive style and is positioned above a horizontal dashed line.

David Antonio Amagua Tucta

1718811399

CERTIFICADO DE DIRECCIÓN DEL TRABAJO DE TITULACIÓN

Yo, Rogelio Alfredo Orizondo Martínez con documento de identificación N° 1757424195, docente de la Universidad Politécnica Salesiana, declaro que bajo mi tutoría fue desarrollado el trabajo de titulación: APLICACIÓN DE LA TRANSFORMADA DE STOCKWELL PARA LA DETECCIÓN Y CLASIFICACIÓN DE FALLAS EN LÍNEAS DE TRANSMISIÓN, realizado por David Antonio Amagua Tuca con documento de identificación N° 1718811399, 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, 27 de octubre del año 2023

Atentamente,



Ing. Rogelio Alfredo Orizondo Martínez, MSc
1757424195

ÍNDICE GENERAL

1	Introducción	2
2	Marco teórico	5
2.1	Falencias en la red de transmisión.....	5
2.2	Enfoque de red neuronal artificial (ANN).....	5
2.3	Transformada de Stockwell	7
2.4	Clasificación de fallas con ST y ANN.....	8
3	Formulación del problema	8
3.1	Base de datos para la ANN.....	9
4	Análisis de resultados.....	11
4.1	Caracterización de fallas para el Sistema IEEE de 9 barras	12
4.2	Caracterización de fallas para el Sistema IEEE de 14 barras	14
5	Conclusiones	16
5.1	Trabajos futuros	17
6	Referencias	17
6.1	Matriz de Estado del Arte.....	21
6.2	Resumen de Indicadores	27

ÍNDICE DE FIGURAS

Figura 1. Técnica para la clasificación de fallas	3
Figura 2. Neurona multi entrada.	6
Figura 3. Perceptrón de tres capas.....	6
Figura 4. Procedimiento para clasificación de fallas.....	9
Figura 5. Arquitectura de técnica de clasificación de fallas.....	9
Figura 6. Sistema IEEE de 9 barras.....	10
Figura 7. Sistema IEEE de 14 barras.....	10
Figura 8. Rendimiento de ANN para el Sistema IEEE de 9 barras.....	11
Figura 9. Rendimiento de ANN para el Sistema IEEE de 14 barras.....	12
Figura 10. ST de voltaje en fase B previo a la falla en el Sistema IEEE de 9 barras.....	12
Figura 11. ST de corriente en fase B previo a la en el Sistema IEEE de 9 barras.	12
Figura 12. ST de voltaje en fase B posterior a la falla en el Sistema IEEE de 9 barras.....	13
Figura 13. ST de corriente en fase B posterior a la falla en el Sistema IEEE de 9 barras.	13
Figura 14. Señal de voltaje en el Sistema IEEE de 9 barras.	13
Figura 15. Señal de corriente en el Sistema IEEE de 9 barras.	13
Figura 16. Clasificador de fallas con ANN.	14
Figura 17. ST de voltaje en fase B previo a la falla en el Sistema IEEE de 14 barras.....	14
Figura 18. ST de corriente en fase B previo a la falla en el Sistema IEEE de 14 barras.	14
Figura 19. ST de voltaje en fase B posterior a la falla en el Sistema IEEE de 14 barras.....	15
Figura 20. ST de corriente en fase B posterior a la falla en el Sistema IEEE de 14 barras. ...	15
Figura 21. Señal de voltaje en el Sistema IEEE de 14 barras.	15
Figura 22. Señal de corriente en el Sistema IEEE de 14 barras.	15
Figura 23. Clasificador de fallas con ANN en el Sistema IEEE de 14 barras.	16
Figura 24. Resumen e indicador de la temática - Estado del arte.	27
Figura 25. Indicador de formulación del problema - Estado del arte.....	27
Figura 26. Indicador de solución al problema - Estado del arte.....	27

ÍNDICE DE TABLAS

Tabla 1. Lógica de clasificación de fallas.	9
Tabla 2. Casos de estudio para la ANN con ST	12
Tabla 3. Resultados de clasificador de fallas para sistema IEEE de 9 barras	14
Tabla 4. Resultados del clasificador de fallas para el Sistema IEEE de 14 barras.....	16
Tabla 5. Resultados de clasificador de fallas para sistema IEEE de 14 barras	16
Tabla 6: Matriz de estado del arte.	21

APLICACIÓN DE LA TRANSFORMADA DE STOCKWELL PARA LA DETECCIÓN Y CLASIFICACIÓN DE FALLAS EN LÍNEAS DE TRANSMISIÓN

Resumen

En esta investigación se propone un método para detectar diferentes tipos de falla en el sistema de transmisión. Para lo cual, se emplea la técnica de procesamiento de señales como la transformada de Stockwell (ST) y una red neuronal artificial (ANN) como técnica de aprendizaje no supervisado. En este contexto, la ST se emplea para el análisis tiempo - frecuencia de las señales de voltaje y corriente resultantes del estudio de cortocircuito. Con estas se crea una base de datos que sirve para el entrenamiento, validación y prueba de la ANN, de tal forma que se crea un predictor para identificar y clasificar las fallas en tiempo real.

El rendimiento de la metodología propuesta se comprueba en los sistemas IEEE de 9 y 14 barras. Asimismo, los resultados obtenidos se comparan con la clasificación de fallas en base a la transformada de wavelet. De esta forma, se comprueba que la ST es superior a la transformada de wavelet. Además, la ANN presenta una efectividad del 98% con un 2% de error en la clasificación de fallas.

Palabras Clave: Transformada ST, análisis tiempo-frecuencia, algoritmo de clasificación de fallas, red neuronal artificial, detección de fallas

Abstract

In this research, a method to detect different types of faults in the transmission system is proposed. For this purpose, a signal processing technique such as the Stockwell Transform (ST) and an artificial neural network (ANN) are used as an unsupervised learning technique. In this context, the ST is used for the frequency-time analysis of the current, voltage signals resulting from the short-circuit study. These signals are used to create a database for training, validation and testing of the ANN, so that a predictor is created to identify and classify faults in real time.

The performance of the proposed methodology is tested on IEEE 9-bar and 14-bar systems. Also, the obtained results are compared with the fault classification based on the wavelet transform. In this way, it was found that the TS is superior to the wavelet transform. In addition, the ANN presents an effectiveness of 98% with a 2% error in fault classification.

Keywords: ST-transform, time-frequency analysis, fault classification algorithm, artificial neural network, fault detection.

1 Introducción

La agrupación de varios elementos que interactúan entre sí de forma dinámica como generadores, líneas de transmisión y transformadores, se denomina Sistema eléctrico de Potencia (SEP). Por consiguiente, existe la posibilidad que se originen perturbaciones o fallas eléctricas.

En este contexto, una falla eléctrica se entiende como un evento que altera el funcionamiento normal del sistema. Las causas que originan estas fallas son de diversa índole, entre las que se ubican, el funcionamiento incorrecto de los equipos, condiciones meteorológicas adversas, sobrecarga del SEP, errores humanos y los cambios bruscos de señal. Como consecuencia de los fallos, el SEP puede colapsar y generar apagones graves, que implican pérdidas económicas y humanas [1].

En el sistema de transmisión, existen dos tipos de fallas, que son fallas en serie (conductor abierto) y derivación (cortocircuito). En este sentido, las fallas en serie se identifican por medio de la cuantificación de la tensión monofásica, de tal forma que, si la magnitud de la tensión aumenta, significa que se ha producido una falla en el conductor abierto. Además, estas se subclasifican en dos tipos, conductor abierto simple y doble. Asimismo, la frecuencia de ocurrencia de este tipo de fallas es muy baja [2].

En otro sentido, las fallas en derivación se distinguen mediante la observación de la corriente de las fases individuales. De tal forma que, si los valores de la corriente aumentan, indica que se ha producido un cortocircuito. Asimismo, estas se segmentan en dos, fallas asimétricas y simétricas [3]. En el primer tipo existen algunas fallas, como la fase bifásica a tierra (LLN), doble fase (LL) y fase simple a tierra (LN), mientras que, en el segundo grupo se ubican, las fallas de tres fases a tierra (LLLN) y tres fases (LLL) [4].

En contraste, es evidente que las líneas de transmisión son una parte esencial para garantizar el suministro eléctrico. En este contexto, cuando se detecta una avería, el relé de protección debe responder de forma rápida para aislar la línea averiada y preservar la estabilidad del resto del sistema. En este sentido, se necesita una estimación precisa de la localización de la falla para la inspección, el mantenimiento y la reparación de la avería real. Por lo tanto, la identificación y clasificación de fallas son temas muy importantes que se deben analizar [5]. dicho diagnóstico de fallas, en los sistemas de energía incluye la detección del origen temporal, la clasificación y localización del evento ocurrido en estos sistemas. Asimismo, el restablecimiento de los equipos defectuosos se debe realizar en forma pronta y eficaz, para que, se estimule la investigación en sistemas de diagnóstico y clasificación de fallas [6].

En contraste, en el SEP existen algunas oscilaciones de potencia, que afectan a las formas de onda de corrientes y tensiones, puesto que, estas se comportan de forma similar a las ondas de una avería, lo cual, produce un mal funcionamiento de los relés de distancia [7]. En este sentido, existen diversas técnicas que se emplean para procesar señales, entre las que se incluyen, la transformada de wavelet (WT), lógica difusa, transformada de Stockwell (ST) y redes neuronales. Estas contribuyen para detectar y clasificar fallas en el SEP [8].

En contraste, para solventar el problema de la identificación y diagnóstico de fallas, para su posterior clasificación, en el SEP, existen varias investigaciones que abordan este problema desde diferentes perspectivas, las cuales se detallan a continuación.

En [9], los autores realizan una exploración exhaustiva sobre las técnicas que se emplean para la localización, detección y clasificación de fallas. Dentro de este marco, el primer paso consiste, el muestro de las señales de corriente y

voltaje. Luego, estos puntos pasan al módulo de erradicación de características, el cual, se encarga de obtener las características utilizadas por el detector, clasificador y el localizador de fallas. Para obtener a la salida, el tipo de falla, la localización proporcionada por el clasificador de fallos y la ubicación de fallos, respectivamente.




Figura 1. Sistemas Eléctricos de Potencia.

En la investigación propuesta en [10] se presenta un algoritmo para identificar, clasificar, y discriminar fallas en el SEP. Para lo cual, se emplea la información de ondas de alta frecuencia (ondas viajeras), junto con el análisis de la transformada Wavelet y dos tipos de arquitecturas de redes neuronales, redes neuronales de base radial y redes neuronales probabilísticas. Además, los tipos de fallas que se consideran para la detección son: una fase a tierra (AN, BN, CN), doble fase a tierra (ABC, BCN, CAN), bifásicas (AB, BC, CA) y trifásica a tierra (ABCN).

