

**DISEÑO E IMPLEMENTACIÓN DE UN MÉTODO DE LOCALIZACIÓN DE FALLAS DE ALTA IMPEDANCIA EN LÍNEAS DE TRANSMISIÓN DE ENERGÍA ELÉCTRICA AÉREAS BASADO EN REDES NEURONALES.**

**Autora: Ing. Tatiana Susana León Paternina**

**TRABAJO DE GRADO PRESENTADO COMO REQUISITO PARA OPTAR AL TÍTULO DE MAGISTER EN INGENIERÍA CON ENFÁSIS EN ELÉCTRICA Y ELECTRÓNICA**

**Directora: PhD. Sonia Helena Contreras Ortiz**

**UNIVERSIDAD TÉCNOLÓGICA DE BOLÍVAR**

**FACULTAD DE INGENIERÍA  
PROGRAMA DE MAESTRÍA EN INGENIERÍA CON ENFASIS EN ELÉCTRICA Y ELECTRÓNICA  
CARTAGENA DE INDIAS D.T. Y C.**

**2015**

**Nota de aceptación**

---

---

---

---

---

---

**Firma del Director**

---

**Firma del jurado**

---

**Firma del jurado**

---

*A Dios por brindarme la sabiduría y la persistencia para alcanzar mis metas y mis sueños. Igualmente a mis padres: Juan y Ángela y a mis hermanos: Juan Manuel y Cindy Paola y a mi novio Manuel por todo su apoyo constante e incondicional. Igualmente a mis abuelitos: Juan Pérez, Susana, Pedro y Nelida por todo su cariño y apoyo. A mis profesores y amigos. Y demás familiares que me brindaron su apoyo constantemente en la realización de mis estudios.*

## **AGRADECIMIENTOS**

La autora expresa sus agradecimientos a:

A la PhD. Sonia Helena Contreras Ortiz, Coordinadora de la Maestría en Ingeniería con énfasis en Eléctrica y Electrónica de la Universidad Tecnológica de Bolívar.

Al MsC. Jhon Albeiro Calderón Serna, Especialista Ingeniería Subestaciones de ISA.

A la PhD. José Luis Villa Ramírez, Director de la Maestría en Ingeniería con énfasis en Eléctrica y Electrónica de la Universidad Tecnológica de Bolívar.

Al MsC. Ricardo Arjona, Director de Programa de Ingeniería Eléctrica y Electrónica.

Por su gran colaboración y apoyo constante en la realización de este trabajo de grado.

## CONTENIDO

CAPÍTULO I. ESPECIFICACIONES DEL PLANTEAMIENTO DEL PROBLEMA .....	16
1.1 Introducción.....	16
1.2 Planteamiento del Problema .....	20
1.2.1 Formulación de las preguntas de Investigación.....	21
1.3 Objetivos.....	22
1.3.1 Objetivo General.....	22
1.3.2 Objetivos Específicos .....	22
CAPÍTULO II. ESTADO DEL ARTE .....	23
2.1 Introducción.....	23
2.2 Redes de Distribución .....	23
2.3 Líneas de Transmisión .....	28
2.4 Conclusiones.....	40
CAPÍTULO III. MARCO TEÓRICO.....	41
3.1 Introducción.....	41
3.2 Generalidades de un Sistema Eléctrico de Potencia .....	41
3.2.1 Sistemas de Generación.....	41
3.2.2 Sistemas de Transmisión.....	44
3.2.2.1 Parámetros de una línea de Transmisión.....	47
3.2.3 Sistema de Distribución.....	48
3.3 Fallas en los Sistema Eléctrico de Potencia.....	51
3.3.1 Fallas Monofásicas (L-T).....	53
3.3.2 Fallas Bifásicas a Tierra (L-L-T).....	53
3.3.3 Fallas Bifásicas (L-L) .....	54

3.3.4	Fallas Trifásicas a tierra (L-L-L) .....	54
3.4	Conclusiones.....	55
CAPÍTULO IV. MÉTODOS Y EQUIPOS UTILIZADOS PARA LOCALIZAR FALLAS EN LOS SISTEMAS ELÉCTRICOS DE POTENCIA. ....		56
4.1	Introducción .....	56
4.2	Metodologías utilizadas para la localización de fallas en líneas de transmisión.....	56
4.2.1	Método de la Reactancia [36].....	57
4.2.2	Método utilizando datos de voltaje y corriente de una terminal de una línea de transmisión [37] .....	59
4.2.3	Algoritmo de Schweitzer para líneas cortas [36] .....	61
4.2.4	Algoritmo de Eriksson [36] .....	62
4.3	Protecciones Eléctricas y sus aplicaciones en la localización de fallas en líneas de transmisión .....	64
4.3.1	Clasificación de los Relés de Protección.....	65
4.4	Conclusiones.....	67
CAPÍTULO V. ASPECTOS METODOLÓGICOS PROPUESTO .....		68
5.1	Introducción.....	68
5.2	Planteamiento Metodológico .....	69
5.2.1	Caracterización del sistema eléctrico de Potencia Seleccionado .....	69
5.2.2	Simulación y/o adquisición de datos .....	69
5.2.3	Extracción de información las señales eléctricas .....	70
5.2.4	Diseño e Implementación de Técnicas de Inteligencia artificial para el proceso de detección de Fallas.....	70
CAPÍTULO VI. CARACTERIZACIÓN DEL SISTEMA ELÉCTRICO DE POTENCIA.....		72
6.1	Introducción.....	72
6.2	Análisis y Resultados de la Caracterización del Sistema Eléctrico de Potencia.....	73

6.2.1	Métodos de Análisis de estabilidad de Tensión en un SEP .....	73
6.2.1.1	Análisis con curvas PV y VQ.....	74
6.2.1.2	Análisis Modal.....	76
6.2.1.3	Análisis de Sensibilidad.....	78
6.2.2	Identificación de Potencia Activa en cada nodo del Sistema Eléctrico de Potencia 78	
6.3	Conclusiones.....	80
CAPÍTULO VII. ADQUISICIÓN, EXTRACCIÓN Y PREPARACIÓN DE LOS DATOS .....		81
7.1	Introducción.....	81
7.2	Análisis matemático para Fallas de Alta Impedancia para el SEP del caso estudio. 81	
7.3	Extracción de las variables y/o características del SEP mediante simulaciones.....	82
7.3.1	Resultados de Simulación para fallas de Alta Impedancia.....	87
7.4	Técnicas de Procesamiento y normalización de los datos extraídos de las fallas de alta impedancia en el SEP del caso estudio.....	88
7.4.1	Transformada discreta de Fourier .....	89
7.4.2	Transformada discreta de Wavelet [45] .....	91
7.4.3	Resultados del Procesamiento de la Señales Eléctricas seleccionadas .....	95
7.4.3.1	Resultados del Procesamiento de la Señales Eléctricas mediante la Transformada discreta de Fourier .....	95
7.4.3.2	Resultados del Procesamiento de la Señales Eléctricas mediante la Transformada discreta de Wavelet.....	97
7.5	Conclusiones.....	101
CAPÍTULO VIII. ESTUDIO E IMPLEMENTACIÓN DE REDES NEURONALES PARA EL PROCESO DE LOCALIZACIÓN DE FALLAS DE ALTA IMPEDANCIA. ....		103
8.1	Introducción.....	103
8.2	Modelo de Redes Neuronales Artificiales-RNA.....	103

8.2.1	Operación básica de una Red Neuronal .....	108
8.2.1.1	Entrenamiento.....	108
8.2.1.2	Verificación.....	109
8.2.1.3	Operación:.....	109
8.2.2	Modelos de Red Neuronal .....	110
8.2.2.1	Modelo de Red Perceptrón de una capa.....	110
8.2.2.2	Modelo de Red Perceptrón Multicapa con entrenamiento del tipo Backpropagation.....	111
8.2.3	Diseño e implementación de la Red Neuronal para localización de FAI en sistema eléctrico de potencia seleccionado.....	114
8.2.4	Resultados del Proceso de Entrenamiento, validación y prueba de la Red Neuronal diseñada .....	116
8.3	Conclusiones.....	125
IX. CONCLUSIONES Y TRABAJO FUTURO.....		126
9.1	Conclusiones.....	126
9.2	Recomendaciones y Trabajos Futuros .....	127
CAPITULO X. REFERENCIAS BIBLIOGRÁFICAS.....		128
ANEXO A. ANÁLISIS DE MÉTODOS DE ENTRENAMIENTO DE LA RED NEURONAL PROPUESTA.....		137
ANEXO B. Diseño e Implementación de la Red Neuronal mediante el procesamiento de las señales eléctricas a partir de Transformada Discreta de Fourier.....		181
ANEXO C. Diseño e Implementación de la Red Neuronal mediante el procesamiento de las señales eléctricas a partir de Transformada Discreta de Wavelet.....		183

## LISTA DE TABLAS

Tabla 1. Capacidad efectiva neta del SIN a diciembre 31 de 2012 y 2013 .....	44
Tabla 2. Resultados de localización de fallas por medio DFL e inspección de resultados	61
Tabla 3. Corrientes del Algoritmo de Eriksson .....	63
Tabla 4. Datos de las Líneas.....	72
Tabla 5. Datos de los Generadores .....	73
Tabla 6. Datos del Transformador.....	73
Tabla 7. Tipos de Neuronas y Funciones de activación .....	107
Tabla 8. Resultados del localización de FAI por medio de la Red Neuronal mediante el método de Regulación Bayesiana.....	121
Tabla 9. Tabla comparativa entre el método de la Reactancia y Redes Neuronales .....	123
Tabla 10. Tabla comparativa de Métodos de entrenamiento de una red neuronal tipo Perceptrón Multicapa.....	124
Tabla 11. Resultados del localización de FAI por medio de la Red Neuronal mediante el algoritmo de Levenberg-Marquardt y la Transformada Discreta de Fourier.....	144
Tabla 12. Resultados del localización de FAI por medio de la Red Neuronal mediante el método de BFGS Quasi-Newton y la Transformada Discreta de Fourier.....	149
Tabla 13. Resultados del localización de FAI por medio de la Red Neuronal mediante el método de Resilient Backpropagation y la Transformada Discreta de Fourier.....	154
Tabla 14. Resultados del localización de FAI por medio de la Red Neuronal mediante el algoritmo Scaled Conjugate Gradient y la Transformada Discreta de Fourier.....	159
Tabla 15. Resultados del localización de FAI por medio de la Red Neuronal mediante el algoritmo de Levenberg-Marquardt y la Transformada Discreta de Wavelet.....	164
Tabla 16. Resultados del localización de FAI por medio de la Red Neuronal mediante el algoritmo de Bayesian Regularization la Transformada Discreta de Wavelet.....	168
Tabla 17. Resultados del localización de FAI por medio de la Red Neuronal mediante el algoritmo de BFGS Quasi-Newton y la Transforma Discreta de Wavelet.....	172
Tabla 18. Resultados del localización de FAI por medio de la Red Neuronal mediante algoritmo Resilient Backpropagation y la Transforma Discreta de Wavelet.....	176
Tabla 19. Resultados del localización de FAI por medio de la Red Neuronal mediante el algoritmo Scaled Conjugate Gradient y la Transforma Discreta de Wavelet.....	180

## LISTA DE FIGURAS

Figura 1. Sistemas Fotovoltaicos conectados a la red eléctrica.....	42
Figura 2. Sistemas Fotovoltaicos aislados de la red eléctrica .....	43
Figura 3. Sistema de Transmisión Nacional .....	46
Figura 4. Esquema de un Sistema de Distribución.....	49
Figura 5. Falla de Baja Impedancia.....	51
Figura 6. Falla de Alta Impedancia.....	52
Figura 7.Falla Monofásica a tierra .....	53
Figura 8.Falla Bifásica a tierra .....	53
Figura 9.Falla Bifásica .....	54
Figura 10.Falla Trifásica.....	54
Figura 11.Esquema de una línea corta.....	56
Figura 12. Localizador digital de Falla .....	59
Figura 13. Funcionamiento lógico de un relé.....	65
Figura 14. Esquema Metodológico.....	68
Figura 15. Propuesta Metodológica .....	71
Figura 16. Modelo de SEP-caso estudio .....	72
Figura 17. Simulación del Flujo de carga de SEP-Caso estudio.....	79
Figura 18. Esquema de Potencia del Caso Estudio .....	82
Figura 19. Esquema de Potencia del Caso Estudio en pu .....	84
Figura 20. Esquema de Potencia del Caso Estudio en pu con falla trifásica franca en la barra B1 .....	85
Figura 21. Esquema de Potencia del Caso Estudio en pu con falla trifásica con impedancia en la barra B1 .....	86
Figura 22.Mariposa sencilla y etapas de iteración de la mariposa.....	90
Figura 23. Diagrama Esquemático de la Transformada Discreta de Wavelet.....	92
Figura 24. Neurona Humana .....	104
Figura 25. Red neuronal artificial (Arquitectura de un perceptrón multicapas) .....	104
Figura 26. Modelo de una Red Neuronal .....	106
Figura 27. Modelo de RNA tipo perceptrón aplicado en Matlab.....	110
Figura 28. Neurona con múltiples capas.....	111
Figura 29. Modelo Backpropagation .....	112
Figura 30. Arquitectura de la Red Neuronal Propuesta .....	115
Figura 31. Planteamiento matemático de la Arquitectura de la Red Neuronal Propuesta	116
Figura 32. Progreso del entrenamiento mediante el algoritmo de Regularización Bayesiana y la Transforma Discreta de Fourier .....	118
Figura 33. Histograma de errores en de la red neuronal mediante el algoritmo de Regularización Bayesiana y la Transforma Discreta de Fourier.....	120
Figura 34. Perceptrón con 2 capas ocultas. ....	137

Figura 35. Progreso del entrenamiento mediante el algoritmo de entrenamiento Levenberg-Marquardt y la Transforma Discreta de Fourier .....	141
Figura 36. Histograma de errores en de la red neuronal mediante algoritmo de entrenamiento Levenberg-Marquardt y la Transformada Discreta de Fourier .....	143
Figura 37. Progreso del entrenamiento mediante algoritmo BFGS Quasi-Newton y la Transformada Discreta de Fourier.....	145
Figura 38. Histograma de errores en de la red neuronal mediante el algoritmo BFGS Quasi-Newton y la Transformada Discreta de Fourier .....	148
Figura 39. Progreso del entrenamiento mediante algoritmo Resilient Backpropagation y la Transformada Discreta de Fourier.....	151
Figura 40. Histograma de errores en de la red neuronal mediante el algoritmo Resilient Backpropagation y la Transformada Discreta de Fourier .....	153
Figura 41. Progreso del entrenamiento mediante algoritmo Scaled Conjugate Gradient y la Transformada Discreta de Fourier .....	156
Figura 42. Histograma de errores en de la red neuronal mediante el algoritmo Scaled Conjugate Gradient y la Transformada Discreta de Fourier.....	158
Figura 43. Progreso del entrenamiento mediante el algoritmo de Levenberg-Marquardt y la Transformada Discreta de Wavelet.....	160
Figura 44. Histograma de errores en de la red neuronal mediante el algoritmo de Levenberg-Marquardt y la Transformada Discreta de Wavelet .....	163
Figura 45. Progreso del entrenamiento mediante el algoritmo de Bayesian Regularization y la Transforma Discreta de Wavelet.....	165
Figura 46. Histograma de errores en de la red neuronal mediante algoritmo de Bayesian Regularization y la Transforma Discreta de Wavelet .....	167
Figura 47. Progreso del entrenamiento mediante el algoritmo de BFGS Quasi-Newton y la Transforma Discreta de Wavelet .....	169
Figura 48. Histograma de errores en de la red neuronal mediante el algoritmo de BFGS Quasi-Newton y la Transforma Discreta de Wavelet.....	171
Figura 49. Progreso del entrenamiento mediante el algoritmo Resilient Backpropagation y la Transforma Discreta de Wavelet.....	173
Figura 50. Histograma de errores en de la red neuronal mediante algoritmo Resilient Backpropagation y la Transforma Discreta de Wavelet.....	175
Figura 51. Progreso del entrenamiento mediante el algoritmo Scaled Conjugate Gradient y la Transforma Discreta de Wavelet.....	177
Figura 52. Histograma de errores en de la red neuronal mediante el algoritmo Scaled Conjugate Gradient y la Transforma Discreta de Wavelet .....	179

## LISTA DE GRÁFICAS

Gráfica. 1 Curvas P-V (Caso estudio).....	75
Gráfica. 2 Curvas V-Q (Caso estudio).....	76
Gráfica. 3 Factores de Participación por nodo .....	77
Gráfica. 4 Factores de Participación de Ramas.....	77
Gráfica. 5 Sensibilidades V-Q por nodo .....	78
Gráfica. 6 Variables eléctricas (V, I) ante una FAI en las Barra 1, 2 y 3 con $R_{falla}=60 \Omega$ ....	87
Gráfica. 7 Variables eléctricas (V, I) ante una FAI en las Barra 1, 2 y 3 con $R_{falla}=80 \Omega$ ....	87
Gráfica. 8 Variables eléctricas (V, I) ante una FAI en las Barra 1, 2 y 3 con $R_{falla}=100 \Omega$ ..	88
Gráfica. 9. Armónicos de la señal de Corriente al momento de un falla en la fase A.....	96
Gráfica. 10. Armónicos de la señal de Tensión al momento de un falla en la fase A.....	96
Gráfica. 11. Coeficiente de detalle para la señal de corriente .....	98
Gráfica. 12. Coeficiente de aproximación cA6 para la señal de corriente .....	99
Gráfica. 13. Coeficiente de detalle para la señal de tensión.....	99
Gráfica. 14. Coeficiente de aproximación cA6 para la señal de tensión.....	100
Gráfica. 15. Error cuadrado promedio de la red neuronal mediante el algoritmo de Regularización Bayesiana y la Transforma Discreta de Fourier.....	118
Gráfica. 16. Regresión de la red neuronal mediante el algoritmo de Regularización Bayesiana y la Transforma Discreta de Fourier.....	119
Gráfica. 17. Error cuadrado promedio de la red neuronal mediante algoritmo de entrenamiento Levenberg-Marquardt y la Transforma Discreta de Fourier.....	140
Gráfica. 18. Regresión de la red neuronal mediante el algoritmo de Levenberg-Marquardt y la Transformada Discreta de Fourier .....	142
Gráfica. 19. Error cuadrado promedio de la red neuronal mediante el algoritmo BFGS Quasi-Newton y la Transformada Discreta de Fourier.....	146
Gráfica. 20. Regresión de la red neuronal mediante el algoritmo BFGS Quasi-Newton y la Transformada Discreta de Fourier.....	147
Gráfica. 21. Error cuadrado promedio de la red neuronal con el algoritmo Resilient Backpropagation y la Transformada Discreta de Fourier .....	151
Gráfica. 22. Regresión de la red neuronal mediante el algoritmo Resilient Backpropagation y la Transformada Discreta de Fourier .....	152
Gráfica. 23. Error cuadrado promedio de la red neuronal mediante el algoritmo Scaled Conjugate Gradient y la Transformada Discreta de Fourier.....	156
Gráfica. 24. Regresión de la red neuronal mediante el algoritmo Scaled Conjugate Gradient y la Transformada Discreta de Fourier .....	157
Gráfica. 25. Error cuadrado promedio mediante el algoritmo de Levenberg-Marquardt y la Transformada Discreta de Wavelet.....	161

Gráfica. 26. Regresión de la red neuronal mediante el algoritmo de Levenberg-Marquardt y la Transformada Discreta de Wavelet.....	162
Gráfica. 27. Error cuadrado promedio mediante el algoritmo de Bayesian Regularization y la Transforma Discreta de Wavelet.....	165
Gráfica. 28. Regresión de la red neuronal mediante algoritmo de Bayesian Regularization y la Transforma Discreta de Wavelet.....	166
Gráfica. 29. Error cuadrado promedio mediante el algoritmo de BFGS Quasi-Newton y la Transforma Discreta de Wavelet.....	169
Gráfica. 30. Regresión de la red neuronal mediante el algoritmo de BFGS Quasi-Newton y la Transforma Discreta de Wavelet.....	170
Gráfica. 31. Error cuadrado promedio mediante el algoritmo Resilient Backpropagation y la Transforma Discreta de Wavelet.....	173
Gráfica. 32. Regresión de la red neuronal mediante el algoritmo Resilient Backpropagation y la Transforma Discreta de Wavelet.....	174
Gráfica. 33. Error cuadrado promedio mediante el algoritmo Scaled Conjugate Gradient y la Transforma Discreta de Wavelet.....	177
Gráfica. 34. Regresión de la red neuronal mediante el algoritmo Scaled Conjugate Gradient y la Transforma Discreta de Wavelet.....	178

## LISTA DE ANEXOS

ANEXO A. ANÁLISIS DE MÉTODOS DE ENTRENAMIENTO DE LA RED NEURONAL PROPUESTA ..... **¡Error! Marcador no definido.**

ANEXO B. Diseño e Implementación de la Red Neuronal mediante el procesamiento de las señales eléctricas a partir de Transformada Discreta de Fourier **¡Error! Marcador no definido.**

ANEXO C. Diseño e Implementación de la Red Neuronal mediante el procesamiento de las señales eléctricas a partir de Transformada Discreta de Wavelet **¡Error! Marcador no definido.**

## **RESUMEN**

Este documento describe de forma general el diseño e implementación de un modelo basado en Redes Neuronales para la localización de fallas de alta impedancia en líneas de transmisión eléctrica aéreas. Para la implementación de este modelo, se desarrolló una metodología basada principalmente en las siguientes etapas: caracterización del sistema eléctrico de potencia, extracción y/o adquisición de datos, preparación de los datos mediante técnicas de procesamiento de señales y diseño e implementación de una red neuronal para la localización de este tipo de falla. Esta investigación, tiene como objetivo principal estimar el punto donde ocurrió la falla, mediante la implementación de una red neuronal tipo perceptrón multicapa entrenada con el algoritmo de regularización bayesiana. Con este proyecto se busca ayudar en la reducción del tiempo de respuesta del equipo técnico encargado para solucionar dicho evento cuando se presente en el sistema eléctrico de potencia.

# CAPÍTULO I. ESPECIFICACIONES DEL PLANTEAMIENTO DEL PROBLEMA

## 1.1 Introducción

Las líneas de transmisión son elementos importantes dentro de los sistemas eléctricos de potencia, debido a que por medio de las mismas se transmite toda la energía generada en las centrales eléctricas mediante diferentes fuentes de generación renovables tales como : hidráulica, solar, térmica, eólica, etc. y no renovables como: la nuclear, la fósil entre otras, las cuales a su vez, transportan toda esta energía eléctrica a subestaciones de potencia, para que esta sea distribuida a los usuarios o sectores finales tales como: Residencial, Comercial e Industrial. Es por este motivo, que desde hace tiempo estas han sido objetos de estudios de muchos investigadores [1] [2] [3] [4], debido a que estas presentan constantemente fallas eléctricas en el sistema, las cuales pueden ser ocasionadas por:

- Aislamiento entre las fases a tierra.
- Contacto indirecto con las líneas.
- Contacto de árboles con las líneas.
- Quemadas cercanas por donde pasan las líneas de transmisión.
- Descargas atmosféricas sobre el Sistema Eléctrico de Potencia (líneas, redes, equipos, etc.).

Las anteriores causas ocasionan su vez que el sistema de potencia presente inestabilidad, dando como resultados índices muy bajos de confiabilidad en el mismo. Es por este motivo, que el objetivo principal de varias investigaciones [5] [6] [7] [8] [9] centran su estudio en encontrar soluciones a los problemas y/o efectos que estas tiene sobre el sistema de potencia tales como:

- Inestabilidad en el Sistema Eléctrico de Potencia.
- Bajos niveles de confiabilidad en el Sistema Eléctrico de Potencia.
- Reducción de los índices de calidad del servicio de transmisión, distribución y comercialización de energía.

- Daños en los equipos que estén conectados al sistema que entró en falla en el momento.
- Elevados costos de mantenimiento y restablecimiento del fluido de energía en los tramos afectados del Sistema Eléctrico de Potencia.
- Cambios en los flujos de potencia Sistema Eléctrico de Potencia.

Teniendo en cuenta lo anterior, cabe resaltar que existen diferentes tipos de fallas en el sistema de potencia tales como: Monofásicas, Bifásicas y Trifásicas, las cuales a su vez se dividen en fallas de baja y alta impedancia. Esta última subdivisión se caracteriza principalmente en que: las fallas de baja impedancia, presentan variaciones significativas de corriente y tensión (las cuales pueden ser detectadas con facilidad), mientras que en las fallas de alta impedancia, presentan deltas de variaciones, las cuales en muchas situaciones se pueden confundir por un aumento de potencia en el sistema, ocasionado esto a su vez un problema al momento de determinar su punto de localización de la falla.

A partir de lo expuesto anteriormente, se puede analizar la importancia que radica en desarrollar e implementar metodologías o modelos que permita localizar Fallas específicamente de Alta impedancia en un Sistema Eléctrico, más exactamente en Líneas de Transmisión. El objetivo de esta investigación se centra en estudiar las posibles soluciones que permitan abordar el tema relacionado con la localización de fallas de alta impedancia, la cual no solo radica en detectar a tiempo esta eventualidad y realizar los correctivos y arreglos necesarios, sino que va más allá de mantener el sistema eléctrico estable, por el contrario el principal interés de esta investigación es mantener la integridad de las personas que dependen de estos sistemas, es decir, no solo del equipo técnico que está a cargo del mantenimiento y protección de las redes o líneas eléctricas, sino también a cada uno de los usuarios que están conectado al sistema, ya que el fin último de cualquiera de las empresas prestadoras del servicio de energía es poder brindar a sus usuarios y equipo técnico confiabilidad y estabilidad del sistema eléctrico de potencia al cual pertenecen. Por este motivo, la presente investigación tiene como objetivo principal, diseñar, implementar y evaluar un modelo para la detección de fallas de alta impedancia, tomando como referencia el trabajo desarrollado por Quintero Crespo [5].

La presente investigación ha dividido su estudio en diez capítulos que se resumen a continuación:

En el **Capítulo I: Especificaciones del Planteamiento del Problema**, se describe detalladamente el planteamiento general del problema de la presente investigación, así como también la formulación de las preguntas de investigación que surgen de este mismo, y los objetivos generales y específicos, los cuales direccionarán el desarrollo e implementación del modelo propuesto que permita solucionar en gran medida el problema estudiado.

En el **Capítulo II: Estado del Arte**, se encuentra un análisis del estudio realizado en varias literaturas nacionales e internacionales, que aborda la temática de detección y localización de fallas eléctricas tanto en sistemas de distribución como en sistema de transmisión de energía eléctrica. En este capítulo, también se muestran las ventajas y limitaciones de cada uno de los métodos propuestos, lo cuales ayudarán en el proceso de diseño e implementación del modelo desarrollado en la presente investigación.

En el **Capítulo III: Marco Teórico**, trata temas relacionados a las generalidades de un sistema eléctrico de potencia, tales como: los sistemas de generación, transmisión y distribución de energía eléctrica. Así como también, temáticas relacionadas a los diferentes tipos de fallas eléctricas que se pueden presentar en un SEP teniendo en cuenta las causas y efectos que estas provocan en el sistema eléctrico en general.

En el **Capítulo IV: Métodos y Equipos utilizados para Localizar Fallas en los Sistemas Eléctricos de Potencia**, se describe de forma general algunos de los métodos y/o planteamientos matemáticos, más utilizados en la comunidad para la detección y localización de fallas eléctricas en el sistema. Los métodos estudiados serán: Método de la Reactancia, Método de Schweitzer, Método de Eriksson, entre otros. Así mismo, se realiza un estudio general acerca de los equipos denominados Relés de protección eléctrica, los cuales ayudan en gran parte en el proceso de detección y localización fallas en el sistema.

En el **Capítulo V: Aspectos Metodológicos Propuesto**, en este capítulo se describe de forma detallada cada una de las etapas y planteamientos que se llevarán a cabo en la presente investigación para alcanzar los objetivos propuestos en la misma.

En el **Capítulo VI: Caracterización del Sistema Eléctrico de Potencia**, se muestra la caracterización del sistema eléctrico seleccionado para el caso estudio, el cual contiene: Análisis de estabilidad del SEP y cálculo del flujo de carga en el sistema eléctrico seleccionado, con el objetivo principal de observar y analizar cada una de las características que presente el SEP seleccionado, en relación a la confiabilidad y estabilidad del sistema eléctrico.

En el **Capítulo VII: Adquisición, Extracción y Preparación de los datos**, tiene como objetivo principal realizar el proceso de adquisición de datos por medio de simulaciones de fallas de alta impedancia realizadas en las herramienta SimPowerSystem de Matlab, para posteriormente mediante técnicas de procesamiento de señales, identificar y seleccionar las características (señales de corriente y tensión) que intervienen el proceso de localización de fallas, las cuales serán preparadas como entradas al modelo de Red Neuronal seleccionado para realizar el proceso de localización de la falla.

En el **Capítulo VIII: Estudio e Implementación de Redes Neuronales para el Proceso de Localización de Fallas de Alta Impedancia**, se describe en detalle la formulación, diseño e implementación de Redes Neuronales, una de las técnicas de inteligencia artificial más utilizadas para la localización de fallas en los sistemas eléctricos de potencia. Así mismo, se muestran un estudio general acerca de las principales características del proceso de diseño, entrenamiento, validación y operación de la red.

Finalmente, en el **Capítulo IX: Conclusiones y Trabajos Futuros**, se muestran las conclusiones generales luego de la implementación del modelo y la propuesta sobre algunos trabajos futuros que se podrían desarrollar a partir de la presente investigación.

## 1.2 Planteamiento del Problema

Las entidades prestadoras del servicio de energía eléctrica tanto a nivel nacional como internacional, tales como: Empresas de transmisión, distribución y comercialización, afrontan problemas al momento que se presenta un evento o falla en su sistema eléctrico de potencia. Estas fallas en muchas ocasiones se generan ya sea por algún error humano, descargas atmosféricas o interrupciones inesperadas en el sistema, etc. Dependiendo del número de fases donde se presente la falla, estas se pueden clasificar en: fallas monofásicas, fallas bifásicas y fallas trifásicas.

Una vez detectado el tipo de falla que está afectando el buen funcionamiento del sistema eléctrico, el reto del equipo de trabajo de estas empresas radica en determinar cuál es el punto exacto o por lo menos la zona donde ocurrió este evento, para inmediatamente trasladar su equipo técnico y humano, con el objetivo de solucionar el problema en el menor tiempo posible y de esta forma poder brindar confiabilidad, no solo al sistema eléctrico en general, sino también a sus usuarios. Para solucionar esta situación, a lo largo del tiempo se han desarrollado diferentes investigaciones teniendo como principal interés la temática relacionada con la localización de fallas en los sistemas eléctricos de potencia. Varios autores han investigado acerca de este tema, partiendo si el evento se presenta por una falla de baja o alta impedancia [5] [10].

Las fallas de baja y alta impedancia se diferencian principalmente: en que en las primeras el sistema eléctrico de potencia presenta variaciones significativas de corriente y tensión (las cuales pueden ser detectadas con facilidad), mientras que en las segundas, estas variaciones en muchas situaciones se pueden confundir por un aumento de potencia en el sistema, ocasionado esto a su vez un problema al momento de determinar su punto de localización. Por este motivo, la localización de este tipo de fallas se vuelve un problema para el personal técnico a cargo, al momento analizar y estudiar donde y bajo qué circunstancias ocurrió este tipo de evento.

Con el fin de proveer una herramienta para apoyar la detección y respuesta oportuna ante la localización de fallas de alta impedancia, que no solo ocasiona daños a nivel técnicos sino también gastos a nivel económico, la presente investigación parte de un estudio previo que se realizó en área de transmisión de energía eléctrica en Colombia, denominado: "Desarrollo de un Modelo para la Localización de Fallas en Sistemas de Transmisión de Energía Eléctrica Utilizando

Técnicas De Inteligencia Artificial [5]”. A partir de los resultados y limitaciones de este estudio, se pretende implementar y validar un modelo de localización de fallas en sistemas de transmisión de energía eléctrica. Para esto, se empleará como técnica de inteligencia artificial las Redes Neuronales Artificiales (RNA) para localizar el punto de la falla en una línea de transmisión.

### **1.2. 1 Formulación de las preguntas de Investigación**

Teniendo en cuenta el planteamiento del problema expuesto anteriormente, a continuación se muestra la formulación de las preguntas de Investigación:

- ¿Cuáles son las variables que se deben tener en cuenta al momento de analizar puntos de fallas en una línea de transmisión de un Sistema Eléctrico de Potencia?
- ¿Cuáles son los modelos o técnicas más eficientes que permiten localizar el punto de falla de alta impedancia en una línea de transmisión de un Sistema Eléctrico de Potencia?
- ¿Cuáles son las herramientas que permiten validar las diferentes técnicas o modelos de localización de fallas existentes?

## **1.3 Objetivos**

### **1.3.1 Objetivo General**

- Diseñar, implementar y evaluar un modelo basado en redes neuronales que permita localizar fallas de alta impedancia en un sistema de transmisión de energía eléctrica aéreo.

### **1.3.2 Objetivos Específicos**

- Determinar las principales variables eléctricas que intervienen directamente en la localización de Fallas de alta impedancia, por medio de la caracterización del sistema eléctrico de potencia seleccionado para el estudio.
- Extraer información útil para la localización de fallas de alta impedancia mediante el análisis de las señales eléctricas provenientes de la caracterización del sistema, empleando herramientas matemáticas tales como: Filtro de Kalman, Transformada de Fourier o Transformada de Wavelet
- Evaluar modelos basados en redes neuronales y algoritmos empleados para localizar fallas de alta impedancia en un sistema eléctrico de potencia.
- Validar el modelo propuesto mediante la selección de datos de fallas de alta impedancia extraídos de simulaciones.

## **CAPÍTULO II. ESTADO DEL ARTE**

### **2.1 Introducción**

Las compañías del sector eléctrico en el país y a nivel internacional en general, tales como: Empresas de Transmisión, Distribución y Comercialización de Energía Eléctrica, frecuentemente se ven afectadas por fallas o daños en los sistemas eléctricos de potencia, que no solo ocasionan pérdidas a nivel eléctrico y económico, sino también pueden producir pérdidas humanas. Teniendo en cuenta la problemática expuesta anteriormente, se han desarrollado diferentes investigaciones relacionadas con la temática de localización de fallas en los sistemas eléctricos de potencia, cuyo objetivo principal no es únicamente estudiar las causas que provocan este tipo de fallas eléctricas, sino también todas las posibles soluciones a nivel técnico que se pueden tener en cuenta, no solo para reparar los daños causados sino también para poderlos prevenir.

A continuación, se muestran algunas características principales de varias investigaciones realizadas con la temática de localización y detección de fallas presentadas tanto en redes de distribución como líneas de transmisión eléctrica:

### **2.2 Redes de Distribución**

#### **High impedance fault detection methodology using wavelet transform and artificial neural networks [6]**

En esta investigación se muestra una nueva técnica utilizada para estudiar el problema de detección de fallas de alta impedancia (FAI) en redes de distribución eléctrica partir de la combinación de la transformada Wavelet (WT) y redes neuronales. La metodología utilizada en este estudio es la siguiente:

1. En la primera etapa se analizan las señales de corriente de los alimentadores a través de la transformada Wavelet (WT).
  - Una de las ventajas de utilizar la WT es debido a que su aplicación en el análisis de detección de fallas permitirá: reducir el ruido de las

señales de corriente, descomponer la señal y extraer de características del sistema (consiste en encontrar el parámetro de onda distintivo con información significativa que puedan representar las características principales del problema). En esta investigación se consideró el uso de la transformada discreta de Wavelet (DWT) en lugar de la transformada continua de Wavelet (CWT), con el objetivo de reducir el trabajo computacional y los datos que la CWT requiere.

2. En la segunda etapa se utilizan las redes neuronales artificiales para clasificar el estado de cada alimentador.
  - En esta investigación se utilizan las redes neuronales para aprender la relación entre las entradas y salidas de los vectores de entrada características.
  - La metodología para el uso de las redes neuronales se basa en tres etapas:
    - o Formación: Se basa en proporcionar valores de la desviación estándar de las señales descompuestas para la red neuronal seleccionada, los cuales se extraen de las señales de corriente de varios casos, considerando diferentes operaciones del sistema de distribución.
    - o Verificación: Las configuraciones de la red formada, se verifican mediante la herramienta SARENEUR, en referencia a sus capacidades de generalización bajo situaciones no entrenadas.
    - o Operación: Cuando se concluyen los procesos de formación y las validaciones, las redes resultantes ya están listas para funcionar. Las salidas del método propuesto dan el estado (sano o defectuoso) del alimentador de distribución. Sin embargo, cuando el alimentador está bajo una situación normal, el método vuelve a tomar una nueva ventana de datos después de 32 muestras y esta metodología de detección se repite nuevamente.
  - El modelamiento del método planteado en esta investigación se realiza con el objetivo de obtener las señales de datos relevantes del sistema eléctrico de potencia, bajo diferentes condiciones de operación.

Las fortalezas que presenta esta investigación son las siguientes:

- La implementación de la transformada discreta de Wavelet para el análisis de la señal, permite detectar tanto las discontinuidades en la señal como los momentos en los cuales se presentan los cambios de frecuencia en proceso que se está analizando, lo cual es muy útil al momento de analizar los diferentes eventos que se presentan en el SEP<sup>1</sup>.
- La transformada discreta de Wavelet (DWT) reduce el trabajo computacional al momento de analizar el comportamiento de la señal.

Algunas de las limitaciones que presenta esta investigación, radica en que el uso de este tipo de transformada para bajas frecuencias presenta buena resolución en cuanto frecuencia pero baja resolución en cuanto tiempo, lo cual que permite analizar que para el caso estudio, el análisis del tiempo de actuación de la falla no podrá ser analizado en su totalidad debido a esta característica [11].

### **Adaptive Kalman filter and neural network based high impedance fault detection in power distribution networks [12]**

En esta investigación los autores implementan una técnica de reconocimiento de patrones híbridos por medio del uso de filtros adaptables extendidos Kalman y redes neuronales para la detección y clasificación de fallas de alta impedancia (FAI). Estos filtros son estimadores estocásticos de dominio de tiempo no lineal, los cuales permiten realizar una buena estimación de los componentes armónicos generados por las corrientes de fallas que se generan al momento de ocurrir el evento. El objetivo de esta investigación se centró en lograr combinar las redes neuronales con los filtros extendidos de Kalman para diseñar un detector de FAI partiendo de cada una de las variaciones y condiciones a las cuales se encuentra expuesto el sistema eléctrico de potencia. Esta investigación basa su estudio en dos tipos de sistemas: subestaciones de distribución radial y red tipo malla, las cuales fueron analizadas a partir de los resultados de las simulaciones realizadas a estos sistemas eléctricos. Los sistemas fueron simulados a partir de cargas lineales y no lineales, las cuales fueron expuestas a varias condiciones para observar cada uno de sus comportamientos. Para representar las cargas no lineales utilizaron un rectificado de 6 pulsos.

---

<sup>1</sup> SEP: Sistema Eléctrico de Potencia

Una de las fortalezas que presenta esta investigación es la siguiente:

- La implementación de filtros de Kalman, permiten estimar el estado futuro de un sistema a partir del filtrado óptimo de la señal de salida del mismo. En este caso, el estado futuro que se va a estimar corresponde a las componentes armónicas de las corrientes que se producen durante la falla de alta impedancia. Si se logra determinar estas componentes, se podría realizar un modelamiento más detallado para describir cada uno de los cambios que provoca este tipo fallas y con esto lograr diseñar mecanismos de reacción oportunos que permitan optimizar la localización acertada de la falla y por ende la estabilización del sistema eléctrico.

Algunas de las limitaciones que presenta este estudio son:

- La ganancia generada por la utilización del filtro de Kalman es independiente a las medidas, de esta forma el estado estable comienza a ser menos sensible a los parámetros de variación con los cuales se está evaluando el sistema y empieza a perder la habilidad de seguimiento de tiempo de los parámetros variables.
- Para el caso de análisis en sistemas no lineales se utiliza el filtro de Kalman extendido, el cual presenta la desventaja que para sistemas no lineales se requieren más cálculos y más tiempo para su implementación en una aplicación específica [13].
- Para implementar el filtro de Kalman se requieren condiciones iniciales del sistema a modelar tales como: la media y la varianza del vector estado para iniciar el algoritmo recursivo [13].

## **The artificial neural-networks-based relay algorithm for the detection of stochastic high impedance faults [14]**

En esta investigación se muestra un estudio práctico de una red neuronal basada en un algoritmo de relé para la detección de fallas de alta impedancia. El modelo desarrollado permite reconocer las distorsiones tanto de corriente como de tensión que se producen al momento de generarse la falla de alta impedancia en el sistema eléctrico, lo cual permite analizar en gran parte el comportamiento de este evento sobre el sistema y de esta forma permite actuar inmediatamente sobre los equipos o elementos que este afectado el sistema en general.

Las redes neuronales fueron entrenadas por la alimentación con los vectores de entrada (magnitudes o ángulos de fase de los armónicos de bajo orden, las cuales podrían ser consideradas para revelar la presencia de fallas de alta impedancia) y de salidas correspondientes. En este estudio se utilizaron dos redes neuronales: una de perceptrón y otra de propagación. Las primeras tienen una estructura de red menos compleja pero su salida se encuentra limitada únicamente por dos valores: 0 o 1 (la lógica 0 y 1 representan la ausencia o presencia de falla respectivamente), mientras que la red de propagación emplea una arquitectura más compleja, además de ofrecer salidas análogas, las cuales requieren de más análisis que las primeras.

En el esquema de detección, los datos del conjunto de entrenamiento fueron obtenidos a partir de los resultados arrojados de la simulación de un sistema típico de distribución. Debido a que las perturbaciones resultantes de las FAI<sup>2</sup> pueden parecerse a las conmutaciones de los condensadores y el cambio del Tap de transformador, lo cual hace necesario incluir contingencias al sistema para asegurarse que las redes neuronales no sean confundidas por el alto nivel de armónicos generados.

---

<sup>2</sup> FAI: Fallas de Alta Impedancia

Algunas de fortalezas que presenta esta investigación son:

- La Red neuronal entrenada reacciona muy rápidamente ante una falla de alta impedancia.
- El esquema de detección empleado solo utiliza bajos armónicos de las cantidades residuales, lo cual mejora en gran medida su viabilidad y flexibilidad.

Este modelo presenta algunas limitaciones tales como:

- Se deben crear una serie de contingencias al sistema para que las redes neuronales no se confundan al momento de operar, es decir, si se presenta un evento y este no estuvo en la parte del enteramiento de misma, la red muy probablemente no lo va a detectar y por el contrario se confundirá con otras características del sistema, como por ejemplo: que estas puedan confundir al relé de falla de alta impedancia debido ya sea a: la conmutación de los condensadores, cambio de líneas monofásicas o conmutación de cargas no lineales.

## **2.3 Líneas de Transmisión**

### **Transmission lines fault location using transient signal spectrum [7]**

En esta investigación se presenta un método para localizar fallas en las líneas de transmisión por medio del uso de la Transformada Rápida de Fourier (FFT), la cual permite realizar un análisis del tiempo en el dominio de la frecuencia para los primeros armónicos generados por las fallas mediante la implementación de la teoría de onda de la línea de transmisión. En este método se utiliza el análisis del espectro de la señal transitoria para determinar la distancia a la cual ocurrió la falla mediante la aplicación de la FFT.

Los espectros de frecuencia son obtenidos mediante la FFT de las señales transitorias medidas de uno de los terminales de la línea de transmisión, la cual se utiliza para detectar el tiempo de viaje de la onda de falla generada.

El modelo simulado en este estudio consta de una línea de transmisión de 240km 400kV, sobre la cual se simularon 4 diferentes tipos de falla en un sistema

eléctrico de potencia, tales como: línea a tierra (LG), línea a línea (LL), doble línea a tierra(LLG) y falla trifásica simétrica(LLL) mediante el uso de la herramienta computacional ATP.

Una de las limitaciones que presenta este modelo es que especialmente para bajas frecuencias la resolución de espectro de la FFT afecta la precisión al momento de estimar la distancia a la cual ocurrió la falla. Por este motivo, es necesario que para aumentar la resolución de la frecuencia de la FFT se deben añadir más ceros a la señal muestreada de la ventana. Otros de los efectos que puede afectar la precisión, es en este caso la presencia de elementos reactivos tales como la inductancia de la fuente, pero esta restricción como se muestra en este estudio, puede ser superada mediante la distribución de la inductancia de la fuente a través de la línea.

La fortaleza que presenta este modelo es que este método puede ser aplicado para varias situaciones de fallas como las descritas anteriormente. Así mismo, este modelo ha demostrado que la inductancia de la fuente afecta en la precisión de la localización de la falla y por este motivo en la investigación se propuso un algoritmo que permite eliminar casi por completo esta restricción.

### **Fault location on transmission lines using complex-domain neural networks**

[2]

El artículo propone una aplicación de redes neuronales en el dominio complejo para el mapeo de la relación entre las señales eléctricas y la localización de fallas en las líneas de transmisión. Este tipo de redes [15] [16] se han desarrollado para evitar el fraccionamiento de las partes reales e imaginarias de las variables con valores complejos. Además, en esta investigación se muestra que el tema de localización de fallas se puede mejorar si la combinación del procesamiento de la señal y la selección del modelo también consideran el dominio apropiado para las variables de entrada (fasores de corrientes y tensiones de pre y post-falla).

Para la implementación del modelo propuesto en esta investigación, se utilizaron datos reales provenientes de una línea de transmisión de 440kV en el sureste de Brasil. Esta línea se representó mediante una conexión en cascada con circuitos individuales como una línea de transmisión real. Cada línea de transmisión no transpuesta fue representada por un modelo de frecuencia dependiente con una matriz de transformación constante, esto debido a que permite que el sistema simulado esté más cerca de la realidad y que las líneas de transmisión tengan un menor número de armónicos.