En el estudio [11], se describe en detalle un método para determinar fallas de alta

impedancia. Para lo cual, se aplica la transformada de Stockwell con el fin de obtener las características de las señales de tensión, que se simulan bajo diversas situaciones de falla en la red eléctrica. En este sentido, los parámetros de las fallas de alta impedancia se ejecutan bajo diferentes valores de resistencia y ubicación. Asimismo, se analiza el efecto del ruido en las características extraídas mediante la transformada de Stockwell.

Por otro lado, en la investigación propuesta en [12] se expone un procedimiento híbrido para identificar, clasificar y ubicar fallas en el SEP. Para lo cual, se emplea métodos de aprendizaje automático. En primera instancia, se aplica la técnica de la Transformación Wavelet (WT) para visualizar las características de las ondas de tensión y corriente, mismas, que se descomponen en once coeficientes. Estos coeficientes se calculan por niveles de energía, y los datos de los tipos de fallas se convierten en una imagen RGB. En segundo lugar, se aplica el modelo GoogLeNet para clasificar la falla, y se emplea una red neuronal convolucional (CNN) para localizar la falla. En este sentido, se consideran valores aleatorios de resistencia de falla.

En [13], los autores exponen un procedimiento para la clasificación de fallas en el SEP. Para lo cual, se recaban las señales de corriente y tensión mediante simulaciones sobre un sistema de 14 barras. Estas se procesan mediante la técnica de la transformada multiresolución de Stockwell. En este contexto, la energía de las ondas de tensión y corriente se calculan mediante el teorema de Parseval, para distinguir los diversos tipos de fallos.

En [14], los investigadores exponen una estrategia que permite la detección de fallas en el SEP. Para lo cual, se consideran algunos tipos de fallas, entre los que se encuentran, LG, LL, LLG y LLLG, en presencia de carga resistiva. Las ondas de voltaje y corriente se emplean para la

extracción de características mediante la transformada de Stockwell. En este sentido, se realiza una simulación en seis ciclos, donde se descomponen las señales de tensión y corriente para las tres fases. Esto permite obtener la matriz S , para encontrar el contenido de frecuencia y la curva de varianza, las cuales, se utilizan para detectar y discriminar los distintos tipos de fallas del sistema eléctrico.

El trabajo de investigación propuesto en [15] detalla una metodología para la detección de diferentes tipos de fallas, como LL, LLG, LG y LLLG con generación de energía eólica. Para lo cual, se emplea la transformada de Stockwell basada en la mediana con generación de energía eólica, de tal forma que, se identifica la falla en ausencia de generación de energía renovable.

En el estudio descrito en [16] se propone una técnica híbrida para detectar y clasificar fallas en el sistema de transmisión. La técnica en mención combina la transformada de Stockwell con las redes neuronales multicapa. En este sentido, la ST permite extraer las características útiles de la señal de corriente y las envía a la red neuronal con la intención para detectar y clasificar dichas fallas en el sistema.

El estudio presentado en [17] describe una estrategia para identificar fallas en el SEP. Para lo cual, el estudio se basa en el enfoque del ángulo de fase. En este sentido, el cómputo de los ángulos de fase instantánea se obtiene a partir de las ondas de tensión y corriente. A su vez, estos se emplean para el cálculo de los índices de fase derivados y los índices medios de fase. Además, se investiga los efectos de la presencia de ruido, asimetría, armónicos y desequilibrio de fase en las señales de prueba cuando se trata de caracterizar una falla.

En la investigación propuesta en [18] se evalúa la precisión que ofrece la red neuronal para la búsqueda y clasificación de fallas, sin emplear un método de

procesamiento de señales. Para lo cual, se emplea las señales de tensión y corriente como entrada a una red neuronal de reconocimiento de patrones. En este sentido, los tipos de fallas que se consideran para la clasificación son: LG, LL y LLL.

En el estudio descrito en [19] se propone un enfoque para el rastreo y clasificación de fallas. Este consiste en el uso de dos técnicas, dicha transformada de wavelet discreta como la transformada de Clarke. En primera instancia, la transformada de Clarke se usa para convertir un sistema trifásico a uno bifásico, donde, el resultado se convierte en una transformada de wavelet discreta. De esta forma, se combina la descomposición de los modos de propagación de las ondas electromagnéticas empleando la transformada de Clarke para el procesamiento de señales, basada en la mayor amplitud de la onda, con el propósito de precisar los tiempos de intrusión.

En [20], los autores se formula un enfoque para la determinación, clasificación y posicionamiento de fallas en el dominio tiempo-frecuencia. Para lo cual, se cuantifica las señales de tensión y corriente, para luego aplicar la ST, de tal forma que, se obtiene la energía de cada señal para su posterior análisis con la lógica de clasificación.

En contraste, en este estudio se presenta una metodología, para la identificación y categorización de fallas en el SEP. Para lo cual, se aplica la transformada de Stockwell a las ondas de voltaje y corriente en el punto de afección, junto con una técnica de aprendizaje no supervisado. En primera instancia, se construye un conjunto de datos, donde se almacenan los resultados del máximo valor de la ST que pertenecen a las ondas de corriente, voltaje y secuencia cero, asimismo, estas son las entradas para la red neuronal. Por otro lado, las salidas se modelan mediante variables binarias, una por cada fase. Por último, se efectúa la ejecución de la red neuronal para obtener

los datos de clasificación y detección de fallas.

De aquí en adelante, la investigación se distribuye en cinco diferentes secciones, donde, la introducción se detalla en la primera sección. Asimismo, en el segundo apartado se elabora el marco teórico relacionado con la transformada de Stockwell y la red neuronal. Por otro lado, la formulación del problema se detalla en la sección tres, mientras que, en el cuarto epígrafe se analizan los resultados. Por último, en el quinto apartado se concluye la investigación y se presentan los trabajos futuros, así como, las referencias.

2 Marco teórico

En este apartado se detallan las definiciones, conceptos y teorías, que se requiere para el progreso de la estrategia de identificación y clasificación, de fallas en el SEP. En este sentido, se detallan los tipos de fallas, el enfoque de la red neuronal y la técnica de tiempo - frecuencia descrita por la ST. Asimismo, se analiza la lógica para la caracterización de fallas aplicando la ST y ANN.

2.1 Fallas en la red de transmisión

Las fallas eléctricas se refieren a un estado no deseado que ocurre entre dos fases o una fase y tierra. Es así como, un cortocircuito es la falla más riesgosa para el SEP, debido a que, las corrientes bajas y altas pueden originar sobrecalentamiento, así como, fuerzas mecánicas que desgastan al equipamiento. De tal forma que, a largo plazo esto puede afectar de forma negativa a los elementos y equipos del SEP. En este contexto, las fallas se dividen en tres categorías, que son: fallas de circuito abierto, asimétricas y simétricas [21].

Una falla simétrica se caracteriza por generar corrientes de 120 veces su valor nominal. Por ejemplo, en la falla trifásica se cortocircuitan las tres líneas, con o sin tierra. A su vez, las falencias de doble fase, monofásica y bifásica a tierra corresponden

al grupo de fallas simétricas, las cuales se detallan a continuación.

La falla monofásica a tierra (LG) corresponde a un cortocircuito entre cualquiera de los conductores de fase y la tierra, donde, la probabilidad de ocurrencia es del 70% al 80%. Además, entre las causas de ocurrencia se identifican, fallas de aislamiento y rotura o caída del conductor de fase al suelo [22].

Por otro lado, la falla de dos fases a tierra (LLG) se refiere a un cortocircuito entre dos líneas aleatorias y tierra, cuya probabilidad de ocurrencia se ubica alrededor del 10% al 17%. Asimismo, la falla de línea a línea (LL) corresponde a un cortocircuito entre dos fases cualquiera entre sí, donde, la probabilidad de ocurrencia es del 8% al 10%. Por último, la falla trifásica (LLL) se produce por un cortocircuito entre las tres fases del sistema, además, la probabilidad de ocurrencia es del 2% al 3% [23].

En contraste, ante un fallo, la línea de transmisión de energía se puede proteger mediante algunos elementos, como fusibles, relés de sobre corriente, relés de distancia, esquemas de protección piloto o un sistema híbrido de los anteriores. En este contexto, los fusibles y los relés de sobre corriente se utilizan para la protección de las líneas de distribución, debido a que, estos dispositivos son simples y económicos. Por otro lado, los relés de sobre corriente también son aplicables, cuando se trata de un componente de impedancia alta como un transformador. Las corrientes generadas, por una falla, en el extremo de carga de un transformador son considerablemente menores que las corrientes asociadas a una falla en el extremo de la generación. Por lo tanto, es evidente que los relés deben actuar de forma rápida y oportuna para aislar la falla [24].

2.2 Enfoque de red neuronal artificial (ANN)

La ANN posee una arquitectura inspirada biológicamente en las células

neuronal del cerebro humano, las cuales se describen como un conjunto de neuronas interconectadas y dispuestas en varias capas. En este sentido, la estructura de una ANN de propagación inversa o perceptrón posee un modelo matemático de una neurona. En la Figura 2 se presenta una neurona de entrada múltiple, asimismo, en la Figura 3 se ilustra un perceptrón de tres capas. Es así como, una neurona j se describe mediante la ecuación (1) [25].

$$f\left(\sum_{i=0}^{N_o} w_i * a_i\right) = f(\varphi) = y \quad (1)$$

De tal forma que, $w_i * a_i$ corresponde al valor umbral, $f(\varphi)$ pertenece a la función de accionamiento de la neurona, Φ se refiere a la señal de salida de la sumatoria e y es la salida de la neurona [26].




Figura 2. Neurona multi entrada.

$$\varphi = W^T * A \quad (2)$$

En este sentido, A y W corresponden a los vectores de entradas y pesos respectivamente. Los cuales se definen como $W = [w_0 w_1 w_2 \dots w_{N_o}]$ y $A = [a_0 a_1 a_2 \dots a_{N_o}]^T$.

Por otro lado, existen varias funciones de activación, como la función escalonada, lineal, sigmoide, unipolar y sigmoide bipolar. Una función de activación decide el efecto sobre la suma de las entradas en las

salidas. De esta forma, se elige la función de activación adecuada para obtener el mejor rendimiento [27].

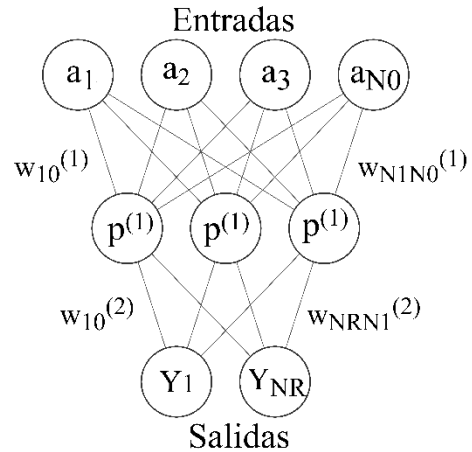


Figura 3. Perceptrón de tres capas.

Es así como, el funcionamiento básico de la ANN es encontrar la relación entre la matriz de entrada A , y el conjunto de datos representados por la matriz de destino Y , para lo cual, se determinan los pesos. Al principio, la ANN asume los valores iniciales de W y calcula el error entre las salidas y los objetivos, de tal forma que, se cambia los valores de W , hasta alcanzar el rendimiento de validación (MSE) adecuado [28].

En contraste, si la ANN cambia de forma continua los valores de W , el MSE aumenta. Por lo que, los valores de W con el menor MSE son los mejores y se guardan como valores finales de este. Además, la ANN puede predecir en el futuro cualquier salida, con nuevos datos de entrada. Asimismo, el algoritmo de aprendizaje retropropagación (Backpropagation) se emplea para entrenar el detector y clasificador de fallas [29]. En este contexto, el MSE se emplea para cuantificar el error y medir el rendimiento de la ANN. Asimismo, se utiliza la técnica de mínimos cuadrados amortiguados (Levenberg-Marquardt), para entrenar la ANN, que está diseñado para trabajar con funciones de pérdida considerando la suma de errores al cuadrado [30].

2.3 Transformada de Stockwell

Entre los métodos de procesamiento de señales, la técnica más popular es la transformada de Fourier (FT), la cual, permite el análisis de señales estacionarias. No obstante, la FT discreta y la continua proporcionan información errónea para las señales no estacionarias, lo cual, se debe a la pérdida de datos temporales, aunque estas contienen información de componentes espectrales [31]. En consecuencia, existen métodos avanzados de sucesión de señales, como la ST, transformada de wavelet (WT) y transformada de Fourier, de tiempo corto (STFT), que permiten el análisis eficaz de las señales no estacionarias [32]. Asimismo, la STFT emplea marcos de prospección fijos, que se ejecutan para el diagnóstico en tiempo-frecuencia, sin embargo, una mejor resolución de tiempo puede conducir a una peor resolución de frecuencia y viceversa. Por el contrario, la WT utiliza ventanas relativamente grandes en bajas frecuencias y pequeñas en frecuencias altas, que superan los problemas de resolución de la STFT y es muy eficaz para extraer información tanto en el dominio de la frecuencia como del tiempo. Sin embargo, la WT no posee datos de la fase para las señales procesadas, además, esta es sensible al ruido [33]. Es así como, para mantener la data, referente a la fase de las ondas no estacionarias, existe la transformada de Stockwell. Esta combina las ventajas de la STFT y la WT. La ST proporciona una descomposición tiempo - frecuencia detallada de las señales no estacionarias, las cuales, disponen de la data para la línea, así como, la frecuencia absolutamente referenciada [34]. La ST de una función dada $x(t)$ se representa mediante la Ecuación (3).

$$S(\tau, f) = S\{x(t)\} = \int_{-\infty}^{+\infty} x(t)w(\tau - t, f)e^{-j2\pi ft} dt \quad (3)$$

En este sentido, la $w(t, f) = \frac{|f|}{\sqrt{2\pi}} e^{-\frac{t^2 f^2}{2}}$ es la función de ventana gaussiana, t y τ son las variables temporales, y f es la frecuencia. En contraste, la ST descompone la señal $x(t)$ en componentes temporales y de frecuencia. Los coeficientes de la ST crean resoluciones completas para cada frecuencia designada y cubren todo el eje temporal seleccionando los posibles valores de τ , como τ se refiere al centro de la función ventana. Los tamaños de las ventanas gaussianas se ajustan mediante diferentes valores de f para realizar la multirresolución sobre diferentes frecuencias en el eje temporal. Es así como, en base a las aplicaciones, la ST aplica diferentes funciones de ventana como la gaussiana, bigaussiana e hiperbólica [35]. Asimismo, en el dominio de Fourier, la ecuación (3) se puede reescribir para dar forma a la Ecuación (4).

$$S(\tau, f) = \int_{-\infty}^{+\infty} X(\alpha + f) e^{-\frac{2\pi^2 \alpha^2}{f^2}} e^{j2\pi \alpha \tau} d\alpha \quad (4)$$

$f \neq 0$

Donde, $X(\alpha + f) = \int_{-\infty}^{+\infty} x(t)e^{-j2\pi(\alpha+f)t} dt$. Por otro lado, la serie temporal discreta de $x(t)$ denotada por $x[kT]$, $k = 0, 1, 2, \dots, N - 1$ con un intervalo de muestreo de tiempo de T . Con lo cual, la FT discreta se representa mediante la Ecuación (5).

$$X\left[\frac{n}{NT}\right] = \frac{1}{N} \sum_{k=0}^{N-1} x[kT] e^{j\frac{2\pi nk}{N}} \quad (5)$$

Empleando las ecuaciones antes descritas y considerando $\tau = pT$ y $f = \frac{n}{NT}$, la ST de la $x[kT]$ discreta se describe mediante la Ecuación (6).

$$S\left[pT, \frac{n}{NT}\right] = \quad (6)$$

$$\sum_{m=0}^{N-1} X \left[\frac{m+n}{NT} \right] e^{-\frac{2\pi^2 m^2}{n^2}} e^{\frac{j2\pi mp}{N}}$$

$n \neq 0$

En este contexto, $m, n, p = 0, 1, 2 \dots, N-1$ y N es el número total de muestras. Por otro lado, la inversa discreta de la ST se calcula mediante la Ecuación (7).

$$\sum_{n=0}^{N-1} \left\{ \frac{1}{N} \sum_{p=0}^{N-1} S \left[pT, \frac{n}{NT} \right] \right\} e^{-\frac{j2\pi nk}{N}} \quad (7)$$

La salida de la ST es una matriz $N \times M$, la cual, se conoce como matriz S , donde, sus columnas corresponden al tiempo y las filas a la frecuencia. Los elementos de la matriz S son números complejos, no obstante, la matriz de energía de la señal $x(t)$ se puede calcular mediante la Ecuación (8) a partir de la matriz S [36].

$$E_{MXN} = |S_{MXN}|^2 \quad (8)$$

2.4 Clasificación de fallas con ST y ANN

En la actualidad, la tecnología digital influye de forma significativa en el funcionamiento de los relés, lo cual, posibilita mejoras sustanciales a comparación de los relés electromagnéticos convencionales. Un ejemplo de esto son las ANN que permiten identificar y clasificar fallas en tiempo real. En este sentido, para emplear la ANN se requiere tres conjuntos de datos, los cuales, corresponden a la información necesaria para el entrenamiento, validación y testeo. De tal forma que, para obtener la base de datos es necesario simular una falla, para cuantificar las ondas de voltaje y corriente en su punto de origen. Luego, con las ondas resultantes, se aplica un sistema, basado en la ST, para procesar ondas. Esta técnica permite extraer información esencial de las ondas en tiempo – frecuencia. En este sentido, la

información recabada se almacena de forma ordenada para su posterior uso con la ANN. Es así como, se presenta un diagrama (Figura 4) que explica el procedimiento necesario para la caracterización de fallas en el SEP, empleando la ST y una ANN.

3 Formulación del problema

En un SEP, el mayor inconveniente que puede afectar a la continuidad de la energía son las fallas. En este contexto, es imprescindible contar un mecanismo de protección correctamente consolidado, que permita identificar y aislar, de modo efectivo, las fallas del sistema. De esta manera se minimizan los daños y el mal funcionamiento del sistema eléctrico. No obstante, al existir una cifra importante de posibles fallas que pueden ocurrir en el sistema, es necesario adoptar un método que contribuya con la detección oportuna para la identificación de fallas. De manera que, el operador del sistema pueda actuar en tiempo adecuado.

Por lo tanto, en esta investigación se presenta una ANN basada en dicha ST como técnica de procesamiento de las señales señaladas, para lograr una identificación y caracterización de fallas en el SEP de forma efectiva.

En contraste, los parámetros importantes para efectuar la clasificación de fallas son: voltajes y corrientes de fase, así como, secuencia cero. Estas señales se analizan en el dominio de tiempo – frecuencia para obtener el valor máximo de la matriz S descrita por la ST, es decir que, se obtiene un total de 8 entradas. Por otro lado, se considera a cada fase como una variable binaria, es decir que, se requiere 4 variables binarias para representar las fases ABC y el neutro N. Asimismo, la estructura general de la ANN (Figura 5) consta de 8 neuronas en ingreso; 6 para la capa oculta y 4 para la de salida. Por lo que, mediante la arquitectura descrita es posible detectar y clasificar 9 tipos de fallas (Tabla 1).




Figura 4. Procedimiento para clasificación de fallas.

Tabla 1. Lógica de clasificación de fallas.

Falla tipo	Salida de la ANN			
	A	B	C	N
AN	1	0	0	1
BN	0	1	0	1
CN	0	0	1	1
AB	1	1	0	0
BC	0	1	1	0
CA	1	0	1	0
ABN	1	1	0	1
BCN	0	1	1	1
CAN	1	0	1	1

3.1 Base de datos para la ANN

Para aplicar la técnica de aprendizaje no supervisado es necesario generar una base de datos con las señales variantes de entrada y las salidas esperadas en la ANN. Lo cual se logra mediante ejecución iterativas de estudios de cortocircuito de diversos tipos, en los esquemas de ensayo IEEE de 9 (Figura 6) y 14 (Figura 7) barras. En este contexto, se varían algunos parámetros, como la resistencia y localización de la falla. La primera variable se modela 20 veces, desde 0.01 hasta 95 en pasos de 5, para cada tipo de falla, es decir que, se tiene un total de 180 (20*9) ejecuciones. Por otro lado, la segunda variable se modela 19 veces, desde 10 hasta 190 en pasos de 10, para cada tipo de falla, es decir que, se obtiene 171 (19*9) ejecuciones. En resumen, la base de datos se compone del valor máximo de la transformada S, descrita por la ST, para las señales de corriente y tensión que se obtienen de los 351 estudios de cortocircuito.

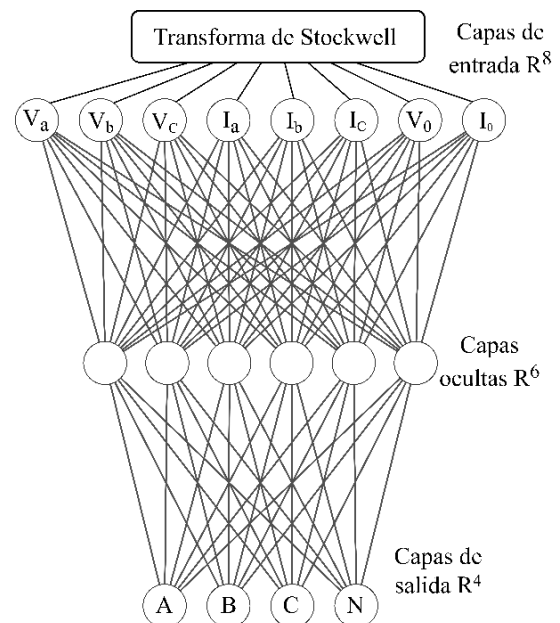


Figura 5. Arquitectura de técnica de clasificación de fallas.




Figura 6. Sistema IEEE de 9 barras.