El modelo propuesto de localización de fallas sigue básicamente la siguiente metodología: las variables de entrada que se utilizan para estimar el modelo de la red neuronal propuesta son adquiridas de los fasores de corriente y tensión de pre y post-falla. Luego, se procesan un segundo conjunto de datos que almacenan señales transitorias electromagnéticas, en dos nuevas bases de datos (una proveniente de la transformada discreta de fourier y otra de la transformada estacionaria de wavelet).

La limitación que se presenta al utilizar la transformada de fourier es que cuando se requiere analizar una señal, es difícil decir cuando se lleva a cabo un evento en particular, lo cual se debe a que las funciones básicas utilizadas en el análisis de Fourier, están definidas en el dominio de la frecuencia.

Una de las fortalezas que se encuentra en este modelo es que concluye que la ganancia proporcionada por el uso de una red neuronal en el dominio complejo es mayor que la que se produce por un análisis de multiresolución.

### **Desarrollo de un Modelo para la Localización de Fallas en Sistemas de Transmisión de Energía Eléctrica Utilizando Técnicas De Inteligencia Artificial [5]**

Esta investigación se desarrolló un modelo que permite localizar las fallas en los Sistemas de transmisión de Energía basándose principalmente en redes neuronales artificiales (RNA) y sistemas de inferencia neuro-difusos adaptativos (ANSI). Estas técnicas se utilizaron para la localización de fallas monofásicas a partir de análisis de 30300 datos que fueron obtenidos de varias simulaciones realizadas a un sistema de transmisión de energía con un nivel de tensión de 230kV, una longitud mayor a 100km.

El esquema propuesto fue offline, es decir, inmediatamente después que ocurra el evento o falla en el sistema eléctrico de potencia (SEP) y teniendo en cuenta los registros de oscilopertográficos generados antes y después de esta perturbación en el sistema, se inicia el análisis y procesamiento de los mismos, para que posteriormente sean utilizados para alimentar la base de datos del modelo desarrollado. Cabe resaltar que este modelo, puede detectar o localizar tanto Fallas de alta impedancia monofásicas como Fallas de baja impedancia.

La metodología desarrollada por esta investigación es la siguiente:

1. Realizar la caracterización del sistema de transmisión del caso estudio. Esta caracterización, debe incluir parámetros y características generales del sistema tales como: longitud de la línea, impedancia de los elementos de SEP (generadores, transformadores, conductores, etc.) y el esquema de protección, es decir, la configuración de cada uno de los elementos de protección utilizados en SEP, con el objetivo de conocer cuáles son los tiempos de respuesta ante cualquier eventualidad, para aislar la falla y proteger los equipos o elementos conectados al mismo.
2. Obtener los registros de osciloperturbografía del SEP antes y después de falla, para realizar posteriormente el análisis y acondicionamiento de estos datos mediante la aplicación de varias transformaciones matemáticas y filtros, los cuales permitirán obtener a su vez cada una de las variables de mayor interés para el estudio y detección de las fallas. En esta etapa se extraen las características de las señales de entrada (corrientes y tensiones) de los registros de osciloperturbografía.
3. Realizar acondicionamiento de las señales que se obtienen de estos registros del SEP.
4. Detectar el tipo de falla que ocurre en el SEP, para poder conocer cuál es la metodología con el cual se abordará el problema.
5. Análisis de las variables y armónicos de las señales. Las variables y los armónicos se calcularon mediante la diferencia de un ciclo completo de corriente y voltaje en pre-falla y post-falla. Los armónicos fueron obtenidos a través de un filtro digital, mediante el uso de un filtro de Fourier.
6. A partir de análisis del comportamiento de las variables de interés, se determinan cuáles son los factores que influyen o representan mejor al evento o fenómeno, mediante un análisis adimensional, denominado: "Teorema de Pi de Vaschy-Buckingham".

Al finalizar estas etapas de análisis, se inicia el proceso de localización de falla a partir de dos técnicas: la primera es un método que permite obtener un resultado directo mediante la utilización de redes neuronales y la segunda permite obtener un resultado indirecto por medio de sistema de inferencia difusa-ANFIS. La aplicación de estas técnicas da como resultado final, la distancia a la cual se encuentra localizada la falla.

A continuación se presenta algunas de las fortalezas de este modelo:

- Implementan técnicas como redes neuronales y sistemas de inferencia difusa-ANFIS, las cuales permiten mejorar el proceso de detección y localización de fallas en el sistema eléctrico de potencia, debido a que estas técnicas a partir de registros a priori logran obtener generalidades posteriores para nuevos casos o eventos.

Algunas de las limitaciones que presenta el modelo son:

- Una de las limitaciones que presenta esta investigación es que no considera otras características de las fallas tales como: causas del evento, detección de los equipos donde se presenta la falla y seguimiento y monitoreo de los equipos de protección que intervienen en el buen funcionamiento del SEP.
- Una red neuronal solo se entrena para un problema específico [17], es decir, no pueden tratar más de un lineamiento a la vez. Por este motivo, en este caso estudio solo es utilizada para el análisis de detección de la falla y no para detectar el tipo o la causa de la misma, para ello se debe hacer uso de otra técnica que permita el análisis de múltiples efectos.

### **Real time evaluation of DWT-based high impedance fault detection in EHV transmission [18]**

En este artículo se expone un algoritmo para la detección de FAI a partir de una serie de pruebas en tiempo real realizadas en líneas de transmisión de alta tensión. El principio matemático utilizado en esta investigación es el análisis de la transformada de Wavelet. Este algoritmo utiliza un método muy recursivo para lograr sumar los valores absolutos de las señales de alta frecuencia generadas durante un ciclo. De esta forma, este método presenta una limitación en cuanto a la reconstrucción de la señal, esto debido a que solo toma los valores de las señales de alta frecuencia y las de baja frecuencia no, comportándose de esta forma como un filtro pasa alto de señales. Los resultados arrojados por esta investigación muestran que este método presenta la ventaja de que puede detectar las FAI en las líneas de transmisión EHV, pero con la limitación de que solo se puede detectar a la mitad de un ciclo desde el instante que se presentó.

## **A new and accurate fault location algorithm for combined transmission lines using Adaptive Network-Based Fuzzy Inference System [4]**

En este artículo se presenta un nuevo algoritmo que permite localizar fallas en sistemas combinados de líneas de transmisión aéreas y subterráneas por medio de la implementación de Redes adaptativas basadas en sistemas de inferencia difusa. Este algoritmo de localización de falla se lleva a cabo en tres etapas incluyendo: clasificación de tipo de falla, detección de la sección donde se encuentra la falla y la ubicación de la falla. En el modelo propuesto, se utilizan 10 redes ANFIS de las cuales: 1 red es para la clasificación del tipo de falla, otra red es para la detección de la sección donde se presenta la falla y las otras 8 redes restantes se utilizan para la localización de la falla (2 por cada tipo de falla).

Estas redes emplean dos métodos de aprendizajes. El primer método, se hace un paso hacia adelante mediante parámetros actuales para optimizar reglas consecuentes a los parámetros por medio de la estimación de mínimos cuadrados basados en el error de salida. En segundo método, denominado aprendizaje híbrido se realiza un paso hacia atrás para modificar los parámetros de premisa utilizando un aprendizaje basado en el gradiente.

La ventaja que presenta este modelo es que debido a la metodología utilizada para la localización de falla se mantuvo un error máximo por debajo del 0,07%, lo que indica un grado bueno de efectividad en la implementación del mismo.

Una de las limitaciones que presenta este modelo, que se su procesamiento es secuencial, es decir, ejecuta cada una de las actividades paso a paso y no de forma simultánea, lo que podría permitir tener como ventaja con respecto a otros modelos, es que sus redes puedan comunicarse entre sí, permitiendo esto un mejor rendimiento del sistema en general. Así mismo, otra de las limitaciones que se generan al utilizar estos sistemas inteligentes radica en que su entrenamiento debe ser lo más preciso posible, debido a que estos sistemas se entrenan para actividades específicas, cuando se les presente un evento diferente al aprendiendo en el entrenamiento, no va a tener la capacidad de responder inmediatamente ante este cambio sino por el contrario, solo podrá responder en una segunda ocasión cuando se le presente nuevamente un evento con estas mismas características y en este momento, si podrá funcionar debido a que ya lo ha aprendido de una experiencia anterior.

### **Performance Evaluation of an Adaptive-Network-Based Fuzzy Inference System Approach for Location of Faults on Transmission Lines Using Monte Carlo Simulation [19]**

Esta investigación se basa en un análisis de multiresolución de la transformada de Wavelet(MRA) mediante el uso de redes adaptativas y sistemas de inferencia difusa, las cuales son utilizadas para superar las dificultades asociadas a las mediciones de voltaje y corriente que se presentan al momento de localizar fallas en la líneas de transmisión. El método empleado en esta investigación difiere de otros, ya que presenta la ventaja de que implementa cálculos determinísticos por medio de uso de la transformada de wavelet y técnicas inteligentes como: Sistemas de inferencia adaptativo neurodifuso(ANFIS), Sistema de inferencia difusa(FIS) y Redes neuronales artificiales (ANN) con el objetivo de obtener información o datos relevantes que permita abordar el tema de detección de fallas. Los datos obtenidos se validan a través de las simulaciones de MonteCarlo, método estadístico que permite representar de forma aleatoria una aproximación de la localización de la falla. Una de las limitaciones que presenta esta metodología, es que al momento de utilizar sistemas inteligentes es necesario contar con equipos que cumplan con alta potencia de procesamiento, lo cual en términos económicos es un poco costoso.

### **Fault Detection and Classification in Transmission Lines Based on Wavelet Transform and ANN [20]**

Esta investigación tiene como objetivo desarrollar una metodología que permita detectar y clasificar fallas en las líneas de transmisión mediante el uso de registros oscilograficos de fallas que ha ocurrido en el sistema eléctrico de potencia, mediante la implementación de redes neuronales entrenadas para clasificar las fallas por medio de las señales de corriente y tensión obtenidas en los registros oscilográficos.

El algoritmo propuesto por los autores consta de dos parte: la primera hace referencia a la Detección de fallas, en las cuales las entradas son las corrientes y tensiones tomadas de los registros que se guardan durante la falla ; y la segunda hace referencia a la clasificación de fallas, en la cual se hace un análisis de las corrientes y tensiones obtenidas en los registros y mediante la implemnetación de redes neuronales, se clasifican estos eventos según las características que presenten cada uno.

En el modulo de detección, las etapas que se desarrollan son: Normalización de la corriente, detección de la falla e identificación de la falla. Finalmente, en el modulo de Clasificación se desarrollan las siguientes actividades: Normalización de tensiones y corrientes, Remuestreo de tensiones y corrientes(en esta etapa se convierte de una frecuencia alta de muestreo a una frecuencia más pequeña eligiendo para este caso 1200Hz), Tensiones y corrientes de ventana y clasificación de fallas. Cabe resaltar , que en esta última etapa la salida de la red neuronal indica el tipo de falla que esta relacionado como: 1 (estado de falla) y 0 (estado sin falla).

### **A Novel Algorithm for Fault Classification in Transmission Lines using a combined Adaptive Network and Fuzzy Inference System [9]**

Debido a la importancia que radica en la detección oportuna y acertada de los diferentes tipos de falla tanto de baja impedancia como de alta impedancia en las líneas de transmisión eléctrica, en este trabajo los autores proponen un algoritmo que permite detectar y clasificar el tipo de falla (alta y baja impedancia) en el SEP a partir de un modelo de inferencia difusa basadas en una red adaptativa (ANFIS). Donde la inferencia va indicar si hay alguna situación de falla o no, es decir, si la inferencia es cero significa que no hay de falla sistema y por el contrario los resultados de inferencia son distintos de cero, entonces indica que hay presencia de algun tipo de falla en el sistema.

Este algoritmo permite clasificar los valores RMS de las corrientes de fase en combinación con las corrientes de secuencia cero con el objetivo de: adquirir corrientes trifásicas, calcular las corrientes de secuencia cero y deducir el tipo de falla a través de los sistemas ANFIS. En este sistema, las variables de entrada son las señales de corriente con base a las corrientes trifásicas y a la corriente de secuencia cero del mismo.

El modelo estudiado, es un sistema electrico de potencia Coreano de 154kV, compuesto de un línea de transmisión de 26km, dos fuentes generadoras de 240 MVA y 180MVA en ambos extremos de la línea, en los cual los datos de fallas son generados a partir de varias condiciones de falla como: la variación en la distancia de falla, el angulo inicial de falla y los diferentes tipos de falla con una tasa de muestreo de 64 muestras por ciclo.

La ventaja que se presenta al momento de implementar sistemas difusos es que son favorables porque su comportamiento se puede explicar por medio de reglas difusas y su desempeño se puede ajustar por medio de estas reglas. Pero, estos sistemas también presentan una serie de limitaciones que radica básicamente en la adquisición de conocimiento, ya que el universo de discurso de cada variable debe ser dividido en intervalos, por lo que de esta forma, los problemas que puede abordar este tipo de sistema se restringen a utilizar un número pequeño de variables de entrada, por lo cual en el caso de detección de una falla, este modelo limita el análisis de múltiples variables en el sistema, impidiendo de esta forma observar cómo influyen estas o no sobre el sistema en el cual están actuando [21]

### **A Fault Location Algorithm for Transmission Line based in Distributed Parameter [22]**

En esta investigación se desarrolla un algoritmo que permite localizar fallas basado en parámetros distribuidos mediante muestreos sincronizados con el Sistema de Posicionamiento Global (GPS). Este algoritmo de búsqueda solo tiene los parámetros de la línea y los datos sincronizados desde ambos extremos, y consiste en introducir los datos procedentes de los dos extremos de la línea, lo cual requiere de una sincronización de tiempo. El localizador de fallas consiste básicamente en un equipo de adquisición de datos y un receptor GPS como el proveedor de temporización para cada extremo. La ventana de datos utilizados en el cálculo contiene los datos posteriores a la falla de uno o dos ciclos.

En este modelo las componentes de fase se transforman en componentes del modelo para desacoplar las redes polifásicas en redes monofásicas desacopladas o independientes, lo cual se lleva a cabo mediante la aplicación de la teoría de nodos y la teoría de la matriz de función.

La simulación de este algoritmo se realizó mediante la herramienta de simulación EMTP para las siguientes fallas: fase-tierra, dos fases a tierra, fase a fase y tres fases a tierra.

La ventaja que presenta este modelo, es que debido a que el algoritmo implementado se basa en parámetros de distribución en la línea, este permite eliminar el efecto de la capacitancia en paralelo y por ende mejorar significativamente la precisión del algoritmo para localizar las fallas. Así mismo,

permite mostrar que la localización de la falla es independiente a la distancia a la cual ocurre el evento, al tipo de falla y al ángulo de falla.

Unas de la limitaciones que presenta este modelo, es que debido a que utiliza un GPS como receptor para cada extremo de la línea, la precisión de la localización de la falla dependerá en gran parte de: los fenómenos atmosféricos, la configuración espacial, cobertura de señal, entre otros.

### **A new approach to fault location in two-terminal transmission lines using artificial neural networks [1]**

En este artículo se presenta un método que permite determinar a que distancia se produce una falla en una línea de transmisión de dos terminales, utilizando redes neuronales artificiales(ANN) mediante el análisis de las variables de entrada , las cuales son las componentes fundamentales de 50 y 60Hz de las tensiones y corrientes de falla y pre-falla.

La metodología utilizada en esta investigación para implementar la red neuronal en el proceso de localización de fallas en líneas de transmisión es la siguiente:

- Selección de una arquitectura de red adecuada: uno de los factores que determinan el tamaño y la estructura adecuada de la red son el número de entradas y salidas del sistema, ya que cuando menor sea el número de entrada el tamaño de la red se reduce.
- Aprender a seleccionar las reglas en el sistema: la regla de aprendizaje de propagación hacia atrás es utilizada para ajustar los pesos y sesgos de las redes para minimizar la sumatoria del cuadrado del error.
- Proceso de formación: en esta etapa se deben seleccionar los ejemplos más representativos de las características fundamentales del sistema, los cuales servirán como entrenamiento para el aprendizaje de la red en situaciones específicas. Para el proceso de entrenamiento se utilizó el software FALNEUR.
- Verificación del comportamiento de la red: al finalizar el proceso de entrenamiento, el siguiente paso es verificar como es el comportamiento de la red ante situaciones con previo aprendizaje y en situaciones completamente diferentes a las aprendidas en el proceso de formación.

Una de las fortalezas que presenta este modelo, es que por medio de la implementación de las redes neuronales, el error promedio en el proceso de determinación de la distancia de falla durante el entrenamiento fue inferior al 0,12%.

Una de las limitaciones que presenta este método es que cuando se tienen bajos niveles en el proceso de formación se presenta el riesgo de que la red no responda correctamente ante situaciones distintas a las entrenadas durante este proceso.

### **Protective relay testing and characteristic analysis for high impedance faults in transmission lines [23]**

Dada la importancia de analizar no solo el punto de falla en el SEP, sino también los elementos o equipos de protección que intervienen en el sistema en general, esta investigación cuenta con la ventaja de presentar un método de prueba de relés de protección que se utilizan para detectar fallas de alta impedancia, lo cual es muy importante debido a que al momento que se presente cualquier eventualidad en el sistema es necesario que este, cuente con un excelente esquema de protecciones que permitan aislar la falla del sistema en tiempo relativamente cortos, esto para evitar daños graves o más aún daños irreparables al sistema y las cargas que este conectadas al mismo al momento de presentarse el evento.

En esta investigación se estudian tanto relés de distancia como relés diferenciales, los cuales son muy utilizados para este tipo de aplicaciones. Estos equipos dependiendo de las características de protección que manejan, se ubican en cada una de las zonas por las cuales está delimitada SEP, esto con el objetivo de proteger el sistema en general.

Cada uno de estos relés se prueban utilizando RTDS (Simulador digital en tiempo real) y RTPS (Simulador de reproducción en tiempo real). Posteriormente se realizan una serie de comparaciones entre estos equipos para analizar la disponibilidad que presentan para detectar una FAI, dando como resultado que los relés tipo cuadriláteros muestran una mejor disponibilidad para detectar fallas que los relés tipo mho. Una de las limitaciones que podría presentar este método, es que debido a las características que presenta una FAI, las cuales en varias ocasiones se confunden por aumentos del carga en cualquier punto en el sistema, si estos equipos no son programados adecuadamente, podrían confundir estos aumentos de carga, con el evento que en realidad está sucediendo en este instante de tiempo y por ende no podría actuar a tiempo para aislar la falla del sistema.

## **An Artificial Neural Network based Real-Time Fault Locator for Transmission Lines [24]**

Esta investigación se basa en una aplicación de redes neuronales para describir algoritmo, de un localizador de falla para una terminal de una línea de transmisión a partir del análisis de las variables de entradas a la Red Neuronal, las cuales corresponden a los fasores de pre-falla y a datos de corriente y tensión de todas las fases de la línea de transmisión. La implementación del algoritmo propuesto, permite dar como salida del sistema, la posición a la cual ocurre la falla y la resistencia de la falla.

El sistema eléctrico de potencia utilizado para este estudio fue una línea de transmisión de 400kV 300 km con dos barras.

Para el desarrollo del algoritmo se asumieron varios supuestos, dentro de los cuales caben resaltar que: las condiciones de pre-falla son los estados estacionarios normales, las impedancias en ambos extremos de la fuente son simétricas (siguen siendo las misma ante y durante de la falla), se delimitó la amplitud y el ángulo entre la tensiones en las barras. Así mismo, se seleccionaron tres capas feed-forward para implementar el algoritmo de búsqueda o detector de falla, igualmente para arquitectura del mismo, se utilizó como función de transferencia para la capa oculta la función  $\tanh^3$  y para la capa de salida una función lineal.

Debido a que la red neuronal diseñada debe cubrir todo el sistema y las condiciones de falla, tales como: carga de pre-falla, localización y resistencia de la falla, en este modelo se encuentra que una de sus fortalezas, es que para obtener un buen rendimiento del sistema, se decide dividir la red neuronal en subredes neuronales de acuerdo a la condición de pre-falla medida en el extremo local. Teniendo en cuenta lo anterior, en los resultados de esta investigación se muestra que en todos los casos simulados, la localización de la falla basada en redes neuronales puede ser estimada con un error menor del 1%. Así mismo, muestra que cuando la impedancia de la fuente en el extremo remoto varía, la red neuronal es capaz de tomar una decisión interna para conocer en cual fuente se debe aplicar.

Una de las limitaciones que presenta este modelo es la utilización de la técnica de optimización del algoritmo Levenberg-Marquardt, para la etapa de entrenamiento

---

<sup>3</sup> Tangente hiperbólica

de la red, debido a que pesar de ser muy potente para este tipo de aplicaciones necesita de una gran cantidad de almacenamiento de memoria para su procesamiento.

## **2.4 Conclusiones**

Teniendo en cuenta las anteriores investigaciones se puede concluir:

- Cuando se diseñan o implementan metodologías para la detección y localización de fallas es recomendable seguir una serie de actividades o pasos tales como: Caracterización energética de sistema de potencia del caso estudio, simulaciones y/o adquisiciones de datos de pre y post-falla, extracción de las variables más importante que interviene en el proceso de detección y localización de la falla, normalización de los variables mediante planteamientos matemáticos tales como: Transformada de Fourier, Wavelet, etc., y desarrollo e implementación de técnicas de inteligencia artificial para localización y detección de fallas.
- En el proceso de extracción y normalización de los datos es recomendable implementar planteamientos matemáticos como las transformadas discretas: Fourier o Wavelet, debido a que estas permiten reducir el trabajo computacional al momento de analizar el comportamiento de la señal.
- Cuando se implementan técnicas como redes neuronales y sistemas de inferencia difusa-ANFIS, en el proceso de localización y detección de fallas, estas permiten mejorar dicho proceso, debido a partir de registros a priori logran obtener generalidades a posteriori para nuevos casos o eventos.
- Es recomendable controlar la etapa de entrenamiento de la red neuronal, debido a que si estas son sobre entrenadas pueden llegar confundirse y al momento de mostrar la respuesta o salida, estas puedan presentar alto nivel de error.

## CAPÍTULO III. MARCO TEÓRICO

### 3.1 Introducción

El siguiente capítulo tiene como objetivo realizar un estudio detallado acerca de los principales conceptos que permitirán llevar a cabo el desarrollo de la presente investigación. Dentro los conceptos, metodologías y formulaciones matemáticas que se desarrollaran en el presente capítulo se relacionan los siguientes ítems:

Generalidades del sistema eléctrico de potencia, donde se explican en detalles las principales características que se lleva a cabo en el proceso de generación, transmisión y distribución de energía en Colombia. Así mismo, se estudian conceptos relacionados a los diferentes tipos de fallas que se pueden presentar en el sistema eléctrico de potencia y las metodologías utilizadas para la localización y detección de fallas mediante el diseño e implementación de modelos de inteligencia artificial.

### 3.2 Generalidades de un Sistema Eléctrico de Potencia

Un Sistema Eléctrico de Potencia está constituido principalmente por:

**3.2.1 Sistemas de Generación:** Las centrales generadoras son las encargados de generar o producir energía eléctrica por medio de fuentes convencionales o no convencionales de energía [25], los cuales que se encuentran conectadas al Sistema Interconectado del país, tales como:

- **Centrales Hidráulicas:** La energía hidráulica es una de las fuentes de energía renovable más utilizadas a nivel mundial, la cual es obtenida mediante la energía cinética y potencia I provenientes de corrientes de agua, las cuales caen a diferentes niveles de altura a una turbina hidráulica que convierta todo la energía mecánica del movimiento de sus aspas en energía eléctrica. Como se indica en [26] el uso de la energía hidráulica representa aproximadamente un 19% de la producción total de electricidad

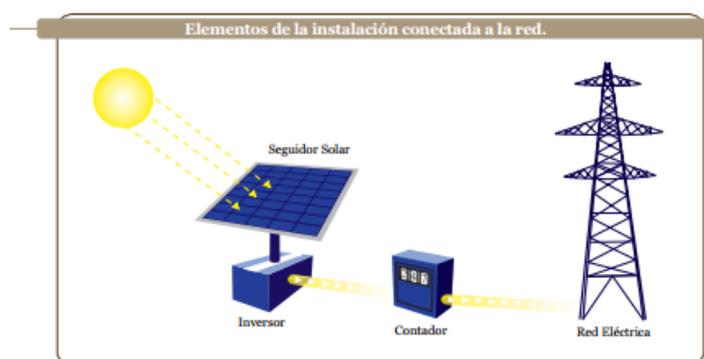
a nivel mundial, siendo Canadá el generador más importante de energía hidráulica, seguido de Estados Unidos y Brasil.

- **Centrales Térmicas:** En este tipo de centrales eléctrica, se genera electricidad a partir de la energía liberada en forma de calor de la combustión de combustibles fósiles como el carbón, petróleo, gas natural [25]. En la cual el calor liberado, es utilizado para mover las turbinas de vapor o gas, por medio de las cuales se transforma esta energía en energía eléctrica.

Igualmente, existen otras fuentes de energía denominadas fuentes no convencionales de energías, dentro de las cuales se encuentran principalmente:

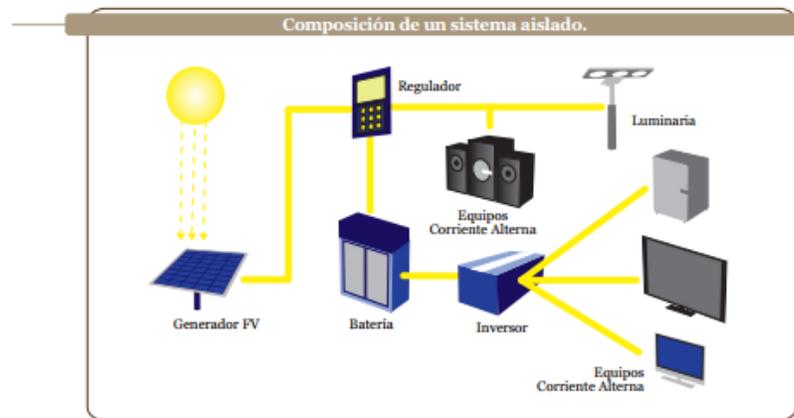
- **Centrales Eólicas:** En este tipo de centrales tienen como actividad generar energía a partir de la energía cinética proveniente de viento. También es denominada un tipo de energía Renovable [25].
- **Centrales Fotovoltaicas:** En estas centrales se convierte toda la energía proveniente de la luz o radiación solar en energía eléctrica por medio del uso de celdas fotovoltaicas [25]. Existen dos formas de realizar instalaciones fotovoltaicas [27], las cuales son: Sistemas conectados a la red eléctrica (Figura 1) e Instalaciones aisladas de la red eléctrica (Figura 2).

**Figura 1. Sistemas Fotovoltaicos conectados a la red eléctrica**



Fuente: Sistema Riojano de Innovación, Gobierno de la Rioja, Agencia de Desarrollo Económico de la Rioja, . P. R. d. A. I. Globaltech Rioja y F. E. d. D. R. Comisión Europea, «Estudio de BenchMarking Tecnológico Internacional Sector Energía Solar Fotovoltaica,» 2008. [En línea]. Available: [http://www.ader.es/fileadmin/redactores/PUBLICACIONES/Estudios/Estudio\\_Benchmarking\\_sector\\_fotovoltaico.pdf](http://www.ader.es/fileadmin/redactores/PUBLICACIONES/Estudios/Estudio_Benchmarking_sector_fotovoltaico.pdf). [Último acceso: 9 Febrero 2014].

**Figura 2. Sistemas Fotovoltaicos aislados de la red eléctrica**



Fuente: Sistema Riojano de Innovación, Gobierno de la Rioja, Agencia de Desarrollo Económico de la Rioja, . P. R. d. A. I. Globaltech Rioja y F. E. d. D. R. Comisión Europea, «Estudio de BenchMarking Tecnológico Internacional Sector Energía Solar Fotovoltaica,» 2008. [En línea]. Available: [http://www.ader.es/fileadmin/redactores/PUBLICACIONES/Estudios/Estudio\\_Benchmarking\\_sector\\_fotovoltaico.pdf](http://www.ader.es/fileadmin/redactores/PUBLICACIONES/Estudios/Estudio_Benchmarking_sector_fotovoltaico.pdf). [Último acceso: 9 Febrero 2014].

- **Centrales de Biomasa:** La biomasa es una de las principales fuentes de energía renovables, a partir de la cual se puede obtener energía eléctrica de forma limpia, es decir, que no contaminante para el medio ambiente. La biomasa es cualquier material orgánico que proviene de los seres vivos como: las plantas, los animales, los cuales pueden utilizarse para producir energía eléctrica [25].
- **Centrales Mareomotriz:** La energía mareomotriz es otra fuente de energía renovable, la cual se obtiene de la energía cinética y potencial proveniente de los cambios o diferencias entre las mareas las cuales accionan las aspas de los rotores de las turbinas que se encuentran situados en el fondo del mar, convirtiendo de esta forma la energía mecánica producida por el movimiento de las aspas en energía eléctrica [28].

El porcentaje de utilización de estos tipos de generación de electricidad varía para cada región y/o país a nivel mundial, debido a que su utilización depende principalmente de la disposición de los diferentes recursos o fuentes primarias para la generación de electricidad (agua, carbón, luz solar, etc.). Por ejemplo para el caso de Colombia, en la tabla 1 se observan con esta distribuido el potencial energético en el país teniendo en cuenta estas fuentes de energía:

**Tabla 1. Capacidad efectiva neta del SIN a diciembre 31 de 2012 y 2013**

<b>Recursos</b>	<b>2012 MW</b>	<b>2013 MW</b>	<b>Participación %</b>	<b>Variación (%) 2013 - 2012</b>
Hidráulicos	9,185	9,315	64.0%	1.4%
Térmicos	4,426	4,515	31.0%	2.0%
Gas	2,122	1,972		
Carbón	997	997		
Fuel - Oil	0	0		
Combustóleo	307	307		
ACPM	678	917		
Jet1	46	46		
Gas-Jet A1	276	276		
Menores	693	662	4.5%	-4.4%
Hidráulicos	591	560		
Térmicos	83	83		
Eólica	18	18		
Cogeneradores	57	66	0.5%	15.7%
<b>Total SIN</b>	<b>14,361</b>	<b>14,559</b>	<b>100.0%</b>	<b>1.4%</b>

Fuente: [29]

Otros de los agentes activos en el proceso de energético son:

### **3.2.2 Sistemas de Transmisión**

Un sistema de transmisión está constituido principalmente por líneas de transmisión, que cumplen la función de transportar energía en el sistema eléctrico de potencia desde las centrales de generación hasta la distribución a los consumidores finales [30].

Dependiendo de la longitud de las líneas de transmisión, estas se pueden clasificar como [5]:

- Líneas cortas: Son las que se encuentran con longitudes inferiores a los 80km.
- Líneas medidas: Son las que se encuentran con longitudes entre 80km e inferior a 240km.
- Líneas largas: Con longitudes superiores a los 240km.

Teniendo en cuenta que existen diferentes niveles de tensión en la transmisión de energía eléctrica, para el caso de Colombia los niveles de transmisión permitidos son: 500kV, 220kV y los niveles de subtransmisión son: 110kV y 66kV (solo en la costa del país).

La compañía que tiene mayor porcentaje de participación en el sistema de transmisión de energía en el Colombia es Interconexión Eléctrica S.A ESP con un porcentaje de participación del 75% aproximadamente, seguida de las empresas en orden de importancia de acuerdo con el porcentaje de propiedad de activos que posee, tales como: Transelca, EEB(Empresa de Energía de Bogotá), EEPPM(Empresas Públicas de Medellín), EPSA(Empresa de Energía del Pacífico), ESSA(Electrificadora de Santander, Distasa, Corelca, Central Hidroeléctrica de Betania (CHB), Centrales Eléctricas de Norte de Santander (CENS) y EBSA (Electrificadora de Boyacá) [31].

A continuación en la figura 3 se muestra un esquema del Sistema Interconectado Nacional:

Figura 3. Sistema de Transmisión Nacional



Fuente: [32]

Debido a que en la transmisión eléctrica se realiza a niveles de tensión elevados como mostró anteriormente, con el objetivo de minimizar las pérdidas energéticas en el sistema [33], es de gran importancia conocer algunos conceptos relacionados con esta temática. En la siguiente sección se muestra una breve descripción de los cuatro parámetros principales que afectan una línea de transmisión, los cuales son: la resistencia, inductancia, capacitancia y conductancia [30]. A continuación se presenta en detalle algunas de las características generales de estos parámetros:

### 3.2.2.1 Parámetros de una línea de Transmisión

Los parámetros eléctricos que afectan directamente la capacidad de transportar energía en una línea de transmisión son:

- **Resistencia:** Es la capacidad que tiene un conductor en oponerse al paso de la corriente eléctrica. La resistencia efectiva de un conductor se calcula a partir de la siguiente expresión [30]:

$$R = \frac{\text{Pérdida de potencia en el conductor [w]}}{|I|^2 [A]} \quad \text{Ecuación 1}$$

Dónde:

I: es la corriente que fluye a través de conductor.

Si la distribución de corriente a través del conductor es uniforme, la resistencia efectiva es igual a la resistencia de corriente directa, la cual está dada por la siguiente ecuación:

$$R_0 = \frac{\rho l}{A} \quad \text{Ecuación 2}$$

Dónde:

$\rho$ : Resistividad de conductor

l: longitud del conductor

A: área de la sección transversal de conductor

- **Inductancia:** La inductancia es el campo magnético que se produce cuando una corriente eléctrica fluye a través de un conductor. Si la permeabilidad ( $\lambda$ ) es constante, los enlaces de flujo resultantes se pueden expresar como [30]:

$$L = \frac{\lambda}{I} [\text{Webers} - \text{vuelta}] \text{ Ecuación 3}$$

Dónde:

$\lambda$ : permeabilidad

$I$ : Corriente que fluye en el conductor

- **Capacitancia:** La capacitancia de una línea de dos conductores está definida como la relación entre la carga sobre los conductores ( $q$ ) y la diferencia de tensión entre ellos ( $v$ ). La capacitancia por unidad de longitud se calcula a partir de la siguiente ecuación [30]:

$$C = \frac{q}{v} [F/m] \text{ Ecuación 4}$$

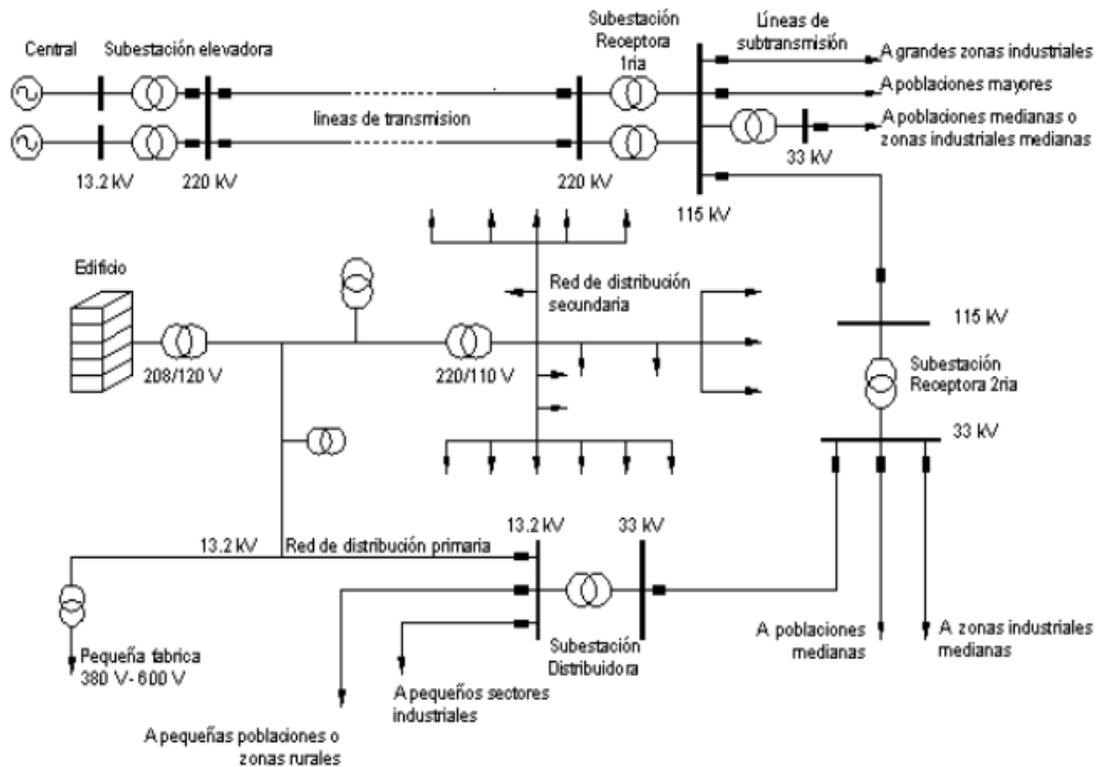
- **Conductancia:** La conductancia es el inverso de la resistencia, en la cual se evalúa la relación entre la intensidad de corriente que fluye por unidad de tensión aplicada al conductor eléctrico [33].

### 3.2.3 Sistema de Distribución

El sistema de distribución está compuesto por redes eléctricas, las cuales permiten distribuir la energía a cada uno de los usuarios finales en la cadena de energética. Los niveles de distribución que se utilizan en Colombia son: 13800V, 13200V y 11400V (en Bogotá).

A continuación en la figura 4 se muestra un esquema de un sistema de distribución primaria y secundaria dentro de un sistema eléctrico de potencia:

Figura 4. Esquema de un Sistema de Distribución



Fuente: [34]

Los elementos principales de un sistema de distribución son:

- **Subestaciones Receptoras Primarias:** Estas subestaciones tienen la función de transformar la energía recibida de las líneas de transmisión provenientes de las subestaciones elevadoras a niveles más de tensión más bajos dando origen a las llamadas líneas de subtransmisión.
- **Subestaciones Receptoras Secundarias:** Son las encargadas de transformar la energía que transportan las líneas de subtransmisión en circuitos de distribución primarios.
- **Circuitos primarios:** para el caso de Colombia, los niveles de tensión que se utilizan para la distribución primaria son: 13.8kV, 13.2kV, 7620V, etc.
- **Circuitos secundarios:** para el caso de Colombia, los niveles de tensión que se utilizan para la distribución secundaria son: 110/220V, 120/240V, 120/208V, etc.

- **Transformadores de Distribución:** son equipos de transformación de tensión que se conectan a un circuito de distribución primario y suministran niveles de tensión más bajos a los suministros que se encuentran conectados a los circuitos secundarios.

Los sistemas de distribución se clasifican de acuerdo a su construcción en [34]:

- **Redes de distribución aéreas:** En este caso, los conductores están tendidos en la red usualmente desnudos para los circuitos primarios y para circuitos secundarios con conductores desnudos o aislados con calibres que oscilan entre el 4/0 Y 2 AWG. Existen diferentes tipos de redes de distribución de acuerdo a su configuración, tales como: Red Chilena, Red abierta, Red Trenzada, entre otras. Algunos de los principales elementos que se pueden encontrar en una red abierta son: aisladores (cerámicos), crucetas (madera o hierro galvanizado), postes, conductores, cortacircuitos, transformadores de distribución, etc.
- **Redes de distribución subterráneas:** Este tipo de redes se utilizan cuando existen zonas en las cuales, debido a razones de urbanismo, estética, etc., no es aconsejable la instalación de redes aéreas. Algunas de las ventajas de este tipo de redes son: son más estéticas, son más seguras, permiten blindar más la medida del vandalismo. Pero una de sus principales desventajas es que su instalación es muy costosa en comparación de una red aérea. Algunos de los elementos que componen una red subterráneas son: Ductos, uniones, terminales, cables, etc.

Los sistemas de distribución se clasifican de acuerdo a tipo de carga:

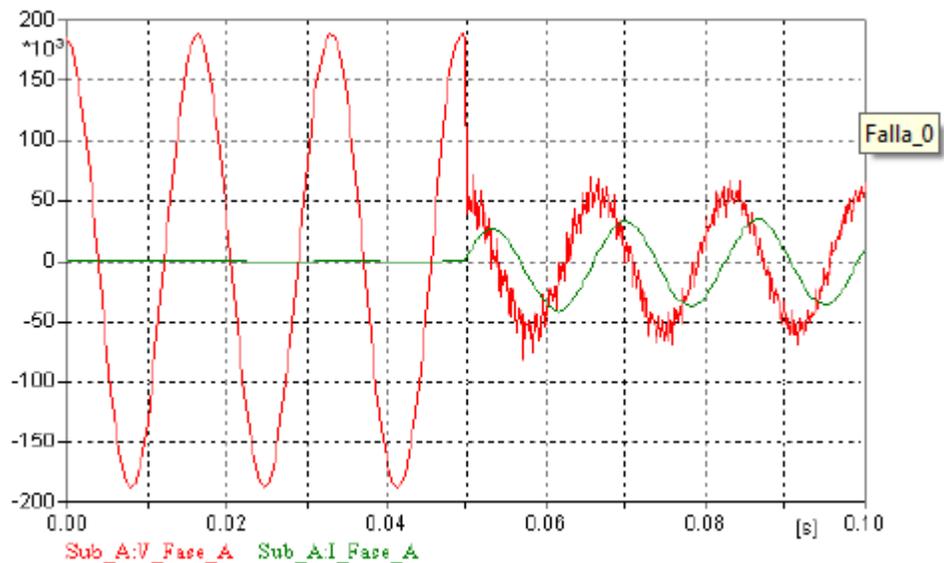
- **Redes de distribución para cargas residenciales**
- **Redes de distribución para cargas comerciales**
- **Redes de distribución para cargas industriales**
- **Redes de distribución para cargas de alumbrado público**

### 3.3 Fallas en los Sistema Eléctrico de Potencia

Las Fallas son eventos que ocurren durante un determinado tiempo ya sea muy corto, corto o largo en un sistema eléctrico de Potencia, causando en muchas ocasiones daños en los equipos u elementos que estén conectados al mismo. Dependiendo del tipo de falla que presente el sistema, estas se pueden clasificar de acuerdo a sus niveles de impedancia en [5]:

- **Fallas de baja impedancia:** Se distinguen principalmente por presentar variaciones significativas de corriente y tensión, las cuales se pueden identificar con facilidad por medio de los registros oscilopertográficos del sistema al momento de presentarse esta eventualidad. En la figura 5 se muestra un ejemplo de falla de baja impedancia:

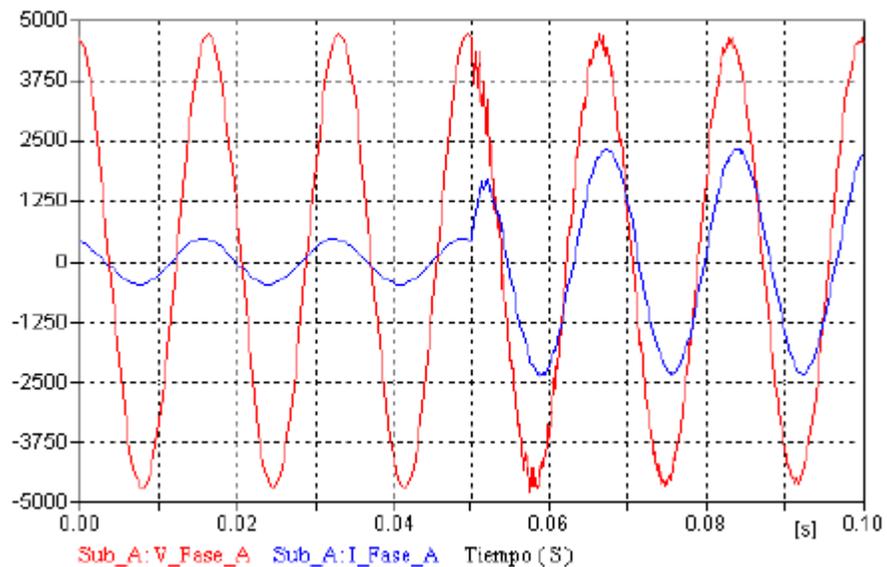
Figura 5. Falla de Baja Impedancia



Fuente: Quintero Crespo, Erwin. "Desarrollo de un Modelo para la Localización de Fallas en Sistemas de Transmisión de Energía Eléctrica Utilizando Técnicas De Inteligencia Artificial". Medellín 2010. 91 págs.

- **Fallas de alta impedancia:** su característica principal es que presentan cambios de carga o aumentos en las amplitudes de corriente [6], las cuales se pueden confundir con aumentos de impedancia en el sistema, provocando que en varias ocasiones estas no sea detectadas a tiempo y provoquen daños más graves al SEP. Cabe resaltar, que teniendo en cuenta esta característica, este tipo fallas presentan más complejidad al momento de detectar y localizar el punto donde ocurrió el evento. En la figura 6 se muestra un ejemplo de falla de alta impedancia:

**Figura 6. Falla de Alta Impedancia**



Fuente: Quintero Crespo. Erwin. "Desarrollo de un Modelo para la Localización de Fallas en Sistemas de Transmisión de Energía Eléctrica Utilizando Técnicas De Inteligencia Artificial". Medellín 2010. 91 págs.

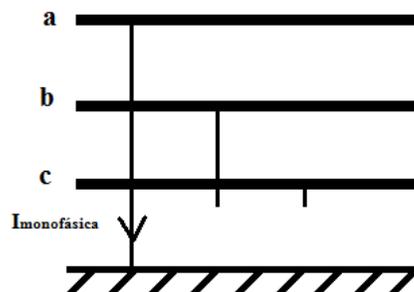
Existen dos tipos de fallas de alta impedancia: las fallas activas y las pasivas. Las fallas activas se caracterizan por presentar arcos eléctricos y corrientes por debajo de las que puedan detectar los equipos de protección como los relés. Mientras que las fallas pasivas no presentan arcos eléctricos. Por este motivo, este tipo de fallas son consideradas más peligrosas para las personas ya que no se presenta ninguna indicación de falla en el sistema. Al igual que las fallas activas, en estas fallas el esquema de protección de sobrecorriente tampoco logra detectar la misma, para aislarla rápidamente del sistema eléctrico de potencia [35].