Algoritmo 2. Construcción y generación del conjunto de información

- Paso 1 Introducir los factores de falla como: resistencia, clase y distancia de falla.
- Paso 2 Realizar el estudio de cortocircuito
- Paso 3 Cuantificar las ondas de voltaje y corriente.
- Paso 4 Emplear el algoritmo 1, para calcular la transformada de ST.
- Paso 5 Crear arreglo matricial con los valores obtenidos

$$[V_a V_b V_c I_a I_b I_c V_0 I_0]$$
- Paso 6 Asociar los resultados de la ST con el tipo de falla binario

$$[V_a V_b V_c I_a I_b I_c V_0 I_0]$$

$$[A B C N]$$
- Paso 7 Almacenar los valores de la ST y el tipo de falla en base de datos.
- Paso 8 Volver al paso 1




Figura 7. Sistema IEEE de 14 barras.

Por último, se presentan los algoritmos que se emplean, para el cálculo de la ST, la generación y construcción del conjunto de información, el entrenamiento de la ANN y la clasificación de fallas.

Algoritmo 1. Cálculo de la transformada de Stockwell

- Paso 1 Ejecutar el estudio de cortocircuito.
- Paso 2 Cuantificar las ondas de voltaje y corriente.
- Paso 3 Definir la ventana gaussiana para análisis.

$$S(\tau, f) = S\{x(t)\} = \int_{-\infty}^{+\infty} x(t)w(\tau - t, f)e^{-j2\pi ft} dt$$

- Paso 4 Calcular la transformada de ST para las señales de voltaje y corriente.

$$S\left[pT, \frac{n}{NT}\right] = \sum_{m=0}^{N-1} X\left[\frac{m+n}{NT}\right] e^{-\frac{2\pi^2 m^2}{n^2}} e^{\frac{j2\pi mp}{N}}$$

$$n \neq 0$$

- Paso 5 Calcular la energía de la matriz compleja S

$$E_{MXN} = |S_{MXN}|^2$$

- Paso 6 Extraer el valor máximo de la matriz de energía E_{MXN}
- $$\max(E_{MXN})$$

- Paso 7 Volver al paso 1

Algoritmo 3. Proceso de entrenamiento de la ANN

- Paso 1 Cargar a MATLAB la base de datos creada con el algoritmo 2.
- Paso 2 Ejecutar la herramienta Neural Network Fitting de MATLAB.
- Paso 3 Seleccionar los valores que corresponde a la transformada de Stockwell y el tipo de falla como datos de entrada y salida de la ANN respectivamente.
- Paso 4 disociar los datos de entrada en 3. Para su entrenamiento 70%. 15% corresponde a la validación Para pruebas, el 15 %
- Paso 5 Establecer la arquitectura de la ANN que distribuye las neuronas de la siguiente forma:

	Entrada: 8 Capa oculta: 6 Salida: 4
Paso 6	Entrenar la ANN mediante la técnica de mínimos cuadrados amortiguados
Paso 7	Graficar los diagramas de la ANN Condición de entrenamiento Rendimiento en cada iteración Error de histograma

Algoritmo 4. Caracterización de fallas	
Paso 1	Introducir los factores de falla como: resistencia, tipo y distancia de falla.
Paso 2	Ejecutar el cortocircuito
Paso 3	Cuantificar las ondas de voltaje y corriente.
Paso 4	Emplear el algoritmo 1, para calcular la transformada de ST.
Paso 5	Ingresar los resultados de la transformada de ST, al predictor de la ANN
Paso 6	Predecir el tipo de falla mediante la lógica de la ANN Hacer para todo N_o
	$f\left(\sum_{i=0}^o w_i * a_i\right) = f(\varphi) = y$
Paso 7	Representar los resultados de la clase de falla
Paso 8	Retorno al paso 1

4 Análisis de resultados

Para analizar el rendimiento de la técnica de procesamiento de señales ST y la ANN, se procede a realizar simulaciones sobre los archivos de pruebas de sistema de 9 y 14 barras (IEEE). Para lo cual, se analiza el rendimiento de la ANN, donde se detalla la efectividad en la fase de entrenamiento, validación y examen, como se presenta en la Figura 8.

La precisión asociada a los datos de entrenamiento es del 97% (Figura 8), es decir que, un 3% corresponde a detección y clasificación de fallas de forma errónea. Asimismo, los datos de validación

presentan una efectividad del 97%, con un 3% de detecciones erróneas. Por otro lado, los datos de prueba describen un 98% de efectividad, junto con un 2% de detecciones erróneas. Es así como, el rendimiento general de la ANN basado en la técnica de procesamiento de señales ST, para el Sistema IEEE de 9 barras, presenta una efectividad general del 97%.

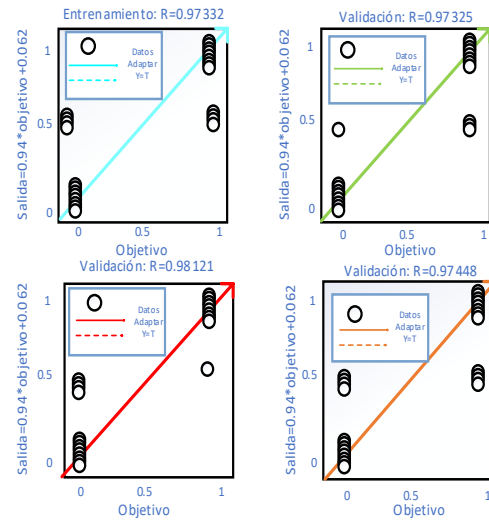


Figura 8. Rendimiento de ANN para el Sistema IEEE de 9 barras (IEEE).

Por otro lado, en la Figura 9 se muestra las métricas de la ANN para el Sistema IEEE de 14 barras. En este se observa que la precisión asociada a los datos de entrenamiento es del 97%, es decir que, un 3% corresponde a detección y clasificación de fallas de forma errónea. Asimismo, los datos de validación presentan una efectividad del 97%, con un 3% de detecciones erróneas. Además, los datos de prueba describen un 98% de efectividad, junto con un 2% de detecciones erróneas. Es así como, el rendimiento general de la ANN basado en la técnica de procesamiento de señales ST, para el sistema IEEE de 14 barras, presenta una efectividad general del 97%.

En contraste, para comprobar la efectividad de la técnica de procesamiento de señales ST y la ANN se plantea 11 casos de estudio (Tabla 2). Para lo cual se analiza

el gráfico de la ST detalladamente, las señales de voltaje, corriente con sus secuencias preestablecidas a ser implementadas las cuales son positiva, negativa, cero para ser analizadas, y el comportamiento del clasificador de fallas en el sistema IEEE de 14 barras.




Figura 9. Rendimiento de ANN para el Sistema IEEE de 14 barras (IEEE)

Tabla 2. Casos de estudio para la ANN con ST

Caso	Rf (Ω)	Tipo de falla	Distancia (%)	Duración (seg)
1	0.01	AN	10	0.1
2	0.01	BN	90	0.1
3	0.01	CN	50	0.1
4	0.01	ABN	25	0.1
5	0.01	BCN	55	0.1
6	0.01	ACN	35	0.1
7	0.01	AB	45	0.1
8	0.01	BC	30	0.1
9	0.01	AC	10	0.1
10	0.01	ABC	50	0.1
11	0.01	ABCN	25	0.1

4.1 Caracterización de fallas para el Sistema IEEE de 9 barras

Para realizar un análisis detallado del esquema de identificación y clasificación de faltas, se elige el caso de estudio # 1 (Tabla 2) que corresponde a una falla entre la fase

A y la referencia N. Además, los valores resultantes para cada caso se recopilan de forma resumida (Tabla 3).

Asimismo, se presenta la ST de la señal de voltaje previo a la falla, en la cual, se observa que la magnitud de la onda, en la ventana de frecuencia negativa, es de 5.7×10^6 , mientras que, en la ventana positiva, la señal posee una magnitud de 7×10^6 (Figura 10).

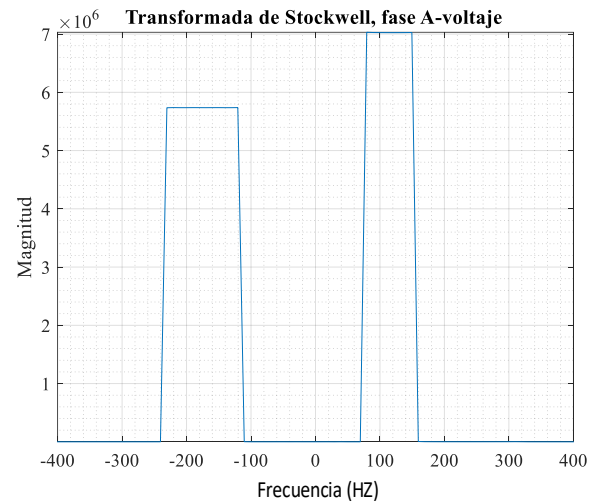


Figura 10. ST de voltaje en fase B previo a la falla en el Sistema IEEE de 9 barras (IEEE).

Asimismo, en la Figura 11 se presenta la ST de la señal de corriente previo a la falla. En esta se observa que la magnitud de la onda, en la ventana de frecuencia negativa, es de 5.9×10^6 , mientras que, en la ventana positiva, la señal posee una magnitud de 7.3×10^6 .




Figura 11. ST de corriente en fase B, previo a la falla en el Sistema IEEE de 9 barras.

Por otro lado, en la Figura 12 se observa que la ST de voltaje posterior a la falla se deforma, la cual, adopta un valor máximo de 6.1×10^6 . Asimismo, la Figura 13 presenta la ST de corriente posterior a la falla, donde, se observa que la onda adopta un valor máximo de 6×10^4 .

Al mismo tiempo, la onda de voltaje tiende a cero mientras dura la falla (Figura 14). Asimismo, la magnitud de la onda de corriente se incrementa de forma significativa, presentando un pico de 2.1×10^4 (Figura 15).

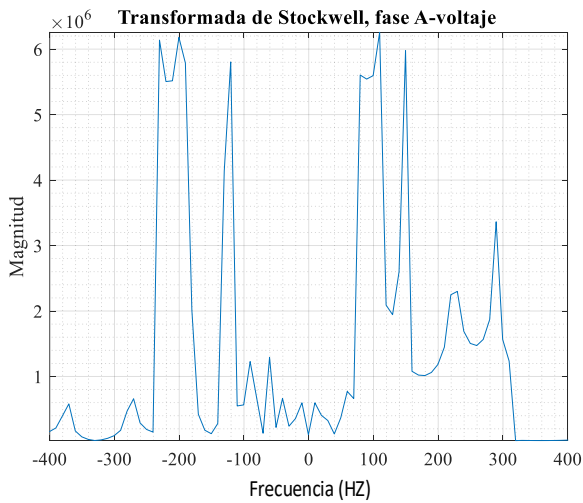


Figura 12. ST de voltaje en fase B posterior a la falla en el sistema IEEE de 9 barras (IEEE).

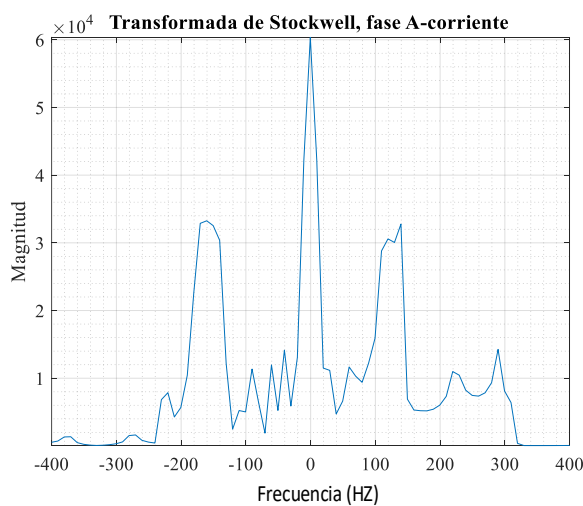


Figura 13. ST de corriente en fase B posterior a la falla en el Sistema IEEE de 9 barras (IEEE).




Figura 14. Señal de voltaje en el Sistema IEEE de 9 barras.

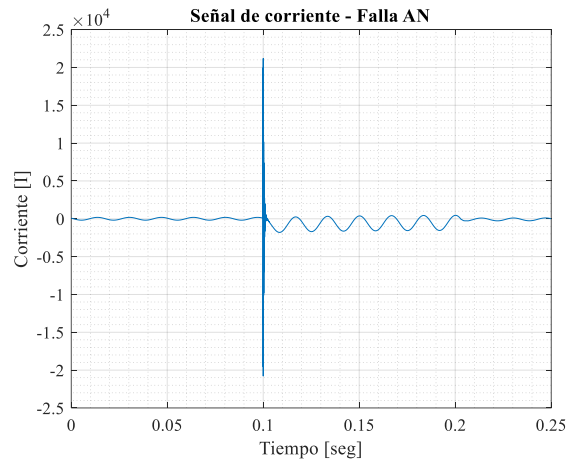


Figura 15. Señal de corriente en el Sistema IEEE de 9 barras (IEEE).

En Figura 16 se registra que a los 0.1 segundos que se origina la falla, el detector cambia de valor de 0 a 1. Asimismo, la única falla que se activa es la AN, es decir, que la técnica clasifica e identifica la falla de forma exitosa. Por último, en la Tabla 3 se evidencia que la ANN responde de forma satisfactoria ante los 11 tipos de fallas consideradas para las pruebas.

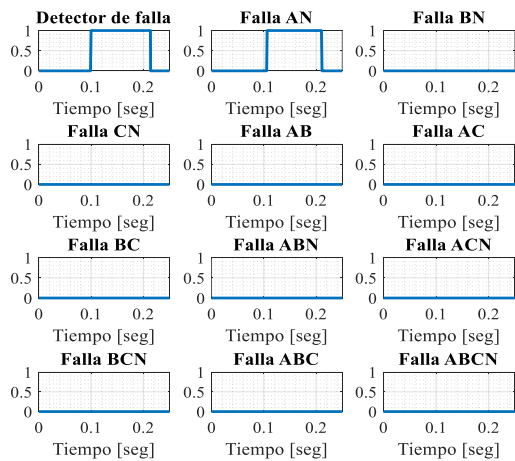


Figura 16. Clasificador de fallas con ANN.

Tabla 3. Resultados de clasificador de fallas para sistema IEEE de 9 barras

Caso	Parámetros para estudio de cortocircuito			Clasificación resultante por ANN con ST			
	RF	Tipo	Distancia (%)	A	B	C	N
	1	0.01	AN	5	1	0	0
2	0.01	BN	15	0	1	0	1
3	0.01	CN	25	0	0	1	1
4	0.01	ABN	35	1	1	0	1
5	0.01	BCN	45	0	1	1	1
6	0.01	ACN	55	1	0	1	1
7	0.01	AB	65	1	1	0	0
8	0.01	BC	75	0	1	1	0
9	0.01	AC	85	1	0	1	0
10	0.01	ABC	5	1	1	1	0
11	0.01	ABCN	15	1	1	1	1

4.2 Caracterización de fallas para el Sistema IEEE de 14 barras

Para realizar un análisis detallado del esquema de identificación y clasificación de faltas, se elige el caso de estudio # 8 (Tabla 2) que corresponde a una falla entre las fases A y C. Además, los valores resultantes para cada caso se recopilan de forma resumida (Tabla 4).

Asimismo, se presenta la ST de la señal de voltaje previo a la falla, en la cual se observa que la magnitud de la onda, en la

ventana de frecuencia negativa, es de 2.1×10^6 , mientras que, en la ventana positiva, la señal posee una magnitud de 2.2×10^6 (Figura 17). Del mismo modo, en la Figura 18 se presenta la ST de la señal de corriente previo a la falla. En esta se observa que la magnitud de la onda, en la ventana de frecuencia negativa, es de 3710, mientras que, en la ventana positiva, la señal posee una magnitud de 3927.

Por otro lado, en la Figura 19 se registra que la ST de voltaje posterior a la falla se deforma, la cual, adopta un valor máximo de 2.4×10^6 . Asimismo, la Figura 20 presenta la ST de corriente posterior a la falla, donde se observa que la onda adopta un valor máximo de 5×10^4 .

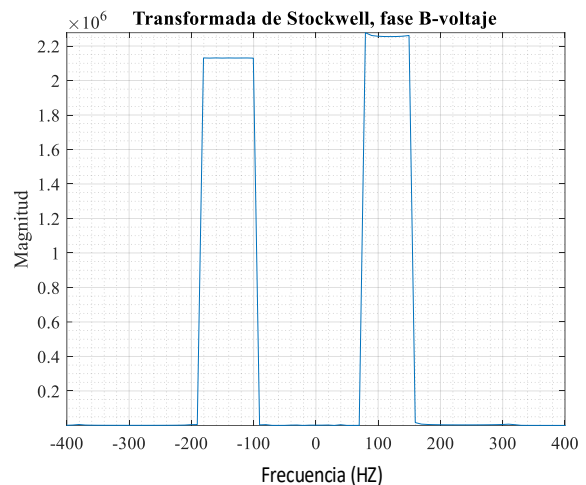


Figura 17. ST de voltaje en fase B previo a la falla en el Sistema IEEE de 14 barras (IEEE).




Figura 18. ST de corriente en fase B previo a la falla en el Sistema IEEE de 14 barras (IEEE).

Al mismo tiempo, la onda de voltaje (Figura 21) de la fase B tiende a cero, mientras que, el voltaje de la Fase C disminuye su amplitud mientras dura la falla. Asimismo, la magnitud de la onda de corriente (Figura 22) de las dos fases incrementa de forma significativa, presentando un pico de 3833 y 4487, para la fase B y C respectivamente.

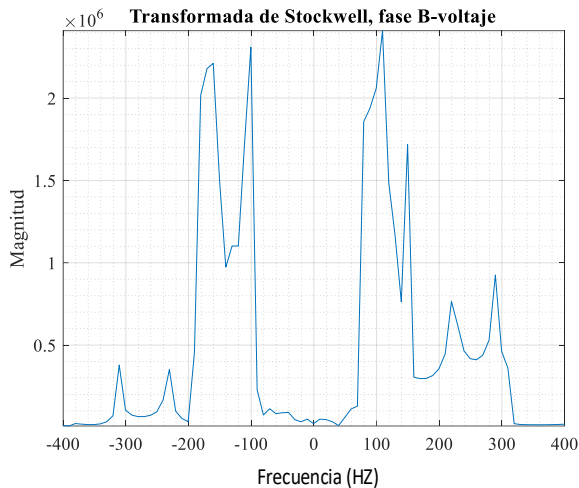


Figura 19. ST de voltaje en fase B posterior a la falla en el Sistema IEEE de 14 barras (IEEE).

En este contexto, se evidencia que a los 0.1 segundos que se origina la falla, el detector cambia de valor de 0 a 1 (Figura 23). Asimismo, la única falla que se activa es la BC, es decir, que la técnica clasifica e identifica la falla de forma exitosa. Por último, en la Tabla 4 se evidencia que la ANN responde de forma satisfactoria ante los 11 tipos de fallas consideradas para las pruebas.

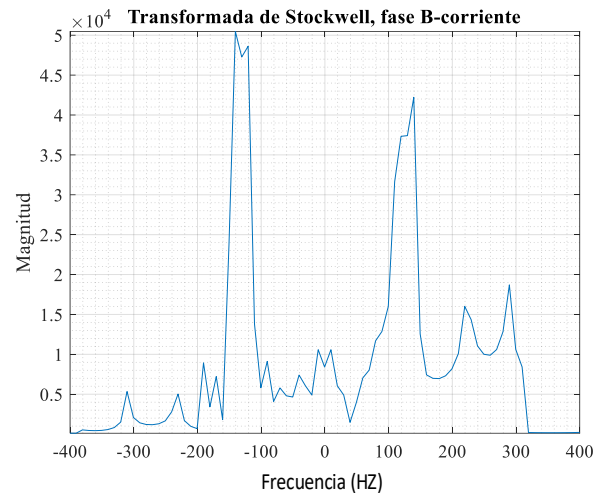


Figura 20. ST de corriente en fase B posterior a la falla en el Sistema IEEE de 14 barras (IEEE).

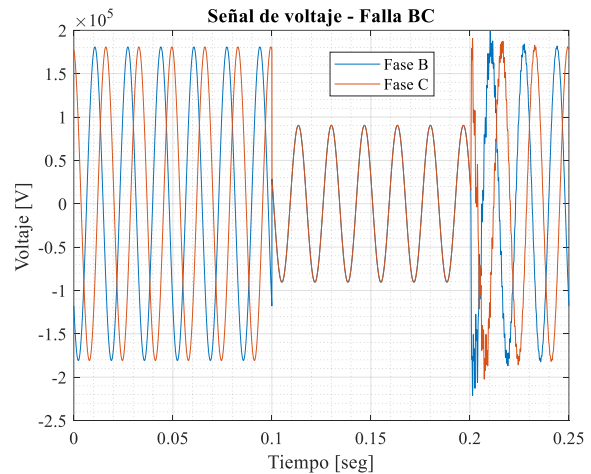


Figura 21. Señal de voltaje en el Sistema IEEE de 14 barras (IEEE).

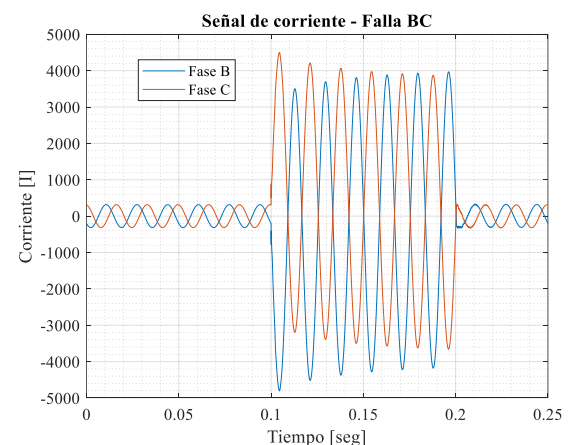


Figura 22. Señal de corriente en el Sistema IEEE de 14 barras (IEEE).