Dependiendo del número de fases se encuentran afectadas al momento de presentarse el evento en el SEP, las fallas se pueden clasificar como:

### 3.3.1 Fallas Monofásicas (L-T)

Estos tipos de fallas se caracterizan porque una fase entra en contacto con la tierra, lo cual provoca aumentos de corriente y caídas de tensión en la fase donde ocurrió el evento. Gráficamente una falla monofásica a tierra se representa como se muestra en la figura 7:

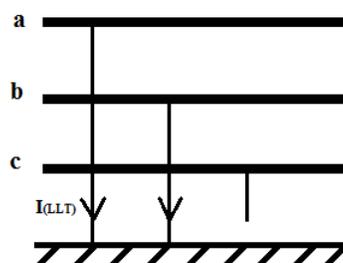
Figura 7. Falla Monofásica a tierra



### 3.3.2 Fallas Bifásicas a Tierra (L-L-T)

Las fallas bifásicas a tierra se caracterizan porque presentan aumentos en la corriente y caídas de tensión en las dos fases donde ocurrió el evento. Gráficamente una falla bifásica a tierra se representa como se muestra en la figura 8:

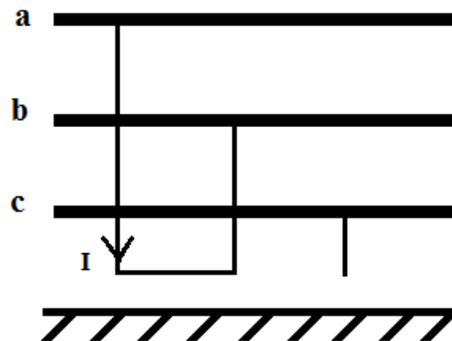
Figura 8. Falla Bifásica a tierra



### 3.3.3 Fallas Bifásicas (L-L)

Las fallas bifásicas se presentan cuando hay un contacto entre dos fases y estas se encuentran aisladas de la tierra, como se muestra en la figura 9:

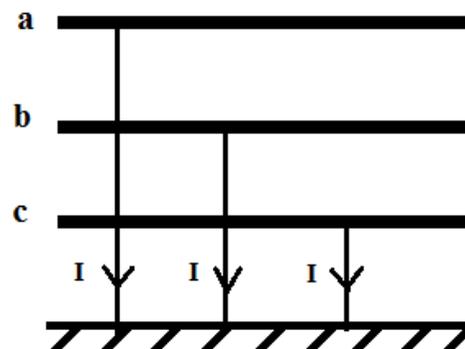
Figura 9.Falla Bifásica



### 3.3.4 Fallas Trifásicas a tierra (L-L-L)

Las fallas trifásicas se presentan cuando las tres fases entran en contacto con la tierra, presentando caídas de tensión y aumento de corriente en las mismas. Gráficamente una falla trifásica a tierra se representa como se muestra en la figura 10:

Figura 10.Falla Trifásica



### 3.4 Conclusiones

Teniendo en cuenta el capítulo anterior, se puede concluir:

- Un sistema de potencia está expuesto a diferentes eventos o fallas que ocasionan inestabilidad, bajos niveles de confiabilidad, reducción de la calidad en el servicio de transmisión, distribución y comercialización de energía, daños en los equipos, elevados costos de mantenimiento, cambios en los flujos de potencia, etc. Y ante todo y más importante la pérdida de vidas humanas cuando estas fallas no son detectadas a tiempo.
- Las fallas eléctricas en la gran mayoría de los casos son ocasionadas por: Aislamiento entre las fases a tierra, contacto indirecto entre las líneas, contacto entre líneas y árboles, descargas atmosféricas, entre otros.
- Las fallas de alta impedancia son más difíciles de localizar en comparación a las fallas de baja impedancia, debido a que en varias ocasiones estas tienden a confundirse con aumentos de carga en el sistema, debido a los aumentos inesperados de corriente en el mismo.

## CAPÍTULO IV. MÉTODOS Y EQUIPOS UTILIZADOS PARA LOCALIZAR FALLAS EN LOS SISTEMAS ELÉCTRICOS DE POTENCIA.

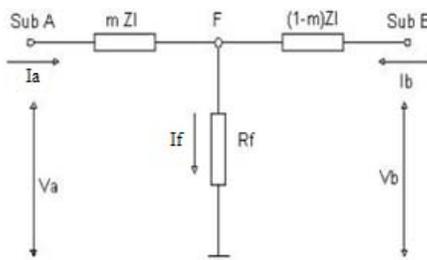
### 4.1 Introducción

En este capítulo se presenta una descripción detallada de cuatro algoritmos utilizados en varias investigaciones [5] [36] relacionadas principalmente en la localización de fallas en sistemas de transmisión de energía eléctrica. Los siguientes algoritmos fueron seleccionados, debido a que son unos los métodos más representativos en la utilización de información proveniente de equipos de protección de sistemas eléctricos de potencia, debido a que utilizan información extraídas de las variables monitoreadas por estos equipos (corrientes, tensiones, etc.), los cuales a su vez permiten alimentar los sistemas que se diseñan finalmente para la localización y detección de fallas en los SEP [36].

### 4.2 Metodologías utilizadas para la localización de fallas en líneas de transmisión

Los métodos de localización de fallas como el de: Reactancia, Takagi, Schweitzer y Ericksson basan su estudio en la ecuación característica de una línea corta como se muestra en la figura 11:

Figura 11. Esquema de una línea corta



Fuente: [3]

Dónde:

m: Longitud total de la línea

Zl: Impedancia de la secuencia positiva

Rf: Resistencia de falla

If: Corriente de falla

Ia: Corriente de fase A

Va: Tensión de fase A

F: Punto de falla

Sub A: Subestación A

Sub B: Subestación B

Realizando un análisis de malla del circuito de la línea corta que se muestra en la figura 11 se obtiene:

$$V_a = (m * Zl) * I_a + (R_f * I_f) \text{ Ecuación 5}$$

A partir de la ecuación 5 es que los diferentes algoritmos de localización de fallas basan su estudio de localización de fallas para calcular m, es decir, la distancia a la cual se va a encontrar el punto de falla F en la línea donde ocurrió el evento.

#### 4.2.1 Método de la Reactancia [36]

En este algoritmo se toma la parte imaginaria de la impedancia Zl de la ecuación 5, partiendo que:

$$Z_l = R + jX_l$$

Reemplazando se obtiene:

$$V_a = (m * (jX_l)) * I_a + (R_f * I_f) \text{ Ecuación 6}$$

Asumiendo que la resistencia de falla es muy pequeña  $R_f \cong 0$  se obtiene:

$$V_a = (m * (jX_l)) * I_a$$

Despejando:

$$m = \text{Im} \left[ \frac{V_a}{I_a} \right] * \frac{1}{jX_l} \text{ Ecuación 7}$$

Donde el error del algoritmo es calculado como:

$$e = \frac{R_f}{X_l} \text{Im} \left[ \frac{I_F}{I_A} \right] \text{ Ecuación 8}$$

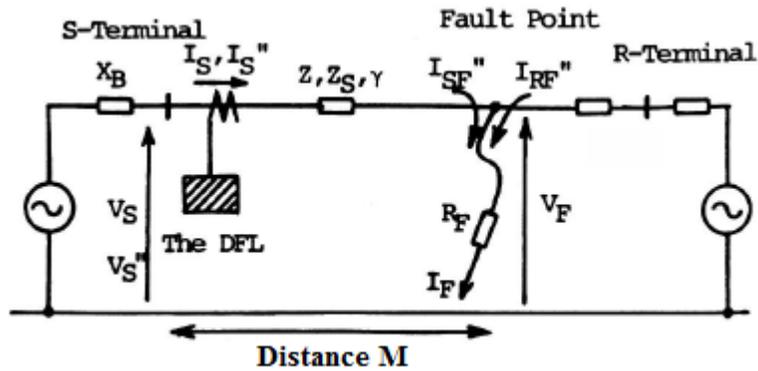
De ecuación 8 cabe resaltar que el error es cero cuando  $I_f$  y  $I_a$  están en fase, es decir el sistema es homogéneo. Pero como en el sistema de transmisión nacional estas condiciones no se cumplen, el error se multiplica por la resistencia de falla  $R_f$ , lo que ocasiona desventajas de este algoritmo frente a fallas de alta impedancia, debido a que si se tiene en cuenta  $R_f$  la impedancia total estará dada como:

$$Z_f = R_f + jX_f \text{ Ecuación 9}$$

#### 4.2.2 Método utilizando datos de voltaje y corriente de una terminal de una línea de transmisión [37]

Este método permite calcular la reactancia de falla en una línea de transmisión, por medio del cálculo de la distancia a la cual ocurrió en evento en el sistema eléctrico de potencia. El planteamiento matemático que se implementa en este modelo para calcular la distancia  $M$  a la cual se encuentra la falla, se basa en el circuito eléctrico que se muestra en la figura 12 es:

Figura 12. Localizador digital de Falla



Fuente: [37]

Este circuito eléctrico representa un localizador digital para fallas (Digital Fault Locator-DFL), el cual fue probado en noviembre de 1980 en la línea de Naka-Tokyo en la central nuclear de Shinanogawa de Tokyo Electric Power Co. (TEPCO).

$$I_a = I_a' + I_a'' \quad \text{Ecuación 10}$$

$$K_a = K_a * e^{j\theta} = \frac{I_f}{I_a''} \quad \text{Ecuación 11}$$

Despejando  $I_f$  de la ecuación 11 se obtiene:

$$I_f = K_a * I_a'' = K_a(I_a - I_a') \quad \text{Ecuación 12}$$

Multiplicando el conjugado de este valor en la ecuación 5 y asumiendo  $R_f$  con un valor muy pequeño se obtiene:

$$V_a = (m * ZL) * I_a = (m * ZL) * (I'_a + I''_a) \quad \text{Ecuación 13}$$

$$m = \frac{V_a}{ZL(I'_a + I''_a)} = \frac{Im[V_a * I''_a * K_a^*]}{Im[ZL * I_a * K_a^* * I''_a^*]} \quad \text{Ecuación 14}$$

Reemplazando se obtiene:

$$m = \frac{Im[V_a * I''_a * e^{j\theta}]}{Im[ZL * I_a * e^{j\theta} * I''_a^*]} \quad \text{Ecuación 15}$$

En este método se realiza la siguiente aproximación  $\theta = 0$  para minimizar el error de tal forma que  $R_f$  no ingresa a la parte imaginaria de la ecuación 5, pero para el caso Colombiano este criterio no aplica porque el factor  $e$  depende de la configuración y del punto de operación del sistema [36].

Este método se ha probado en varios eventos que han ocurrido y ha dado muy buenos resultados como los que se muestran en la tabla 2:

Tabla 2. Resultados de localización de fallas por medio DFL e inspección de resultados

Case	The DFL Locating Results (A)			The Inspection Results (B)	Error (A-B) km
	Date	Kind of Fault	Locating Result	Distance	
1	'81-Jan-18	S-1LG	25.7km	Not found	*
2	'81-Jan-19	R-1LG	41.8km	41.3km	0.5km
3	'81-Jan-20	S-1LG	54.7km	55.1km	-0.4km
4	'81-Jan-21	RT-2LG	32.8km	32.6km	0.2km
5	'81-Jan-21	T-1LG	44.9km	45.3km	-0.4km
6	'81-Jan-22	RT-2LG	(46.6km)	49.0km 34.2km	*
7	'81-Jan-31	T-1LG	31.0km	30.2km	0.8km
8	'81-Feb-3	S-1LG	(40.9km)	38.5km	*
9	'81-Jul-12	T-1LG	70.7km	69.8km	0.9km

\*Case 1: Marks of an arc were not found.

\*Case 6: Multi-Fault at the different points.

\*Case 8: Not converged because of fluctuated fault current.

Fuente: [37]

#### 4.2.3 Algoritmo de Schweitzer para líneas cortas [36]

Este algoritmo parte del análisis de malla del circuito de la línea corta que se muestra en la figura 11 donde se obtiene:

$$V_f = V_a - m * Z_l * I_a \text{ Ecuación 16}$$

$$V_f = V_b - [(1 - m) * Z_l * I_b] \text{ Ecuación 17}$$

Resolviendo este sistema de ecuaciones y despejando m se obtiene:

$$m = \frac{V_a - V_b + (Z_l * I_b)}{Z_l(I_a + I_b)} \text{ Ecuación 18}$$

Cabe resaltar que esta ecuación puede arrojar datos imaginarios debido a las imprecisiones en los equivalentes de líneas y medida en los extremos [36].

#### 4.2.4 Algoritmo de Eriksson [36]

Este algoritmo al igual que en los algoritmos expuestos en las anteriores secciones parten de la ecuación 5. En esta metodología se parte además de:

$$D = De^J = \frac{Ia''}{If} = \frac{1}{Ka} \text{ Ecuación 19}$$

Reemplazando la ecuación 19 en la ecuación 5 se obtiene:

$$Va = m * Zl * Ia + Rf * If = m * Zl * Ia + \left[ Rf * \frac{Ia''}{D} \right]$$

$$Va = m * Zl * Ia + \left[ Rf * \frac{Ia''}{D} \right] \text{ Ecuación 20}$$

Se tiene además que:

$$D = \frac{(1-m)*Zl*Zb}{Za+Zl+Zb} \text{ Ecuación 21}$$

Sustituyendo la ecuación 21 en la 20 se obtiene:

$$m^2 - m \cdot K_1 + K_2 - K_3 * Rf = 0 \text{ Ecuación 22}$$

Dónde:

$$K_1 = \frac{Va}{Zl*Ia} + 1 + \frac{Zb}{Zl} \text{ Ecuación 23}$$

$$K_2 = \frac{Va}{Zl*Ia} * \frac{Zb}{Zl} + 1 \text{ Ecuación 24}$$

$$K_3 = \frac{Ia''}{Zl*Ia} * \frac{Zb+Za}{Zl} + 1 \text{ Ecuación 25}$$

Separando la ecuación 22 en parte real e imaginaria, se resuelve el sistema de ecuación eliminando  $R_f$ , quedando un sistema de la forma  $am^2 - bm + c = 0$

Dónde:

$$a = Im(K_3)$$

$$b = Re(K_3)Im(K_1) - Re(K_1)Im(K_3)$$

$$c = Re(K_2)Im(K_3) - Re(K_3)Im(K_2)$$

Cabe resaltar que para cortocircuitos entre fases el cambio de corrientes se utiliza directamente, mientras que para fallas a tierra e utilizan magnitudes de secuencia positiva.

El valor  $I_a''$  que se utiliza en la ecuación 25 depende del tipo de falla, este valor se puede obtener de la siguiente tabla 3:

**Tabla 3. Corrientes del Algoritmo de Eriksson**

Tipo de Falla	$I_a''$
Ag	$(3/2) * (I_{Aa}'' - I_{A0})$
Bg	$(3/2) * (I_{Ab}'' - I_{A0})$
Cg	$(3/2) * (I_{Ac}'' - I_{A0})$
ab,abg	$I_{Aa}'' - I_{Ab}''$
bc,bcg	$I_{Ab}'' - I_{Ac}''$
ca,cag	$I_{Ac}'' - I_{Aa}''$

Fuente: [38]

Una de las grandes ventajas que presentan los sistemas de potencias actuales, es que cuentan con equipos modernos, los cuales monitorean y controlan en cada instante de tiempo, la operación adecuada de cada uno de los elementos que componen el sistema en general. Es por este motivo, que en varias ocasiones cuando se presentan fallas en el sistema, estos equipos están diseñados para

actuar en cuestión de milisegundos, para aislar automáticamente el equipo y/o la zona del sistema que se encuentre afectada por la misma, con el objetivo principal de proteger tanto la vida humana como el resto de elementos del SEP que se encuentren operando en el sistema.

A continuación se presenta una sección donde se detallan algunas de las características generales de los equipos de protección más utilizados en líneas de transmisión:

#### **4.3 Protecciones Eléctricas y sus aplicaciones en la localización de fallas en líneas de transmisión**

Las protecciones eléctricas son equipos y/o esquemas que se han diseñado y desarrollado para proteger los sistemas eléctricos donde sean instalados o implementados. Dependiendo del tipo de protección que sea necesario instalar, los equipos o también llamados relés de protección, de acuerdo a su aplicación se pueden clasificar como:

- Relés de sobrecorriente
- Relés de sobre o bajo voltaje.
- Relés direccionales.
- Relés de distancia.
- Relés diferenciales
- Relés de sincronización, entre otros.

Los requerimientos principales que se deben tener en cuenta al momento de seleccionar algunos de estos tipos de equipos de protección son [39]:

- **Confiability:** Es la habilidad que tiene una protección para operar de forma correcta y no accionarse bajo condiciones normales. Consta de dos elementos: Dependencia (certeza de una operación correctamente alguno evento o falla) y seguridad (habilidad para evitar malas operaciones).
- **Velocidad de operación:** Se refiere al mínimo tiempo de permanencia de a falla para evitar posibles daños.
- **Selectividad:** Una protección es selectiva cuando solo actúa sobre la o las zonas para las cuales fue programada.
- **Costos:** hace referencia a la minimización u optimización de costos pero asegurando siempre la maximización de la protección de los equipos.

### 4.3.1 Clasificación de los Relés de Protección

Los relés de protección son equipos electromagnéticos, electrónicos o numéricos, los cuales son programados para que operen ante condiciones que detecten superiores a las ajustadas en su operación, posteriormente envía señales DC para abrir o cerrar a los interruptores que se encuentra protegiendo la zona afectada por la falla en el SEP.

Independientemente del tipo de relé que se utilice en el esquema de protección del SEP, todos siguen el siguiente esquema lógico que se muestra en la figura 13:

**Figura 13. Funcionamiento lógico de un relé**



Los relés de protección pueden ser clasificados según su función en:

- Auxiliares.
- Protección.
- Monitores.
- Reguladores.

Según la estructura de construcción en:

- Electromagnéticos.
- Estado Sólido.

- No Eléctricos (de presión, térmicos, etc.).
- Microprocesadores.
- Numéricos.

Según la señal de entrada en:

- Corriente.
- Voltaje.
- Potencia.
- Frecuencia.
- Temperatura.
- Presión.
- Velocidad, etc.

Según el tipo de funcionamiento en:

- Sobrecorriente.
- Sobrecorriente direccional.
- Sobrevoltaje.
- Diferencial, etc.

## 4.4 Conclusiones

Teniendo en cuenta el capítulo anterior se puede concluir:

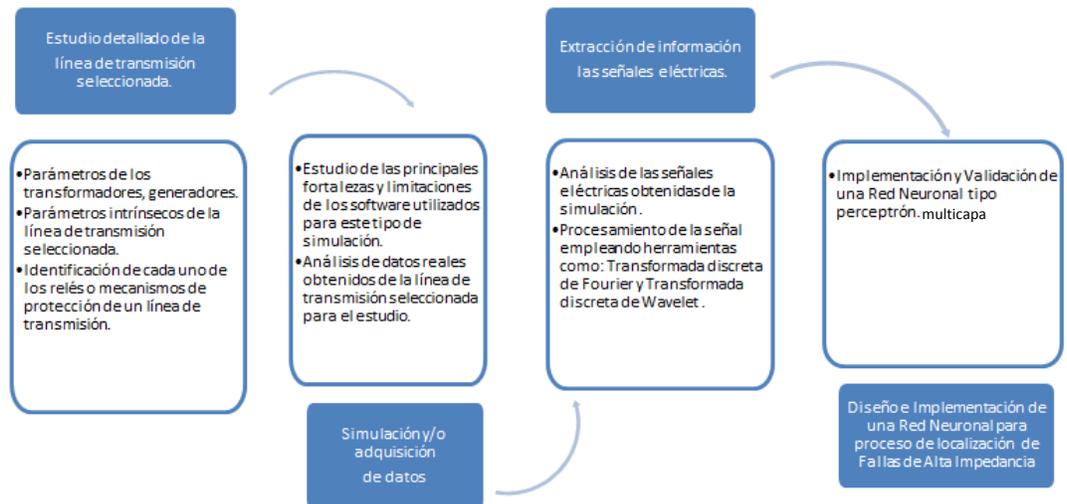
- Existen varios métodos o planteamientos matemáticos que permiten localizar el punto de falla en el SEP, de lo cual cabe resaltar, que la gran mayoría parten del estudio de líneas cortas para el desarrollo del modelo y se van diferenciando en la medida en que optimizan el error obtenido para el cálculo de las distancias de falla.
- Los equipos de protección diseñados para los sistemas eléctricos de potencia tales como los relés de protección, permiten brindar información valiosa que sirve de gran ayuda al momento de localizar y detectar el punto de falla con mayor facilidad. Con la única desventaja, que presentan índices de costos para el sistema, ya que a medida que se cuenta con varios equipos de protección para localizar fallas, los índices de costos y mantenimientos aumentan. Es por este motivo, que desde hace varios años se están implementando técnicas de inteligencia artificial que permiten localizar y detectar fallas a partir de los registros proporcionados por estos equipos, con el fin de minimizar en un grado, los costos y el tiempo de detección de las fallas.

## CAPÍTULO V. ASPECTOS METODOLÓGICOS PROPUESTO

### 5.1 Introducción

En esta sección se explicará detalladamente el modelo metodológico a implementar para alcanzar cada uno de los objetivos planteados anteriormente. A continuación, en la figura 14 se muestra el esquema a implementar basándose principalmente en las investigaciones de los autores [5] [10]:

Figura 14. Esquema Metodológico



## 5.2 Planteamiento Metodológico

La metodología propuesta en la presente investigación consta de las siguientes etapas:

**5.2.1 Caracterización del sistema eléctrico de Potencia Seleccionado:** en esta primera fase se realiza un estudio detallado de la línea de transmisión seleccionada, el cual abarca el siguiente :

- Identificación de los elementos que componen el sistema eléctrico de Potencia del caso estudio: Esta etapa de la investigación tiene como objetivo principal realizar un análisis detallado de cada uno de los equipos u elementos que conforman el sistemas eléctrico de potencia, como lo es el caso de la línea de transmisión aérea utilizada para la implementación y validación del presente modelo. Así mismo, este análisis incluirá los parámetros individuales e intrínsecos de cada uno de los equipos que operan como lo son: los transformadores, generadores como también los parámetros del conductor utilizado en la línea de transmisión del caso estudio. A finalizar esta etapa, el resultado será un diagrama unifilar completo con cada una de las especificaciones técnicas de los equipos que se tendrá en cuenta al momento de realizar las respectivas simulaciones al sistema propuesto.

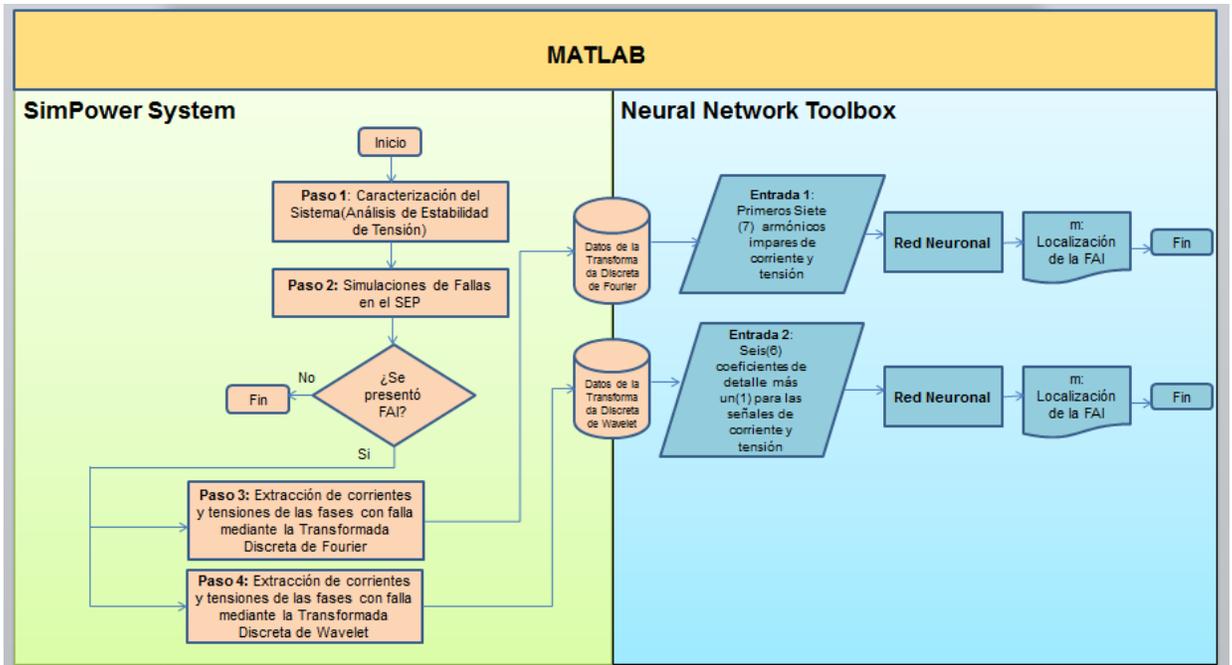
**5.2.2 Simulación y/o adquisición de datos:** Esta etapa tiene como objetivo principal identificar cual la mejor herramienta o software que permita realizar una buena simulación de fallas en el sistema eléctrico del presente estudio, ya que de esta dependerá, la resolución o validez de los datos obtenidos, los cuales serán las entradas al modelo de inteligencia artificial a implementar, para tratar el tema de localización de fallas de alta impedancia. Igualmente, se utilizaran datos reales de la línea de transmisión para el análisis de comportamiento del sistema eléctrico de potencia.

**5.2.3 Extracción de información las señales eléctricas:** En esta etapa se realiza el tratamiento de las señales eléctricas, que consta principalmente de la extracción de datos como: corrientes, tensiones, factores de potencia, etc. A partir de los cuales se realiza un análisis detallado para obtener como resultado cuales son las variables más significativas dentro del proceso de localización de fallas, las cuales serán las entradas principales de modelo que se implementará en esta investigación.

**5.2.4 Diseño e Implementación de Técnicas de Inteligencia artificial para el proceso de detección de Fallas:** En esta etapa se realiza el proceso de localización de Fallas de Alta impedancia mediante la utilización de Técnicas de inteligencia artificial, donde se van considerar técnicas inteligentes como las redes neuronales utilizadas tanto a nivel nacional [5] [10] como internacional [1] [2] [14] [24] para tratar esta temática.

A continuación, en la figura 15 se presenta un diagrama de flujo del modelo propuesto, el cual permite observar la metodología que se desarrollará en la presente investigación:

Figura 15. Propuesta Metodológica

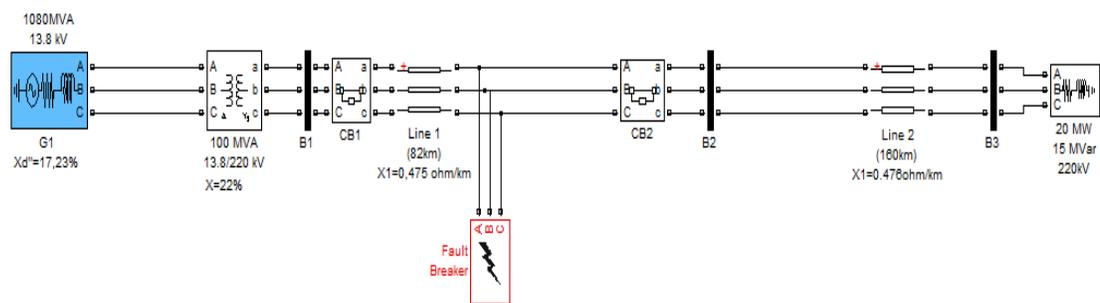


## CAPÍTULO VI. CARACTERIZACIÓN DEL SISTEMA ELÉCTRICO DE POTENCIA

### 6.1 Introducción

En esta sección se describen detalladamente cada uno de los parámetros de los elementos que componen el SEP que se tomará como referencia para el caso estudio de la presente investigación. A continuación en la figura 16 se muestra el esquema del diagrama unifilar del SEP-caso estudio:

**Figura 16. Modelo de SEP-caso estudio**



Este sistema de transmisión está compuesto por dos líneas a una tensión de 220kV: Línea 1 y Línea 2, las cuales presentan las características que se muestran en la tabla 4:

**Tabla 4. Datos de las Líneas**

Línea	Frecuencia	Longitud [km]	Tensión [kV]	$R_1$ [ohm/km]	$R_0$ [ohm/km]	$X_1$ [ohm/km]	$X_0$ [ohm/km]
Línea 1	60	82	220	0,033	0,37	0,475	1,32
Línea 2	60	160	220	0,054	0,265	0,476	1,29

En la Tabla 5, se muestran los datos del generador que se encuentra conectados a los barrajes del SEP del caso estudio:

**Tabla 5. Datos de los Generadores**

<b>Generador</b>	<b>Tensión(kV)</b>	<b>Frecuencia(Hz)</b>	<b>Potencia [MVA]</b>	<b>Xd''[%]</b>
G1	13,8	60	1080	17,23

Así mismo, en tablas 6 se encuentran los datos del Transformador del SEP del caso estudio:

**Tabla 6. Datos del Transformador**

<b>Transformador</b>	<b>Tensión (kV)</b>	<b>Frecuencia (Hz)</b>	<b>Potencia [MVA]</b>	<b>X [%]</b>
Trafo 1	13,8/220	60	100	22

## **6.2 Análisis y Resultados de la Caracterización del Sistema Eléctrico de Potencia**

Teniendo en cuenta los datos anteriores, a continuación se inicia el proceso de análisis de SEP a partir de los siguientes estudios:

### **6.2.1 Métodos de Análisis de estabilidad de Tensión en un SEP**

Desde hace varios años el problema de estabilidad en un SEP<sup>4</sup> ha sido la temática central de varias investigaciones [40] [41]. Algunas de las técnicas utilizadas para el análisis de estabilidad de tensión en un SEP son por medio de: las curvas PV, curvas VQ, análisis modal mediante vector y valores propios, análisis de sensibilidad QV, entre otros.

---

<sup>4</sup> SEP: Sistema Eléctrico de Potencia

El análisis de estabilidad de tensión para un SEP involucra el estudio de aspectos [42]:

- a) Proximidad hacia la inestabilidad de tensión: la distancia hacia la inestabilidad puede ser medida en términos de cantidades físicas como: nivel de carga, flujo de potencia activa y reserva de potencia reactiva. La selección de una apropiada medida depende de las especificaciones del sistema y el margen de estabilidad del mismo.
- b) Mecanismos que ocasionan inestabilidad de tensión: en este aspecto se evalúan cada una de las condiciones o factores que influyen directa o indirectamente sobre la estabilidad del sistema. Por este motivo, para este análisis se tienen en cuenta aspectos relacionados con la sensibilidad del sistema antes de fallas o eventos, análisis modal, entre otros. Todos estos relacionados, con cada uno de los equipos y/o elementos que estén conectados al sistema eléctrico que se está analizando.

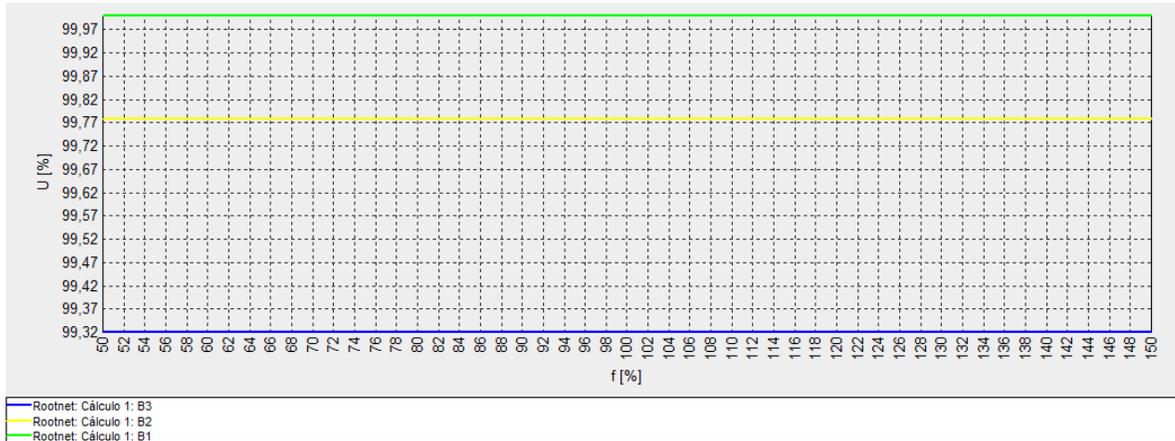
A continuación se muestran algunas de las técnicas de análisis:

#### **6.2.1.1 Análisis con curvas PV y VQ**

Las curvas PV y VQ son métodos que analizan los límites de cargabilidad de cada uno de los nodos o barras de un SEP. Las curvas PV por su parte, analizan cuánta potencia activa entrega cada nodo o grupo de nodos manteniendo la estabilidad de tensión. Mientras que las curvas VQ, analizan cuánta potencia reactiva consume cada nodo y cómo influye esto, con respecto a la variación de tensión en los mismos.

Para calcular las curvas P-V y V-Q del SEP del caso estudio anterior, se hace uso de la herramienta de simulación NEPLAN versión 5.43, donde se obtiene lo siguiente gráfica 1:

**Gráfica. 1 Curvas P-V (Caso estudio)**

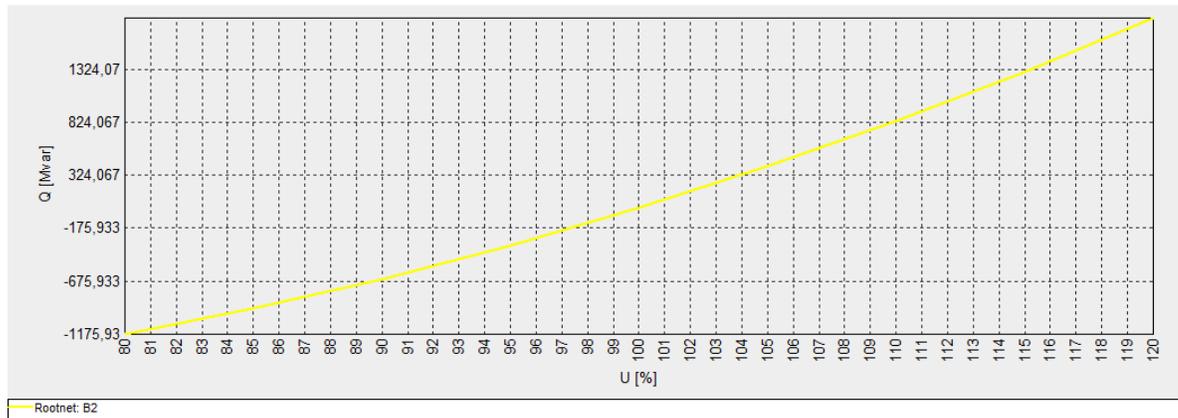


De la gráfica de 1 se observa las curvas P-V del SEP del caso estudio, donde puede analizar que la potencia que entrega cada nodo es constante ante cualquier cambio de tensión, debido a que cuando hay generadores en el sistema y estos no tienen límites, pueden entregar toda la potencia reactiva al sistema. Cabe resaltar que estas curvas se obtienen a partir de varios flujos de carga que se realizan al SEP, donde se van calculando los cambios de tensión ante los deltas de incrementos de la carga en el sistema.

Así mismo en la gráfica 2 se muestran las curvas V-Q de este sistema, donde se observa que:

- El Nodo B2 entrega potencia reactiva al sistema, lo que significa que este representa un valor muy importante ante la estabilidad del sistema con respecto a la tensión, debido a que la tensión en un SEP podría variar cuando se presentan consumos de potencia reactiva por los elementos del mismo, pero como en este caso no se está consumiendo sino aportando potencia reactiva, este sistema potencia va a presentar altos índices de confiabilidad con respecto a la estabilidad de tensión del mismo. Cabe resaltar que el Nodo B1, no presenta curva V-Q debido a que este nodo es controlado por tensión mediante un equivalente de red y en este caso las sensibilidades de estos nodos son iguales a cero [8].

**Gráfica. 2 Curvas V-Q (Caso estudio)**



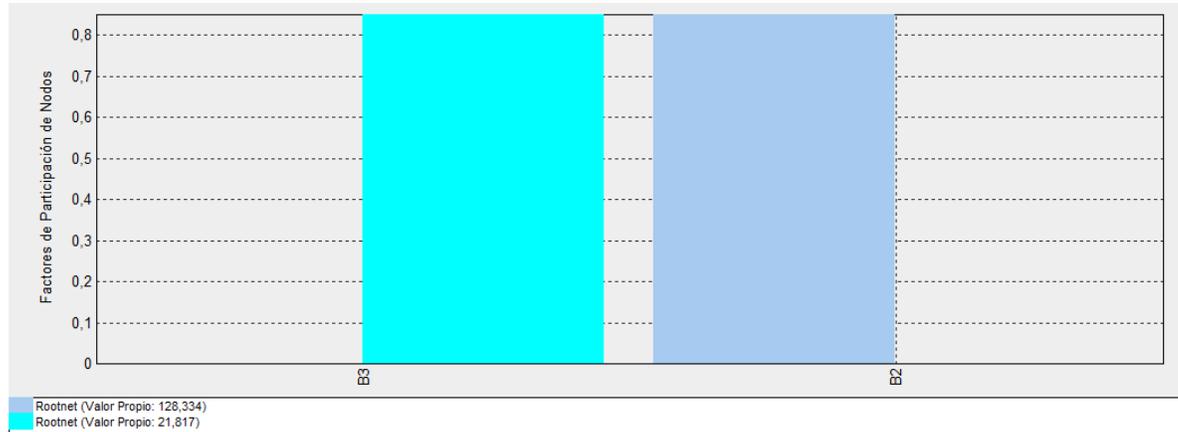
### 6.2.1.2 Análisis Modal

En este análisis se identifica cuáles son los nodos o áreas del sistema que son más vulnerable o sensible ante cualquier eventualidad o falla en el sistema eléctrico de potencia. Este análisis modal se realiza por medio del cálculo de valores y vectores propios provenientes de la matriz jacobiana reducida del SEP seleccionado. Cabe resaltar, que los valores propios son de gran ayuda al momento de analizar los motivos o causas que generaron inestabilidad al sistema. A continuación, se presenta el estudio nodal realizado al SEP del caso estudio:

- **Factores de participación por nodo:** indican los nodos más críticos dentro de un modo, el cual es seleccionado teniendo en cuenta los valores propios del sistema [8].

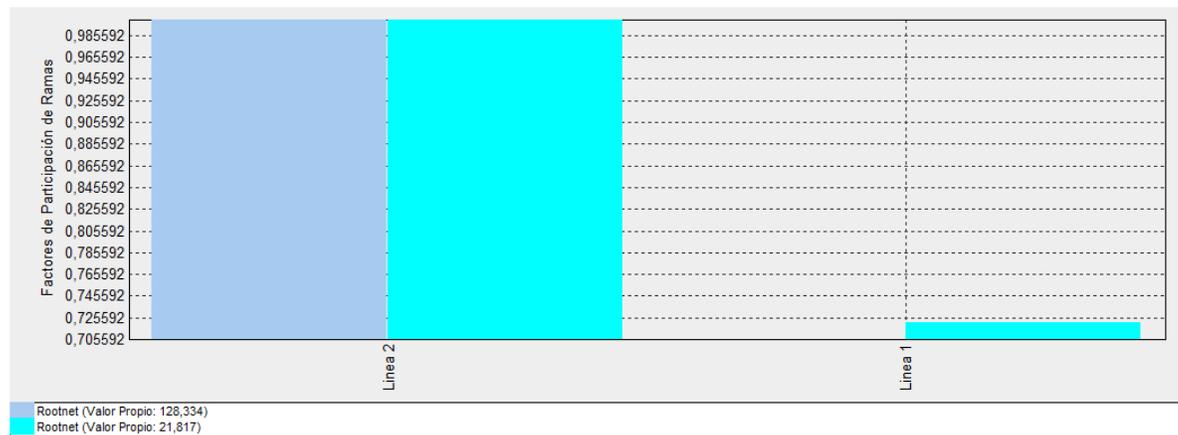
El estudio de los factores de participación por nodo para el caso de investigación se realizó por medio de la herramienta NEPLAN versión 5.43. En la gráfica 3 se puede observar que el nodo con mayor participación en el SEP para el modo definido por el valores propio: 21,817 en el Nodo B3 y para el modo con valor propio de 128,334 el modo que mayor participación tiene en el Nodo B2.

**Gráfica. 3 Factores de Participación por nodo**



- **Factores de participación por rama:** Estos factores hacen referencia a los elementos que consumen más potencia reactiva del sistema ante aumentos de carga en el mismo. Para el caso estudio, en la gráfica 4, se muestra como varían estos factores teniendo en cuenta los valores propios:
  - Para el modo con valor propio: 21,817: el elemento que más consumen potencia reactiva es la Línea 2, lo que significa que esta línea va a ocasionar problemas de inestabilidad de tensión en el sistema, debido a que cuando se consume potencia reactiva , la tensión tiende a disminuir .
  - Para el modo con valor propio: 128,334: el elemento que presenta mayor consumo de reactiva es la Línea 2 como se puede observar en la gráfica 4.

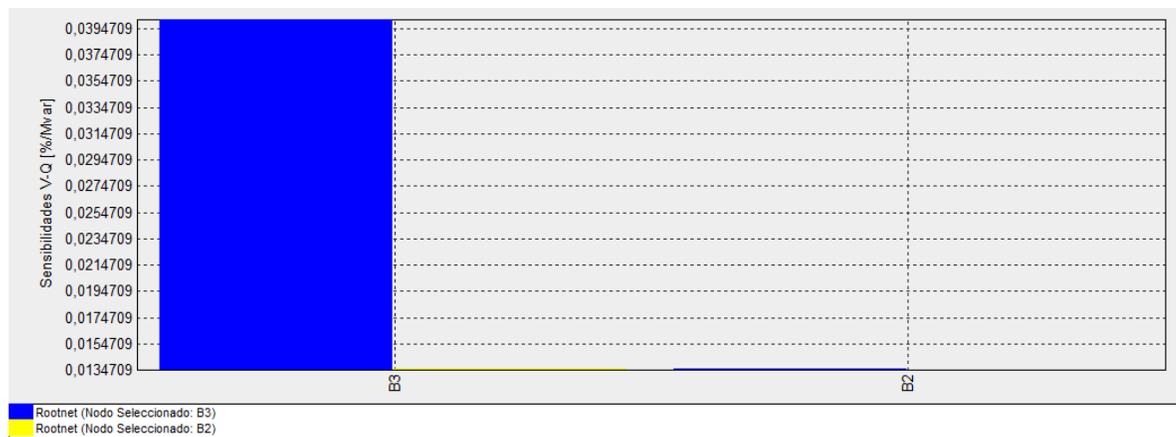
**Gráfica. 4 Factores de Participación de Ramas**



### 6.2.1.3 Análisis de Sensibilidad

Este tipo de análisis se realiza para observar que tan sensibles son los nodos del sistema, es decir, cual es comportamiento de cada nodo con base a su tensión ante variaciones de potencia reactiva en el mismo. Para el caso estudio, se realizó este análisis mediante simulaciones en la herramienta NEPLAN versión 5.43, como se observa en la gráfica 5:

**Gráfica. 5 Sensibilidades V-Q por nodo**



De la gráfica anterior, se puede analizar que el nodo más sensible que presenta el sistema eléctrico de potencia del caso estudio es el Nodo B3, para este caso es necesario que se compense con reactivos en esta zona, debido a que este es un punto clave que puede ocasionar inestabilidad de tensión al sistema, lo que dará como resultado una zona con muchas posibilidades de presentar en gran porcentaje fallas eléctricas dentro del sistema en general.

### 6.2.2 Identificación de Potencia Activa en cada nodo del Sistema Eléctrico de Potencia

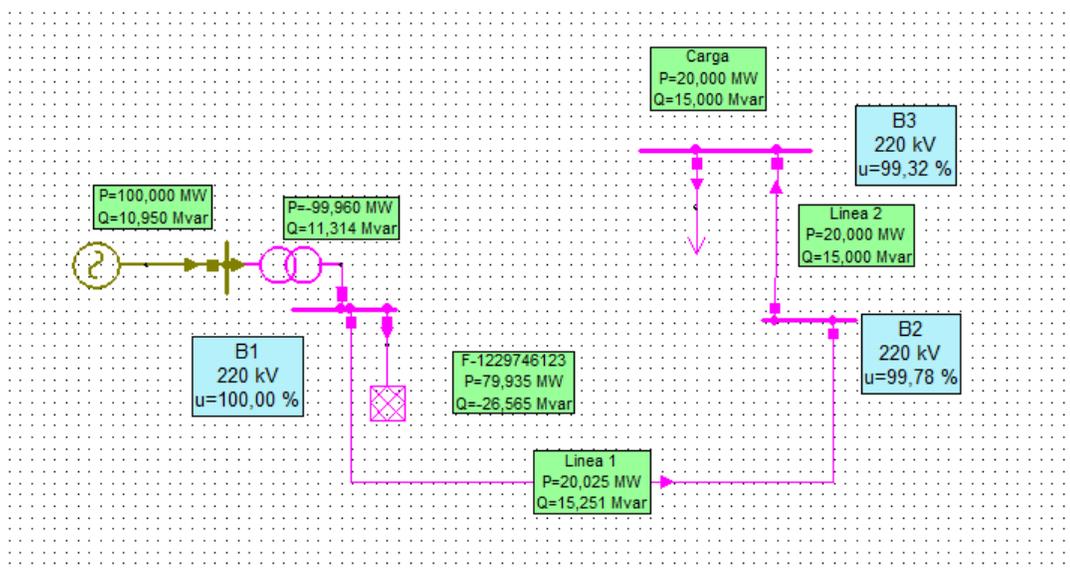
En esta etapa de la investigación, se realiza un estudio detallado de la línea de transmisión seleccionada, por medio de análisis de transferencia de carga de cada nodo o grupo de nodos al sistema. Para realizar este análisis, es necesario determinar diferentes curvas de potencia activa vs tensión para cada uno de los nodos del sistema. Estas curvas se obtienen mediante la siguiente metodología:

- Identificación de las variables globales para el estudio del sistema.