Para concluir se requiere un análisis comparativo (Tabla 5) del esquema de identificación y clasificación de faltas

propuesto en esta investigación y el sistema presentando en [37], el cual, emplea la WT para las señales de corriente y voltaje, junto con un proceso de exploración de patrones para lograr una clasificación efectiva de fallas.

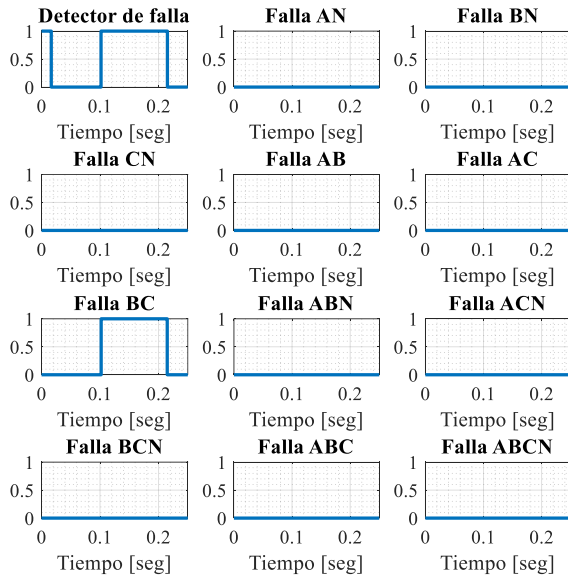


Figura 23. Clasificador de fallas con ANN en el Sistema IEEE de 14 barras.

Tabla 4. Resultados del clasificador de fallas para el Sistema IEEE de 14 barras.

Caso	Parámetros para estudio de cortocircuito			Clasificación resultante por ANN con ST			
	RF	Tipo	Distancia (%)	A	B	C	N
	1	0.01	AN	5	1	0	0
2	0.01	BN	15	0	1	0	1
3	0.01	CN	25	0	0	1	1
4	0.01	ABN	35	1	1	0	1
5	0.01	BCN	45	0	1	1	1
6	0.01	ACN	55	1	0	1	1
7	0.01	AB	65	1	1	0	0
8	0.01	BC	75	0	1	1	0
9	0.01	AC	85	1	0	1	0
10	0.01	ABC	5	1	1	1	0
11	0.01	ABCN	15	1	1	1	1

Tabla 5. Resultados de clasificador de fallas para sistema IEEE de 14 barras

Casos	Tipo	Resultado con ST y ANN				Resultado con técnica Wavelet			
		A	B	C	N	A	B	C	N
1	AN	1	0	0	1	1	0	0	1
2	BN	0	1	0	1	0	1	0	1
3	CN	0	0	1	1	0	0	1	1
4	ABN	1	1	0	1	1	1	0	1
5	BCN	0	1	1	1	0	1	1	1
6	ACN	1	0	1	1	1	0	1	1
7	AB	1	1	0	0	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	0	1	1	1	1
11	ABCN	1	1	1	1	1	1	1	1

Del análisis comparativo se evidencia que el desempeño de la ST con ANN es superior a la transformada de wavelet. Esto se debe a que en la clasificación de una falla trifásica ABC, la ST la identifica de forma correcta, mientras que, la transformada de wavelet la detecta como una ABCN.

5 Conclusiones

El enfoque basado en la ST con ANN, para detectar y clasificar fallas en el SEP, se precisó en este artículo. Para lo cual, fue necesario realizar múltiples estudios de cortocircuito bajo diferentes parámetros, entre los que se incluyen, resistencia, distancia y tipo de falla, lo cual, fue posible con la ayuda del software Matlab/Simulink. En este sentido, mediante la programación en Matlab se construyó la base de datos para la ANN, donde, se cuantificaron las ondas de voltaje, corriente y secuencia cero, para luego aplicar la técnica de procesamiento de señales denominada transformada de Stockwell. A partir de resultados obtenidos de la ST se calcula la energía y se archiva en una matriz, puesto, que estos son los datos que se emplean para la ejecución, confirmación y testeo de la ANN.

Análogamente, se procede a crear la arquitectura de la ANN, la cual posee 8 neuronas de ingreso; 6 en la capa encubierta y 4 en la capa de salida. En este sentido, la cantidad de neuronas que contiene capa oculta, se obtiene mediante la experimentación puesto que una arquitectura fija no tiene la misma efectividad para los problemas de clasificación de fallas. Asimismo, la lógica que sustenta las 4 variables de salida se asocia a la modelación de cada fase por medio de una variable binaria.

Asimismo, para realizar las pruebas en tiempo real fue necesario crear un bloque en Simulink con la ANN entrenada, de forma que, al realizar un estudio de cortocircuito se cuantifican las ondas de voltaje y se calcula la ST, para ingresar los resultados a la ANN. En este sentido es muy importante considerar el orden de las variables de entrada debido a que tiene que seguir el mismo orden que se empleó en la base de datos.

Por otro lado, para comprobar la efectividad del esquema de identificación y clasificación de fallas, se plantearon once escenarios, una por cada falla. Con lo cual se comprueba que la ST permite realizar el diagnóstico en el dominio de la frecuencia en la ventana negativa y positiva de la fase afectada, además, esto contribuye a detectar la falla puesto que las ondas en el dominio de la frecuencia cambian de forma significativa antes de la falla y posterior a ella.

El rendimiento de la ANN basado en la técnica de procesamiento de señales denominada ST presenta una efectividad del 98%, lo que implica que el 2% de detecciones se asocian a clasificaciones erróneas. No obstante se comprueba que la técnica presentada en la presente investigación es superior en comparación con la ANN basada en la transformada de wavelet.

5.1 Trabajos futuros

El sistema propuesto en esta investigación, para la detección y clasificación de fallas, presenta una efectividad del 98%, lo que se debe a los datos dispersos. Por lo que, en futuros trabajos se propone analizar una hibridación de las técnicas de procesamiento de señales entre la ST y la WT. Por consiguiente se podría aumentar el grado de efectividad de la ANN.

6 Referencias

- [1] B. Singh, O. P. Mahela, and T. Manglani, "Detection and Classification of Transmission Line Faults Using Empirical Mode Decomposition and Rule Based Decision Tree Based Algorithm," in *2018 IEEE 8th Power India International Conference (PIICON)*, Dec. 2018, pp. 1–6. doi: 10.1109/POWERI.2018.8704372.
- [2] 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.
- [3] 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.
- [4] 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.
- [5] L. Jain, G. Tsihrintzis, and V. Balas, *Data Communication and Networks*, Primera ed. Poland: Springer, 2019.
- [6] 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.
- [7] 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.
- [8] 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.
- [9] K. Chen, C. Huang, and J. He, "Fault detection, classification and location for transmission lines and distribution systems: a review on the methods," *High Volt.*, vol. 1, no. 1, pp. 25–33, Apr. 2016, doi: 10.1049/hve.2016.0005.
- [10] N. S. Wani, R. P. Singh, and M. U. Nemade, "Detection, Classification and Localization of Faults of Transmission Lines using Wavelet Transform and Neural Network," *Int. J. Appl. Eng. Res.*, vol. 13, no. 1, pp. 98–106, 2018.
- [11] N. Banerjee and R. Author, "Application of S-Transform for Detection of High Impedance Faults in Power System Network," *Int. J. Eng. Res. Technol.*, vol. 9, no. 11, 2021.
- [12] 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.
- [13] P. W. Choudhary, S. S. Jadhao, R. K. Mankar, and S. R. Parasakar, "Classification Of faults in power system using signal processing approach," *Proc. - 2nd Int. Conf. Comput. Commun. Control Autom. ICCUBEA 2016*, 2017, doi: 10.1109/ICCUBEA.2016.7860102.
- [14] N. Agarwal, O. P. Mahela, and B. Kumar, "Detection of Power System Faults in the Presence of Linear Loads Using Stockwell Transform," *IOSR J. Electr. Electron. Eng.*, vol. 11, no. 05, pp. 37–45, 2016, doi: 10.9790/1676-1105013745.
- [15] B. P. Singh, S. K. Goyal, S. A. Siddiqui, and P. Kumar, "A Study and Comprehensive Overview of Inverter Topologies for Grid-Connected Photovoltaic Systems (PVS)," in *Lecture Notes in Electrical Engineering*, vol. 607, 2020, pp. 1009–1017. doi: 10.1007/978-981-15-0214-9_107.
- [16] M. Shafiullah and M. A. Abido, "S-Transform Based FFNN Approach for Distribution Grids Fault Detection and Classification," *IEEE Access*, vol. 6, pp. 8080–8088, 2018, doi: 10.1109/ACCESS.2018.2809045.
- [17] 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.
- [18] 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.
- [19] 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.
- [20] O. C. Iwuamadi, O. A. Ezechukwu, and V. C. Ogbob, “Application of S – Transform For Fault Studies on 330KV Transmission Line,” *Am. J. Eng. Res.*, vol. 11, no. 01, pp. 75–98, 2022.
- [21] G. Rivera and M. Ruiz, “Ubicación de fallas en líneas de transmisión eléctrica basado en el análisis de señales transitorias,” 2020.
- [22] F. Pabón and R. Pérez, “Diagnóstico de Fallas en Sistemas Eléctricos de Distribución mediante La Transformada de Wavelet,” *Tesis Pregr. Univ. Politécnica Sales. Quito, Ecuador*, pp. 1–23, 2016.
- [23] M. Coban and S. S. Tezcan, “Detection and classification of short-circuit faults on a transmission line using current signal,” *Bull. Polish Acad. Sci. Tech. Sci.*, vol. 69, no. 4, pp. 1–9, 2021, doi: 10.24425/bpasts.2021.137630.
- [24] P. Chiradeja and A. Ngaopitakkul, “Classification of Lightning and Faults in Transmission Line Systems Using Discrete Wavelet Transform,” *Math. Probl. Eng.*, vol. 2018, 2018, doi: 10.1155/2018/1847968.
- [25] G. N. Lopes, T. S. Menezes, G. G. Santos, L. H. P. C. Trondoli, and J. C. M. Vieira, “High Impedance Fault detection based on harmonic energy variation via S-transform,” *Int. J. Electr. Power Energy Syst.*, vol. 136, no. September 2021, p. 107681, 2022, doi: 10.1016/j.ijepes.2021.107681.
- [26] D. A. Gadanayak and R. K. Mallick, “Interharmonics based high impedance fault detection in distribution systems using maximum overlap wavelet packet transform and a modified empirical mode decomposition,” *Int. J. Electr. Power Energy Syst.*, vol. 112, no. October 2018, pp. 282–293, 2019, doi: 10.1016/j.ijepes.2019.04.050.
- [27] J. Han, S. Miao, Y. Li, W. Yang, and H. Yin, “Faulted-Phase classification for transmission lines using gradient similarity visualization and cross-domain adaption-based convolutional neural network,” *Electr. Power Syst. Res.*, vol. 191, no. June 2020, p. 106876, 2021, doi: 10.1016/j.epsr.2020.106876.
- [28] S. R. Fahim, Y. Sarker, S. K. Sarker, M. R. I. Sheikh, and S. K. Das, “Self attention convolutional neural network with time series imaging based feature extraction for transmission line fault detection and classification,” *Electr. Power Syst. Res.*, vol. 187, no. May, p. 106437, 2020, doi: 10.1016/j.epsr.2020.106437.
- [29] R. Arranz, Á. Paredes, A. Rodríguez, and F. Muñoz, “Fault location in Transmission System based on Transient Recovery Voltage using Stockwell transform and Artificial Neural Networks,” *Electr. Power Syst. Res.*, vol. 201, no. September, 2021, doi: 10.1016/j.epsr.2021.107569.
- [30] C. Liu, Y. Meerten, K. Declercq,

- and K. Gryllias, "Vibration-based gear continuous generating grinding fault classification and interpretation with deep convolutional neural network," *J. Manuf. Process.*, vol. 79, no. September 2021, pp. 688–704, 2022, doi: 10.1016/j.jmapro.2022.04.068.
- [31] A. K. Gangwar and A. G. Shaik, "Detection and classification of faults on transmission line using time-frequency approach of current transients," *2018 IEEMA Eng. Infin. Conf. eTechNxt 2018*, pp. 1–5, 2018, doi: 10.1109/ETECHNXT.2018.8385354.
- [32] J. J. Chavez, M. Popov, D. López, S. Azizi, and V. Terzija, "S-Transform based fault detection algorithm for enhancing distance protection performance," *Int. J. Electr. Power Energy Syst.*, vol. 130, no. February, 2021, doi: 10.1016/j.ijepes.2021.106966.
- [33] N. Huang *et al.*, "Short-circuit fault detection and classification using empirical wavelet transform and local energy for electric transmission line," *Sensors (Switzerland)*, vol. 17, no. 9, pp. 1–24, 2017, doi: 10.3390/s17092133.
- [34] A. Kulshrestha, O. P. Mahela, M. K. Gupta, B. Khan, H. H. Alhelou, and P. Siano, "Hybridization of the stockwell transform and wigner distribution function to design a transmission line protection scheme," *Appl. Sci.*, vol. 10, no. 22, pp. 1–15, 2020, doi: 10.3390/app10227985.
- [35] A. Bhakat, N. B. Roy, and P. B. Deb, "High Impedance Fault Analysis in Transmission Line using S-Transform Analysis Different Types of Fault in Transmission Line," *Int. J. Eng. Res. Technol.*, vol. 9, no. 11, pp. 275–280, 2021, doi: 10.17577/IJERTCONV9IS11065.
- [36] A. Raza, A. Benrabah, T. Alquthami, and M. Akmal, "A review of fault diagnosing methods in power transmission systems," *Appl. Sci.*, vol. 10, no. 4, pp. 0–27, 2020, doi: 10.3390/app10041312.
- [37] 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.jee.20160405.11.

6.1 Matriz de Estado del Arte

Tabla 6: Matriz de estado del arte.

APLICACIÓN DE LA TRANSFORMADA DE STOCKWELL PARA LA DETECCIÓN Y CLASIFICACIÓN DE FALLAS EN LÍNEAS DE TRANSMISIÓN																									
ITEM	DATOS				TEMÁTICA			FORMULACIÓN DEL PROBLEMA				RESTRICCIONES DEL PROBLEMA				PROPUESTAS PARA RESOLVER EL PROBLEMA					SOLUCIÓN PROPUESTA				
	AÑO	TÍTULO DEL ARTÍCULO	REFERENCIA	CITAS	DETECCIÓN DE FALLAS	UBICACIÓN DE LA FALLA	CLASIFICACIÓN DE FALLAS	VOLTAJES	CORRIENTES	TRANSFORMADA DE WAVELET	TRANSFORMADA DE STOKWELL	TIPOS DE FALLAS	CANTIDAD DE DATOS DE VOLTAJES Y CORRIENTES	NÚMERO DE CAPAS DE ENTRADA	NÚMERO DE CAPAS DE SALIDA	FRECUENCIA	ANN	ÁRBOLES DE DECISIÓN	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	Detection and Classification of Transmission Line Faults Using Empirical Mode Decomposition and Rule Based Decision Tree Based Algorithm	Singh Balvinder Mahela Om Prakash Manglani Tanuj	8	☒		☒	☒	☒		☒	☒		☒	☒	☒	☒	☒					☒	☒	
2	2020	Fault detection and identification using levenberg machine learning algorithm	Anil Kumar T Dinesh T	10	☒		☒	☒	☒		☒		☒	☒		☒							☒	☒	
3	2021	Fault location determination in three-terminal transmission lines connected to industrial microgrids without requiring fault classification data and independent of line parameters	Abasi, Mahyar Rohani, Arash Hatami, Farhad Joorabian, Mahmood Gharehpetian, Gevork B.	5	☒	☒	☒	☒	☒			☒	☒						☒				☒		
4	2021	Deep learning through LSTM classification and regression for transmission line fault detection, diagnosis and location in large-scale multi-machine power systems	Belagoune, Soufiane Bali, Nouredine Bakdi, Azzeddine Baadji, Bousaadia Atif, Karim	22	☒		☒	☒	☒			☒		☒	☒				☒				☒	☒	
5	2019	Data Communication and Networks	Jain, Lakhmi Tsihrintzis, George Balas, Valentina	10	☒		☒	☒	☒			☒		☒	☒								☒	☒	
6	2021	A deep learning based intelligent approach in detection and classification of transmission line faults	Fahim, Shahriar Rahman Sarker, Subrata K. Muyeen, S. M. Das, Sajal K. Kamwa, Innocent	10	☒		☒	☒	☒			☒		☒	☒								☒	☒	

APLICACIÓN DE LA TRANSFORMADA DE STOCKWELL PARA LA DETECCIÓN Y CLASIFICACIÓN DE FALLAS EN LÍNEAS DE TRANSMISIÓN

ITEM	AÑO	TÍTULO DEL ARTÍCULO	REFERENCIA	CITAS	TEMÁTICA			FORMULACIÓN DEL PROBLEMA				RESTRICCIONES DEL PROBLEMA				PROPUESTAS PARA RESOLVER EL PROBLEMA					SOLUCIÓN PROPUESTA		
					DETECCIÓN DE FALLAS	UBICACIÓN DE LA FALLA	CLASIFICACIÓN DE FALLAS	VOLTAJES	CORRIENTES	TRANSFORMADA DE WAVELET	TRANSFORMADA DE STOKWELL	TIPOS DE FALLAS	CANTIDAD DE DATOS DE VOLTAJES Y CORRIENTES	NÚMERO DE CAPAS DE ENTRADA	NÚMERO DE CAPAS DE SALIDA	FRECUENCIA	ANN	ÁRBOLES DE DECISIÓN	RECONOCIMIENTO DE PATRONES	SISTEMA ADAPTATIVO DIFUSO	ANÁLISIS DE SECUENCIAS	TRANSFORMADA DE CLARKE	CLASIFICACIÓN DE TIPO DE FALLA
7	2021	End to end machine learning for fault detection and classification in power transmission lines	Rafique, Fezan Fu, Ling Mai, Ruikun	7	☒		☒	☒		☒	☒		☒	☒	☒						☒	☒	
8	2018	Fault detection and classification in transmission lines based on a PSD index	Guillen, Daniel Paternina, Mario R.Arrieta Ortiz-Bejar, Jose Tripathy, Rajesh Kumar Zamora-Mendez, Alejandro Tapia-Olvera, Ruben Tellez, Eric S.	23	☒		☒	☒		☒	☒			☒				☒			☒	☒	
9	2016	Fault detection, classification and location for transmission lines and distribution systems: a review on the methods	Chen, Kunjin Huang, Caowei He, Jinliang	248	☒	☒	☒		☒	☒			☒	☒		☒	☒	☒	☒		☒	☒	☒
10	2018	Detection, Classification and Localization of Faults of Transmission Lines using Wavelet Transform and Neural Network	Wani, Nilish S Singh, R P Nemade, Milind U	5	☒		☒	☒	☒		☒			☒							☒	☒	
11	2021	Application of S-Transform for Detection of High Impedance Faults in Power System Network	Banerjee, Nabamita Author, Roy	0	☒		☒	☒		☒	☒			☒	☒						☒	☒	
12	2022	Fault Identification, Classification, and Location on Transmission Lines Using Combined Machine Learning Methods	Bon, Nguyen Nhan Van Dai, Le	0	☒	☒		☒	☒			☒	☒	☒					☒		☒	☒	
13	2017	Classification Of faults in power system using signal processing approach	Choudhary, Pratik W. Jadhao, Saurabh S. Mankar, Ravindra K. Parasakar, S. R.	5	☒		☒	☒	☒		☒										☒	☒	

APLICACIÓN DE LA TRANSFORMADA DE STOCKWELL PARA LA DETECCIÓN Y CLASIFICACIÓN DE FALLAS EN LÍNEAS DE TRANSMISIÓN

ITEM	AÑO	TÍTULO DEL ARTÍCULO	REFERENCIA	CITAS	TEMÁTICA			FORMULACIÓN DEL PROBLEMA				RESTRICCIONES DEL PROBLEMA				PROPUESTAS PARA RESOLVER EL PROBLEMA				SOLUCIÓN PROPUESTA			
					DETECCIÓN DE FALLAS	UBICACIÓN DE LA FALLA	CLASIFICACIÓN DE FALLAS	VOLTAJES	CORRIENTES	TRANSFORMADA DE WAVELET	TRANSFORMADA DE STOCKWELL	TIPOS DE FALLAS	CANTIDAD DE DATOS DE VOLTAJES Y CORRIENTES	NÚMERO DE CAPAS DE ENTRADA	NÚMERO DE CAPAS DE SALIDA	FRECUENCIA	ANN	ÁRBOLES DE DECISIÓN	RECONOCIMIENTO DE PATRONES	SISTEMA ADAPTATIVO DIFUSO	ANÁLISIS DE SECUENCIAS	TRANSFORMADA DE CLARKE	CLASIFICACIÓN DE TIPO DE FALLA
14	2016	Detection of Power System Faults in the Presence of Linear Loads Using Stockwell Transform	Agarwal, Neha Mahela, Om Prakash Kumar, Bipul	2	☒		☒	☒	☒		☒	☒		☒	☒						☒	☒	
15	2020	A Study and Comprehensive Overview of Inverter Topologies for Grid-Connected Photovoltaic Systems (PVS)	Singh, Bhuwan Pratap Goyal, Sunil Kumar Siddiqui, Shahbaz Ahmed Kumar, Prakash	4	☒		☒	☒	☒		☒	☒		☒	☒						☒	☒	
16	2018	S-Transform Based FFNN Approach for Distribution Grids Fault Detection and Classification	Shafullah, Md Abido, M. A.	67	☒		☒	☒	☒		☒	☒		☒	☒						☒	☒	
17	2021	Phase angle-based fault detection and classification for protection of transmission lines	Kumar, Bandi Ravi Mohapatra, Abheejeet Chakrabarti, Saikat Kumar, Avinash	6	☒		☒	☒	☒		☒			☒	☒						☒	☒	
18	2020	Fault Classification Accuracy Measurement for a Distribution System with Artificial Neural Network without using Signal Processing Technique	Khond, S V Dhokane, G A	0	☒	☒	☒		☒	☒	☒			☒	☒			☒		☒	☒		
19	2018	Algorithm for fault location and classification on parallel transmission line using wavelet based on Clarke's transformation	Saini, Makmur Mohd Zin, A. A. Mustafa, M. W. Sultan, A. R. Nur, Rusdi	16	☒		☒	☒	☒		☒			☒	☒				☒		☒	☒	
20	2022	Application of S – Transform For Fault Studies on 330KV Transmission Line	Iwuamadi, O C Ezechukwu, O A Ogbob, V C	0	☒		☒	☒	☒		☒	☒		☒	☒						☒	☒	