- Definición y caracterización cada uno de los parámetros de la línea de transmisión que se va analizar.
- Diseño de la función que permita calcular las curvas PV para cada nodo del sistema

A continuación en la figura 17, se muestran el flujo de potencia realizado para el SEP-caso estudio, en el cual se puede observar cual es la potencia activa máxima que soporta cada uno de los tramos de línea y los elementos que componen el sistema:

**Figura 17. Simulación del Flujo de carga de SEP-Caso estudio.**



Del flujo de potencia anterior, puede analizar que, ninguna de las dos líneas presenta sobrecarga, lo que indica que con los parámetros característicos de las mismas, estas pueden soportar la potencia a la cual fueron diseñadas y no van a causar inestabilidad de tensión en el sistema de potencia.

### 6.3 Conclusiones

Teniendo en cuenta las anteriores simulaciones se puede concluir que el SEP del caso estudio:

- Se encuentra diseñado con parámetros que permiten brindarle estabilidad al sistema eléctrico de potencia, lo cual se comprobó al momento de realizar el flujo de carga al sistema, donde no se evidenció que el sistema presenta sobrecargas trabajando en operación normal.
- El nodo B3 es el que presenta el mayor índice tanto de sensibilidad como de participación en el sistema. Por este motivo, debe estar protegido con un buen esquema de protecciones, como: protecciones de sobrecarga instantánea y/o temporizada (ANSI 50-51), protección diferencial (ANSI 87L), Sobrevoltaje (ANSI 27), entre otros. Con el objetivo de aislar cualquier daño o evento en el SEP.
- Las fallas que con frecuencia puedan afectar al sistema será ocasionadas en su mayoría por factores externos al sistema, tales como: aumento de carga o demanda al SEP, daños en equipos, etc. y en porcentajes pequeños relacionados con el diseño o parámetros del mismo SEP.

## **CAPÍTULO VII. ADQUISICIÓN, EXTRACCIÓN Y PREPARACIÓN DE LOS DATOS**

### **7.1 Introducción**

Este capítulo tiene como objetivo principal seleccionar las técnicas más adecuadas para la adquisición, extracción y preparación de los datos que serán las entradas al modelo de localización de falla diseñado mediante técnicas de inteligencia artificial que se estudiarán en el capítulo 8. Para el proceso de adquisición y extracción de datos se realizaron varias simulaciones de fallas de alta impedancia variando la impedancia de la falla ( $Z_{falla}$ ) mediante la herramienta SimPowerSystem de Matlab. Así mismo, para la preparación de los datos se emplearon las siguientes herramientas: Transformada discreta de Fourier y Transformada discreta de Wavelet.

A continuación, se muestran la metodología y actividades desarrolladas para llevar a cabo esta segunda y tercera fase del proyecto de investigación:

### **7.2 Análisis matemático para Fallas de Alta Impedancia para el SEP del caso estudio.**

Para analizar los diferentes eventos y/o fenómenos que presentan los sistemas eléctricos de potencia tales como: transitorios, fallas, flujos de carga, cortocircuitos, etc., existen diferentes programas y/o software que permiten simular todos estos fenómenos eléctricos. A partir de estos resultados, se obtiene información importante que permite realizar estudios detallados para brindarle tanto estabilidad como confiabilidad al sistema eléctrico. Algunas de las herramientas computacionales más utilizadas en la comunidad de estudio son: Neplan, Digsilent, ATP (Alternative Transient Program), EMTP/ATP, SimPowerSystem (Matlab), entre otros. Para el caso estudio, la herramienta seleccionada para las simulaciones de las fallas monofásicas y trifásicas de alta impedancia es SimPowerSystem (Matlab).

Teniendo en cuenta que para realizar el análisis matemático de la presente investigación se parte del esquema de una línea corta como el que se mostró en

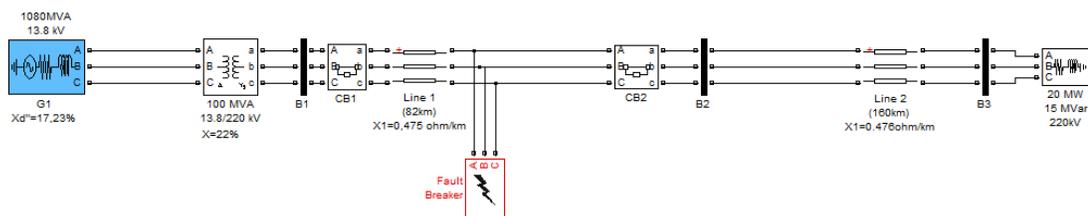
la figura 11, debido a que las dos líneas del caso estudio no superan los 80km de longitud.

Como se mencionó en secciones anteriores, el sistema de potencia del caso estudio cuenta con dos líneas de transmisión con una longitud aproximada de 80km y un nivel de tensión de 220kV conectadas a dos subestaciones perteneciente al sistema eléctrico colombiano. A partir de la investigación [43], las líneas de transmisión serán modeladas mediante el modelo de línea de transmisión que presenta la herramienta SimPowerSystem (Matlab), y para la simulación de FAI se utilizarán resistencias lineales de fallas con valores superiores a 50  $\Omega$ , las cuales fueron elegidas en varias investigaciones anteriores [5] [6].

### 7.3 Extracción de las variables y/o características del SEP mediante simulaciones

La extracción de los datos y/o variables del SEP del caso estudio son obtenidos por medio de las simulaciones realizadas en la herramienta SimPowerSystem, donde se modelaron varias fallas monofásicas de alta impedancia con rangos del 60  $\Omega$  a 100  $\Omega$  en el esquema de potencia de la figura 18.

Figura 18. Esquema de Potencia del Caso Estudio



Antes de realizar el análisis de fallas de alta impedancia en el esquema de potencia del caso estudio, se procede a calcular las corrientes de corto circuito trifásico en las barras: B1, B2 y B3 con el objetivo de tener un referencia acerca de los niveles de corto que se pueden presentar en SEP. Para iniciar este estudio, es necesario llevar el esquema de potencia de la figura 17 en por unidad (pu). A

continuación, se muestra el procedimiento del cálculo en por unidad del SEP para una Tensión base=220kV y una Potencia aparente base de 100MVA:

1. Se determina los voltajes base por Zona:

Voltaje base en la Zona 1(zona del generador):

$$V_{BG1} = \left( \frac{13,8kV}{220kV} \right) * 220kV = 13,8kV$$

2. Se calcula la impedancia base por Zona:

Impedancia base en la Zona 1(zona del generador):

$$Z_{BG1} = \left( \frac{V_{BG1}}{S_B} \right) = \left( \frac{13,8kV}{100MVA} \right) = 1,9044\Omega$$

Impedancia base en la Zona de las líneas de transmisión:

$$Z_{BL} = \left( \frac{V_{BL}}{S_B} \right) = \left( \frac{220kV}{100MVA} \right) = 484\Omega$$

3. Se calcula la impedancia en por unidad para cada elemento del SEP partiendo de la siguiente ecuación:

$$Z_{pu} = \frac{Z_{real}}{Z_{base}}$$

- Para el Generador G1

$$Z_{pu,G1} = Z_{vieja} * \left( \frac{V_{vieja}}{V_{nueva}} \right) * \left( \frac{S_{nueva}}{S_{vieja}} \right)$$

$$Z_{pu,G1} = (0,1723\Omega) * \left( \frac{13,8kV}{13,8kV} \right) * \left( \frac{100MVA}{1080MVA} \right) = 0,01595pu$$

- Para el Transformador T1:

$$Z_{pu,T1} = Z_{vieja} * \left( \frac{V_{vieja}}{V_{nueva}} \right) * \left( \frac{S_{nueva}}{S_{vieja}} \right)$$

$$Z_{pu,T1} = (0,22\Omega) * \left( \frac{220kV}{220kV} \right) * \left( \frac{100MVA}{100MVA} \right) = 0,22pu$$

- Para las Líneas:

$$Z_{pu,Line1} = \frac{Z_{real}}{Z_{base}} = \frac{\left( \frac{0,475\Omega}{km} \right) * (82km)}{484\Omega} = 0,08047pu$$

$$Z_{pu,Line2} = \frac{Z_{real}}{Z_{base}} = \frac{\left(\frac{0,476\Omega}{\text{km}}\right) * (160\text{km})}{484\Omega} = 0,1573pu$$

- Para la Carga:

La potencia aparente está determinada por:

$$S = P + jQ = (20 + j15)MVA$$

Con una base de 100MVA, la potencia aparente de la carga en pu es:

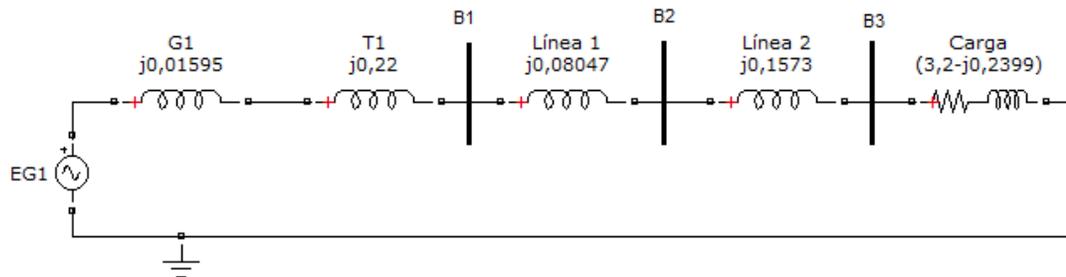
$$S_{carga (pu)} = P + jQ = (0,2 + j0,15)pu$$

Teniendo en cuenta lo anterior, la impedancia en pu de la carga es:

$$Z_{carga(pu)} = \frac{V_{carga(pu)}}{S_{carga(pu)}} = \frac{1pu}{(0,2 + j0,15)pu} = (3,2 - j2,399)pu$$

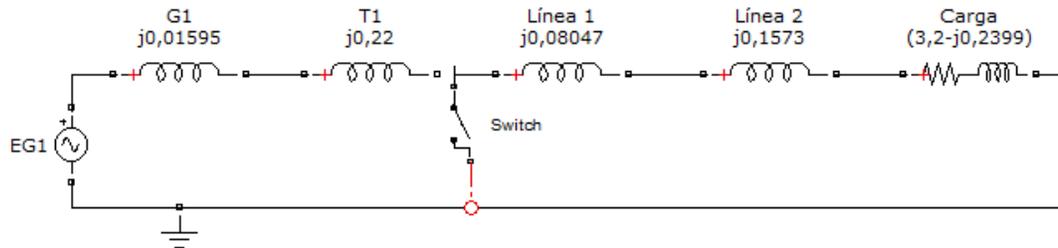
Finalmente, el SEP en pu es el que se muestra en la figura 19:

**Figura 19. Esquema de Potencia del Caso Estudio en pu**



Partiendo del esquema de potencia que se muestra en la figura 18, se procede a realizar el cálculo y el análisis de corto circuito trifásico franco en las Barras: B1, B2 y B3, asumiendo una impedancia de falla nula. Para este análisis se parte del hecho de que el sistema permanece balanceado durante la falla y por consiguiente, para el cálculo de las corrientes de falla solo se utilizará el esquema de potencia en secuencia positiva. Para la simulación de la falla en cada barra, se procede a colocar un switch en cada barra falla como se muestra a continuación en la figura 20:

**Figura 20. Esquema de Potencia del Caso Estudio en pu con falla trifásica franca en la barra B1**



Las corrientes trifásicas generadas por las fallas en las barras: B1, B2 y B3, se calculan resolviendo cada circuito por las leyes de Kirchhoff, dando como resultado lo siguiente:

$$I_{falla\ B1} = \frac{V_{fuente}}{Z_{B1}} = \frac{1}{j(0,1595 + 0,22)} = -j4,24pu$$

$$I_{falla\ B2} = \frac{V_{fuente}}{Z_{B2}} = \frac{1}{j(0,1595 + 0,22 + 0,08047)} = -j2,17pu$$

$$I_{falla\ B3} = \frac{V_{fuente}}{Z_{B3}} = \frac{1}{j(0,1595 + 0,22 + 0,08047 + 0,1573)} = -j1,62pu$$

Expresando los valores en amperios:

$$I_{falla\ B1} = 4,24 * \frac{100 * 10^3 kVA}{\sqrt{3} * 220 kV} = 1112,71 kA$$

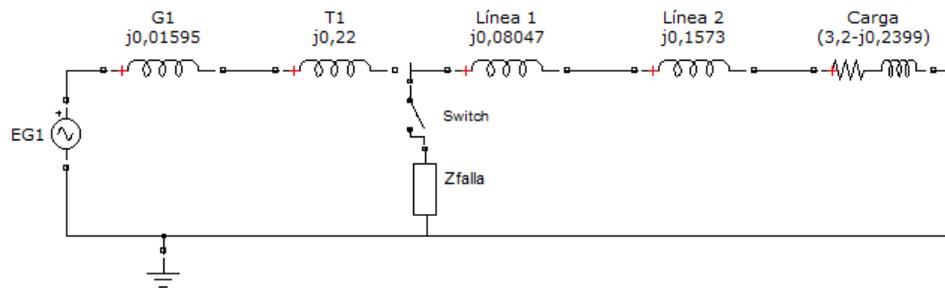
$$I_{falla\ B2} = 2,17 * \frac{100 * 10^3 kVA}{\sqrt{3} * 220 kV} = 569,48 kA$$

$$I_{falla\ B3} = 1,62 * \frac{100 * 10^3 kVA}{\sqrt{3} * 220 kV} = 425,14 kA$$

A partir de estos datos de corriente se concluye que a medida que la falla se aleja de la fuente de energía, las corrientes tienden a disminuir considerablemente en cada una de las barras, debido a que el efecto transitorio de la falla se va atenuando a medida que se aleja del punto fallido.

Teniendo en cuenta que el objetivo principal de la presente investigación es la localización y detección de fallas de alta impedancia, a continuación se realiza el cálculo de las corrientes ante una falla trifásica en las barras: B1, B2 y B3 para una impedancia de falla de  $Z_{falla}=100\text{ohm}$ . El esquema de potencia en pu utilizado para este cálculo es el que se muestra en la figura 21:

**Figura 21. Esquema de Potencia del Caso Estudio en pu con falla trifásica con impedancia en la barra B1**



Resolviendo cada falla trifásica en las barras: B1, B2 y B3 mediante la aplicación de las leyes de Kirchhoff, se obtiene:

$$I_{falla\ B1} = \frac{V_{fuente}}{Z_{B1}} = \frac{1}{j(0,1595 + 0,22 + 0,207)} = -j1,705pu$$

$$I_{falla\ B2} = \frac{V_{fuente}}{Z_{B2}} = \frac{1}{j(0,1595 + 0,22 + 0,08047 + 0,207)} = -j1,5pu$$

$$I_{falla\ B3} = \frac{V_{fuente}}{Z_{B3}} = \frac{1}{j(0,1595 + 0,22 + 0,08047 + 0,1573 + 0,207)} = -j1,21pu$$

Expresando estos los valores en amperios:

$$I_{falla\ B1} = 1,705 * \frac{100 * 10^3 kVA}{\sqrt{3} * 220kV} = 447,44kA$$

$$I_{falla\ B2} = 1,5 * \frac{100 * 10^3 kVA}{\sqrt{3} * 220kV} = 393,65kA$$

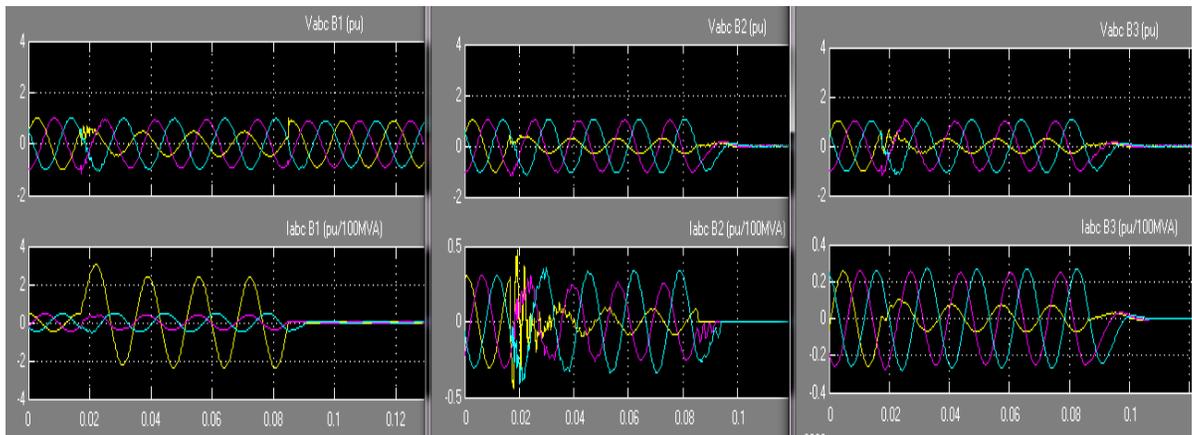
$$I_{falla\ B3} = 1,21 * \frac{100 * 10^3 kVA}{\sqrt{3} * 220kV} = 317,54kA$$

### 7.3.1 Resultados de Simulación para fallas de Alta Impedancia

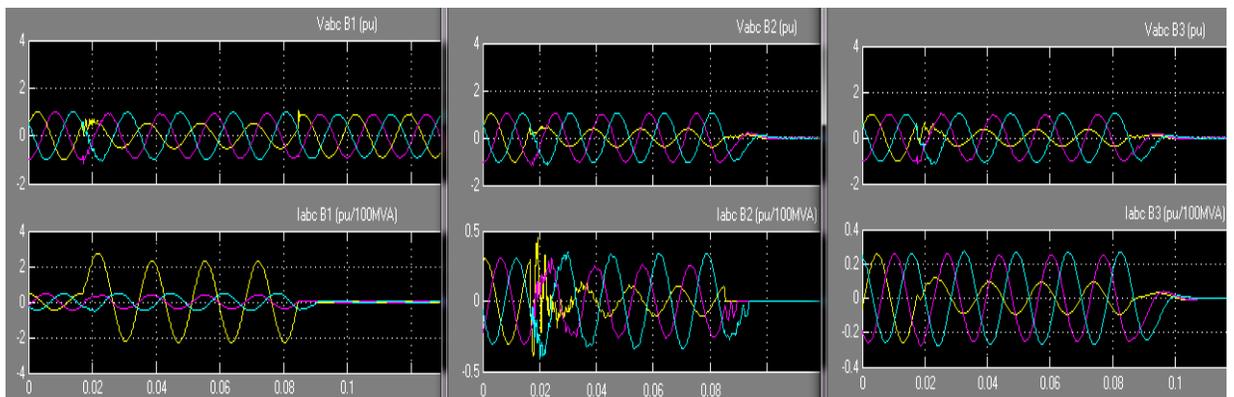
En las gráficas de la 6 a la 8 se muestran los resultados obtenidos de las simulaciones realizadas al esquema de potencia del caso estudio. En estas gráficas se observan las diferentes variaciones que presentan las variables de corriente y tensión ante una falla monofásica de alta impedancia en la fase A de Línea L<sub>gr</sub>.

Las simulaciones fueron realizadas en la herramienta SimPowerSystem para los siguientes casos de fallas de alta impedancia con  $R_{falla}$  de: 60  $\Omega$  (Gráfica 6), 80  $\Omega$  (Gráfica 7) y 200  $\Omega$  (Gráfica 8):

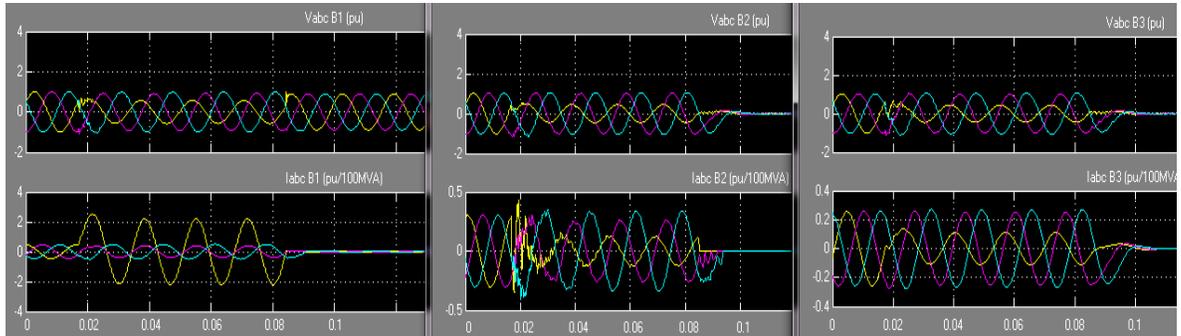
**Gráfica. 6 Variables eléctricas (V, I) ante una FAI en las Barra 1, 2 y 3 con  $R_{falla}=60 \Omega$**



**Gráfica. 7 Variables eléctricas (V, I) ante una FAI en las Barra 1, 2 y 3 con  $R_{falla}=80 \Omega$**



**Gráfica. 8 Variables eléctricas (V, I) ante una FAI en las Barra 1, 2 y 3 con  $R_{falla}=100 \Omega$**



#### **7.4 Técnicas de Procesamiento y normalización de los datos extraídos de las fallas de alta impedancia en el SEP del caso estudio**

Las técnicas utilizadas para el procesamiento de señales tiene como objetivo principal transformar la señal de entrada (señal análoga o digital) mediante formulaciones matemáticas tales como: Transformada rápida de Fourier, Transformada de Wavelet, entre otras, en datos o características normalizadas, las cuales serán utilizadas como entrada en otros procesos o sistema; obteniendo a su vez una señal de salida con cambios en: la amplitud o frecuencia, lo cual dependerá básicamente del tipo de procesamiento de datos que se implemente.

Teniendo en cuenta planteamientos utilizados en las investigaciones [18] [7], el grupo investigador a partir de los resultados obtenidos en estos estudios, decide realizar el procesamiento mediante las metodologías planteadas por la Transformada de Discreta de Fourier y la Transformada Discreta de Wavelet. Aunque el filtro de Kalman, también es utilizado para el procesamiento de la señal, no se implementó en este estudio debido a que presenta la limitación que para implementar este tipo de filtro, se requieren condiciones iniciales del sistema a modelar tales como: la media y la varianza del vector estado<sup>5</sup> para iniciar el algoritmo recursivo [13].

---

<sup>5</sup> Vector estado: es el que contiene las variables de interés. Para el caso estudio, correspondería los valores de corriente y tensión (Pre-falla, Falla y Post-Falla) del SEP seleccionado.

A continuación, se presentan los planteamientos matemáticos para las técnicas de procesamiento de señal seleccionadas:

### 7.4.1 Transformada discreta de Fourier

La transformada discreta de Fourier [44] se define como se muestra en la ecuación 26:

$$X(k) = \sum_{n=0}^{N-1} x(n) * e^{-j2\pi k / N} \quad \text{Ecuación 26}$$

Dónde:

$$W_N = e^{-j2\pi k / N}$$

Reemplazando:

$$X(k) = \sum_{n=0}^{N-1} x(n) * W_N \quad \text{Ecuación 27}$$

De la ecuación 27 se observa que el cálculo de X(k) requiere de N multiplicaciones complejas para cada valor de k y N-1 sumas complejas.

La ecuación 27 se descompone en dos ecuaciones una donde se expresan las muestras pares y otras donde se expresan las muestras impares, como se muestra en las siguientes expresiones:

$$X(2k) = \sum_{n=0}^{N/2-1} x(2K) * W_N^{2nk} \quad \rightarrow \text{Muestras\_pares}$$

$$X(2k+1) = \sum_{n=0}^{N/2-1} x(2k+1) * W_N^{(2n+1)k} \quad \rightarrow \text{Muestras\_impares}$$

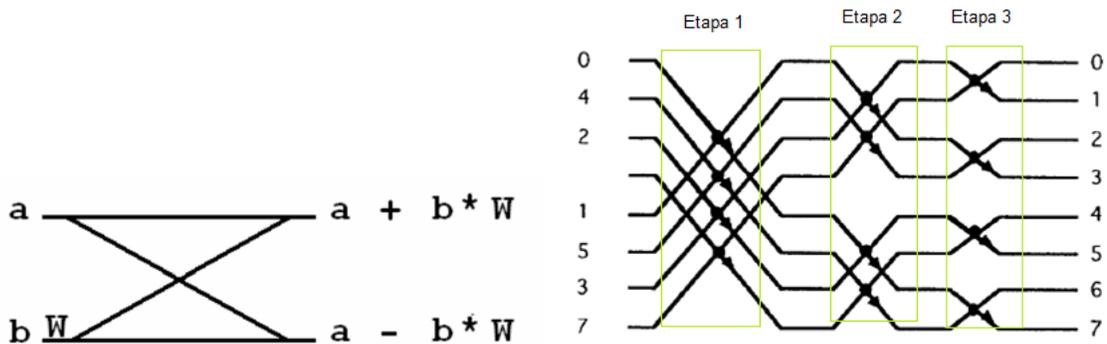
Reemplazando las anteriores expresiones en la ecuación 27 se obtiene:

$$X(k) = \sum_{n=0}^{N/2-1} f(n) * W_{N/2}^{nk} + \sum_{n=0}^{N/2-1} g(n) * W_{N/2}^{nk} * W_N^k \quad \text{Ecuación 28}$$

Cada expresión independiente de la ecuación 28 expresa la transformada de Fourier para N/2 puntos.

Las operaciones para obtener f(n) y g(n) a partir de la metodología llamada mariposa, como se muestra en la figura 22:

**Figura 22. Mariposa sencilla y etapas de iteración de la mariposa**



Fuente: Acosta Orozco. Julián F, Vera-Lizcano. Mario, Velasco Medina. Jaime. FFT de 8 Puntos IEEE754 Sintetizado en FPGA. [En línea]: < [http://bionano.univalle.edu.co/FFT\\_8\\_SPS05.pdf](http://bionano.univalle.edu.co/FFT_8_SPS05.pdf) >

Para el análisis de la transformada se recomienda tener en cuenta las siguientes propiedades:

**Propiedad de Simetría:**

$$W_N^{k+N/2} = -W_N^k$$

**Propiedad de Periodicidad**

$$W_N^{k+N} = -W_N^k$$

### 7.4.2 Transformada discreta de Wavelet [45]

La Transformada Wavelet es muy utilizada para aplicaciones de análisis de señales no estacionarias [6] [18] [46] [47] [48], ya que permite el análisis multiresolución con ventanas dilatadas, la cual es una técnica capaz de analizar las señales en múltiples bandas de frecuencia [49]. Es una técnica que divide los datos, funciones y operadores en diferentes componentes de frecuencia, para luego estudiar cada uno de los componentes de la transformada como una resolución adaptada a su escala [50].

El diseño de una Transformada Discreta de Wavelet consiste en definir una apropiada red discreta de parámetros de escalas y traslaciones:  $\{(a_j; b_{jk})\}$  de modo de que la familia de wavelets sea válida. Algunas de las clases de wavelets válidas son los tipos: Spline, Daubechies, entre otras. Estas clases se asocian a la red diádica:

$$a_j = 2^{-j} ; b_{jk} = 2^{-j}k$$

Teniendo en cuenta estos parámetros, la expresión utilizada para representar a las Wavelets es:

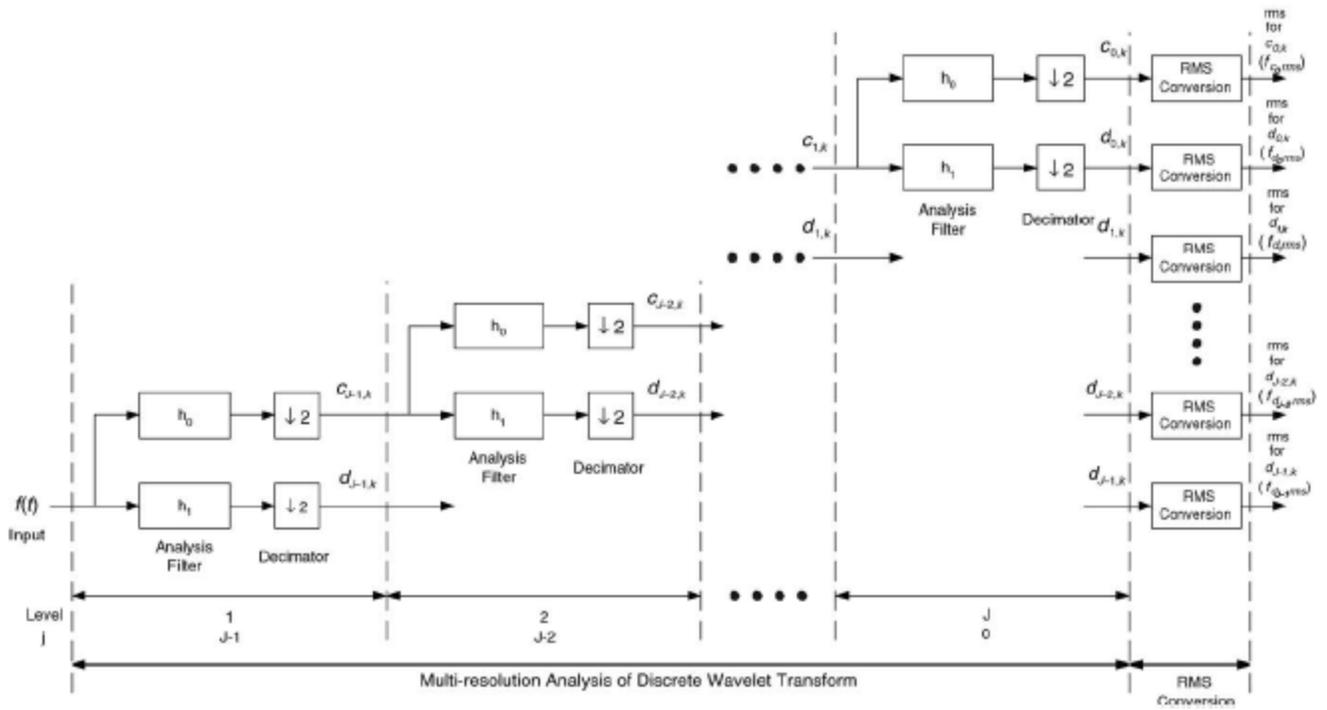
$$\varphi_{jk}(t) = 2^{\frac{j}{2}} \varphi(2^j t - k)$$

Asumiendo que la wavelet madre real y una señal  $s(t)$  de energía finita, la Transformada Discreta se define como:

$$DW_{\varphi} s(j, k) = \langle s, \varphi_{jk} \rangle = \int_{-\infty}^{\infty} s(t) \varphi_{jk}(t) dt$$

En la figura 23 se muestra un esquemático de la Transformada Discreta de Wavelet:

Figura 23. Diagrama Esquemático de la Transformada Discreta de Wavelet



Fuente: [48]

- **Mapeo de las escalas a rango de frecuencia [48]:** Para el mapeo de las escalas existen dos niveles de resolución que son utilizados con frecuencia, los cuales son:

- Nivel de orden ascendente, el cual va desde el nivel de resolución más fino (1) hasta el nivel de resolución más grueso (J).
- Nivel de orden descendente, el cual comprende desde el nivel de resolución más fino (J-1) hasta el nivel de resolución más grueso (0).

Nota: J es el nivel total de resolución y se define como:

$$\text{Nivel} = J - j \quad \text{Ecuación 29}$$

Y la escala de resolución es definida como:

$$Escala_{nivel} = 2^{j-Nivel} = 2^j \text{ Ecuación 30}$$

Las señales de entrada  $d_{j+1}$  en el nivel de resolución superior se divide en la aproximación  $c_j$  por un filtro pasa bajos  $h_0$  y el detalle  $d_j$  por un filtro pasa alto  $h_1$ . La primera aproximación de  $c_{j-1}$  y el primer detalle de  $d_{j,1}$  en el nivel de resolución 1 son muestreados a la mitad de la frecuencia de la señal. Teniendo en cuenta lo anterior, la máxima frecuencia  $freq_{nivel}$  para las señales  $c_j$  y  $d_j$  es:

$$freq_{nivel} = \frac{freq_s}{2^{Nivel}} \text{ Ecuación 31}$$

- **Calculo de los valores rms desde los coeficientes de escalas/coeficientes wavelet [48]:** Estos coeficientes representan la señal distorsionada  $s(t)$  en diferentes niveles de resolución con el objetivo de realizar el análisis multi-resolución definido como:

$$\begin{aligned} & \text{rango de frecuencia baja} \rightarrow \text{rango de frecuencia alta} \\ & coeff_{señal} = [c_0 | d_0 | d_1 | \dots | d_{j-2} | d_{j-1}] \end{aligned}$$

Dónde:

$J$ : máximo nivel en el análisis multi – resolución

$c_0$ : coeficiente de aproximación en el nivel 0

$d_j$ : detalle en el nivel  $j$

Los valores rms para los coeficientes de aproximación o detalle en cada nivel de wavelet se puede representar por extensión periódica en los bordes. Los coeficientes de escala en el nivel  $J(j=0)$ , los valores rms en este nivel se define como:

$$f_{c0rms} = \sqrt{\frac{\|f_{c0}\|_2^2}{L_{f(t)}}} = \sqrt{\frac{\sum_k c_0(k)^2}{2^J L_{c_0}}} \text{ Ecuación 32}$$

Dónde:

$$L_{f(t)}: \text{número de puntos de } f(t) \text{ y } L_{c0}$$

Para los coeficientes wavelet, los coeficientes rms en el nivel j se define como:

$$f_{d_j rms} = \sqrt{\frac{\|f_{d_j}(t)\|_2^2}{L_{f(t)}}} = \sqrt{\frac{\sum_k d_j(k)^2}{2^{nivel} L_{d_j}}} = \sqrt{\frac{\sum_k d_j(k)^2}{2^{J-j} L_{d_j}}} \quad \text{Ecuación 33}$$

$$L_{f(t)} = 2^{nivel} L_{d_j} = 2^{J-j} L_{d_j}$$

Dónde:

$$L_{f(t)}: \text{número de puntos en los coeficientes wavelet } d_j$$

Finalmente, los vectores rms que representan la escala de coeficientes y coeficientes wavelet de la señal distorsionada s(t) en los diferentes niveles de resolución son:

$$rms_{señal} = [f_{c0rms} | f_{d0rms} | f_{d1rms} \dots | f_{d_{j-2}rms} | f_{d_{j-1}rms}]$$

$$rms_{señal} = \left[ \sqrt{\frac{\sum_k c_0(k)^2}{2^J L_{c0}}} \mid \sqrt{\frac{\sum_k d_0(k)^2}{2^J L_{d0}}} \mid \sqrt{\frac{\sum_k d_1(k)^2}{2^{J-1} L_{d1}}} \mid \dots \mid \sqrt{\frac{\sum_k d_{j-2}(k)^2}{2^2 L_{d_{j-2}}}} \mid \sqrt{\frac{\sum_k d_{j-1}(k)^2}{2^2 L_{d_{j-1}}}} \right]$$

### **7.4.3 Resultados del Procesamiento de la Señales Eléctricas seleccionadas**

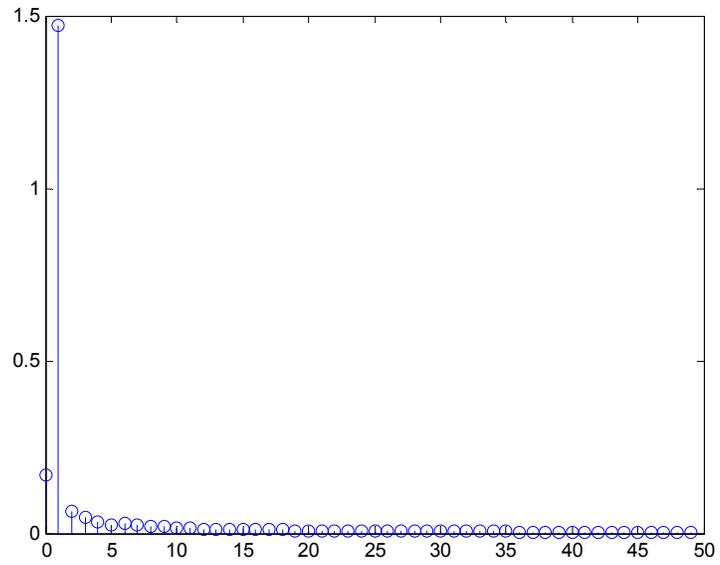
En esta sección se muestran los resultados obtenidos a partir los dos planteamientos matemáticos utilizados para el procesamiento de datos de las señales de corriente y tensiones, generadas durante una falla de alta impedancia en el sistema seleccionado.

#### **7.4.3.1 Resultados del Procesamiento de la Señales Eléctricas mediante la Transformada discreta de Fourier**

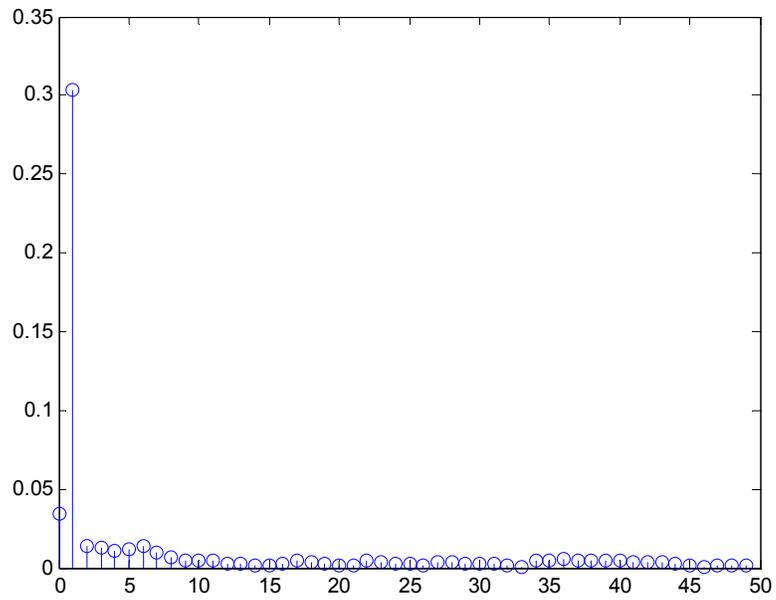
Teniendo en cuenta el planteamiento matemático expuesto en esta sección sobre la Transformada Discreta de Fourier, en la presente investigación se realizó el procesamiento de los datos obtenidos de las simulaciones de alta impedancia realizadas en el capítulo 7 de este documento, el cual permitió analizar los armónicos de la señal generada durante la falla en el sistema. Para el caso estudio, los armónicos seleccionados como entradas a la Red Neuronal son los armónicos impares. Esto debido a que este tipo de armónicos son los más se observan en los sistemas eléctricos, tales como 180Hz el tercer armónico, 300Hz el quinto armónico, 420Hz el séptimo armónico, 540Hz el noveno armónico, 660Hz el décimo primer armónico y así sucesivamente [12] [51].

A continuación en la gráfica 9 y 10 respectivamente, se muestra un análisis espectral de los armónicos de corriente y tensión generados ante una falla ocurrida en la Fase A del Barra 1 del SEP seleccionado, donde se observa cómo se comentó anteriormente, que los armónicos más representativos en un sistema eléctrico de potencia son los componentes impares.

**Gráfica. 9. Armónicos de la señal de Corriente al momento de un falla en la fase A**



**Gráfica. 10. Armónicos de la señal de Tensión al momento de un falla en la fase A**



En el Anexo B, se puede observar con más detalle el código diseñado para el análisis espectral de los armónicos generados para las 180 pruebas realizadas al SEP seleccionado.

Realizando una comparación entre los dos métodos expuestos anteriormente, se analiza que la Transformada de Fourier es muy utilizada para el procesamiento y análisis de las señales, presentando resultados muy satisfactorios para aplicaciones con señales tipo periódicas. Pero cabe resaltar, que para aplicaciones en las cuales los espectros de las señales varían con el tiempo, esta transformada no es la más recomendable, debido que solo detecta una determinada frecuencia y no brinda mucha información acerca de los cambios en el tiempo de las características de la señal [49]. Por este motivo, y teniendo en cuenta el objetivo principal de la presente investigación se enfoca en la localización de FAI por medio del análisis de las señales transitorias que generan este tipo de eventos en el sistema, el grupo investigador decidió optar por implementar otro método de procesamiento de señales como la Transformada de Wavelet ,para analizar y descomponer las señales obtenidas, esto debido a que esta transformada es capaz de analizar fenómenos transitorios y de alta frecuencia mejor que la Transformada de Fourier [49] [6]. A continuación, se muestran los principales resultados del procesamiento de las señales mediante la Transformada discreta de Wavelet:

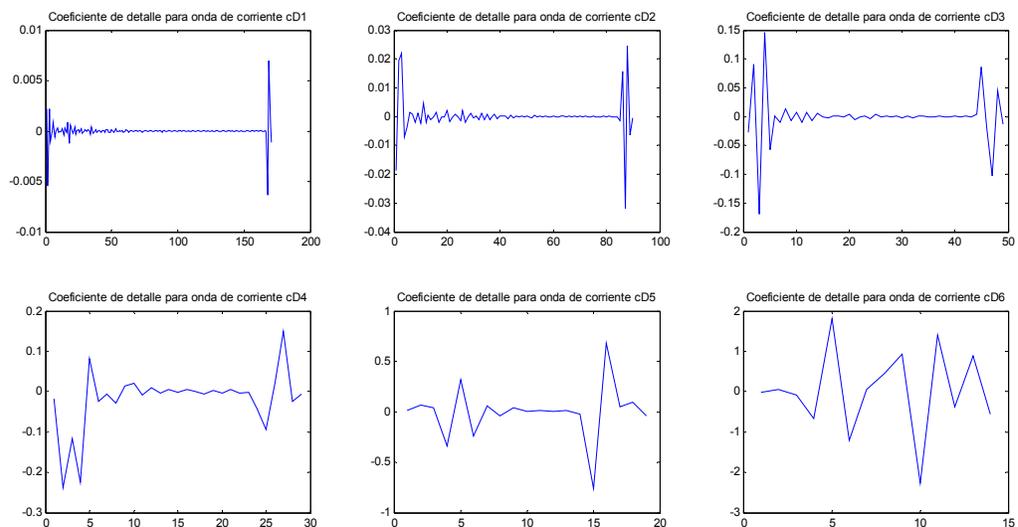
#### **7.4.3.2 Resultados del Procesamiento de la Señales Eléctricas mediante la Transformada discreta de Wavelet**

Como se indicó en el planteamiento matemático expuesto sobre Transformada Discreta de Wavelet, esta permite convertir las tres señales tanto de corriente y como de tensión, en una dimensión en la etapa de eliminación del ruido de la señal [6]. Para este caso en particular, se analizan 6 coeficientes de detalle (cD1, cD2, cD3, cD4, cD5 y cD6) y 1 coeficiente de aproximación (cA6) tanto para las señales de corriente como de tensión generadas durante una falla de alta impedancia en el sistema seleccionado. Teniendo en cuenta los resultados obtenidos en la investigación [6], se utilizó la wavelet madre Daubechies (db5) para el procesamiento de las señales. Posteriormente, estas siete (7)

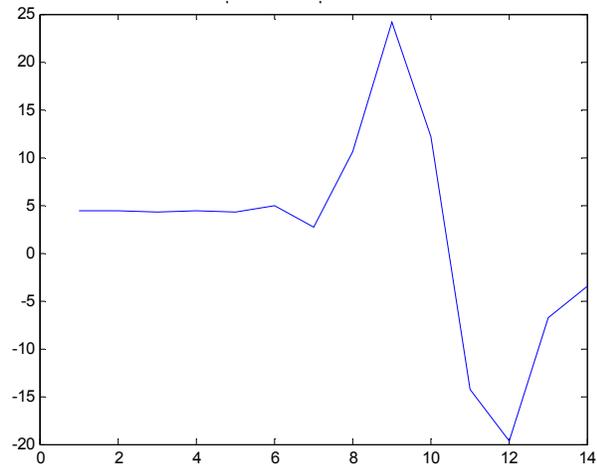
características extraídas tanto de las señales de corriente como de tensión se probaran como las entradas a la Red Neuronal.

A continuación, en las gráficas 11 y 12 se muestran los coeficientes de detalle y el coeficiente de aproximación (cA6) para la señal de corriente y en las gráficas 13 y 14 los coeficientes de detalle y el coeficiente de aproximación (cA6) para la señal tensión, respectivamente, durante una falla de alta impedancia. Se observó, a partir de varias pruebas, que los coeficientes de detalle más allá de la 6ª descomposición, eran muy pequeños en magnitud. Cabe resaltar, que los coeficientes de detalle, permiten observar las variaciones aproximadas de la señal mientras que los coeficientes de aproximación permiten obtener una forma general de la señal

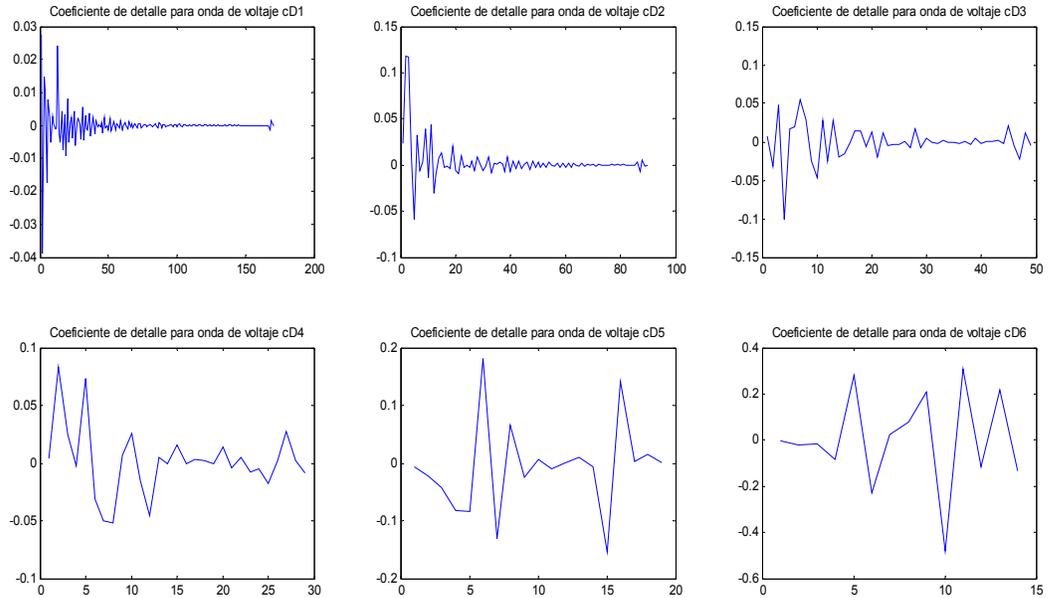
**Gráfica. 11. Coeficiente de detalle para la señal de corriente**



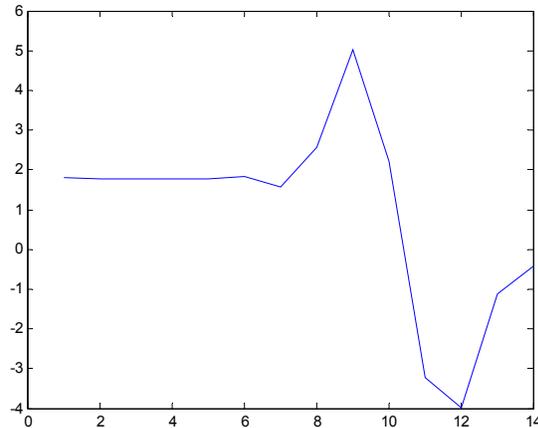
**Gráfica. 12. Coeficiente de aproximación cA6 para la señal de corriente**



**Gráfica. 13. Coeficiente de detalle para la señal de tensión**



**Gráfica. 14. Coeficiente de aproximación cA6 para la señal de tensión**



En el Anexo C, se puede observar con más detalle el código diseñado para el análisis de los coeficientes de detalle y aproximación para las 180 pruebas realizadas al SEP seleccionado.

Teniendo en cuenta los resultados expuestos anteriormente mediante la aplicación de ambas transformadas con la herramienta de simulación Matlab, se obtuvo que el tiempo promedio que se tarda en procesar y extraer los datos de entrada para la red neuronal por medio de la Transformada de Fourier fue de 0,0019 s mientras que para la Transformada de Wavelet fue de 0,0049 s. En ambos casos, el tiempo de procesamiento es menor que el tiempo de un ciclo de las señales eléctricas (corriente y tensión) del sistema, el cual tiene una duración de 0,0166 s. A partir de estos valores, se puede observar que la Transformada de Fourier tiene un tiempo de procesamiento menor que la Transformada de Wavelet, por ende es recomendable utilizar este tipo de procesamiento cuando se analice el sistema con base en los esquemas de protección de mismo, ya que este permitirá realizar el proceso de apertura o cierre del interruptor para despejar con mayor rapidez las fallas en el sistema eléctrico de potencia.

## 7.5 Conclusiones

Teniendo en cuenta los resultados obtenidos tanto en el proceso de simulación de fallas de alta impedancia como en el procesamiento de las señales de corrientes y tensión generadas en la misma, se concluye que:

- En la Barra 1 (barra más cercana a la falla), la corriente en la fase A presentó aumentos considerables, lo cual podría confundirse con un aumento de carga en el sistema y no con una falla de alta impedancia. Así mismo, se observó que para ese lapso de tiempo en el cual la corriente aumentó, la tensión para estos instantes disminuyó un poco con respecto a su amplitud en pre-falla, este comportamiento podría confundirse con perturbaciones de armónicos en el sistema. Pero este no es el caso, en esta situación la Barra 1 está presentando las consecuencias ocasionadas por la falla en la fase A de la línea 1 del sistema, el cual por encontrarse más cercano al punto fallado, presenta aumentos considerables en las señales de corriente y perturbaciones en las señales de tensión esta fase.
- En la Barra 2, la señal de corriente en la fase A disminuyó considerablemente a tal punto que a medida que transcurría el tiempo de falla, estas fueron disminuyendo hasta llegar a valores casi nulos, mientras que la señal de tensión cayó prácticamente a 0V cuando se presentó la falla en el sistema.
- En la Barra 3, tanto la señal de corriente como de tensión disminuyeron considerablemente a tal punto que a medida que transcurría el tiempo de falla, fueron presentando valores casi nulos.
- Los cambios en las señales de corriente y tensión del sistema varían de forma inversamente proporcional con respecto a la  $Z_{falla}$ , es decir, a medida que aumenta la resistencia de falla, la corriente de falla va tomando valores de amplitudes menores.
- Con base en la Transformada de Fourier desarrollada para el procesamiento de las señales generadas por las FAI<sup>6</sup>, se observó que los armónicos impares son los que más aportan en la distorsión de las señales eléctricas en los SEP<sup>7</sup>.

---

<sup>6</sup> FAI: Falla de Alta Impedancia

<sup>7</sup> SEP: Sistema Eléctrico de Potencia

- Transformada de Wavelet en tiempo discreto es capaz de analizar fenómenos transitorios de alta frecuencia en comparación a la Transformada de Fourier [49]. En el caso de estudio, se emplearon 6 niveles de descomposición porque con estos se detectan oscilaciones de alta frecuencia en la señal y a su vez, la forma general de la forma de onda con el coeficiente de aproximación CA6.

## **CAPÍTULO VIII. ESTUDIO E IMPLEMENTACIÓN DE REDES NEURONALES PARA EL PROCESO DE LOCALIZACIÓN DE FALLAS DE ALTA IMPEDANCIA.**

### **8.1 Introducción**

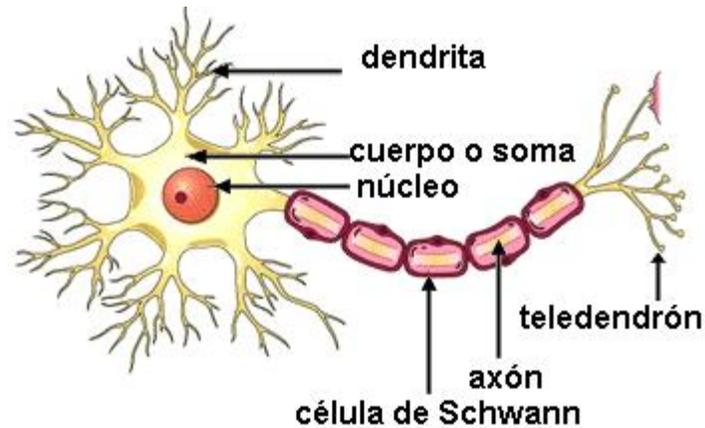
En esta sección se estudian con detalle las principales características de las redes neuronales, así como su proceso de entrenamiento y validación. De igual forma, se presenta una descripción general acerca de la arquitectura y funcionamiento de una red neuronal y la función que cumplen cada uno de los elementos que la componen, tales como: las entradas, los pesos y la función de activación.

### **8.2 Modelo de Redes Neuronales Artificiales-RNA**

Una red neuronal artificial (RNA) es un sistema dinámico que presenta un solo sentido de conexiones, en la cual su funcionamiento es muy similar al proceso de aprendizaje del cerebro humano [14]. Una RNA permite simular el proceso de aprendizaje humano mediante procesos de aprendizajes complejos compuestos por procesadores simples conectados en paralelo, cuya función principal es determinada ya sea por: la estructura de la red, la fuerza en las conexiones y el procesamiento realizado por los nodos del sistema [43].

La estructura básica de una neurona está conformada por tres partes: un cuerpo celular, una entrada (dendrita) y una salida (Axón) como se muestra en la figura 24:

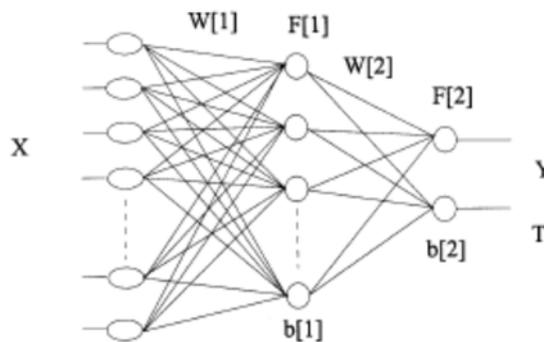
Figura 24. Neurona Humana



Fuente: [52]

Al igual que una neurona humana, las neuronas artificiales también están compuestas por: un cuerpo celular, las entradas y la salida. La figura 25 muestra una RNA.

Figura 25. Red neuronal artificial (Arquitectura de un perceptrón multicapas)



Fuente: [1]

En las redes neuronales artificiales, la unidad análoga a la neurona humana es el elemento procesador (PE-process element), el cual tiene la función principal de procesar varias entradas que pasan a través de pesos o ganancias ( $W$ ), luego son combinadas mediante sumatorias, las cuales son modificadas a su vez por una

función de transferencia se pasan directamente a la salida del elemento procesador [53].

De observaciones acerca de proceso o comportamiento de una neurona biológica con una artificial se ha hallado lo siguiente [54]:

- Las entradas  $X$  son señales que provienen de otras neuronas y se captura por medio de las dendritas. En una neurona artificial, la entrada neta en cada unidad se representa como el producto de la entrada con el peso :

$$neta_i = \sum_{i=1}^n W_i * X_i \text{ Ecuación 34}$$

- Los pesos  $W$  son valores reales que representan la intensidad de la sinapsis que permite conectar a las dos neuronas. Estos pesos pueden ser positivos (excitatorios) o negativos (inhibitorios).
- La función de transferencia  $F$  es la función que la neurona debe sobrepasar para activarse.
- Cuando se calcula función de activación del nodo, el valor de la salida  $Y$  o  $T$  es calculada como función de las entradas :

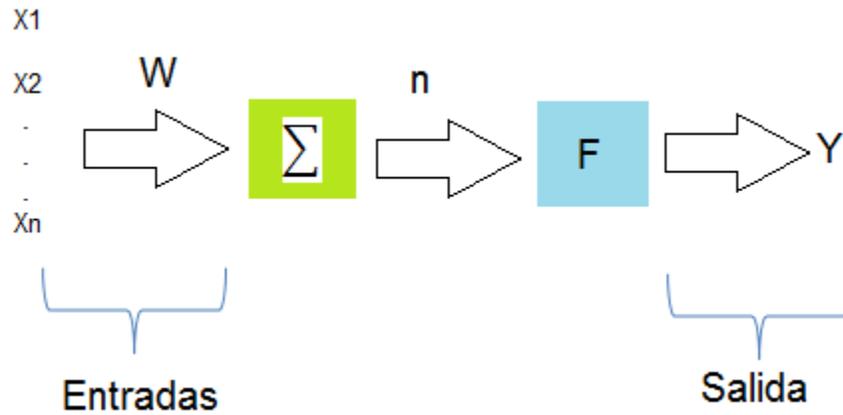
$$Y_i = F_i(neta_i) \text{ Ecuación 35}$$

Una de las características principales que se debe tener en cuenta cuando se diseña una red neuronal es escoger la función de transferencia adecuada que permita activar de la mejor forma la red, cabe resaltar que “esta función es la encargada de relacionar la información de entrada de la neurona con el siguiente estado de activación de la misma”<sup>8</sup>. En la figura 26 se muestra un modelo esquemático de la funcionalidad de una red neuronal:

---

<sup>8</sup> M. Gestal Pose, "Introducción a las Redes de Neuronas Artificiales," [Online]. Available: <http://sabia.tic.udc.es/mgestal/cv/RNAtutorial/TutorialRNA.pdf>. [Accessed 6 Febrero 2015].

**Figura 26. Modelo de una Red Neuronal**



Dónde:

$X_1, X_2, \dots, X_n$ : Entradas

$W$ : Peso

$n$ : Sumador

$Y$ : Salida

A continuación, en la tabla 7 se muestra un resumen detallado acerca de las principales características de cada tipo de función de activación:

**Tabla 7. Tipos de Neuronas y Funciones de activación**

Tipo de Neurona	Tipo de Función	Característica	Relación Entrada/Salida
<p><b>Neuronas lineales:</b> Su salida es linealmente dependiente de sus entradas</p>	<p><b>Lineal</b></p> 	<p>Las neuronas que emplean esta función son las utilizadas para los diseños de redes tipo Adaline. Limitación: cambios pequeños en las entradas producen fluctuaciones grandes en las salidas.</p>	$Y = n$
<p><b>Neuronas no lineales:</b> La salida de la neurona no es una función lineal de sus entradas. Este tipo de neurona genera respuestas acotadas, desapareciendo los problemas de fluctuación</p>	<p><b>Umbral</b></p> 	<p>Restringe la salida a valores entre 1 y -1</p>	$Y = \begin{cases} 1 \rightarrow n \geq 0 \\ -1 \rightarrow n < 0 \end{cases}$
	<p><b>Sigmoide</b></p> 	<p>En esta función los valores de entrada varían entre más y menos infinito y la salida se restringe a valores entre cero y uno.</p>	$Y = \frac{1}{1 + e^{-n}}$
	<p><b>Tangente Sigmoidal Hiperbólica</b></p> 	<p>Es una función suave de la función umbral y sus valores de salida varían entre -1 y 1<sup>9</sup>.</p>	$Y = \frac{e^n - e^{-n}}{e^n + e^{-n}}$

Fuente: [54] [55]

<sup>9</sup> D. J. Matich, Redes Neuronales: Conceptos Básicos y Aplicaciones, 2001.

## 8.2.1 Operación básica de una Red Neuronal

Una red neuronal representa una estructura de procesamiento de información mediante la utilización de múltiples capas en paralelo, que consideran el conocimiento adquirido durante la etapa de entrenamiento para responder ante nuevos eventos de manera apropiada y rápida, teniendo en cuenta las experiencias vividas durante su proceso de formación. La operación básica de una red neuronal se describe en tres etapas [1]:

**8.2.1.1 Entrenamiento:** el objetivo de la etapa de entrenamiento es ajustar todos los pesos y sesgos de la red, para obtener desviaciones mínimas entre los datos esperados y las salidas de la red calculadas en relación con el valor promedio de todas las muestras de entrada. En el proceso de entrenamiento existen diversos mecanismos de aprendizaje de la red, tales como [56]:

- **Aprendizaje supervisado** [56]: Este tipo de aprendizaje se caracteriza porque el proceso de entrenamiento es controlado por un supervisor o agente externo, el cual es el encargado de supervisar que la respuesta se genere a partir de la entrada determinada. Así mismo, tiene la función de modificar o variar los pesos ( $W$ ) con el objetivo de obtener la salida deseada. Este tipo de aprendizaje se puede implementar a través de varias metodologías como:
  - Aprendizaje por corrección de error: Consiste en ajustar los pesos en función del error generado a la salida.
  - Aprendizaje por refuerzo: En este tipo de aprendizaje la salida no se indica exactamente en la etapa de entrenamiento.
  - Aprendizaje estocástico: Consiste en realizar cambios aleatorios en los valores de los pesos y evaluar su efecto a partir del objetivo deseado (salida) y distribuciones probabilísticas.
  
- **Aprendizaje no supervisado** [56]: En este tipo de aprendizaje, la red no requiere un agente externo o supervisor para realizar el ajuste de sus pesos. En este caso, la red debe encontrar las características, relaciones, etc., que puedan establecerse entre los datos que se presentan en la entrada para obtener finalmente la salida. Al igual que el aprendizaje anterior, este tipo de aprendizaje se puede implementar a través de varias metodologías tales como:

- Aprendizaje hebbiano: En este tipo de aprendizaje se extraen las principales características de las entradas para obtener el modelo que genera la salida de la red.
- Aprendizaje competitivo y comparativo: Este tipo de aprendizaje tiene la función de clasificar los datos de entrada, para generar un patrón que permita reconocer estas entradas y relacionarlas con su respectiva salida.

**8.2.1.2 Verificación:** En esta etapa se revisa el diseño de la red neuronal, primero mediante la utilización de las muestras y/o datos utilizados en la fase de entrenamiento y luego mediante datos no utilizados en el entrenamiento, con el objetivo de comprobar que la red si esta lista para ser implementada, ya que responde ante eventos tanto entrenados como no entrenados.

**8.2.1.3 Operación:** En esta etapa se prueba finalmente la red con datos reales y/o simulados del sistema donde se va implementar.

En modelo de una RNA está determinando mediante una arquitectura como la que se mostró en la figura 24, en donde: X representa las entradas de la red, W (i) representa la matriz de pesos, F (i) la función de transferencia, b (i) el vector de sesgos para capas neuronales individuales, T es el vector de salida de entrenamiento de la red y Y el vector de salida, el cual es calculado mediante la siguiente expresión:

$$Y = F[2](W[2] * F[1](W[1] * X - b[1]) - b[2]) \text{Ecuación 36}$$

Teniendo en cuenta la formulación anterior, una RNA se puede utilizar para implementar modelos de aprendizaje en la relación entradas-salidas de vectores de entradas características de diferentes aplicaciones, tales como: reconocimiento de patrones, clasificaciones, diagnostico de fallas, entre otras [6]. Para llevar a cabo estas aplicaciones es recomendable seguir los siguientes pasos de implementación [1]:

- Seleccionar una arquitectura red de acuerdo a la aplicación donde serán implementadas.
- Seleccionar las reglas de aprendizaje.
- Entrenar y verificar el buen funcionamiento y comportamiento de la red ante diferentes eventos que ocurra en el sistema seleccionado para el estudio.

En la presente investigación con el fin de analizar y seleccionar un modelo de red neuronal para la localización de fallas en un SEP, llevó a cabo un estudio detallado acerca de diferentes investigaciones [1] [2] [5] [6] [16] [24] [10] [43] desarrolladas mediante redes neuronales artificiales, dando como resultado la siguiente clasificación de redes neuronales de acuerdo a su tipología:

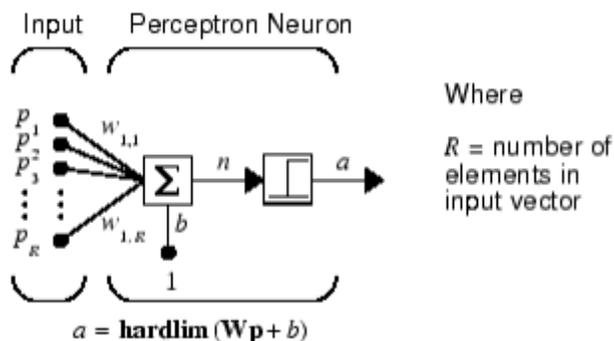
## 8.2.2 Modelos de Red Neuronal

### 8.2.2.1 Modelo de Red Perceptrón de una capa

Este tipo de red es capacitada o entrenada para responder a cada vector de entrada con su correspondiente vector esperado de salida, cuyos elementos son 0 ó 1. Cabe resaltar, que las reglas de aprendizaje de este modelo, se aplican a cada neurona del sistema con el objetivo de ir calculando los nuevos pesos y sesgos de la red [14].

El perceptrón trabaja bajo funciones de activación, las cuales son funciones no lineales que utilizan la suma de los estímulos (entradas) para determinar la salida de la neurona. Como se muestra en la figura 27, cada entrada es multiplicada por un factor de peso, luego estos valores son sumados y evaluados contra un umbral  $q$ , el cual determina que si este valor es mayor al máximo, el perceptrón se activa [43].

Figura 27. Modelo de RNA tipo perceptrón aplicado en Matlab



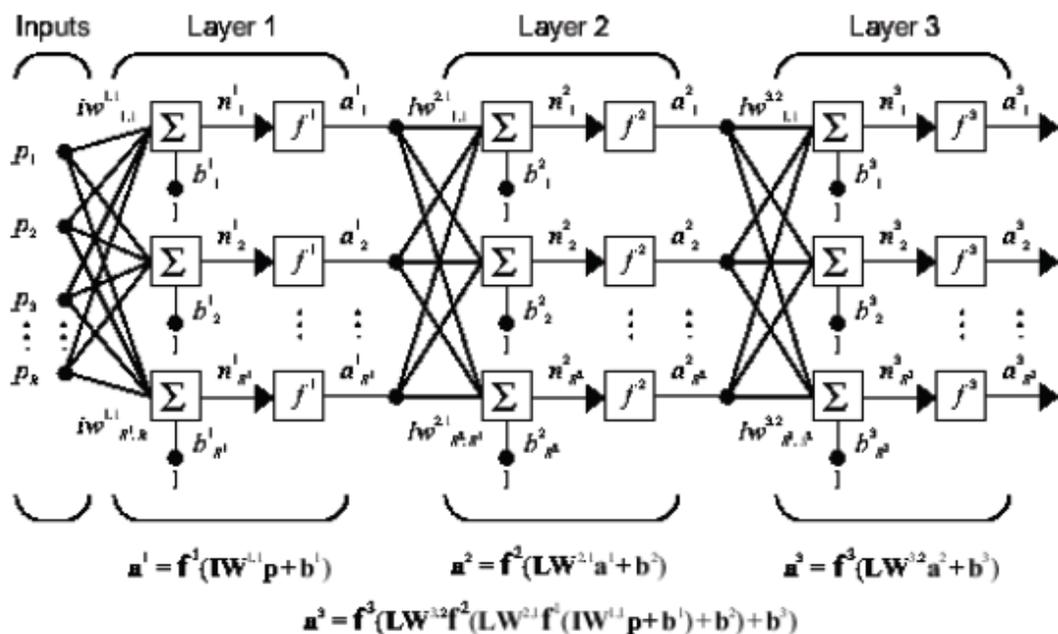
Fuente: [57]

Cabe resaltar, que teniendo en cuenta la investigación [14], el modelo perceptrón aunque su estructura es menos complicada, está limitado por el hecho que su salida sólo puede tomar dos valores 0 ó 1. Así mismo, en [43] muestran que modelo sólo puede resolver una función, si todos los posibles resultados del problema pueden separarse de forma que no se combinen entre sí.

### 8.2.2.2 Modelo de Red Perceptrón Multicapa con entrenamiento del tipo Backpropagation

El modelo de la Red Neuronal Perceptrón Multicapa [57] conocido también como el como modelo feedforward, se caracteriza porque cada capa tiene una matriz de pesos  $W$ , un vector de sesgo “ $b$ ” y un vector de salida “ $a$ ”, como se muestra en la figura 28, en la cual las salidas de cada una de las capas intermediadas son las entradas respectivas a la siguiente capa y así de forma sucesiva hasta que llegan a la última capa y finalmente a la única salida de red.

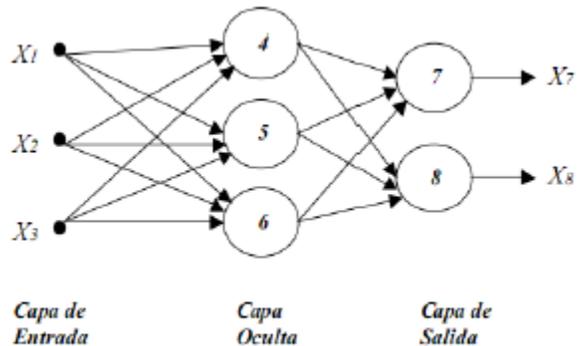
Figura 28. Neurona con múltiples capas



Fuente: [57]

Este modelo de red, comúnmente es entrenado mediante el método de Backpropagation, en el cual la unidad de procesamiento básico se representa como se observa en la figura 29:

**Figura 29. Modelo Backpropagation**



Fuente: [43]

En este modelo la unidad procesadora se caracteriza por realizar una suma ponderada de las entradas, representar una salida y tener un valor asociado que será utilizado en el proceso de ajustes de pesos del modelo, el cual será modificado durante el proceso de aprendizaje de la red (los pesos son ajustados de forma que disminuyan el error entre la salida deseada y la respuesta de la red). Así mismo, este tipo de redes se caracterizan por presentar un entrenamiento supervisado, en el cual se le presentan una serie de parejas de patrones (un patrón de entrada con su patrón de salida) con el objetivo de enseñarle cual deberá ser su respuesta ante el evento presentado [53].

El modelo Backpropagation presenta dos clases de entrenamiento:

**Propagación hacia adelante:** en esta clase de entrenamiento, se presenta un patrón en la capa de entrada de la red. Las unidades de entradas toman su correspondiente elemento del patrón de entrada y calculan el valor de activación para la primera capa (función de transferencia), y este procedimiento lo van propagando hacia adelante en las demás capas de la red hasta obtener la salida de la misma. Cabe resaltar, que las unidades procesadoras de la capa de entrada no realizan ninguna operación de cálculo con sus entradas, ni operaciones, solo asume su salida como un valor el valor correspondiente a la vector de entrada presentado y calcula el error en las unidades de salida [53] [43].

**Propagación hacia atrás:** la propagación hacia atrás se inicia una vez se ha finalizado la propagación hacia adelante. En esta etapa, se calculan las modificaciones para todos los pesos iniciando por la capa de salida y continuando hacia atrás a través de todas de capas de la red hasta llegar a la capa de entrada. Cabe resaltar que el ajuste de los pesos de la red en esta etapa se puede calcular por dos métodos [53]:

- Ajustes en la capa de salida: cada unidad de la capa de salida genera un número real como salida y este es comparado con el valor deseado especificado en el entrenamiento, a partir de esto se calcula el valor del error como se muestra a continuación:

$$\delta_j = (t_j - a_j) f' (S_j) \text{ Ecuación 37}$$

Dónde:

$t_j$ : valor de salida deseado  
 $f'$ : derivada de la función umbral  $f$

- Ajuste en las capas ocultas: debido a que estas capas no tiene un vector de salidas deseadas, el error calculado para este tipo de unidades se obtiene:

$$\delta_j = [\sum_k \delta_k w_{kj}] f' \text{ Ecuación 38}$$

Entonces, el ajuste de los pesos se calcula como:

$$\Delta w_{kj} = n * \delta_j * a_i$$

Dónde:

$n$ : coeficiente de aprendizaje

Teniendo en cuenta algunos resultados de la investigación [14], cuando se emplean modelos de Backpropagation aunque se emplean arquitecturas de red más complejas, las salidas pueden requerir más análisis.

### **8.2.3 Diseño e implementación de la Red Neuronal para localización de FAI<sup>10</sup> en sistema eléctrico de potencia seleccionado**

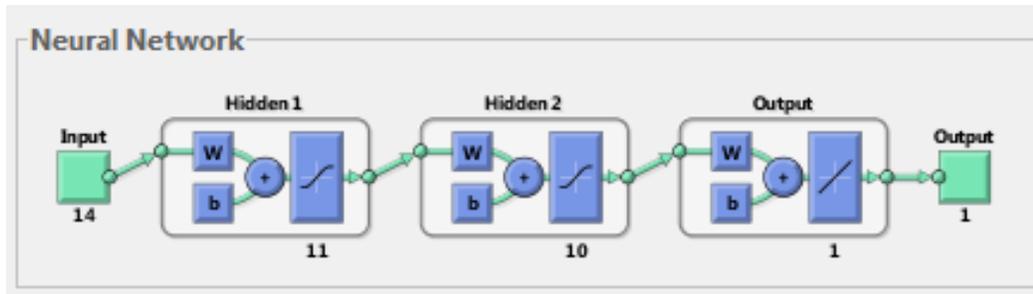
Teniendo en cuenta que el objetivo principal de la presente investigación se enfoca en la localización del punto de falla de alta impedancia en una línea de transmisión aérea de 220kV, y a partir de varias investigaciones relacionada con esta temática [1] [2] [6] [14] [24], se ha diseñado una red neuronal del tipo perceptrón multicapa, conocido como modelo feedforward, en el cual cada capa tiene una matriz de pesos  $W$ , vector de sesgo  $b$  y un vector de salida  $a$  [57], como se mostró en la figura 28. Además, se observa que en este tipo de modelos de red neuronal, las salidas de cada una de las capas intermediadas son las entradas respectivas a la siguiente capa y así de forma sucesiva hasta que llegan a la última capa y finalmente a la única salida de red, que para esta aplicación sería el porcentaje de la longitud de la línea donde ocurrió la falla, el cual está normalizado en valores entre 0 y 1, donde 1 indica el 100% de la línea.

Cabe resaltar, que cada una de las capas por las cuales está conformada esta red neuronal, cumplen funciones diferentes dentro del proceso de implementación, para el caso de la herramienta de simulación utilizada denominada Neural Network Toolbox de Matlab, la última capa se denomina capa de salida, ya que es la que genera la salida de la red y las demás capas son denominadas capas ocultas. Para el diseño de la red neuronal de la investigación, luego de varias pruebas y teniendo en cuenta los errores relativos productos de la diferencia entre la salida y el valor esperado, la red seleccionada fue un Perceptrón Multicapa con entrenamiento de Regularización Bayesiana el cual obtuvo un error promedio relativo de 0,22% para la localización de la falla, que en comparación con otras pruebas realizadas fue el que mejor resultado presentó. La arquitectura de la red que se diseñó e implementó como se muestra en la figura 30:

---

<sup>10</sup> FAI: Falla de Alta Impedancia

Figura 30. Arquitectura de la Red Neuronal Propuesta



En la figura 29, se observa que la red neuronal diseñada que dio como resultado el menor porcentaje de error luego de varias pruebas, fue la red con la siguiente arquitectura:

- 14 entradas que corresponden a los 7 primeros armónicos impares tanto para las corrientes como las tensiones generadas durante la FAI en sistema. Cabe resaltar, que se seleccionaron estos armónicos, debido a que son los armónicos que más se generan en los sistemas eléctricos, tales como 180Hz el tercer armónico, 300Hz el quinto armónico, 420Hz el séptimo armónico, 540Hz el noveno armónico, 660Hz el décimo primer armónico y así sucesivamente [12] [51].
- 2 capas ocultas cada una con 11 y 10 neuronas respectivamente y 1 capa de salida.
- La salida representa el porcentaje de la línea a la cual ocurre la FAI, este resultado se encuentra normalizado entre valores de 0 y 1, donde 1 representa el 100% de la línea.

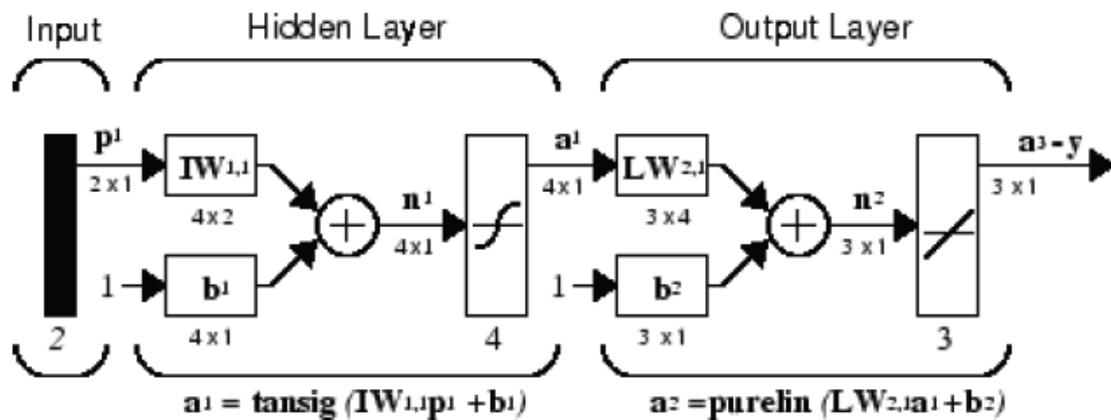
Algunas de las características generales que presenta el diseño de esta red son:

- Para las capas ocultas, la función de activación utilizada fue la Tan-Sigmoid, en la cual la entrada puede tomar valores entre  $-\infty$  y  $+\infty$  y la salida entre el rango de 0 y 1. Debido a que la salida de este sistema varía entre 0 y 1, esta es una de las mejores funciones de activación que cumplen con esta característica
- Para la capa de salida, la función de activación implementada fue una Lineal (purelin). Esta función es comúnmente utilizada para la capa de salida en redes de múltiples capas, ya que son funciones de aproximación [57]. En nuestro

caso, al necesitar calcular la localización de la falla en un intervalo de 0 al 100%, la función de activación lineal permite obtener mayor exactitud en la estimación de la distancia.

En la figura 31 se muestra las anteriores características:

Figura 31. Planteamiento matemático de la Arquitectura de la Red Neuronal Propuesta



Fuente: [57]

- Se realizaron un total de 180 simulaciones de falla de alta impedancia y se extrajeron datos de corrientes y tensiones para los estados de: pre-falla, falla y post-falla. En las simulaciones se realizaron variaciones de: impedancia de falla en los rangos entre 60-100 ohm, ángulos de inyección: 0°, 30°, 60° y 90°, y el porcentaje de longitud de la línea donde ocurrió la falla entre el 20% y 100%. Se extrajo el primer ciclo de la señal de corriente y tensión durante la falla en cada prueba y estas señales se procesaron mediante la transformada discreta de Fourier, para estimar los armónicos. Se seleccionaron los armónicos impares: 1, 3, 5, 7, 9, 11 y 13 de corriente y tensión, y se emplearon como entradas de la red neuronal.

#### 8.2.4 Resultados del Proceso de Entrenamiento, validación y prueba de la Red Neuronal diseñada

El entrenamiento y evaluación de las redes neuronales se realizó con Matlab 2013. Los requerimientos del equipo de cómputo se resumen a continuación [70]:

- Plataforma: Windows 32, Windows 64.
- Sistema Operativo: Windows XP/Server 2003/Server 2008/Vista/W7/W8.
- Memoria RAM mínimo: 1024 MB, recomendado 2048 MB.
- Tipo de Procesador: Intel o AMD x86 soportando SSE2.
- Espacio en el disco: 3-4Gb (instalación típica).

A continuación se presentan las consideraciones tenidas en cuenta en el diseño de la red neuronal, así como los principales resultados del proceso de entrenamiento, validación y prueba. Del total de 180 vectores de prueba que se obtuvieron con las simulaciones, 160 se emplearon para entrenar, validar y probar la red neuronal. Los restantes 20 se emplearon para simular y evaluar el desempeño de la red. La división de la matriz de datos de la red, para el entrenamiento, la validación y la prueba se realizó mediante el algoritmo “dividirand”, el cual divide los 160 vectores de prueba de forma aleatoria en tres grupos: 70% para el entrenamiento, 15% para la validación y 15% para prueba.

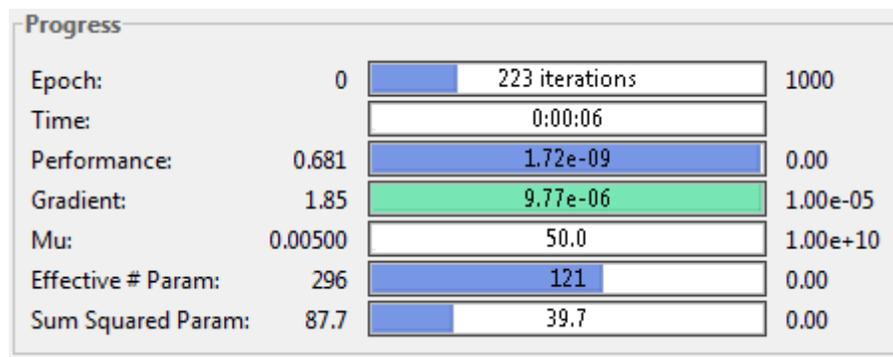
- El método seleccionado para entrenar a la red fue supervisado, a través del algoritmo de Regulación Bayesiana, debido a que fue el cual presentó el menor error en la salida en comparación con otros métodos de aprendizaje (ver Anexo A). Este método consiste en que los pesos de la red se asumen como variables aleatorias con distribuciones específicas, en las cuales los parámetros de la regularización son asociadas a estas distribuciones, y por lo tanto es posible estimar dichos parámetros empleando técnicas estadísticas de aproximación [10].
- La función de rendimiento de la red utilizada en la simulación es la función mse, la cual tiene como objetivo ajustar los valores de los pesos y los sesgos de la red para optimizar el rendimiento de la misma. Esta función mide el promedio del error cuadrado entre la salida “a” y salida objetivo(valor esperado) t; y está definido como [57]:

**Ecuación 39**

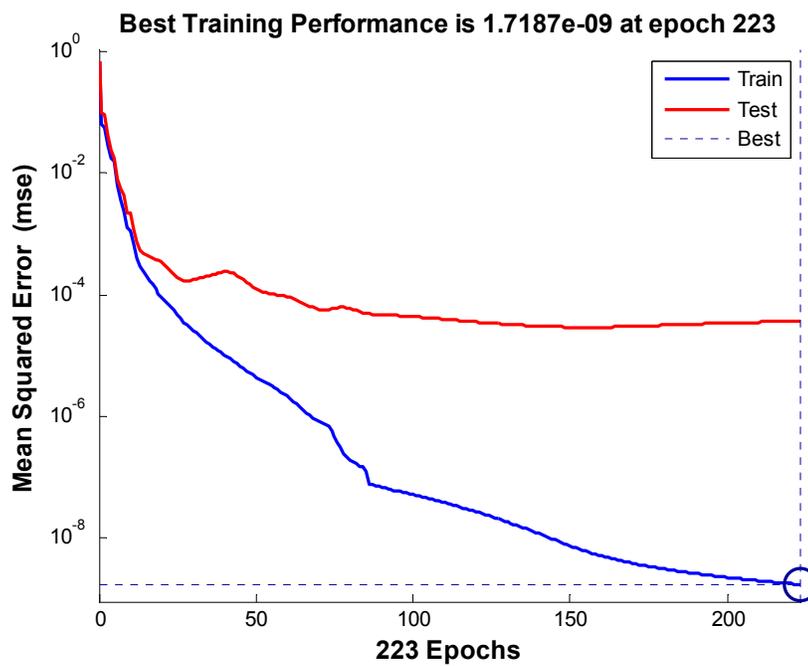
$$F = \frac{1}{N} \sum_{i=1}^N (e_i)^2 = \frac{1}{N} \sum_{i=1}^N (t_i - a_i)^2$$

Para el caso estudio, el rendimiento y el promedio de error cuadrado calculado se muestran en la figura 32 y la gráfica 15 respectivamente.

**Figura 32. Progreso del entrenamiento mediante el algoritmo de Regularización Bayesiana y la Transforma Discreta de Fourier**



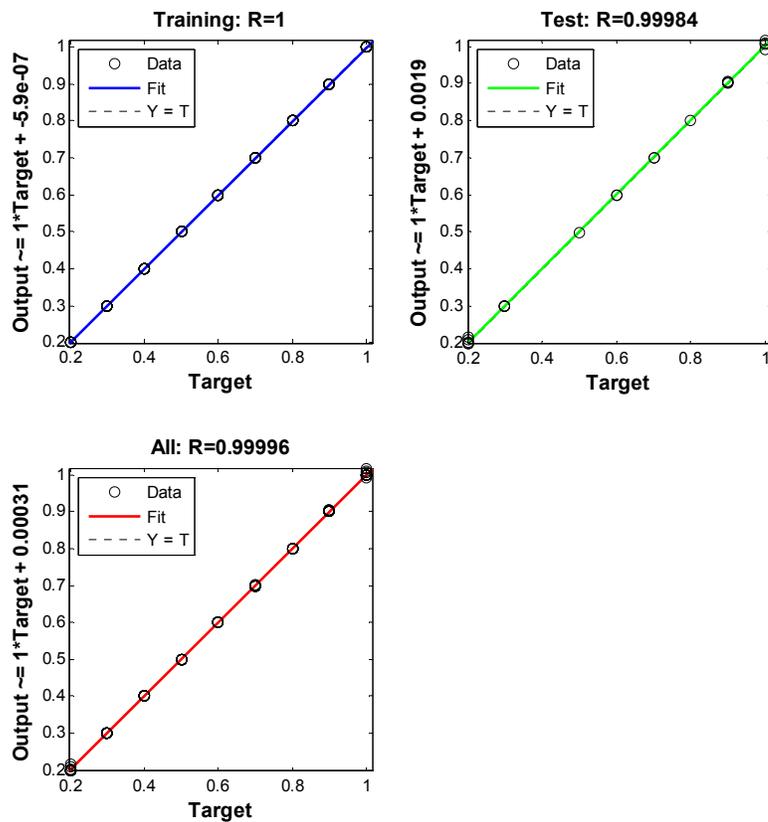
**Gráfica. 15. Error cuadrado promedio de la red neuronal mediante el algoritmo de Regularización Bayesiana y la Transforma Discreta de Fourier**



De la gráfica 15, se puede analizar que el entrenamiento de la red se realizó hasta la iteración 223 y que tanto las curvas de entrenamiento como de prueba son bastante cercanas hasta aproximadamente la iteración 25.

Así mismo, en la gráfica 16 se observa que la regresión tanto para la etapa de entrenamiento, validación y prueba, la R es mayor a 0,9, lo que indica una buena aproximación entre a salida de la red y los datos esperados.

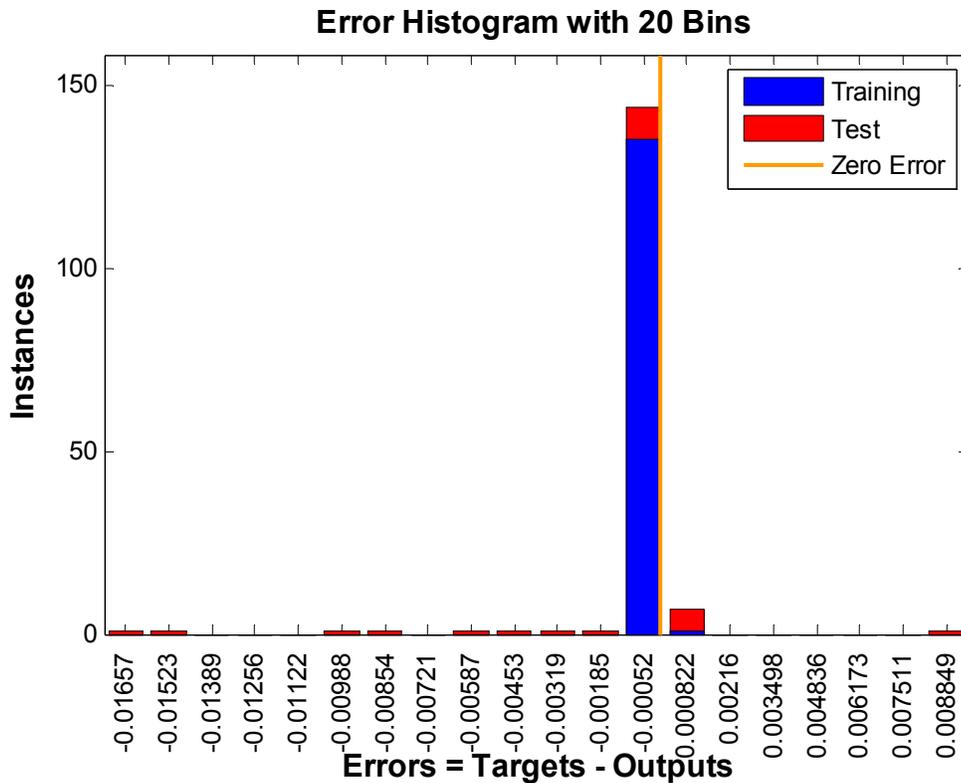
**Gráfica. 16. Regresión de la red neuronal mediante el algoritmo de Regularización Bayesiana y la Transforma Discreta de Fourier**



- El histograma de error que se observa en la figura 33 , muestra la distribución de los errores en la red, del cual se observa que el error medido entre la diferencia del objetivo(valor esperado) y la salida que se presentó con más frecuencia en el proceso de entrenamiento, validación y prueba fue el 0,00052,

lo que indica que la red obtuvo un buen rendimiento en cuanto a la salida esperada (porcentaje de la línea donde ocurrió la falla):

**Figura 33. Histograma de errores en de la red neuronal mediante el algoritmo de Regularización Bayesiana y la Transforma Discreta de Fourier**



Finalmente, en la tabla 8 se muestra un resumen de los resultados obtenidos posteriores a la verificación final de la red, donde se observa que los porcentajes de error relativo promedio igual a 0,2233%, lo que indica que el diseño de la red neuronal obtuvo buena exactitud al momento de localizar la falla.

**Tabla 8. Resultados del localización de FAI por medio de la Red Neuronal mediante el método de Regulación Bayesiana**

<b>R<sub>falla</sub>[ohm]</b>	<b>Ángulo de inyección[°]</b>	<b>Punto de Falla(Valor real) [km]</b>	<b>Localización de la Falla por la RNA [km]</b>	<b>Error relativo[%]</b>
100	30	57,4	57,50588	0,184457
100	30	65,6	65,31359	0,436606
100	60	73,8	73,7875	0,016929
100	90	16,4	16,43783	0,230711
90	0	32,8	32,77672	0,07098
90	0	82	82,26141	0,318785
90	0	73,8	73,77422	0,034932
90	30	49,2	48,99002	0,426785
90	90	41	40,99643	0,008705
90	90	32,8	32,79757	0,007392
80	90	16,4	16,4038	0,023188
80	60	82	82,13023	0,158823
80	90	57,4	57,39698	0,005258
70	0	82	81,89826	0,12407
70	30	65,6	65,49045	0,166997
70	30	32,8	32,18763	1,866973
60	0	65,6	65,59471	0,00806
60	0	16,4	16,42139	0,13045
60	30	49,2	49,26123	0,124453
60	60	32,8	32,83985	0,121495
			<b>Promedio error relativo</b>	<b>0,223302</b>

Así mismo, se puede analizar que los menores porcentajes de error fueron obtenidos cuando se simulaban fallas muy cercanas a la longitud total de la línea, es decir, cuando las fallas ocurren directamente en la barra del sistema o en su

defecto en líneas medias o largas como el caso estudio, donde la línea simulada fue de 82km. Esto se debe principalmente, que cuando se trata de localizar falla a porcentajes pequeños de la longitud total de la línea, es más difícil debido a que la variaciones de tensión no son tan representativas, caso contrario a mayores porcentajes de la longitud total de la línea, donde estos cambios son más notorios y por ende el punto de falla se puede calcular con más facilidad y exactitud.