APLICACIÓN DE LA TRANSFORMADA DE STOCKWELL PARA LA DETECCIÓN Y CLASIFICACIÓN DE FALLAS EN LÍNEAS DE TRANSMISIÓN

ITEM	AÑO	TÍTULO DEL ARTÍCULO	REFERENCIA	CITAS	TEMÁTICA			FORMULACIÓN DEL PROBLEMA				RESTRICCIONES DEL PROBLEMA			PROPUESTAS PARA RESOLVER EL PROBLEMA				SOLUCIÓN PROPUESTA				
					DETECCIÓN DE FALLAS	UBICACIÓN DE LA FALLA	CLASIFICACIÓN DE FALLAS	VOLTAJES	CORRIENTES	TRANSFORMADA DE WAVELET	TRANSFORMADA DE STOCKWELL	TIPOS DE FALLAS	CANTIDAD DE DATOS DE VOLTAJES Y CORRIENTES	NÚMERO DE CAPAS DE ENTRADA	NÚMERO DE CAPAS DE SALIDA	FRECUENCIA	ANN	ÁRBOLES DE DECISIÓN	RECONOCIMIENTO DE PATRONES	SISTEMA ADAPTATIVO DIFUSO	ANÁLISIS DE SECUENCIAS	TRANSFORMADA DE CLARKE	CLASIFICACIÓN DE TIPO DE FALLA
21	2020	Ubicación de fallas en líneas de transmisión eléctrica basado en el análisis de señales transitorias	Rivera, Gabriela Ruiz, Milton	0	☒	☒		☒	☒			☒			☒			☒				☒	☒
22	2016	Diagnóstico de Fallas en Sistemas Eléctricos de Distribución mediante La Transformada de Wavelet	Pabón, Francisco Pérez, Ramón	5	☒		☒	☒	☒		☒		☒	☒	☒	☒					☒	☒	
23	2021	Detection and classification of short-circuit faults on a transmission line using current signal	Coban, Melih Tezcan, Suleyman S.	1	☒		☒	☒	☒		☒		☒	☒	☒						☒	☒	
24	2018	Classification of Lightning and Faults in Transmission Line Systems Using Discrete Wavelet Transform	Chiradeja, Pathomthat Ngaopitakkul, Atthapol	14	☒		☒	☒	☒		☒		☒	☒	☒	☒					☒	☒	
25	2022	High Impedance Fault detection based on harmonic energy variation via S-transform	Lopes, G. N. Menezes, T. S. Santos, G. G. Trondoli, L. H.P.C. Vieira, J. C.M.	4	☒		☒	☒	☒		☒		☒	☒	☒	☒					☒	☒	
26	2019	Interharmonics based high impedance fault detection in distribution systems using maximum overlap wavelet packet transform and a modified empirical mode decomposition	Gadanayak, Debadatta Amaresh Mallick, Ranjan Kumar	27	☒		☒	☒	☒		☒		☒	☒	☒	☒					☒	☒	
27	2021	Faulted-Phase classification for transmission lines using gradient similarity visualization and cross-domain adaption-based convolutional neural network	Han, Ji Miao, Shihong Li, Yaowang Yang, Weichen Yin, Haoran	9	☒		☒	☒	☒		☒		☒	☒	☒						☒	☒	

APLICACIÓN DE LA TRANSFORMADA DE STOCKWELL PARA LA DETECCIÓN Y CLASIFICACIÓN DE FALLAS EN LÍNEAS DE TRANSMISIÓN

ITEM	AÑO	TÍTULO DEL ARTÍCULO	REFERENCIA	CITAS	TEMÁTICA			FORMULACIÓN DEL PROBLEMA				RESTRICCIONES DEL PROBLEMA				PROPUESTAS PARA RESOLVER EL PROBLEMA				SOLUCIÓN PROPUESTA			
					DETECCIÓN DE FALLAS	UBICACIÓN DE LA FALLA	CLASIFICACIÓN DE FALLAS	VOLTAJES	CORRIENTES	TRANSFORMADA DE WAVELET	TRANSFORMADA DE STOKWELL	TIPOS DE FALLAS	CANTIDAD DE DATOS DE VOLTAJES Y CORRIENTES	NÚMERO DE CAPAS DE ENTRADA	NÚMERO DE CAPAS DE SALIDA	FRECUENCIA	ANN	ÁRBOLES DE DECISIÓN	RECONOCIMIENTO DE PATRONES	SISTEMA ADAPTATIVO DIFUSO	ANÁLISIS DE SECUENCIAS	TRANSFORMADA DE CLARKE	CLASIFICACIÓN DE TIPO DE FALLA
28	2020	Self attention convolutional neural network with time series imaging based feature extraction for transmission line fault detection and classification	Fahim, Shahriar Rahman Sarker, Yeahia Sarker, Subrata K. Sheikh, Md Rafiqul Islam Das, Sajal K.	50	☒		☒	☒	☒		☒			☒							☒	☒	
29	2021	Fault location in Transmission System based on Transient Recovery Voltage using Stockwell transform and Artificial Neural Networks	Arranz, Rafael Paredes, Ángel Rodríguez, Alejandro Muñoz, Francisco	5	☒		☒	☒	☒		☒			☒							☒	☒	
30	2022	Vibration-based gear continuous generating grinding fault classification and interpretation with deep convolutional neural network	Liu, Chenyu Meerten, Yannick Declercq, Katrien Gryllias, Konstantinos	0	☒		☒	☒	☒		☒			☒							☒	☒	
31	2018	Detection and classification of faults on transmission line using time-frequency approach of current transients	Gangwar, Amit Kumar Shaik, Abdul Gafoor	8	☒		☒	☒	☒		☒			☒							☒	☒	
32	2021	S-Transform based fault detection algorithm for enhancing distance protection performance	Chavez, Jose J. Popov, Marjan López, David Azizi, Sadegh Terzija, Vladimir	8	☒		☒	☒	☒		☒			☒							☒	☒	
33	2017	Short-circuit fault detection and classification using empirical wavelet transform and local energy for electric transmission line	Huang, Nantian Qi, Jiabin Li, Fuqing Yang, Dongfeng Cai, Guowei Huang, Guilin Zheng, Jian Li, Zhenxin	18	☒		☒	☒	☒		☒			☒							☒	☒	

APLICACIÓN DE LA TRANSFORMADA DE STOCKWELL PARA LA DETECCIÓN Y CLASIFICACIÓN DE FALLAS EN LÍNEAS DE TRANSMISIÓN

ITEM	DATOS			CITAS	TEMÁTICA			FORMULACIÓN DEL PROBLEMA			RESTRICCIONES DEL PROBLEMA			PROPUESTAS PARA RESOLVER EL PROBLEMA				SOLUCIÓN PROPUESTA							
	AÑO	TÍTULO DEL ARTÍCULO	REFERENCIA		DETECCIÓN DE FALLAS	UBICACIÓN DE LA FALLA	CLASIFICACIÓN DE FALLAS	VOLTAJES	CORRIENTES	TRANSFORMADA DE WAVELET	TRANSFORMADA DE STOKWELL	TIPOS DE FALLAS	CANTIDAD DE DATOS DE VOLTAJES Y CORRIENTES	NÚMERO DE CAPAS DE ENTRADA	NÚMERO DE CAPAS DE SALIDA	FRECUENCIA	ANN	ÁRBOLES DE DECISIÓN	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
34	2017	Hybridization of the stockwell transform and wigner distribution function to design a transmission line protection scheme	Huang, Nantian Qi, Jiajin Li, Fuqing Yang, Dongfeng Cai, Guowei Huang, Guilin Zheng, Jian Li, Zhenxin	6	☒		☒	☒	☒	☒	☒		☒	☒	☒	☒	☒						☒	☒	
35	2021	High Impedance Fault Analysis in Transmission Line using S-Transform Analysis Different Types of Fault in Transmission Line	Bhakat, Anshu Roy, Nabamita Banerjee Deb, Pratyusha Biswas	0	☒		☒	☒	☒	☒	☒		☒	☒	☒	☒	☒						☒	☒	
36	2020	A review of fault diagnosing methods in power transmission systems	Raza, Ali Benrabah, Abdeldjabar Alquthami, Thamer Akmal, Muhammad	45	☒		☒	☒	☒	☒	☒		☒	☒	☒	☒							☒	☒	
37	2016	Fault Detection and Classification for Transmission Line Protection System Using Artificial Neural Network	Phyo Thwe, Ei	28	☒		☒	☒	☒	☒	☒		☒	☒	☒	☒							☒	☒	
CANTIDAD:					37	5	35	35	37	18	15	34	3	33	33	19	29	19	2	3	6	1	36	35	2

6.2 Resumen de Indicadores

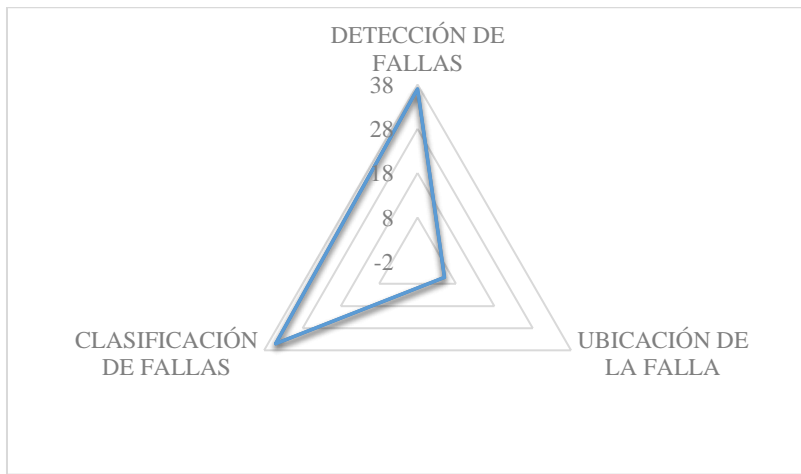


Figura 24. Resumen e indicador de la temática - Estado del arte.




Figura 25. Indicador de formulación del problema - Estado del arte.




Figura 26. Indicador de solución al problema - Estado del arte.