En la Tabla 9 se muestra un estudio comparativo entre métodos tradicionales de localización de Falla como el Método de la Reactancia vs Método de localización con Redes Neuronales, lo cual permite analizar que las Redes Neuronales, presentan un menor error de localización de FAI en comparación con el método de la reactancia. Así mismo, se observa que al igual que con la implementación de la Red Neuronal, cuando la falla se presenta en porcentaje aproximados a la longitud total de la línea, el error relativo de localización de la FAI tiende a ser menor en comparación a longitudes pequeñas de total de la línea fallada.

**Tabla 9. Tabla comparativa entre el método de la Reactancia y Redes Neuronales**

			Localización de la Falla mediante métodos Tradicionales como el Método de la Reactancia		Localización de la Falla mediante Redes Neuronales	
$R_{falla}$ [ohm]	Ángulo de inyección[°]	Punto de Falla(Valor real) [km]	Localización de la Falla[km]	Error relativo[%]	Localización de la Falla por la RNA [km]	Error relativo[%]
100	30	57,4	143,6421688	-150,247681	57,50588	0,184457
100	30	65,6	160,6791228	-144,937687	65,31359	0,436606
100	60	73,8	166,2148144	-125,223326	73,7875	0,016929
100	90	16,4	39,44381467	-140,511065	16,43783	0,230711
90	0	32,8	49,71779245	-51,5786355	32,77672	0,07098
90	0	82	119,1662803	-45,3247321	82,26141	0,318785
90	0	73,8	109,037049	-47,7466788	73,77422	0,034932
90	30	49,2	132,719031	-169,754128	48,99002	0,426785
90	90	41	80,51476583	-96,3774776	40,99643	0,008705
90	90	32,8	66,2282216	-101,91531	32,79757	0,007392
80	90	16,4	37,45734937	-128,398472	16,4038	0,023188
80	60	82	195,0313441	-137,843103	82,13023	0,158823
80	90	57,4	107,5360219	-87,3449859	57,39698	0,005258
70	0	82	115,3274596	-40,6432435	81,89826	0,12407
70	30	65,6	164,5348937	-150,815387	65,49045	0,166997
70	30	32,8	110,6535567	-237,358404	32,18763	1,866973
60	0	65,6	85,5077634	-30,3472003	65,59471	0,00806
60	0	16,4	11,06425645	32,53502166	16,42139	0,13045
60	30	49,2	133,0604052	-170,447978	49,26123	0,124453
60	60	32,8	99,18817933	-202,402986	32,83985	0,121495
			<b>Promedio error relativo mediante el método de la Reactancia</b>	<b>-111,334173</b>	<b>Promedio error relativo mediante la Red Neuronal</b>	<b>0,223302</b>

En la tabla 10 se muestra un estudio comparativo entre diferentes métodos de entrenamiento de la red implementada en la presente investigación. Con base en estos resultados se seleccionó el método de regulación bayesiana para entrenar la red. En el Anexo A se explica detalladamente el proceso de selección del algoritmo de entrenamiento para la red diseñada.

**Tabla 10. Tabla comparativa de Métodos de entrenamiento de una red neuronal tipo Perceptrón Multicapa**

Tipo de red	Configuración de la Red Neuronal	Función de activación de capas ocultas	Algoritmo de entrenamiento	Resultados mediante el procesamiento de datos con la Transformada Discreta de Fourier		Resultados mediante procesamiento de datos con la Transformada Discreta de Wavelet	
				Promedio de Error relativo [%]	Convergencia (número de iteraciones)	Promedio de Error relativo [%]	Convergencia (número de iteraciones)
Perceptrón Multicapa	[11 10]	TanSig	Levenberg-Marquardt	0,38	19	0,57	15
			Bayesian Regularization	0,2233	223	1,54	39
			BFGS Quasi-Newton	5,405	42	4,960	44
			Resilient Backpropagation	4,24	105	5,356	42
			Scaled Conjugate Gradient	3,5268	118	2,60	68

### 8.3 Conclusiones

Con base en la información de la Tabla, puede concluirse:

- El método de entrenamiento que converge con más rapidez es el algoritmo de Levenberg-Marquardt.
- El método que presenta la segunda mejor convergencia una vez realizado el procesamiento los datos de entrada de la red con la Transformada de Wavelet es mediante el algoritmo de Resilient Backpropagation. Cabe resaltar, que este tipo de entrenamiento se distingue por ser uno de los más rápidos en cuanto a problemas de reconocimientos de patrones, aunque los requisitos de memoria son relativamente pequeños en comparación con otros algoritmos [57].
- El algoritmo de Scaled Conjugate Gradient al igual que el de Resilient Backpropagation, presenta un buen rendimiento y rápida convergencia, lo que indica que es un buen método de aprendizaje cuando se tiene problemas de reconocimiento de patrones, como lo es el caso de la presente investigación, donde la salida depende en gran medida de los patrones o características de las señales y corrientes generadas durante fallas de alta impedancia en sistemas eléctricos de potencia.
- El método que permitió entrenar la red con un menor error en la localización de las fallas es mediante el algoritmo de la regularización bayesiana, el cual luego de varias pruebas con diferentes métodos de entrenamiento da como resultado a la salida de la red un error promedio relativo de 0,22%.
- Cuando el procesamiento de las señales generadas durante la falla de alta impedancia, se realiza mediante la Transformada Discreta de Wavelet, el método de entrenamiento de la red que presenta menor error en la localización de fallas es por medio del algoritmo de Levenberg-Marquardt. Este método a su vez es el que requiere menor número de iteraciones en el sistema, lo cual indica que este método converge con más rapidez en comparación con otros algoritmos de entrenamiento.

## IX. CONCLUSIONES Y TRABAJO FUTURO

### 9.1 Conclusiones

Teniendo en cuenta los resultados obtenidos en cada una de las etapas desarrolladas en la presente investigación tales como: Caracterización del Sistema Eléctrico de Potencia, Extracción y procesamiento de las variables seleccionadas para el estudio y el diseño e implementación de una modelo de inteligencia artificial basado en Redes Neuronales para el proceso de localización de fallas de alta impedancia en una línea de transmisión eléctrica aérea, se concluye que:

- El sistema eléctrico de potencia seleccionado se encuentra diseñado con parámetros que permiten brindarle estabilidad al sistema eléctrico de potencia, lo cual se comprobó al momento de realizar el flujo de carga al sistema, donde no se evidenció que el sistema presenta sobrecargas cuando trabaja bajo condiciones normales de operación.
- Los cambios en las señales de corriente y tensión del sistema eléctrico seleccionado varían de forma inversamente proporcional con respecto a la  $Z_{falla}$ , es decir, a medida que aumenta la resistencia de falla, la corriente de falla va tomando valores de amplitudes menores.
- Para el proceso de extracción de características las transformadas de Fourier o Wavelet son muy efectivas, porque permiten caracterizar las distorsiones en las señales de corriente y tensión debidas a las fallas en los sistemas de potencia. El uso de algoritmos eficientes para el cálculo de la transformada discreta de Fourier permiten reducir el trabajo computacional al momento de analizar el comportamiento de la señal. Cabe resaltar, que para el caso estudio la transformada que presentó la mejor opción para el procesamiento de la señal fue la transformada discreta de Fourier.
- El menor error promedio relativo que se obtuvo para la localización de falla de alta impedancia fue de 0,2233%, el cual se presentó para el diseño de una red neuronal tipo perceptrón multicapa, con 14 neuronas en la capa de entrada, dos capas ocultas de 11 y 10 neuronas respectivamente, y una capa de salida con 1 neurona. Los datos de entrada se procesaron con la Transformada Discreta de

Fourier y la red se entrenó con el algoritmo de regulación Bayesiana. En comparación con otras investigaciones acerca de localización de fallas como [68][69] en las cuales los errores al momento de estimar la localización de la falla oscilaron entre 0,1% y 2%, la presente investigación se encuentra entre esos márgenes de error.

## **9.2 Recomendaciones y Trabajos Futuros**

La presente investigación tuvo como objetivo diseñar un modelo de localización de fallas de alta impedancia en líneas de transmisión aéreas mediante Redes Neuronales, con la cual a partir de varios métodos de entrenamiento se determinó cual podría ser la mejor arquitectura de red que permita localizar este tipo de fallas con el menor error posible. Como trabajos futuros se podría recomendar:

- Realizar estudios de localización y detección de fallas no solo para Sistema de Transmisión Aérea sino también para Sistemas de Transmisión Subterráneas y/o Submarinas y Sistemas de Distribución de Energía , validando otras técnicas de inteligencia artificial tales como los sistemas difusos. Así mismo, para obtener un mejor análisis en tiempo real del sistema eléctrico de potencia, se recomienda parametrizar el SEP con datos reales obtenidos del sistema propio de la región o país seleccionado para el estudio. Esto con el objetivo de mostrar una visión más clara acerca del alcance y los beneficios que conlleva implementar métodos de localización de falla basado en técnicas de inteligencia artificial en comparación con métodos tradicionales.
- Obtener datos e información de los registros oscilográficos de los relés utilizados para protección de la línea, los cuales podrían servir de entrada a los modelos de inteligencia artificial. Para ello es necesario rediseñar el sistema teniendo en cuenta las especificaciones del relé, tales como su frecuencia de muestreo y capacidad de procesamiento.

## CAPITULO X. REFERENCIAS BIBLIOGRÁFICAS

- [1] A.J. Mazon, I. Zamora, M.A. Zorrozua, J.F. Miñambres y J.J. Barandiaran, «A new approach to fault location in two-terminal transmission lines using artificial neural networks,» *Electric Power Systems Research*, pp. 26-266, May 2000.
- [2] A. P. Alves da Silva, A. C. Lima y S. M. Souza, «Fault location on transmission lines using complex-domain neural networks,» *Electrical Power and Energy Systems*, p. 720–727, 2012.
- [3] G. M. IDÁRRAGA OSPINA, R. VALENCIA RODRÍGUEZ y J. A. HERNÁNDEZ RIVEROS, «Algoritmos Para Localización De Fallas En Líneas De Transmisión, Análisis Para El Caso Colombiano,» *Dyna*, vol. 71, nº 143, pp. 95-100, 2004.
- [4] Javad Sadeh y Hamid Afradi, «A new and accurate fault location algorithm for combined transmission lines using Adaptive Network-Based Fuzzy Inference System,» *Electric Power Systems Research*, p. 1538–1545, 2009.
- [5] E. Quintero Crespo, «DESARROLLO DE UN MODELO PARA LA LOCALIZACIÓN DE FALLAS EN SISTEMAS DE TRANSMISION DE ENERGIA ELECTRICA UTILIZANDO TECNICAS DE INTELIGENCIA ARTIFICIAL,» Medellín, 2010.
- [6] Ibrahem Baqui, Inmaculada Zamora, J. Mazón y Garikoitz Buigues, «High impedance fault detection methodology using wavelet transform and artificial neural networks,» *Electric Power Systems Research*, p. 1325–1333, 2011.
- [7] Mehmet Salih Mamis, Müslüm Arkan y Cemal Keles, «Transmission lines fault location using transient signal spectrum,» *Electrical Power and Energy Systems*, p. 714–718, 2013.
- [8] L. L. LÓPEZ GÓMEZ y O. P. OSORIO GIRALDO , «ANALISIS DE ESTABILIDAD DE TENSIÓN EN EL SISTEMA DE TRANSMISION REGIONAL (STR),» 2008. [En línea]. Available: <http://repositorio.utp.edu.co/dspace/bitstream/11059/1767/1/6213743L864.pdf>. [Último acceso: 30 Junio 2014].

- [9] S.M. Yeo, C.H. Kim, K.S. Hong, Y.B. Lim, R.K. Aggarwal, A.T. Johns y M.S. Choi, «A novel algorithm for fault classification in transmission lines using a combined adaptive network and fuzzy inference system,» *International Journal of Electrical Power & Energy Systems*, vol. 25, p. 747–758, November 2003.
- [10] J. A. Calderon Serna, «MODELO ADAPTATIVO DE INTELIGENCIA ARTIFICIAL PARA EL DIAGNÓSTICO AUTOMÁTICO DE FALLAS A PARTIR DE REGISTROS DE OSCILOPERTURBOGRAFIA,» Medellín, 2007.
- [11] «Teoría de Wavelets,» [En línea]. Available: [http://catarina.udlap.mx/u\\_dl\\_a/tales/documentos/lem/hernandez\\_d\\_m/capitulo\\_2.pdf](http://catarina.udlap.mx/u_dl_a/tales/documentos/lem/hernandez_d_m/capitulo_2.pdf). [Último acceso: 14 Octubre 2013].
- [12] S.R. Samantaray, P.K. Dash y S.K. Upadhyay, «Adaptive Kalman filter and neural network based high impedance fault detection in power distribution networks,» *Electrical Power and Energy Systems*, p. 167–172, 2009.
- [13] « FILTRO DE KALMAN,» [En línea]. Available: <http://bibing.us.es/proyectos/abreproy/11879/fichero/PFC+Sergio+Pereira+Ruiz%252F7+-+Filtro+de+Kalman.pdf>. [Último acceso: 20 Octubre 2013].
- [14] L.A. Snider y Y.S. Yuen, «The artificial neural-networks-based relay algorithm for the detection of stochastic high impedance faults,» *Neurocomputing*, pp. 243-254, 1998.
- [15] Leung H. y Haykin S., «The complex backpropagation algorithm,» *IEEE Transactions on Signal Processing*, , p. 2101–2104, 1991.
- [16] . M. Smith y Yan Hui , «A data extrapolation algorithm using a complex domain neural network,» *IEEE Transactions on Circuits and Systems II: Analog and Digital Signal Processing.*, pp. 143-147, 1997.
- [17] «Redes Neuronales,» [En línea]. Available: <http://disi.unal.edu.co/~lctorress/RedNeu/LiRna008.pdf>. [Último acceso: 27 Octubre 2013].
- [18] Doaa khalil Ibrahim, El Sayed Tag Eldin, Essam M. Aboul-Zahab y Saber Mohamed Saleh, «Real time evaluation of DWT-based high impedance fault

detection in EHV transmission,» *Electric Power Systems Research*, vol. 80, p. 907–914, August 2010.

- [19] Reddy, M.J.B. y Mohanta, D.K., «Performance Evaluation of an Adaptive-Network-Based Fuzzy Inference System Approach for Location of Faults on Transmission Lines Using Monte Carlo Simulation,» *IEEE Computational Intelligence Society*, vol. 16, pp. 909- 919, 2008.
- [20] K. Silva, B. Souza y N. Brito, «Fault Detection and Classification in Transmission Lines Based on Wavelet Transform and ANN,» *IEEE TRANSACTIONS ON POWER DELIVERY*, vol. 21, nº 4, pp. 2058-2063, October 2006.
- [21] V. H. Hinojosa, «Aplicaciones de Inteligencia Artificial(ANFIS) en sistemas de suministro de Energía Eléctrica: Pronóstico de demanda de muy corto plazo y pronóstico de los precios spot de corto plazo,» [En línea]. Available: <http://biblioteca.cenace.org.ec/jspui/bitstream/123456789/207/1/rte07-08.pdf>.
- [22] Zheng Chen, Chengmu Luo, Jinxi Su y Xinrong Wu , «A fault location algorithm for transmission line based on distributed parameter,» de *Developments in Power System Protection, 2001, Seventh International Conference on (IEE)*, Amsterdam, 2001.
- [23] J.B Lee, C.H Jung, I.D Kim y Y.K Baek, «Protective relay testing and characteristic analysis for high impedance faults in transmission lines,» *Electric Power Systems Research*, vol. 56, p. 129–137, 1 November 2000.
- [24] Chen, Z. y Maun, J.-C. , «An artificial neural network based real-time fault locator for transmission lines,» de *International Conference on Neural Networks*, Houston, TX, 1997.
- [25] Endesa, «Generación,» 2014. [En línea]. Available: <http://www.endesa.com/es/conoceendesa/lineasnegocio/Electricidad/Generacion>. [Último acceso: 28 Marzo 2014].
- [26] Centro de Investigaciones Energéticas, Medioambientales y Tecnológicas-CIEMAT, «Energía Hidráulica,» Octubre 2008. [En línea]. Available: [http://www.energiasrenovables.ciemat.es/suplementos/sit\\_actual\\_renovables/](http://www.energiasrenovables.ciemat.es/suplementos/sit_actual_renovables/)

hidraulica.htm. [Último acceso: 9 Febrero 2014].

- [27] Sistema Riojano de Innovación, Gobierno de la Rioja, Agencia de Desarrollo Económico de la Rioja, . P. R. d. A. I. Globaltech Rioja y F. E. d. D. R. Comisión Europea, «Estudio de BenchMarking Tecnológico Internacional Sector Energía Solar Fotovoltaica,» 2008. [En línea]. Available: [http://www.ader.es/fileadmin/redactores/PUBLICACIONES/Estudios/Estudio\\_Benchmarking\\_sector\\_fotovoltaico.pdf](http://www.ader.es/fileadmin/redactores/PUBLICACIONES/Estudios/Estudio_Benchmarking_sector_fotovoltaico.pdf). [Último acceso: 9 Febrero 2014].
- [28] A. Esquerra , «APROVECHAMIENTO DE LA ENERGÍA DEL MAR,» Diciembre 2008. [En línea]. Available: [http://www.ecogent.cat/index.php?option=com\\_content&view=article&id=155%3Aaprovechamiento-de-la-energia-del-mar&catid=44%3Afoc&Itemid=68&lang=ca&showall=1](http://www.ecogent.cat/index.php?option=com_content&view=article&id=155%3Aaprovechamiento-de-la-energia-del-mar&catid=44%3Afoc&Itemid=68&lang=ca&showall=1). [Último acceso: 28 Marzo 2014].
- [29] XM S.A. E.S.P, «Informe de Operación del SIN y Administración del Mercado,» 2013. [En línea]. Available: <http://informesanuales.xm.com.co/2013/SitePages/operacion/2-6-Capacidad-efectiva-neta.aspx>. [Último acceso: 20 Abril 2014].
- [30] J. J. Grainger y W. D. Stevenson Jr., Análisis de Sistemas de Potencia, México: Mc Graw Hill, 1996.
- [31] Energía de Bogotá, «Sector energético en Colombia,» [En línea]. Available: <http://www.eeb.com.co/transmision-de-electricidad/sector-energetico-en-colombia>. [Último acceso: 20 Abril 2014].
- [32] Ministerio de Minas y Energía Republica de Colombia, «Sector Energía,» 2010. [En línea]. Available: [http://www.minminas.gov.co/minminas/energia.jsp?opcionCalendar=4&cargaHome=2&id\\_noticia=854](http://www.minminas.gov.co/minminas/energia.jsp?opcionCalendar=4&cargaHome=2&id_noticia=854). [Último acceso: 20 Abril 2014].
- [33] A. Dammert Lira, F. Molinelli Aristondo y M. A. Carbajal Navarro, «Fundamentos Técnicos y Económicos del Sector Eléctrico Peruano,» Grapex Perú S.R.L, Perú, 2011.

- [34] S. Ramirez Castaño, «Redes de Distribución de Energía,» Centro de Publicaciones Universidad Nacional de Colombia, Manizales, 2004.
- [35] S. R. Samantaray<sup>1</sup> y P. K. Dash, «High impedance fault detection in distribution feeders using extended kalman filter and support vector machine,» *EUROPEAN TRANSACTIONS ON ELECTRICAL POWER*, 2009.
- [36] G. M. IDÁRRAGA OSPINA, R. VALENCIA RODRÍGUEZ y J. A. HERNÁNDEZ RIVEROS, «Algoritmos para la Localización de Fallas en Líneas de Transmisión, Análisis para el caso Colombiano,» *DYNA*, n° 143, pp. 95-100, Noviembre 2004.
- [37] T.Takagi, Y.Yamakoshi, M.Yamaura, R.Kondow y T.Matsushima, «Development of a New Type Fault Locator Using the One-Terminal Voltage and Current Data,» *IEEE*, August 1982.
- [38] Leif Eriksson, Murari Mohan Saha y G. D. Rockefeller, «AN ACCURATE FAULT LOCATOR WITH COMPENSATION FOR APPARENT REACTANCE IN THE FAULT RESISTANCE RESULTING FROM REMOTE-END INFEEED,» *IEEE Transactions on Power Apparatus and Systems*, Vols. %1 de %2PAS-104, n° 2, pp. 424-436, February 1985.
- [39] J. M. Gers O., Aplicación de Protecciones Eléctricas, Cali: Ediciones Universidad del Valle, 1993.
- [40] P. Kundur, J. Paserba, V. Ajarapu, G. Andersson, A. Bose, C. Canizares, N. Hatziargyriou, D. Hill, A. Stankovic, C. Taylor, T. Van Cutsem y V. Vittal, «Definition and Classification of Power System Stability,» *IEEE Transactions on Power Systems*, vol. 19, n° 2, pp. 1397-1401, 2004.
- [41] M. I. Neicpun Sandoval, «Metodología para la Planificación de la Expansión en Transmisión considerando la Estabilidad de Tensión del Sistema,» Santiago de Chile, 2011.
- [42] Prabha Kundur, Power System Stability and Control, California: McGraw-Hill Inc, 1994.
- [43] A. Arboleda Correa, Localización de Fallas de Alta Impedanca en Líneas de

Transmisión para un estudio de caso mediante Redes Neuronales, Medellín, 2010.

- [44] J. F. Acosta Orozco, M. Vera -Lizcano y J. Velasco Medina, «FFT de 8 Puntos IEEE754 Sintetizado en FPGA,» [En línea]. Available: [http://bionano.univalle.edu.co/FFT\\_8\\_SPS05.pdf](http://bionano.univalle.edu.co/FFT_8_SPS05.pdf). [Último acceso: 13 Septiembre 2014].
- [45] P. S. Eduardo , «INTRODUCCION A LA TRANSFORMADA WAVELET Y SUS APLICACIONES AL PROCESAMIENTO DE SENALES DE EMISIÓN ACÚSTICA,» [En línea]. Available: <http://www.cnea.gov.ar/cac/glea/trabajos/serrano.pdf>. [Último acceso: 28 Enero 2015].
- [46] K. Silva, B. Souza y N. Brito, «Fault Detection and Classification in Transmission Lines Based on Wavelet Transform and ANN,» *IEEE TRANSACTIONS ON POWER DELIVERY*, vol. 21, n° 4, pp. 2058-2063, October 2006.
- [47] Zhengyou He, Ling Fu, Sheng Lin y Zhiqian Bo, «Fault Detection and Classification in EHV Transmission Line Based on Wavelet Singular Entropy,» *IEEE TRANSACTIONS ON POWER DELIVERY*, vol. 25, n° 4, pp. 2156-2163, 2010.
- [48] T.M Lai, L.A Snider y E.Lo, «Wavelet transform based relay algorithm for the detection of stochastic high impedance faults,» *Electric Power Systems Research*, pp. 626-633, 2006.
- [49] «Introducción a la Transformada Wavelet,» 2006. [En línea]. Available: <http://www.exa.unicen.edu.ar/escuelapav/cursos/wavelets/apunte.pdf>. [Último acceso: 28 Enero 2015].
- [50] I. Daubechies, Ten Lectures on Wavelets, Philadelphia: Society for Industrial and Applied Mathematics, 1992.
- [51] «Los Armónicos en las Instalaciones Eléctricas,» [En línea]. Available: <http://www.udistrital.edu.co:8080/documents/42573/87032/T025+LOS+ARMONICOS+EN+LAS+INSTALACIONES+ELECTRICAS>. [Último acceso: 25

Febrero 2015].

- [52] «Tejidos,» [En línea]. Available: [http://www.genomasur.com/BCH/BCH\\_libro/capitulo\\_04.htm](http://www.genomasur.com/BCH/BCH_libro/capitulo_04.htm). [Último acceso: 19 Octubre 2014].
- [53] X. Basogain Olabe, «Redes Neuronales Artificiales y sus aplicaciones,» [En línea]. Available: [http://cvb.ehu.es/open\\_course\\_ware/castellano/tecnicas/redes\\_neuro/contenidos/pdf/libro-del-curso.pdf](http://cvb.ehu.es/open_course_ware/castellano/tecnicas/redes_neuro/contenidos/pdf/libro-del-curso.pdf). [Último acceso: 19 Octubre 2014].
- [54] M. I. Acosta Buitrago y C. A. Zuluaga Muñoz, Tutorial Sobre Redes Neuronales Aplicadas en Ingeniería Eléctrica y su Implementación en un Sitio Web, Pereira, 2000.
- [55] M. Gestal Pose, «Introducción a las Redes de Neuronas Artificiales,» [En línea]. Available: <http://sabia.tic.udc.es/mgestal/cv/RNAtutorial/TutorialRNA.pdf>. [Último acceso: 6 Febrero 2015].
- [56] D. J. Matich, *Redes Neuronales: Conceptos Básicos y Aplicaciones*, 2001.
- [57] M. Hudson Beale, M. T. Hagan y H. B. Demuth, «Neural Network Toolbox User's Guide for Use with MATLAB,» 2014.
- [58] «Introducción a las redes neuronales aplicadas,» [En línea]. Available: <http://halweb.uc3m.es/esp/Personal/personas/jmmarin/esp/DM/tema3dm.pdf>. [Último acceso: 26 Febrero 2015].
- [59] B. O. Romero A., «Convergencia Global del Método BFGS modificado para la minimización No-conve Irrestricla,» Octubre 2012. [En línea]. Available: [http://bibcyt.ucla.edu.ve/Edocs\\_Bciucla/Repositorio/TEGQA402R652012.pdf](http://bibcyt.ucla.edu.ve/Edocs_Bciucla/Repositorio/TEGQA402R652012.pdf). [Último acceso: 1 Marzo 2015].
- [60] G. M. d. J. Ramírez Alonso y M. I. Chacón Murguía, «Clasificación de defectos en madera utilizando redes neuronales artificiales,» *Computación y Sistemas*, vol. 9, nº 1, pp. 017-027, 2005.
- [61] V. G. Vílchez García, «Estimación y clasificación de daños en materiales

utilizando modelos ARy redes neuronales para la evaluaciónno destructiva con ultrasonidos,» Granada, 2010.

- [62] «X Fuzzy 3. Fuzzy Logic Design Tool,» 2012. [En línea]. Available: [http://www2.imse-cnm.csic.es/Xfuzzy/Xfuzzy\\_3.3/tools/xfsl\\_sp.html](http://www2.imse-cnm.csic.es/Xfuzzy/Xfuzzy_3.3/tools/xfsl_sp.html). [Último acceso: 1 Marzo 2015].
- [63] N. Rodríguez Aedo, «Control de procesos no-lineales con realimentación de estado mediante un observaor neuronal no lineal,» Chile, 2014.
- [64] Li, K.K., Lai, L.L. y Lai, L.L., «Application of artificial neural network in fault location technique,» de *International Conference on Electric Utility Deregulation and Restructuring and Power Technologies, 2000. Proceedings. DRPT 2000.* , London, 2000.
- [65] Salat, R. y Osowski, Stainslaw , «Fault location in transmission line using self-organizing neural network,» de *5th International Conference on Signal Processing Proceedings, 2000. WCCC-ICSP 2000.*, Beijing, 2000.
- [66] R. Shariatinasab, M. Akbari y M. Aghaebrahimi, «A Novel Wavelet-Neural Network Method for Fault Location Analysis on Transmission Lines,» *IEEE*, pp. 963-965, 2012.
- [67] D. Lin<sup>1</sup>, P. Jun, S. wenxia, T. Jun y Z. jun, «Fault location for transmission line based on traveling waves using correlation analysis method,» *IEEE*, pp. 681-685, 2008.
- [68] R.N. Mahanty y Dutta Gupta, «Application of RBF neural network to fault classification and location in transmission lines,» *IEEE Xplore*, vol. 151, nº 2, pp. 201-212, 2004.
- [69] Hosung Jung, Young Park, Moonseob Han, Changmu Lee, Hyunjune Park y Myongchul Shin, «Novel technique for fault location estimation on parallel transmission lines using wavelet,» *Electrical Power& Energy Systems*, pp. 76-82, 2006.
- [70] «Universidad Complutense Madrid. Matlab 2013 para Windows, Requisitos y proceso de instalación». [En línea]. Available: <http://www.ucm.es/faq/entradas->

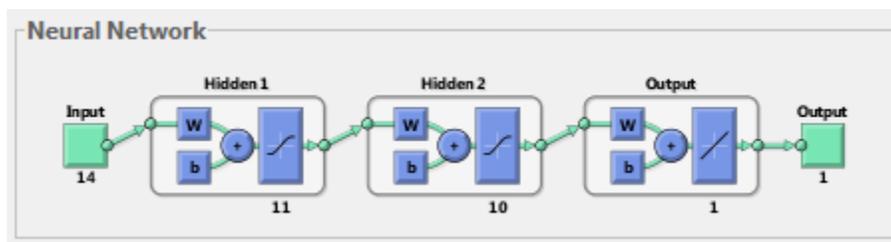
en-matlab/matlab-2013-para-windows-requisitos-y-proceso-de-instalacion.  
[Último acceso: 12 Abril 2015].

## ANEXO A. ANÁLISIS DE MÉTODOS DE ENTRENAMIENTO DE LA RED NEURONAL PROPUESTA

Debido a que el éxito o buen rendimiento de una red neuronal, depende en gran medida del tipo de algoritmo utilizado al momento de su entrenamiento, es temática de estudio seleccionar cual entrenamiento será el mejor y más eficiente para una red en específico, ya que esta depende a su vez de varios factores como: la complejidad del problema, el número de datos, los pesos y sesgos de la red [57]. En esta sección se realiza un estudio comparativo entre cuatro métodos y/o algoritmos de aprendizajes que se implementaron para entrenar una red feedforward (Perceptrón multicapa) mediante la herramienta Neural Network Toolbox de Matlab con las siguientes características de diseño:

- Catorce (14) entradas que corresponden a los 7 primeros armónicos impares tanto para las corrientes como las tensiones generadas durante la FAI en sistema. Cabe resaltar, que se seleccionaron estos armónicos, debido a que son los armónicos que más se generan en los sistemas eléctricos, tales como 180Hz el tercer armónico, 300Hz el quinto armónico, 420Hz el séptimo armónico, 540Hz el noveno armónico, 660Hz el décimo primer armónico y así sucesivamente [12] [51].
- Dos (2) capa ocultas con 11 y 10 neuronas respectivamente y una (1) capa de salida como se muestra en la figura 34:

Figura 34. Perceptrón con 2 capas ocultas.



- La salida representa el porcentaje de la línea a la cual ocurre la FAI, este resultado se encuentra normalizado entre valores de 0 y 1, donde 1 representa el 100% de la línea.

- Para las capas ocultas, la función de activación utilizada fue la Tan-Sigmoid, en la cual la entrada puede tomar valores entre  $-\infty$  y  $+\infty$  y la salida entre el rango de 0 y 1. Debido a que la salida de este sistema varía entre 0 y 1, esta es una de las mejores funciones de activación que cumplen con esta característica
- Para la capa de salida, la función de activación implementada fue una Lineal (purelin), debido a que este tipo de función es comúnmente utilizada para la capa de salida en redes de múltiples capas, ya que son funciones de aproximación. Para el caso estudio, esta función es muy útil debido a que permite minimizar el error a la salida por tener forma lineal [57].
- Para la obtención de los datos, se realizaron varias simulaciones de fallas de alta impedancia en el SEP seleccionado como caso estudio, mediante la herramienta SimPowerSystem de Matlab, variando:
  - Resistencia de falla entre los rangos de 60ohm a 100 ohm.
  - Ángulos de inyección de:  $0^\circ$ ,  $30^\circ$ ,  $60^\circ$  y  $90^\circ$ .
  - Porcentaje de longitud de la línea donde ocurrió la falla entre el 20% y 100%, aumentando gradualmente en 10%.

De esta simulación se obtuvo un total de 180 datos entre corriente y tensiones de: pre-falla, falla y post-falla, los cuales fueron procesados y normalizados mediante: la Transformada Discreta de Fourier y la Transformada Discreta de Wavelet.

A continuación, se presenta un estudio comparativo entre las diferentes técnicas de procesamiento de datos y algoritmos de entrenamiento de la Red Neuronal:

## **1. Procesamiento de la señal mediante la Transformada Discreta de Fourier**

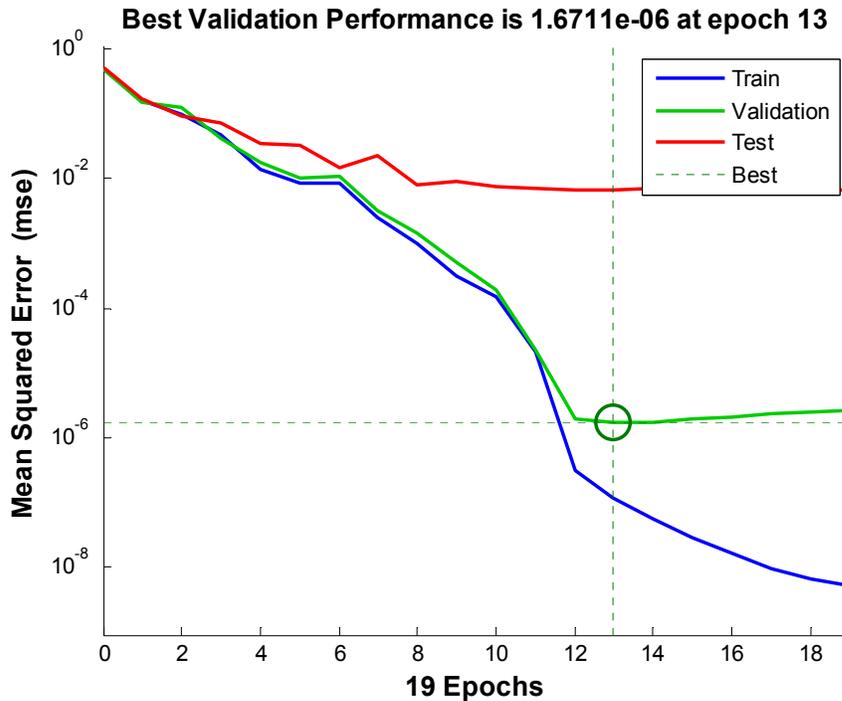
Con base en estas características generales, a continuación se presentan los resultados obtenidos en el proceso de entrenamiento y aprendizaje supervisado de la red utilizando el método de procesamiento de datos mediante la Transformada discreta de Fourier y algoritmos de aprendizaje tales como: Levenberg-Marquardt, BFGS Quasi-Newton, Resilient Backpropagation y Scaled Conjugate Gradient.

### **a) Entrenamiento basado en el algoritmo de Levenberg-Marquardt**

El entrenamiento de la red neuronal mediante el algoritmo de Levenberg-Marquardt (retropropagación del error-Backpropagation), consiste básicamente en ir ajustando los pesos de atrás hacia adelante para minimizar el error obtenido a la salida de la red. Teniendo en cuenta lo anterior, la Red Neuronal diseñada para del caso estudio se entrenó a partir de este algoritmo dando como resultado lo siguiente:

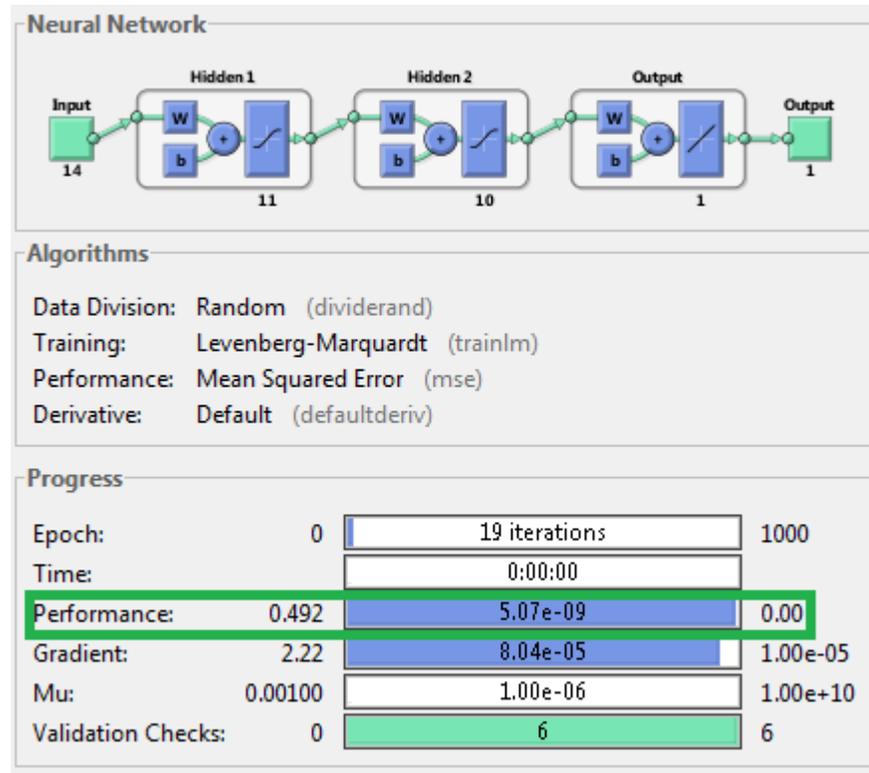
- La etapa de entrenamiento se detuvo en la iteración número 13 cuando el modelo presentó el mejor rendimiento y por ende la mejor convergencia. Esto se puede evidenciar en la gráfica 17, donde se muestra el error cuadrado medio, el cual permite medir el promedio del error cuadrado entre la salida y valor esperado. Así mismo, se observa que tanto las curvas de validación como la de prueba guardan una gran relación, lo que indica que la red quedó bien entrenada a partir de los datos seleccionados de forma aleatoria del grupo de simulaciones que se realizaron al SEP del caso estudio.

**Gráfica. 17. Error cuadrado promedio de la red neuronal mediante algoritmo de entrenamiento Levenberg-Marquardt y la Transforma Discreta de Fourier**



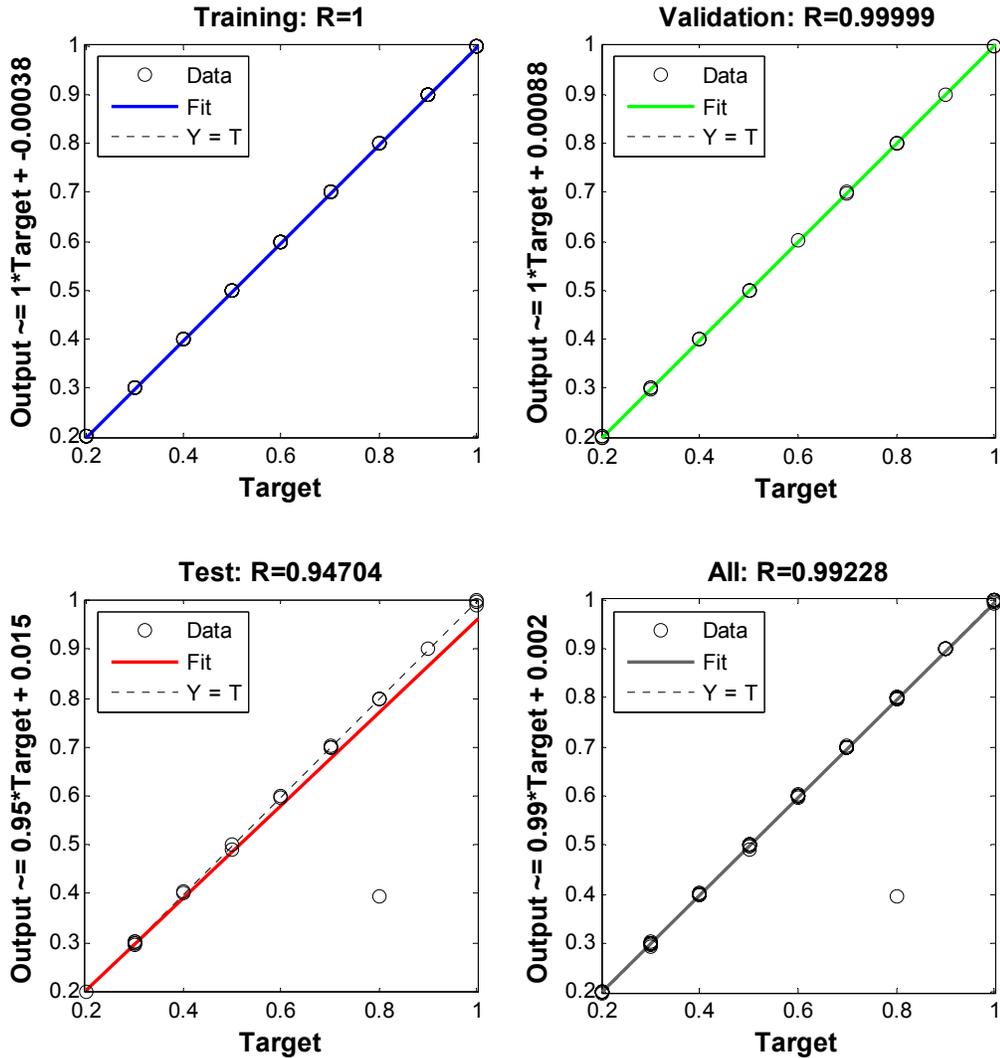
Otra de las metodologías con las cuales se puede medir el rendimiento de la red neuronal diseñada, es a partir del valor de la tasa de aprendizaje, el cual controla la variación de los pesos en cada iteración. Algunos autores recomiendan, que se debe evitar un ritmo de aprendizaje demasiado pequeño porque este puede ocasionar una disminución en la velocidad de convergencia, así mismo indican que el ritmo de aprendizaje no debe ser tan grande porque puede ocasionar cambios en la función de error. Por este motivo, recomiendan que el valor de las tasas de aprendizaje aproximadamente entre el rango de 0,05 y 0,5 [58]. Para este caso, la tasa de aprendizaje de la red fue de 0,492 como se observa en la siguiente figura 35, lo que indica que esta red se encuentra entre las tasas de aprendizajes recomendada.

Figura 35. Progreso del entrenamiento mediante el algoritmo de entrenamiento Levenberg-Marquardt y la Transforma Discreta de Fourier



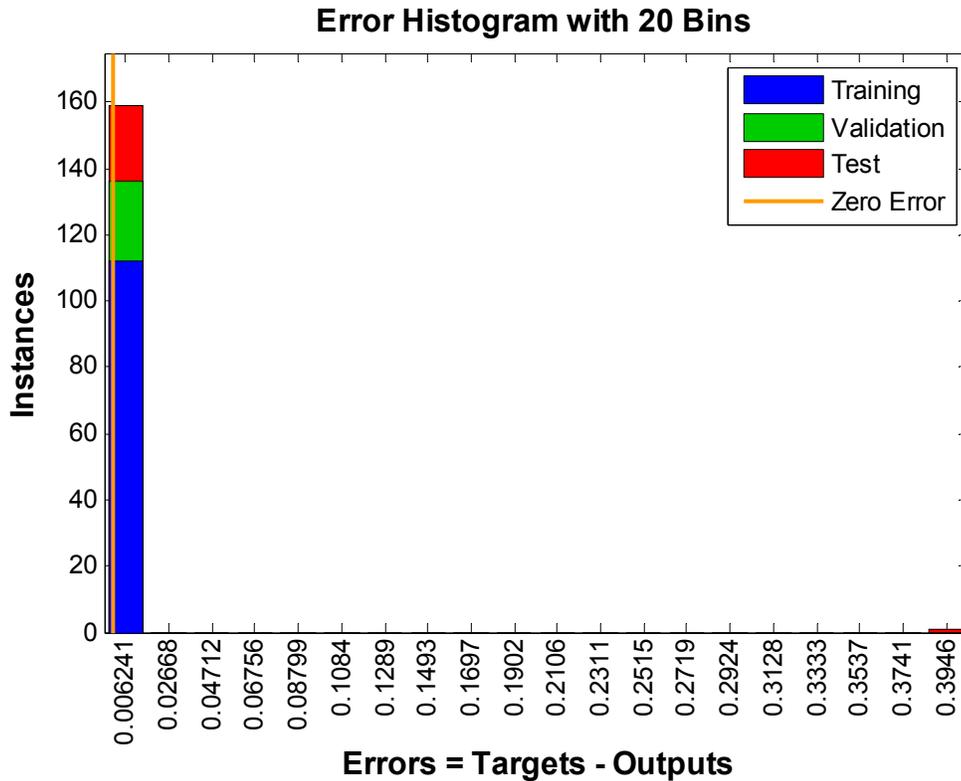
Así mismo, el rendimiento de la red se puede medir a partir de la gráfica 18, donde se observa las regresiones para el proceso de entrenamiento, validación y prueba, en el cual se muestra la relación entre los resultados de la red y los objetivos. Cabe resaltar, que para este caso, los resultados del entrenamiento indican un buen resultado debido a que el valor R es 1. De igual forma, los datos de validación y prueba también muestran un buen resultado ya que el valor de R es mayor a 0,9

**Gráfica. 18. Regresión de la red neuronal mediante el algoritmo de Levenberg-Marquardt y la Transformada Discreta de Fourier**



- El histograma de error que se observa en la figura 36 , muestra la distribución de los errores en la red, del cual se puede resaltar que el error medido entre la diferencia del objetivo(valor esperado) y la salida que se presentó con mayor frecuencia en el proceso de entrenamiento, validación y prueba fue el 0,006241, lo que indica que la red obtuvo un buen rendimiento en cuanto a la salida esperada(porcentaje de la línea donde ocurrió la falla):

**Figura 36. Histograma de errores en de la red neuronal mediante algoritmo de entrenamiento Levenberg-Marquardt y la Transformada Discreta de Fourier**



Finalmente, a partir del análisis de los resultados obtenidos mediante el entrenamiento de la red neuronal con el algoritmo de Levenberg-Marquardt, en la tabla 11 se muestra un resumen de los resultados posteriores a la verificación final de la red, donde se observa que los porcentajes de error relativo promedio es igual a 0,3822%, lo que indica que el diseño de la red neuronal bajo este esquema de entrenamiento presentó una buena exactitud en cuanto a la localización de la falla en el Sistema Eléctrico de Potencia seleccionado.

**Tabla 11. Resultados del localización de FAI por medio de la Red Neuronal mediante el algoritmo de Levenberg-Marquardt y la Transformada Discreta de Fourier**

$R_{falla}[\text{ohm}]$	Ángulo de inyección[°]	Punto de Falla[km]	Localización de la Falla[km]	Error relativo[%]
100	30	57,4	57,84373	0,773039
100	30	65,6	65,48399	0,176845
100	60	73,8	73,88187	0,110928
100	90	16,4	16,38121	0,114528
90	0	32,8	32,79824	0,005367
90	30	49,2	48,47021	1,483322
90	0	82	81,52648	0,577463
90	0	73,8	73,75456	0,061563
90	90	41	41,02846	0,069426
90	90	32,8	32,78811	0,03625
80	90	16,4	16,4595	0,362788
80	60	82	82,10735	0,130913
80	90	57,4	57,42362	0,041149
70	0	82	81,4644	0,653173
70	30	65,6	65,36023	0,365502
70	30	32,8	33,09536	0,900512
60	0	16,4	16,56217	0,988838
60	0	65,6	65,42095	0,272934
60	30	49,2	49,30667	0,216803
60	60	32,8	32,70086	0,302247
<b>Promedio error relativo</b>				<b>0,3821793</b>

Así mismo, se puede analizar que al igual que en el caso del enteramiento mediante la técnica de Regulación Bayesiana, los menores porcentajes de error fueron obtenidos cuando se simularon fallas muy cercanas a la longitud total de la línea, es decir, cuando las fallas ocurren directamente en la barra del sistema o en su defecto en líneas medias o . Es importante resaltar, que cuando se trata de localizar falla porcentajes pequeños de la longitud total de la línea, es más difícil debido a que la variaciones de tensión no se tan representativas como en el caso contrario a porcentajes altos de la línea, donde estos cambios son más notorios y por ende el punto de falla se puede calcular con más facilidad y exactitud.

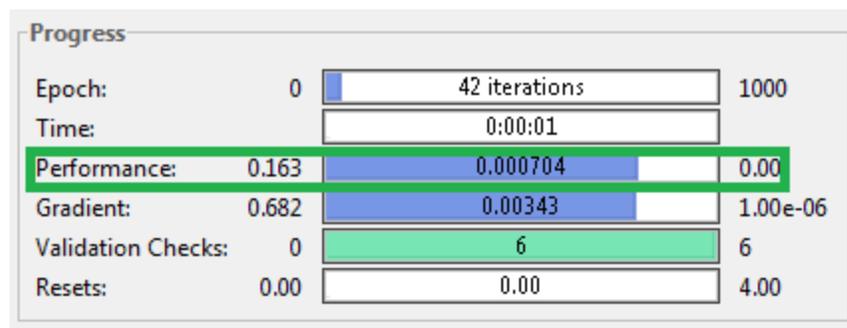
### b) Entrenamiento con el algoritmo BFGS Quasi-Newton

El entrenamiento de una Red Neuronal mediante algoritmos de Quasi-Newton, consiste en tomar el gradiente de la función objetivo en cada iteración, el cual al medir los cambios en los gradientes construye un modelo a la función objetivo (valor esperado) para generar una convergencia supe lineal [59].

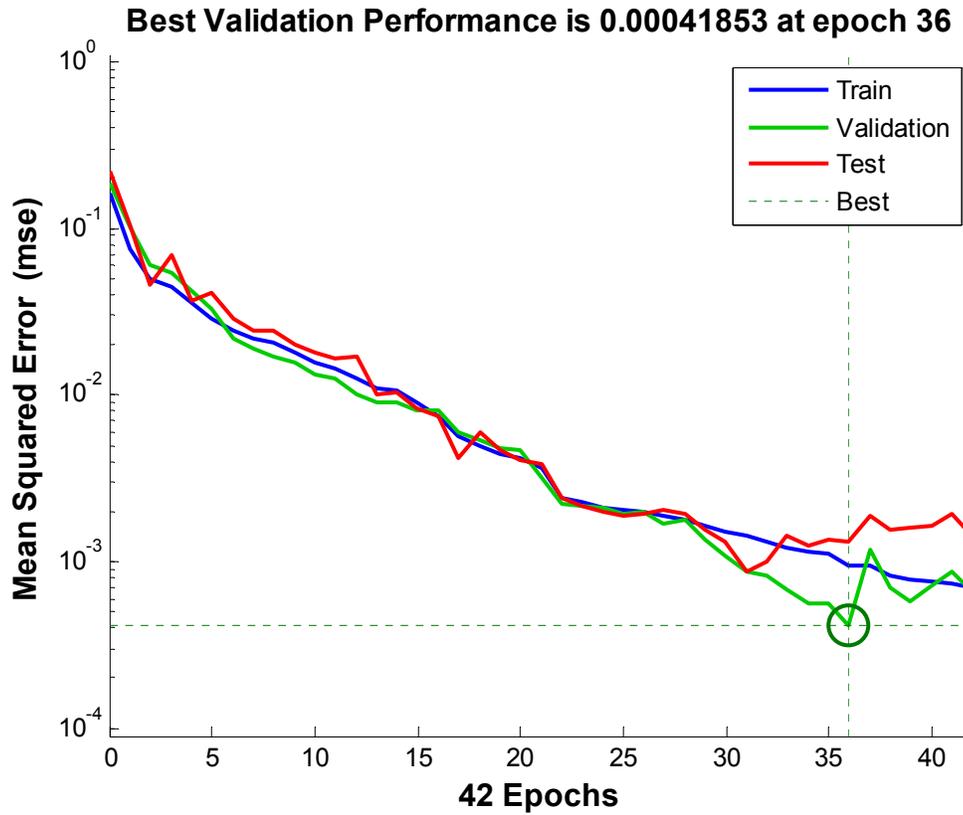
Los principales resultados obtenidos mediante el entrenamiento basado en el algoritmo BFGS Quasi-Newton:

- La función de rendimiento de la red utilizada en la simulación es la función MSE, la cual permite ajustar los valores de los pesos y los sesgos de la red para optimizar el rendimiento de la misma. Para el caso estudio, el rendimiento y el promedio de error cuadrado calculado se muestran en la figura 37 y gráfica 19 , que en comparación con los métodos anteriores, el rendimiento de este método es mayor y converge en 42 iteraciones como se muestra en la gráfica 19 :

**Figura 37. Progreso del entrenamiento mediante algoritmo BFGS Quasi-Newton y la Transformada Discreta de Fourier**

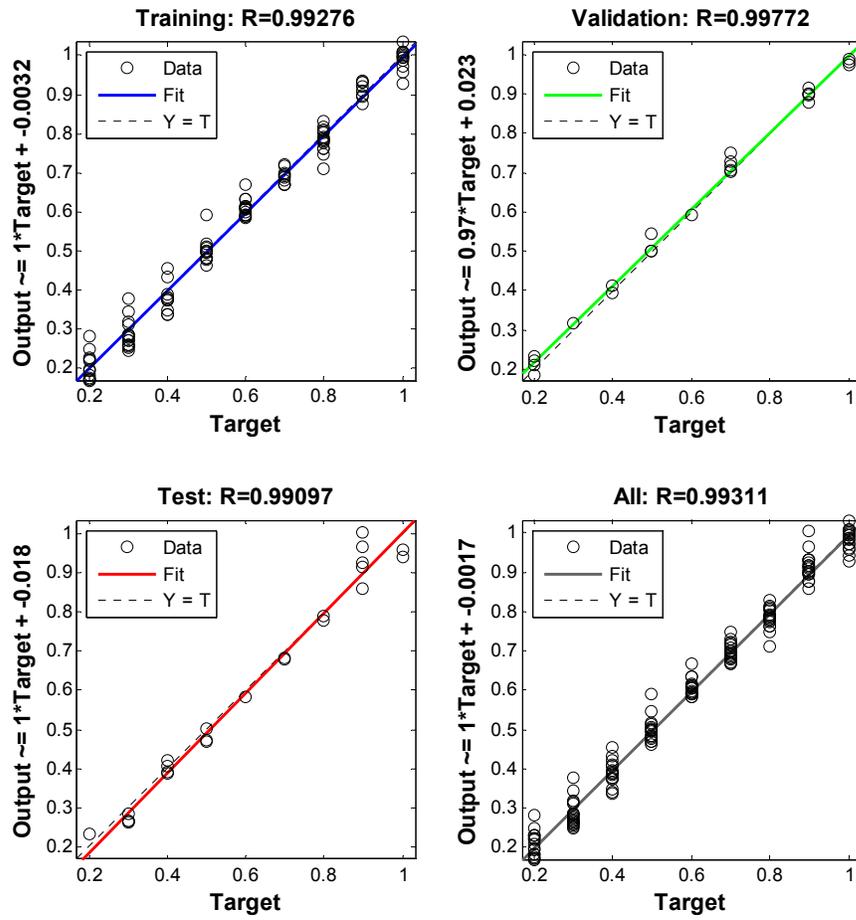


Gráfica. 19. Error cuadrado promedio de la red neuronal mediante el algoritmo BFGS Quasi-Newton y la Transformada Discreta de Fourier



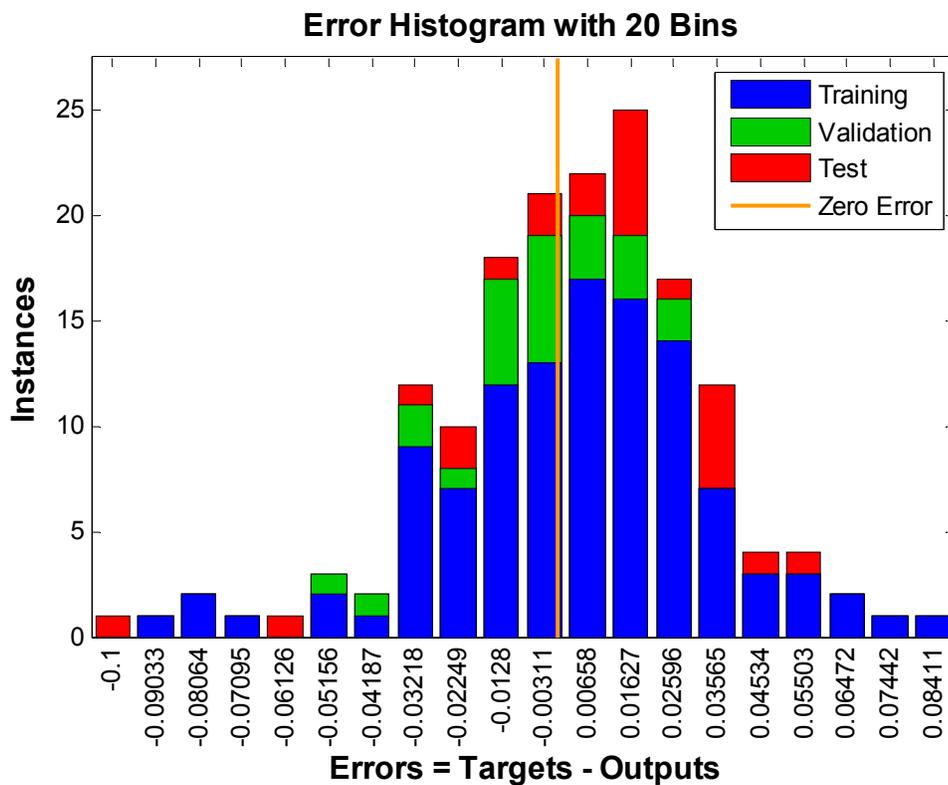
- De igual forma, se puede analizar que la gráfica de regresión obtenida tanto para la etapa de entrenamiento, validación como prueba, el valor de R es mayor a 0,9, lo que indica una buena aproximación entre a salida de la red y los datos esperados, como se observa en la gráfica 20:

Gráfica. 20. Regresión de la red neuronal mediante el algoritmo BFGS Quasi-Newton y la Transformada Discreta de Fourier



- El histograma de error que se observa en la figura 38 , muestra la distribución de los errores en la red, del cual se observa que el error medido entre la diferencia del objetivo(valor esperado) y la salida que se presentó con más frecuencia en el proceso de entrenamiento, validación y prueba fue el 0,01627:

**Figura 38. Histograma de errores en de la red neuronal mediante el algoritmo BFGS Quasi-Newton y la Transformada Discreta de Fourier**



A partir de la implementación del algoritmo de BFGS Quasi-Newton para la etapa de entrenamiento de la red neuronal, se obtuvo que el error promedio relativo al momento de localizar una falla de alta impedancia en el sistema de potencia del caso estudio es de aproximadamente de 5,4%, lo que indica un rendimiento menor en comparación con otros métodos de aprendizaje como el de Regulación bayesiana donde el error promedio relativo no superó el 0,2233%. En la tabla 12, se observa los resultados obtenidos en cuanto a localización de fallas mediante el método de aprendizaje BFGS Quasi-Newton, donde se evidencian 20 muestras

utilizadas para la prueba final de la red, Cabe resaltar, que al igual que en los anteriores métodos de entrenamiento, los errores relativos para este tipo de entrenamiento son inversamente proporcional con respecto al punto de localización de falla, es decir a medida que la falla tiende a representar un porcentaje pequeño de la línea de transmisión, los errores son elativamente mayores en comparación cuando se trata de porcentajes altos de la línea:

**Tabla 12. Resultados del localización de FAI por medio de la Red Neuronal mediante el método de BFGS Quasi-Newton y la Transformada Discreta de Fourier**

$R_{falla}[\text{ohm}]$	Ángulo de incepción[°]	Punto de Falla[km]	Localización de la Falla[km]	Error relativo[%]
100	30	57,4	57,87116	0,820847
100	30	65,6	64,52116	1,644576
100	60	73,8	70,57743	4,366622
100	90	16,4	19,35964	18,04662
90	0	32,8	28,70924	12,47182
90	0	73,8	74,62737	1,121101
90	0	82	77,57015	5,402258
90	30	49,2	49,35913	0,323432
90	90	41	38,94242	5,018496
90	90	32,8	30,61059	6,675015
80	60	82	80,18122	2,218031
80	90	16,4	17,93745	9,3747
80	90	57,4	57,29095	0,189987
70	0	82	82,2921	0,356222
70	30	65,6	66,3829	1,193454
70	30	32,8	29,12641	11,19998
60	0	65,6	68,93221	5,079587
60	0	16,4	17,69532	7,898283
60	0	49,2	53,32061	8,375227
60	60	32,8	30,72532	6,325252
<b>Promedio error relativo</b>				5,405075

### c) Entrenamiento con el algoritmo Resilient Backpropagation

El entrenamiento mediante el algoritmo Resilient Backpropagation [60], es una técnica de entrenamiento derivado del algoritmo de Levenberg-Marquardt, el cual consiste en tomar el signo de la derivada del error con respecto al peso de la neurona con el objetivo principal de determinar la dirección de la actualización de los pesos. Cabe resaltar, que la magnitud de la derivada no tiene efecto sobre la actualización de los pesos. En otras palabras, el cambio de los pesos dependerá de un factor incremental o decremental, de acuerdo a lo siguiente:

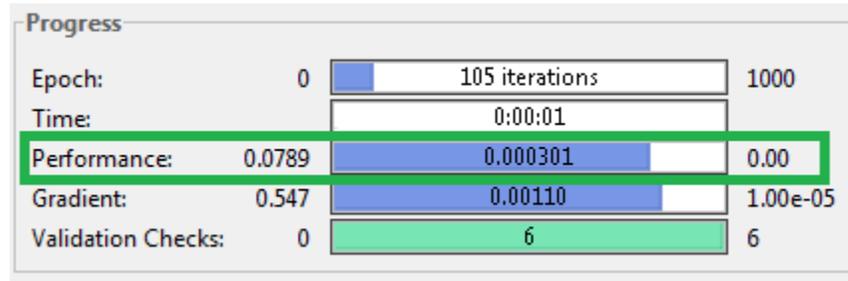
- Si la derivada del error con respecto al peso tiene el mismo signo en dos iteraciones seguidas, el valor de la actualización de pesos se incrementará por un factor  $\Delta_{inc}$ .
- Si la derivada del error con respecto al peso cambia de signo con relación a una iteración anterior, el valor de la actualización de los pesos decrementará por un factor  $\Delta_{dec}$ .
- Si la derivada es cero, el valor de actualización de los pesos será el mismo.
- Si los pesos se encuentran variando, el cambio de los mismos se reducirá.
- Si la actualización de los pesos se realiza en una sola dirección por varias iteraciones, la magnitud de cambio de pesos incrementará.

Nota: El valor para  $\Delta_{inc}$  suele ser de 0,2 y el de  $\Delta_{dec}$  de 0,5 [61].

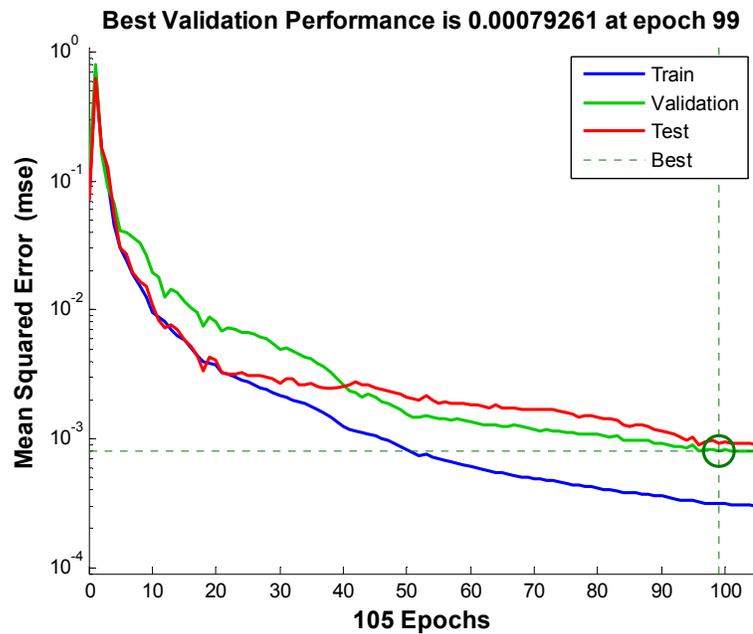
Teniendo en cuenta lo anterior, se procedió a entrenar la red propuesta en la presente investigación mediante este método de entrenamiento y se obtuvo los siguientes resultados:

- El rendimiento y error cuadrado promedio que se obtuvo para este tipo de entrenamiento luego de 105 iteraciones se muestra en la figura 39 y gráfica 21, respectivamente :

**Figura 39. Progreso del entrenamiento mediante algoritmo Resilient Backpropagation y la Transformada Discreta de Fourier**

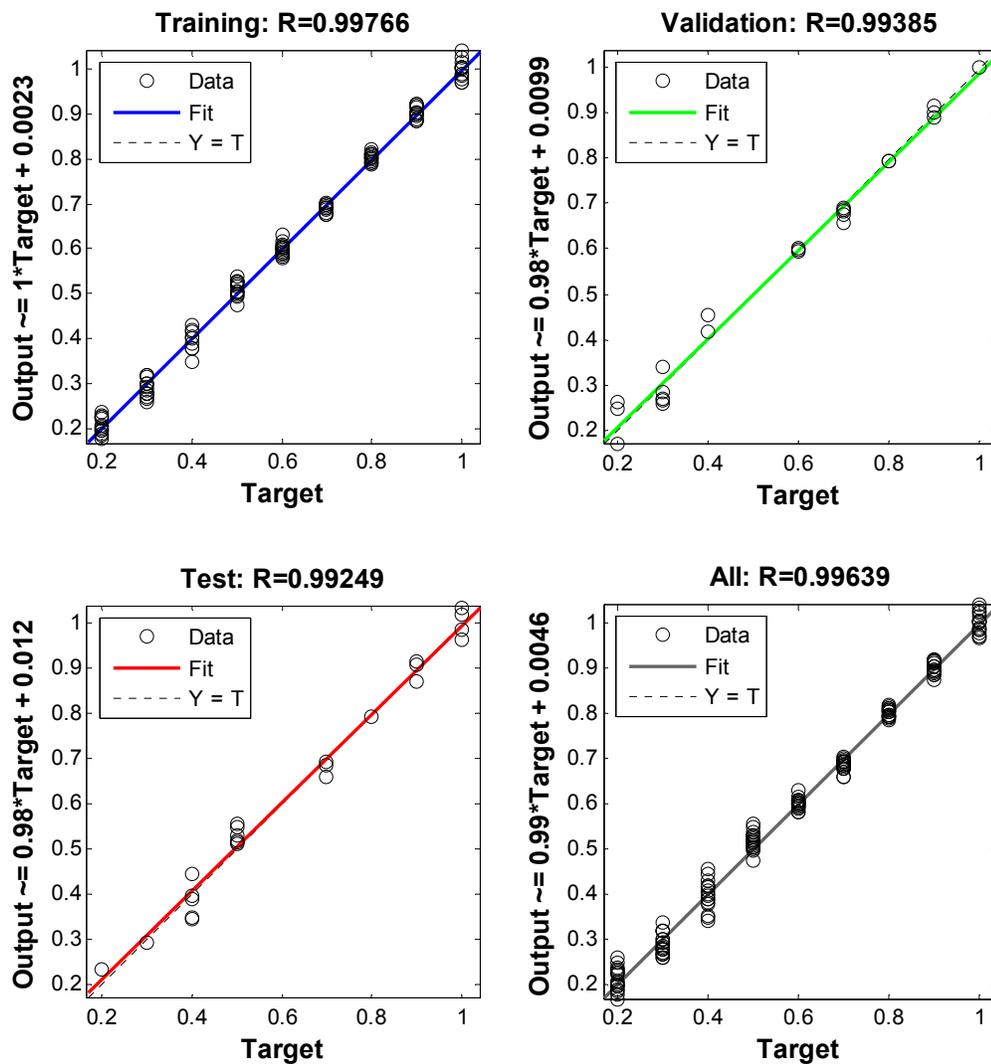


**Gráfica. 21. Error cuadrado promedio de la red neuronal con el algoritmo Resilient Backpropagation y la Transformada Discreta de Fourier**



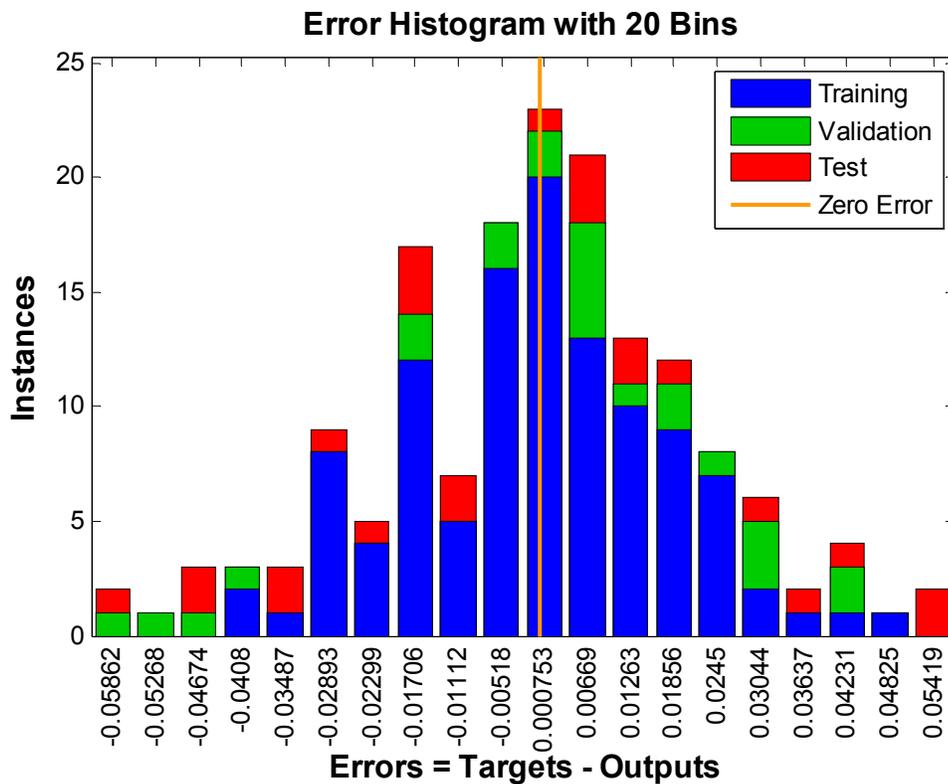
Así mismo se observa, que los datos de salida de la red con respecto a los esperados guardan un gran relación, lo cual se puede evidenciar a partir de la gráfica 22, donde regresión obtenida tanto para la etapa de entrenamiento, validación como prueba, el valor de R es mayor de 0,9, lo que indica un buen rendimiento de la red para este tipo de aprendizaje.

**Gráfica. 22. Regresión de la red neuronal mediante el algoritmo Resilient Backpropagation y la Transformada Discreta de Fourier**



- El histograma de error que se observa en la figura 40 , muestra la distribución de los errores en la red, del cual se observa que el error medido entre la diferencia del objetivo(valor esperado) y la salida que se presentó con más frecuencia en el proceso de entrenamiento, validación y prueba fue el 0,000753:

**Figura 40. Histograma de errores en de la red neuronal mediante el algoritmo Resilient Backpropagation y la Transformada Discreta de Fourier**



A partir de los resultados expuestos para este tipo de aprendizaje, la salida de la red luego finalizar de su etapa de prueba dio como resultado que la localización de punto de falla a partir de este método tiene un error promedio relativo de 4,24% como se indica en la tabla 13 Cabe resaltar, que este método fue el que arrojó mayor porcentaje de error en comparación con otros algoritmos de aprendizaje. Esto debido a como se en la referencia [57] , donde estos resultados se deben a que este algoritmo no presenta un buen desempeño en cuanto a

problemas de aproximación como es el caso de la presente investigación. Así mismo, se puede analizar que su rendimiento decrece cuando el error objetivo de reduce.

**Tabla 13. Resultados del localización de FAI por medio de la Red Neuronal mediante el método de Resilient Backpropagation y la Transformada Discreta de Fourier**

$R_{falla}$ [ohm]	Ángulo de inepción[°]	Punto de Falla[km]	Localización de la Falla[km]	Error relativo[%]
100	30	57,4	57,31972	0,139855
100	30	65,6	64,12812	2,243715
100	60	73,8	72,74817	1,425243
100	90	16,4	22,25627	35,70896
90	0	32,8	33,00341	0,620139
90	0	82	80,99182	1,229486
90	0	73,8	74,65359	1,156618
90	30	49,2	51,30565	4,279768
90	90	41	41,84931	2,071473
90	90	32,8	30,35771	7,446006
80	60	82	81,51705	0,588962
80	90	16,4	16,71906	1,945511
80	90	57,4	56,54545	1,488778
70	0	82	82,35905	0,437872
70	30	65,6	65,40927	0,290755
70	30	32,8	33,3886	1,794529
60	0	16,4	17,97754	9,619152
60	0	65,6	62,77513	4,306196
60	30	49,2	45,88612	6,735539
60	60	32,8	32,38628	1,261349
<b>Promedio error relativo</b>				4,239495

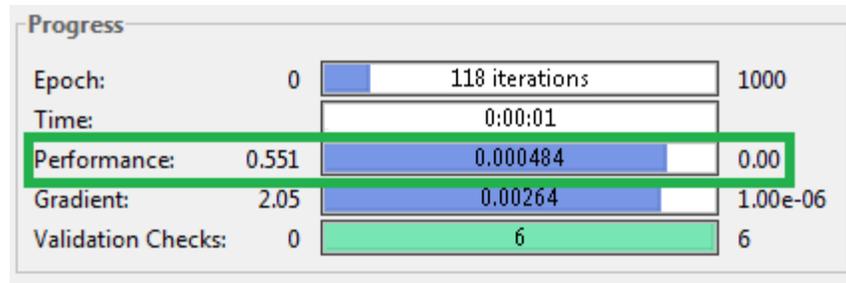
#### **d) Entrenamiento con el algoritmo Scaled Conjugate Gradient**

En el entrenamiento mediante algoritmos de gradientes conjugados [62], el gradiente indica la dirección de la máxima variación de la función. El principal inconveniente de los algoritmos de gradiente conjugado radica, en que la implementación de una búsqueda lineal en cada dirección, resulta costoso al momento de evaluar la función. Esta búsqueda lineal puede evitarse utilizando información de segundo orden, es decir mediante la aproximación de la segunda derivada mediante derivadas primeras próximas, como es el caso del algoritmo de Scaled Conjugate Gradient. En este algoritmo [63], se realiza una búsqueda a través de direcciones conjugadas, el cual conlleva a una convergencia más rápida que en direcciones descendentes pronunciadas, en esta algoritmo a diferencia de los algoritmos de gradiente conjugado, se hace una búsqueda por medio de la dirección del gradiente conjugado con el objetivo de determinar el cambio de los pesos que permitan minimizar la función objetivo a los largo de la línea.

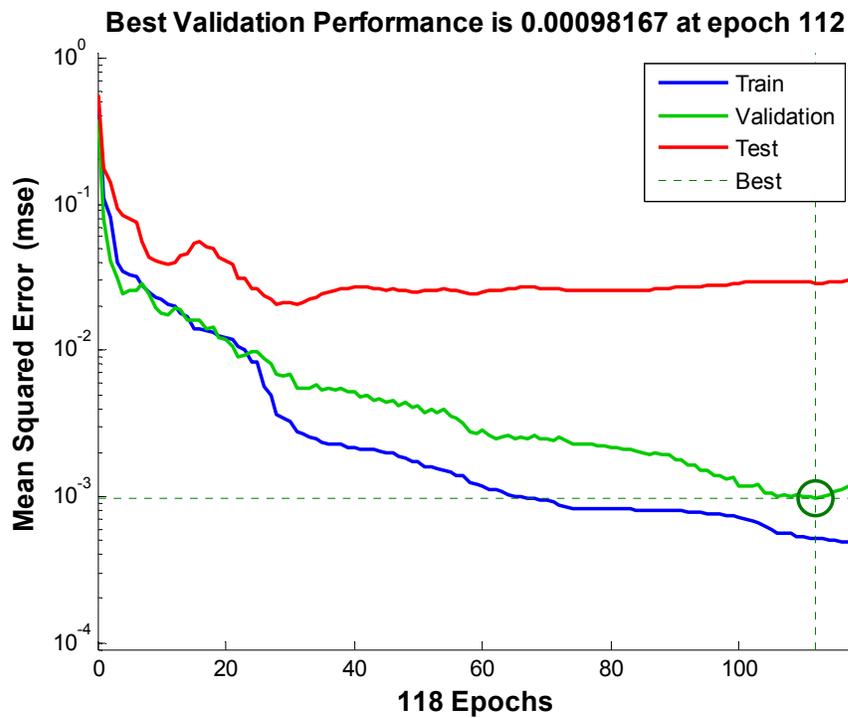
Teniendo en cuenta lo anterior, con el entrenamiento basado el algoritmo Scaled Conjugate Gradient, los principales análisis y resultados obtenidos en la etapa de entrenamiento, validación y prueba de la red neuronal diseñada para investigación son:

- El mejor rendimiento de la red se obtuvo en la iteración 112 como se observa en la gráfica 23. Así mismo, se muestra que el error cuadrado promedio de la red, en relación a los datos de salida y el valor esperado con este tipo de entrenamiento obtuvo un buen rendimiento como se observa en la figura 41:

**Figura 41. Progreso del entrenamiento mediante algoritmo Scaled Conjugate Gradient y la Transformada Discreta de Fourier**

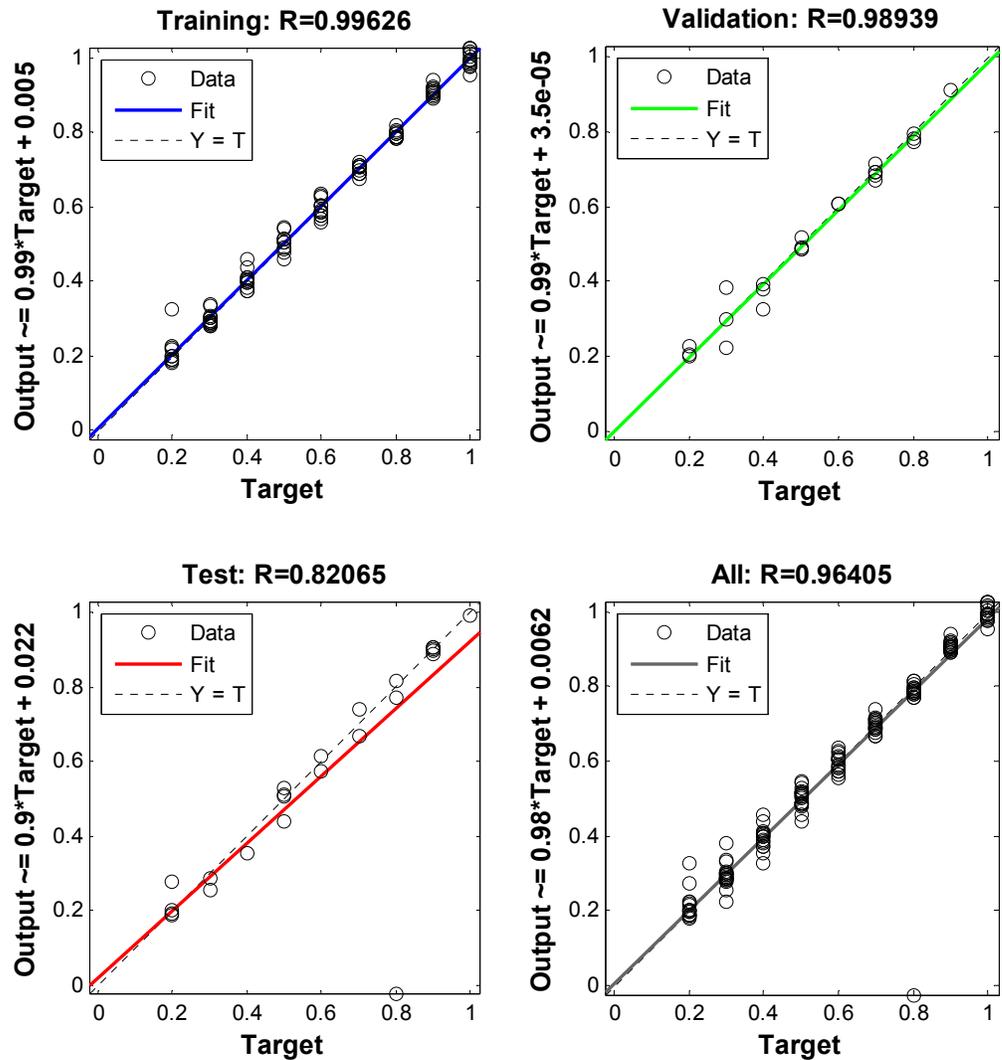


**Gráfica. 23. Error cuadrado promedio de la red neuronal mediante el algoritmo Scaled Conjugate Gradient y la Transformada Discreta de Fourier**



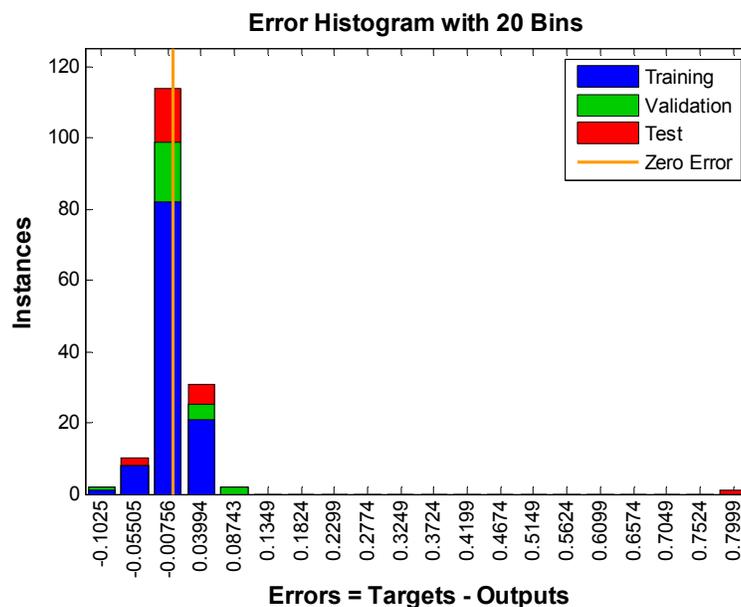
- De igual forma, se observa que red entrenada con este clase de algoritmo presentó una buena relación entre los datos de salida de la red y los esperados, lo cual se puede comprobar en la gráfica 24, donde el valor R en la gráficas la regresión tanto para las etapas de entrenamiento, validación como pruebas en mayor al 0,9.

**Gráfica. 24. Regresión de la red neuronal mediante el algoritmo Scaled Conjugate Gradient y la Transformada Discreta de Fourier**



- El histograma de error que se observa en la figura 42 , muestra la distribución de los errores en la red, del cual se observa que el error medido entre la diferencia del objetivo(valor esperado) y la salida que se presentó mayor frecuencia en el proceso de entrenamiento, validación y prueba fue el 0,00756:

**Figura 42. Histograma de errores en de la red neuronal mediante el algoritmo Scaled Conjugate Gradient y la Transformada Discreta de Fourier**



Con base en los resultados obtenidos en relación al entrenamiento de la red mediante el algoritmo Scaled Conjugate Gradient, en la tabla 13 se muestra que el error promedio relativo para este tipo de entrenamiento es 3,53% que en comparación con otros métodos de entrenamiento probados en esta investigación, presenta el tercer menor error en relación a la localización del punto de falla en el sistema eléctrico de potencia seleccionado. Cabe resaltar, este tipo de entrenamiento es uno de los que necesita más iteraciones para converger como se observa en la tabla 14 de la sección de conclusiones generales. Al igual que en los anteriores métodos de entrenamiento, en este algoritmo aproximadamente el error relativo es inversamente proporcional al porcentaje de localización de la falla, es decir, a media que la falla ocurre a porcentajes pequeños de la longitud total de la línea(82km), el error va aumentándolo cual se debe principalmente a

que cuando se trata de localizar falla de poca longitud, es más difícil debido a que las variaciones de tensión no son tan representativas como en el caso contrario a las líneas con longitudes largas, donde estos cambios son más notorios y por ende el punto de falla se puede calcular con más facilidad y exactitud.

**Tabla 14. Resultados de la localización de FAI por medio de la Red Neuronal mediante el algoritmo Scaled Conjugate Gradient y la Transformada Discreta de Fourier**

<b>R<sub>falla</sub>[ohm]</b>	<b>Ángulo de inyección[°]</b>	<b>Punto de Falla[km]</b>	<b>Localización de la Falla[km]</b>	<b>Error relativo[%]</b>
100	30	57,4	55,94579	2,533466
100	30	65,6	64,20156	2,131773
100	60	73,8	73,61336	0,252895
100	90	16,4	16,40174	0,010579
90	0	32,8	34,47952	5,12049
90	30	49,2	48,14748	2,139266
90	0	82	78,82681	3,869741
90	0	73,8	73,83956	0,053595
90	90	41	39,59343	3,43065
90	90	32,8	31,85409	2,88388
80	60	82	81,41103	0,718265
80	90	16,4	14,92387	9,000813
80	90	57,4	57,17956	0,384045
70	0	82	81,39822	0,73388
70	30	65,6	66,29233	1,055376
70	30	32,8	31,88621	2,785943
60	0	65,6	64,68488	1,395004
60	0	16,4	11,59514	29,29797
60	30	49,2	49,23281	0,066686
60	60	32,8	33,67633	2,671746
<b>Promedio error relativo</b>				3,526803

## 2. Procesamiento de la señal mediante la Transformada Discreta de Wavelet

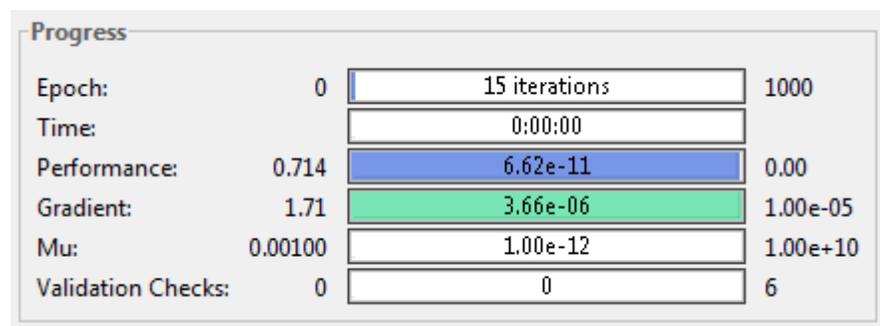
Con base en estas características generales, a continuación se presentan los resultados obtenidos en el proceso de entrenamiento y aprendizaje supervisado de la red utilizando el método de procesamiento de datos de la Transformada discreta de Wavelet y algoritmos de aprendizaje tales como: Levenberg-Marquardt, BFGS Quasi-Newton, Resilient Backpropagation y Scaled Conjugate Gradient.

### a) Entrenamiento con el algoritmo Levenberg-Marquardt

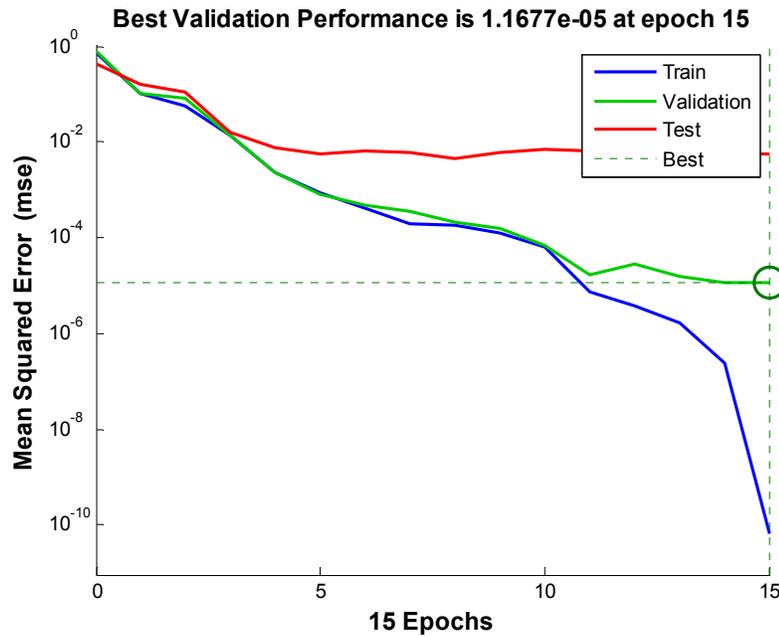
Los resultados obtenidos para este tipo de entrenamiento con el algoritmo Levenberg-Marquardt mediante el procesamiento de los datos realizados con la transformada discreta de wavelet son:

- El rendimiento de la red y el error cuadrado promedio de la red se muestra en la figura 43 y la gráfica 25 respectivamente, donde se puede observar que la relación entre los datos de salida y el valor esperado con este tipo de entrenamiento guardan relación

**Figura 43. Progreso del entrenamiento mediante el algoritmo de Levenberg-Marquardt y la Transformada Discreta de Wavelet**

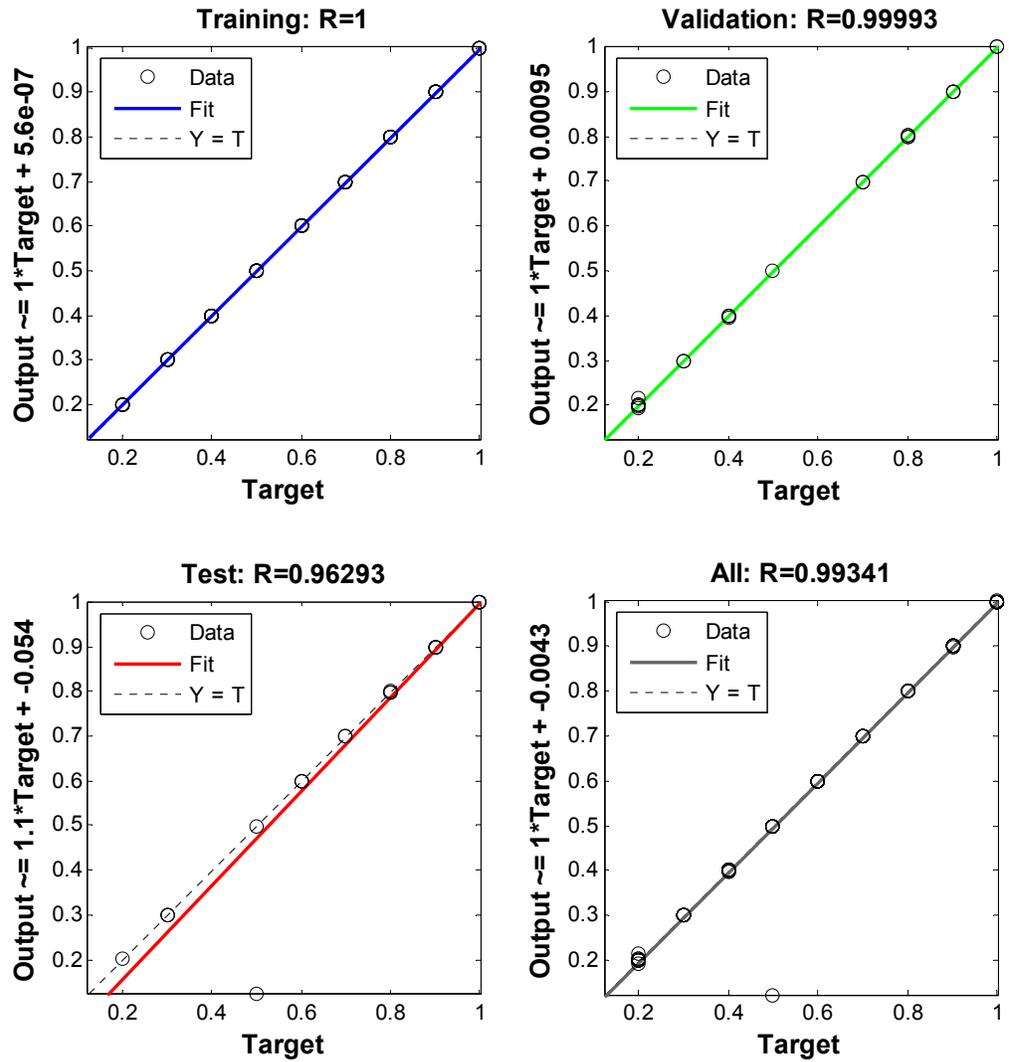


**Gráfica. 25. Error cuadrado promedio mediante el algoritmo de Levenberg-Marquardt y la Transformada Discreta de Wavelet**



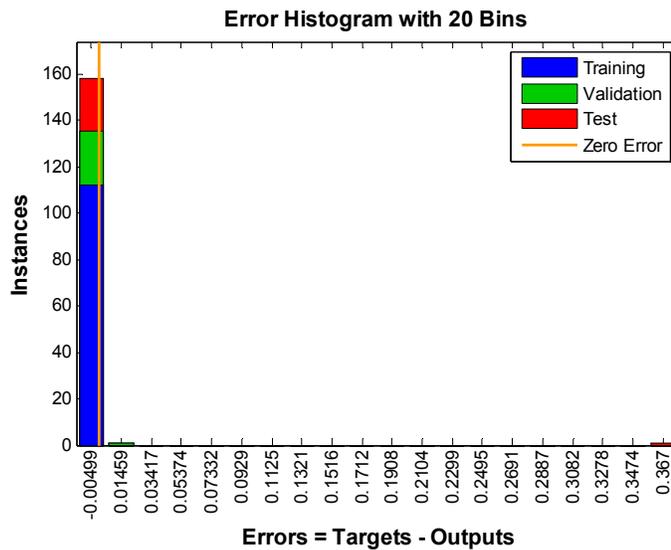
- En la gráfica 26 de regresión se observa que red entrenada con este clase de algoritmo presentó una valor R tanto para las etapas de entrenamiento, validación como pruebas en mayor al 0,9:

Gráfica. 26. Regresión de la red neuronal mediante el algoritmo de Levenberg-Marquardt y la Transformada Discreta de Wavelet



- El histograma de error que se observa en la figura 44, muestra la distribución de los errores en la red, del cual se observa que el error medido entre la diferencia del objetivo(valor esperado) y la salida que se presentó mayor frecuencia en el proceso de entrenamiento, validación y prueba fue el 0,00499:

**Figura 44. Histograma de errores en de la red neuronal mediante el algoritmo de Levenberg-Marquardt y la Transformada Discreta de Wavelet**



- El error relativo promedio de la localización de fallas de alta impedancia para este método es de 0,574% como se indica en la tabla 15 :

**Tabla 15. Resultados del localización de FAI por medio de la Red Neuronal mediante el algoritmo de Levenberg-Marquardt y la Transformada Discreta de Wavelet**

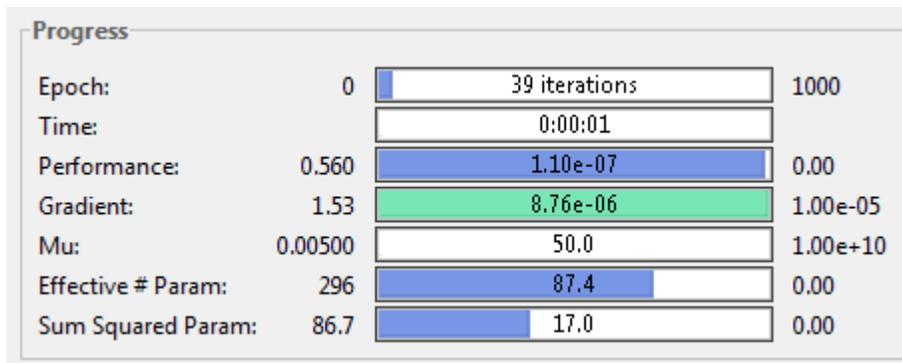
$R_{falla}[\text{ohm}]$	Ángulo de incepción[°]	Punto de Falla[km]	Localización de la Falla[km]	Error relativo[%]
100	90	49,2	49,37464	0,354952
90	60	16,4	15,97567	2,587337
90	0	82	81,99101	0,010956
90	0	32,8	32,78443	0,047467
80	90	57,4	57,40782	0,013634
80	90	41	40,96282	0,090672
80	30	49,2	49,19645	0,007213
80	30	82	81,97741	0,027551
70	0	57,4	57,35524	0,077977
70	30	82	81,97647	0,028695
70	30	57,4	57,38801	0,020883
70	60	16,4	17,02275	3,797254
70	90	41	40,9366	0,154649
70	90	16,4	16,63592	1,438535
60	60	41	41,11147	0,271882
60	60	65,6	66,34164	1,130545
60	60	57,4	57,47296	0,127111
60	60	24,6	24,57333	0,108393
60	90	24,6	24,3142	1,161802
60	30	82	81,98002	0,024369
			<b>Promedio error relativo</b>	0,574094

## b) Entrenamiento con el algoritmo Bayesian Regularization

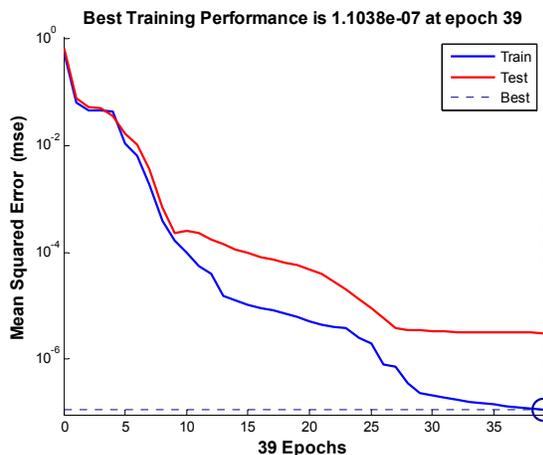
Los resultados obtenidos para este tipo de entrenamiento con el Bayesian Regularization mediante el procesamiento de los datos realizados con la transformada discreta de wavelet son:

- El rendimiento de la red y el error cuadrado promedio de la red se muestra en la figura 45 y la gráfica 27 respectivamente, donde se puede observar que la relación entre los datos de salida y el valor esperado con este tipo de entrenamiento guardan relación:

**Figura 45. Progreso del entrenamiento mediante el algoritmo de Bayesian Regularization y la Transforma Discreta de Wavelet**

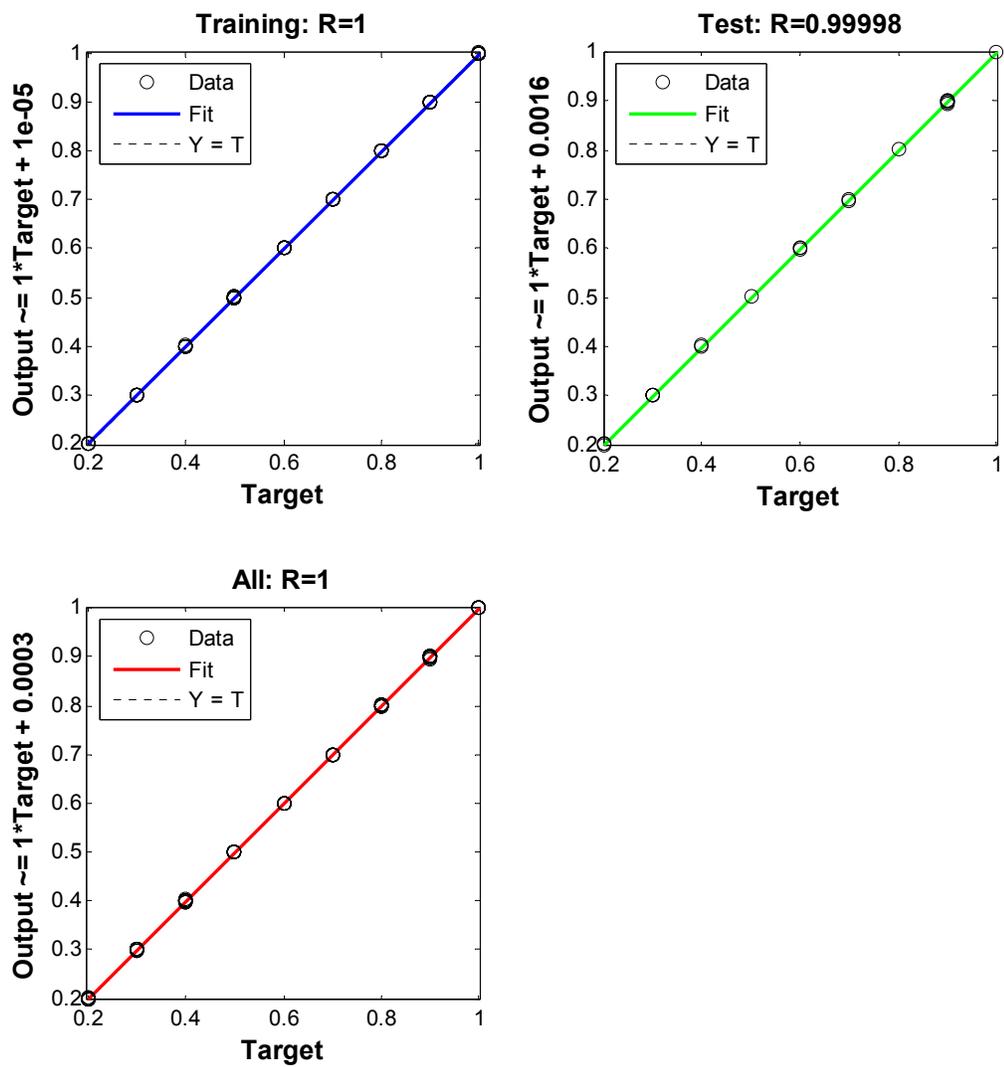


**Gráfica. 27. Error cuadrado promedio mediante el algoritmo de Bayesian Regularization y la Transforma Discreta de Wavelet**



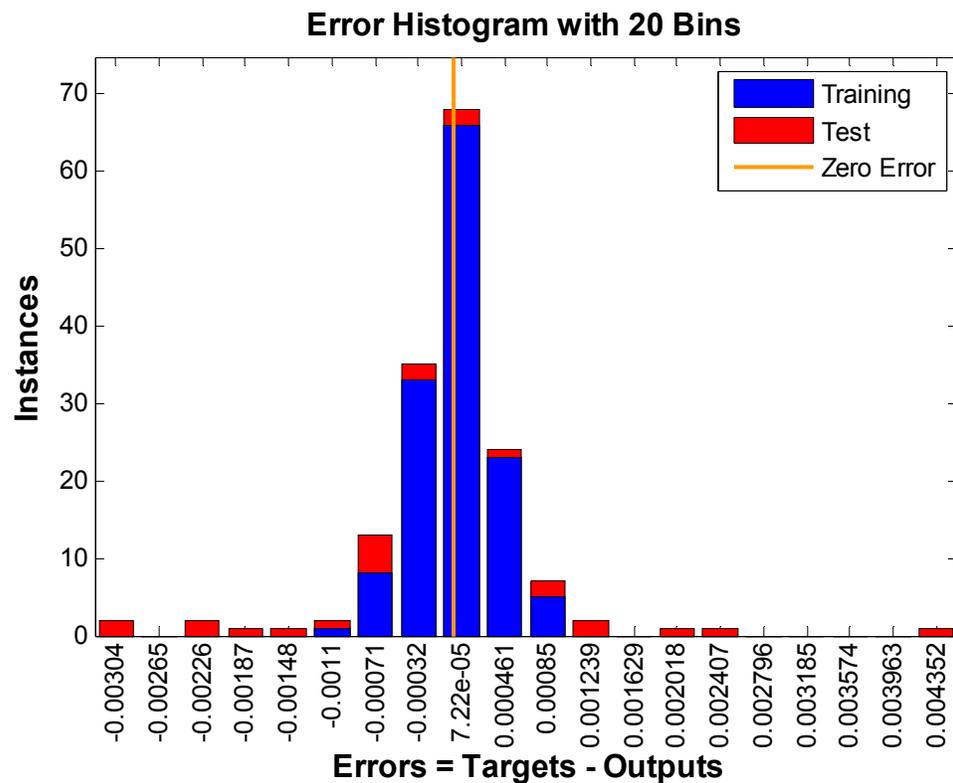
- En la gráfica 28 de regresión se observa que red entrenada con este clase de algoritmo presentó una valor R tanto para las etapas de entrenamiento, validación como pruebas en mayor al 0,9:

**Gráfica. 28. Regresión de la red neuronal mediante algoritmo de Bayesian Regularization y la Transforma Discreta de Wavelet**



- El histograma de error que se observa en la figura 46 , muestra la distribución de los errores en la red, del cual se observa que el error medido entre la diferencia del objetivo(valor esperado) y la salida que se presentó mayor frecuencia en el proceso de entrenamiento, validación y prueba fue el  $7,22e-5$ :

**Figura 46. Histograma de errores en de la red neuronal mediante algoritmo de Bayesian Regularization y la Transforma Discreta de Wavelet**



- El error relativo promedio de la localización de fallas de alta impedancia para este método es de 1,54% como se indica en la tabla 16 :

**Tabla 16. Resultados del localización de FAI por medio de la Red Neuronal mediante el algoritmo de Bayesian Regularization la Transformada Discreta de Wavelet**

$R_{falla}[\text{ohm}]$	Ángulo de inyección[°]	Punto de Falla[km]	Localización de la Falla[km]	Error relativo[%]
100	90	49,2	49,25159	0,104863
90	60	16,4	16,40268	0,0163184
90	0	82	82,03745	0,0456725
90	0	32,8	32,78001	0,0609611
80	90	57,4	57,42776	0,0483635
80	90	41	41,22265	0,5430474
80	30	49,2	49,16085	0,079575
80	30	82	81,88023	0,1460583
70	0	57,4	57,43001	0,0522898
70	90	41	41,17083	0,4166484
70	90	16,4	16,42401	0,1464195
70	60	16,4	16,42916	0,1777812
70	30	82	81,83833	0,197163
70	30	57,4	57,43673	0,0639861
60	60	41	40,95844	0,1013707
60	60	65,6	82,73877	26,126167
60	60	24,6	24,74148	0,5751044
60	60	57,4	57,24128	0,2765232
60	30	82	81,83711	0,1986468
60	90	24,6	24,95757	1,4535398
			<b>Promedio error relativo</b>	1,541525

### c) Entrenamiento con el algoritmo BFGS Quasi-Newton

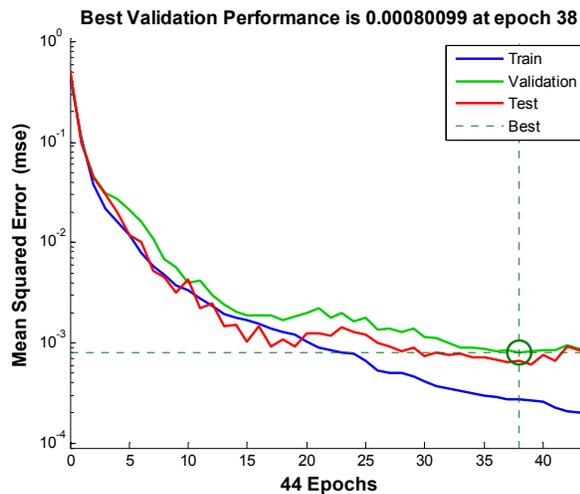
Los resultados obtenidos para este tipo de entrenamiento con el algoritmo BFGS Quasi-Newton mediante el procesamiento de los datos realizados con la transformada discreta de wavelet son:

- El rendimiento de la red y el error cuadrado promedio de la red se muestra en la figura 47 y la gráfica 29 respectivamente, donde se puede observar que la relación entre los datos de salida y el valor esperado con este tipo de entrenamiento guardan relación:

**Figura 47. Progreso del entrenamiento mediante el algoritmo de BFGS Quasi-Newton y la Transforma Discreta de Wavelet**

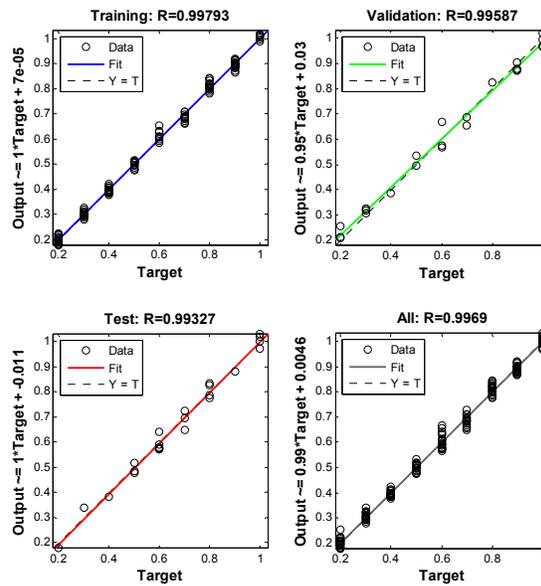


**Gráfica. 29. Error cuadrado promedio mediante el algoritmo de BFGS Quasi-Newton y la Transforma Discreta de Wavelet**



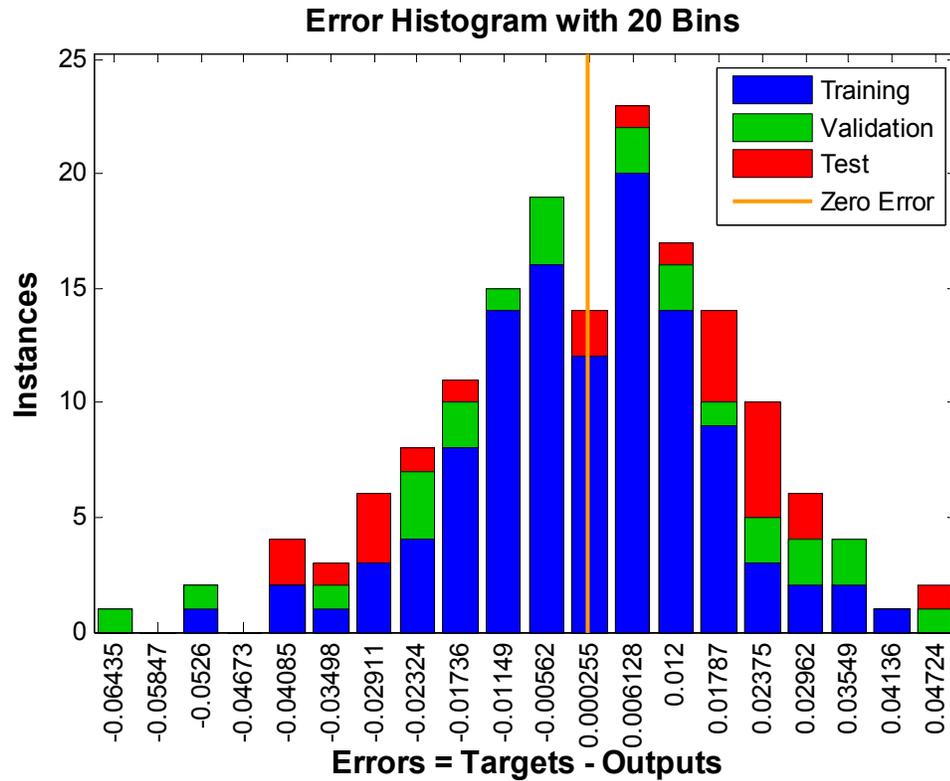
- En la gráfica 30 de regresión se observa que red entrenada con este clase de algoritmo presentó una valor R tanto para las etapas de entrenamiento, validación como pruebas en mayor al 0,9:

**Gráfica. 30. Regresión de la red neuronal mediante el algoritmo de BFGS Quasi-Newton y la Transforma Discreta de Wavelet**



- El histograma de error que se observa en la figura 48 , muestra la distribución de los errores en la red, del cual se observa que el error medido entre la diferencia del objetivo(valor esperado) y la salida que se presentó mayor frecuencia en el proceso de entrenamiento, validación y prueba fue el 0,006128:

Figura 48. Histograma de errores en de la red neuronal mediante el algoritmo de BFGS Quasi-Newton y la Transforma Discreta de Wavelet



- El error relativo promedio de la localización de fallas de alta impedancia para este método es de 4,96% como se indica en la tabla 17 :

Tabla 17. Resultados del localización de FAI por medio de la Red Neuronal mediante el algoritmo de BFGS Quasi-Newton y la Transforma Discreta de Wavelet

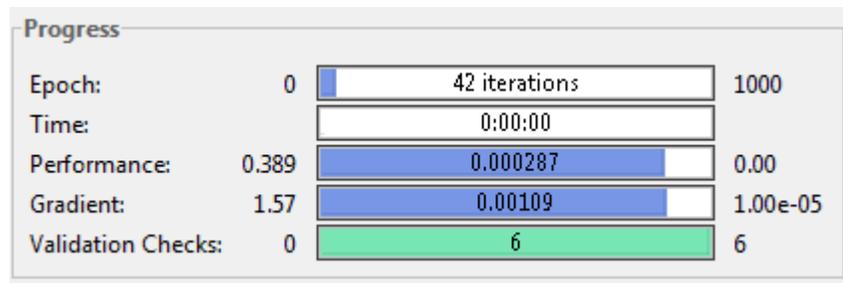
$R_{falla}[\text{ohm}]$	Ángulo de incepción[°]	Punto de Falla[km]	Localización de la Falla[km]	Error relativo[%]
100	90	49,2	48,09287	2,2502554
90	60	16,4	16,16489	1,4336004
90	0	82	82,91546	1,1164114
90	0	32,8	32,73528	0,1973152
80	90	57,4	54,57603	4,9198133
80	90	41	41,84134	2,0520411
80	30	49,2	49,9097	1,4424822
80	30	82	83,01554	1,2384654
70	0	57,4	54,53795	4,9861524
70	30	57,4	57,37386	0,0455479
70	90	41	41,60148	1,4670251
70	90	16,4	15,0712	8,102426
70	60	16,4	16,6732	1,665841
70	30	82	82,34134	0,4162725
60	60	41	42,50589	3,6728968
60	60	65,6	41,67305	36,474015
60	60	57,4	60,26045	4,9833608
60	60	24,6	28,09286	14,198621
60	90	24,6	22,61014	8,0888453
60	30	82	81,58939	0,5007503
			<b>Promedio error relativo</b>	4,962607

#### d) Entrenamiento con el algoritmo Resilient Backpropagation

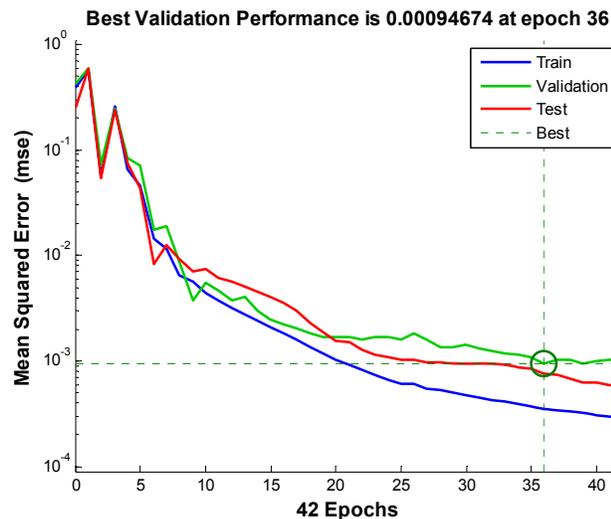
Los resultados obtenidos para este tipo de entrenamiento con el algoritmo Resilient Backpropagation mediante el procesamiento de los datos realizados con la transformada discreta de wavelet son:

- El rendimiento de la red y el error cuadrado promedio de la red se muestra en la figura 49 y la gráfica 31 respectivamente, donde se puede observar que la relación entre los datos de salida y el valor esperado con este tipo de entrenamiento guardan relación:

**Figura 49. Progreso del entrenamiento mediante el algoritmo Resilient Backpropagation y la Transforma Discreta de Wavelet**

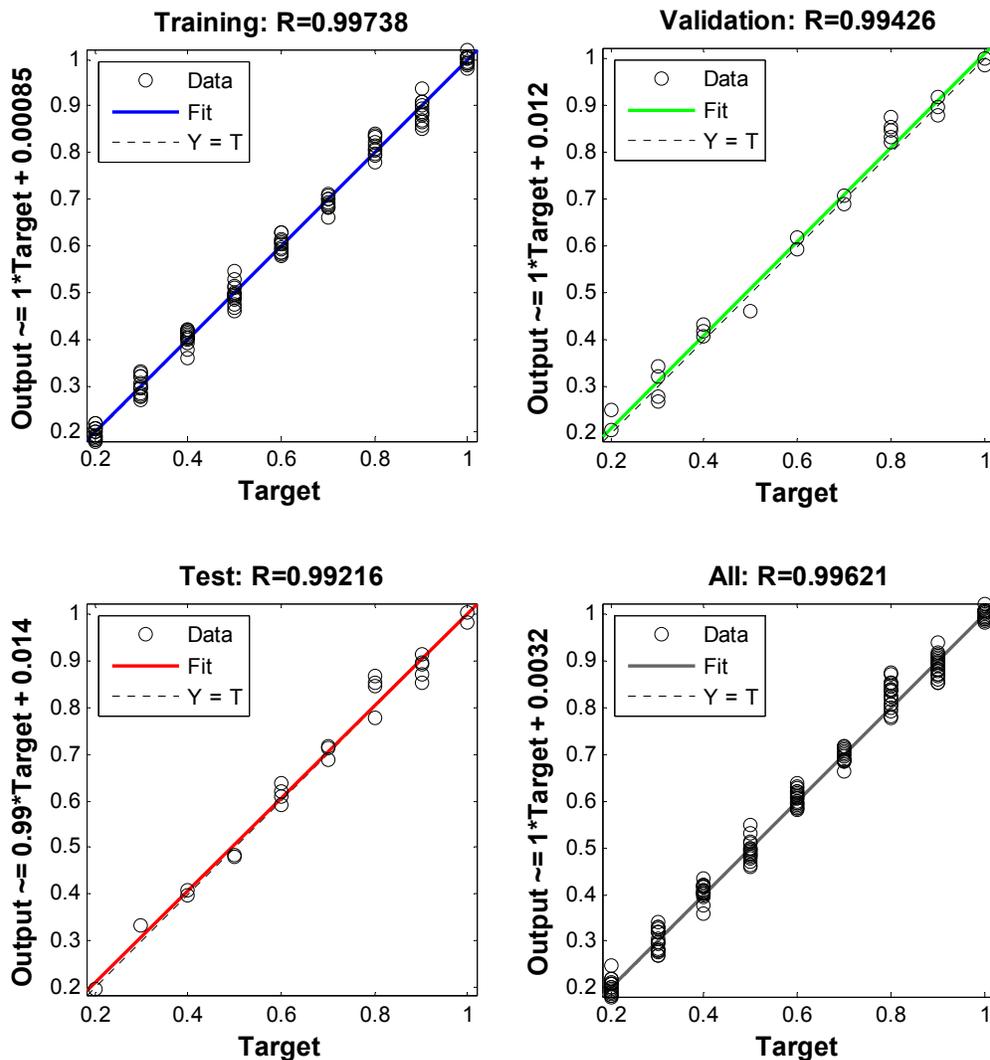


**Gráfica. 31. Error cuadrado promedio mediante el algoritmo Resilient Backpropagation y la Transforma Discreta de Wavelet**



- En la gráfica 32 de regresión se observa que red entrenada con este clase de algoritmo presentó una valor R tanto para las etapas de entrenamiento, validación como pruebas en mayor al 0,9:

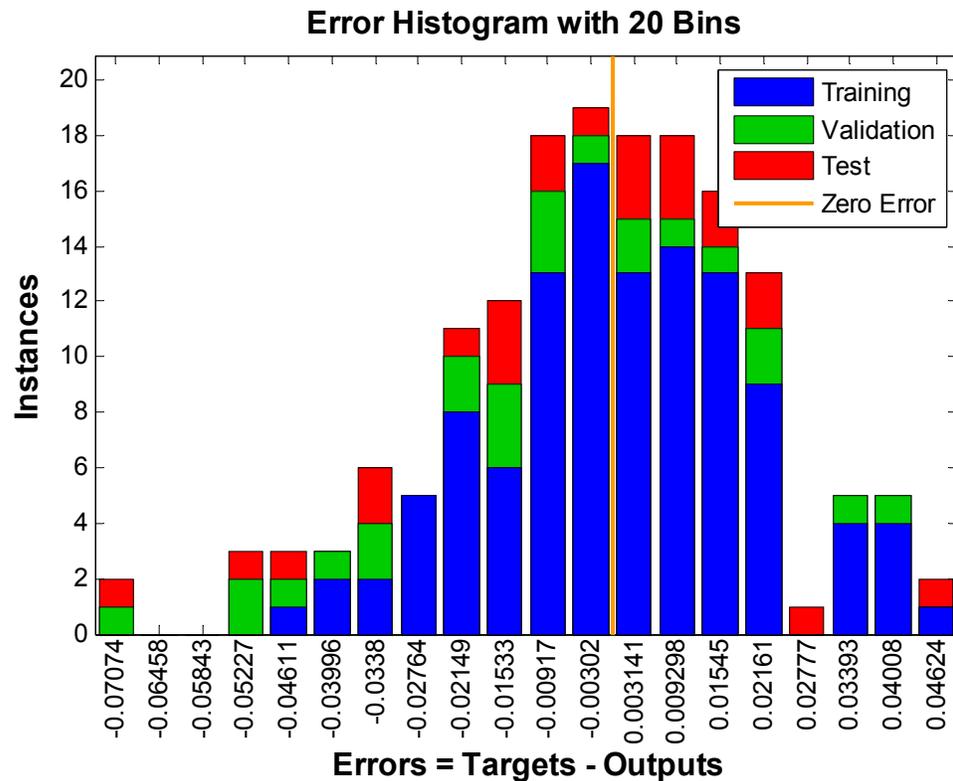
**Gráfica. 32. Regresión de la red neuronal mediante el algoritmo Resilient Backpropagation y la Transforma Discreta de Wavelet**



- El histograma de error que se observa en la figura 50 , muestra la distribución de los errores en la red, del cual se observa que el error medido entre la

diferencia del objetivo(valor esperado) y la salida que se presentó mayor frecuencia en el proceso de entrenamiento, validación y prueba fue el 0,00302:

**Figura 50. Histograma de errores en de la red neuronal mediante algoritmo Resilient Backpropagation y la Transforma Discreta de Wavelet**



- El error relativo promedio de la localización de fallas de alta impedancia para este método es de 5,35 % como se indica en la tabla 18:

**Tabla 18. Resultados del localización de FAI por medio de la Red Neuronal mediante algoritmo Resilient Backpropagation y la Transforma Discreta de Wavelet**

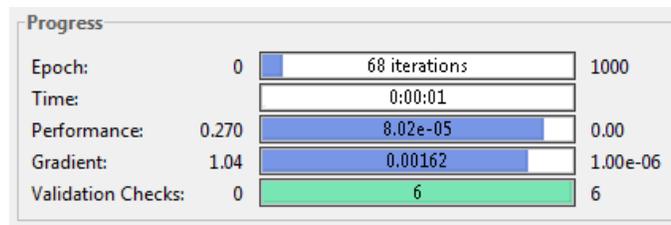
$R_{falla}$ [ohm]	Ángulo de incepción[°]	Punto de Falla[km]	Localización de la Falla[km]	Error relativo[%]
100	90	49,2	52,72133	7,157187
90	60	16,4	19,04549	16,13107
90	0	82	80,21594	2,175684
90	0	32,8	34,19497	4,252938
80	90	57,4	56,91016	0,853389
80	90	41	37,96919	7,392221
80	30	49,2	48,79784	0,8174
80	30	82	81,36252	0,777406
70	90	41	37,75218	7,921514
70	90	16,4	15,69645	4,28996
70	60	16,4	17,21836	4,990021
70	30	82	81,22145	0,949449
70	30	57,4	55,18979	3,850546
70	0	57,4	57,57363	0,30249
60	90	24,6	28,60867	16,2954
60	60	41	39,6249	3,353899
60	60	65,6	57,32419	12,61557
60	60	57,4	55,49585	3,31733
60	60	24,6	22,54377	8,358671
60	30	82	80,91995	1,317139
			<b>Promedio error relativo</b>	5,355964

### e) Entrenamiento con el algoritmo Scaled Conjugate Gradient

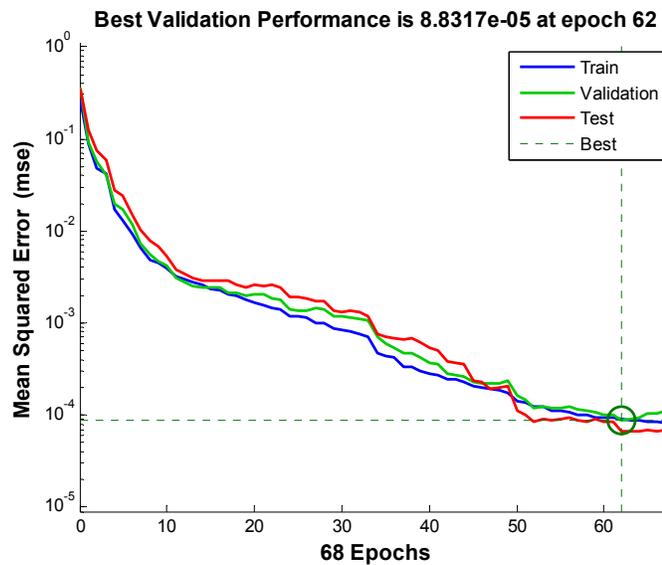
Los resultados obtenidos para este tipo de entrenamiento con el algoritmo Scaled Conjugate Gradient mediante el procesamiento de los datos realizados con la transformada discreta de wavelet son:

- El rendimiento de la red y el error cuadrado promedio de la red se muestra en la figura 51 y la gráfica 33 respectivamente, donde se puede observar que la relación entre los datos de salida y el valor esperado con este tipo de entrenamiento guardan relación:

**Figura 51. Progreso del entrenamiento mediante el algoritmo Scaled Conjugate Gradient y la Transforma Discreta de Wavelet**

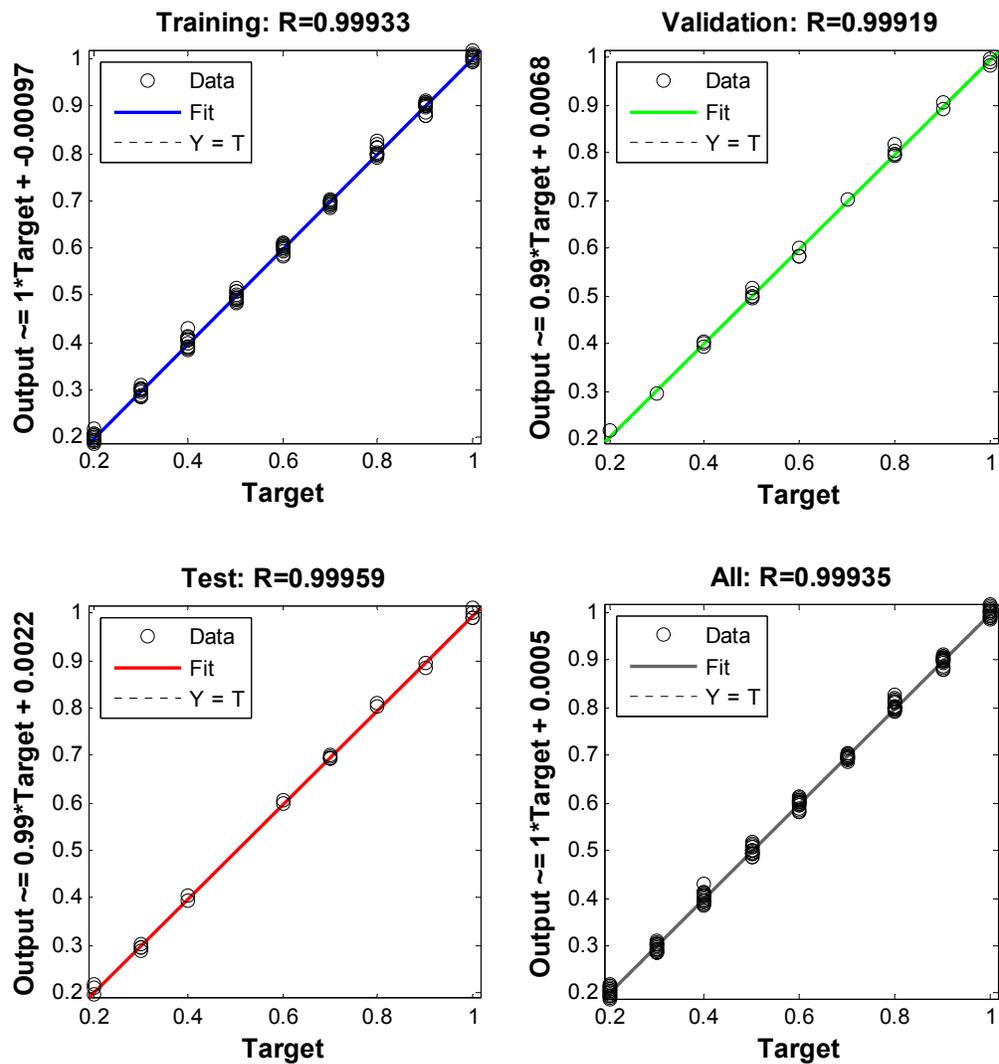


**Gráfica. 33. Error cuadrado promedio mediante el algoritmo Scaled Conjugate Gradient y la Transforma Discreta de Wavelet**



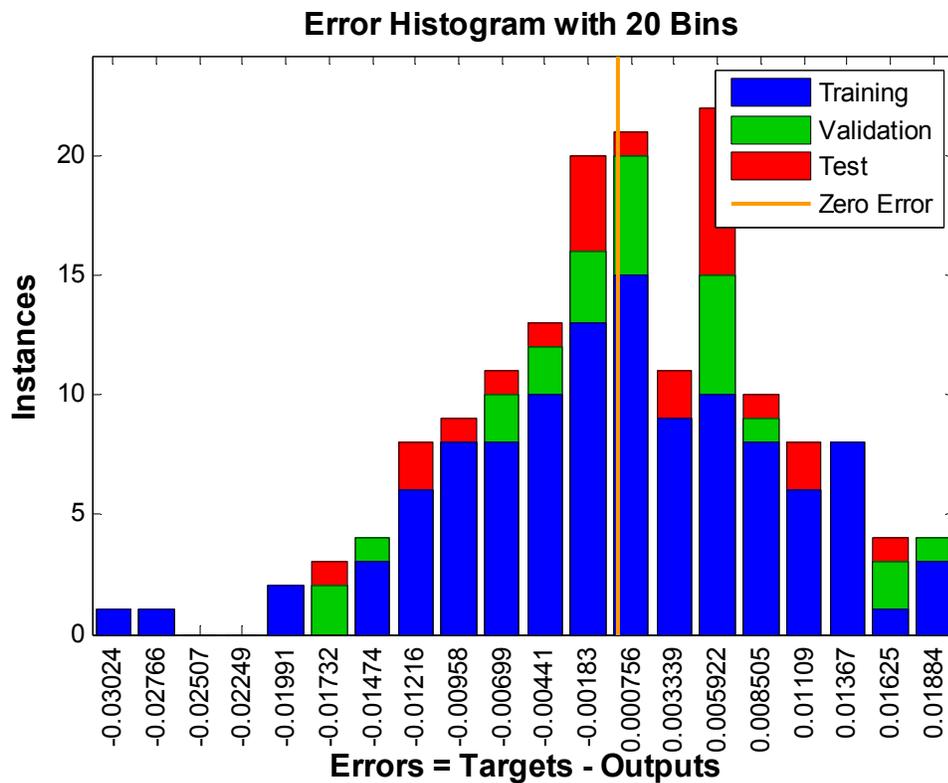
- En la gráfica 34 de regresión se observa que red entrenada con este clase de algoritmo presentó una valor R tanto para las etapas de entrenamiento, validación como pruebas en mayor al 0,9:

**Gráfica. 34. Regresión de la red neuronal mediante el algoritmo Scaled Conjugate Gradient y la Transforma Discreta de Wavelet**



- El histograma de error que se observa en la figura 52 , muestra la distribución de los errores en la red, del cual se observa que el error medido entre la diferencia del objetivo(valor esperado) y la salida que se presentó mayor frecuencia en el proceso de entrenamiento, validación y prueba fue el 0,005922:

**Figura 52. Histograma de errores en de la red neuronal mediante el algoritmo Scaled Conjugate Gradient y la Transforma Discreta de Wavelet**



- El error relativo promedio de la localización de fallas de alta impedancia para este método es de 2,60 % como se indica en la tabla 19 :

**Tabla 19. Resultados del localización de FAI por medio de la Red Neuronal mediante el algoritmo Scaled Conjugate Gradient y la Transforma Discreta de Wavelet**

$R_{falla}[\text{ohm}]$	Ángulo de inceptión[°]	Punto de Falla[km]	Localización de la Falla[km]	Error relativo[%]
100	90	49,2	50,40273	2,444561
90	60	16,4	15,60321	4,858441
90	0	82	81,75291	0,301334
90	0	32,8	34,15182	4,121391
80	90	57,4	56,87369	0,916912
80	90	41	40,04767	2,32277
80	30	49,2	48,82606	0,760031
80	30	82	81,62045	0,462858
70	90	41	39,89456	2,696199
70	90	16,4	16,22974	1,038168
70	60	16,4	16,58933	1,154455
70	30	82	81,35975	0,780785
70	30	57,4	56,95205	0,780407
70	0	57,4	57,11771	0,491806
60	90	24,6	25,48341	3,591087
60	60	41	41,70005	1,707449
60	60	65,6	55,55393	15,31414
60	60	57,4	58,04152	1,117634
60	60	24,6	26,09777	6,088497
60	30	82	81,07791	1,124498
<b>Promedio error relativo</b>				<b>2,603671</b>

## ANEXO B. Diseño e Implementación de la Red Neuronal mediante el procesamiento de las señales eléctricas a partir de Transformada Discreta de Fourier

En siguiente código fue realizado en la herramienta de simulación Matlab y tiene como objetivo el cálculo de los armónicos generados en las señales de corriente y tensión durante el momento de una falla de alta impedancia en el SEP seleccionado, y posteriormente el diseño e implementación de una Red Neuronal tipo Perceptrón Multicapa.

### Código:

```
%Procesamiento de las Señales de corriente y tensión

close all
clear all
N=334;%Número de muestras
k=0:N-1;
E=180;
Datos=zeros(29,E);
ini=340; % inicio y fin de un ciclo de la señal
fin=673;
for p=1:180,
    filename = sprintf('simulaciones/falla%03d.xlsx', p);
    x=xlsread(filename);
    i1=x(:,1);
    v1=x(:,2);
    i1f=i1(ini:fin);
    I1f=fft(i1f)/N;
    v1f=v1(ini:fin);
    V1f=fft(v1f)/N;
    Datos(1:13,p)=abs(I1f(2:2:26)); % armónicos de corrientes
    Datos(14:26,p)=abs(V1f(2:2:26)); % armónicos de voltajes
    Datos(27,p)=x(1,3); % impedancia
    Datos(28,p)=x(1,4); % ángulo
    Datos(29,p)=x(1,5); % localización
    % figure,plot(i1)
    % title('onda de corriente')
    % title('onda de corriente de falla')
    % figure,stem(k,abs(I1f))
    % figure,plot(v1f)
    % title('onda de voltaje de falla')
    % figure,stem(k(1:50),abs(I1f(1:50)))
    % title('armónicos de la corriente falla')
    % figure,stem(k(1:50),abs(V1f(1:50)))
    % title('armónicos del voltaje de falla')
end
```

```

% Diseño de la Red Neuronal Tipo Perceptrón Multicapa
p = randperm(E);
Datos = Datos(:,p);

datos_entrada = zeros(14,160);
datos_prueba = zeros(14,20);

datos_entrada(1:7,:) = Datos(1:7,1:160);
datos_entrada(8:14,:) = Datos(14:20,1:160);

datos_salida = Datos(29,1:160);

datos_prueba(1:7,:) = Datos(1:7,161:180);
datos_prueba(8:14,:) = Datos(14:20,161:180);
datos_sal_prueba = Datos(29,161:180);

%%%

net = feedforwardnet([11 10], 'trainbr');%Red Neuronal con 2 capas
ocultas
net = train(net,datos_entrada,datos_salida);
y1 = sim(net,datos_prueba);
error_absoluto = datos_sal_prueba - y1
error_relativo = abs(error_absoluto)./datos_sal_prueba*100

```

## ANEXO C. Diseño e Implementación de la Red Neuronal mediante el procesamiento de las señales eléctricas a partir de Transformada Discreta de Wavelet

En siguiente código fue realizado en la herramienta de simulación Matlab y tiene como objetivo el cálculo de los coeficientes de detalle y aproximación en las señales de corriente y tensión generadas durante una falla de alta impedancia en el SEP seleccionado. Posteriormente, estos valores serán las entradas a la Red Neuronal tipo Perceptrón Multicapa implementada en la presente investigación.

### Código:

```
% to de las señales de corriente y tensión mediante la Transformada
Discreta de Wavelet

close all
clear all
N=334;
k=0:N-1;
E=180;
Datos=zeros(29,E);
ini=340; % inicio y fin de un ciclo de la señal
fin=673;
for p=1:1,
    filename = sprintf('simulaciones/falla%03d.xlsx', p);
    x=xlsread(filename);
    il=x(:,1);
    vl=x(:,2);

    % Transformada Wavelet de la corriente
    ilf=il(ini:fin);
    [Lo_D,Hi_D,Lo_R,Hi_R] = wfilters('db5');
    [C,L]=wavedec(ilf,6,Lo_D,Hi_D);
    cA6 = appcoef(C,L,'db5',6);% Extrae el coeficiente de aproximación
del nivel 6 desde
    cD6 = detcoef(C,L,6); %Extrae coeficientes de detalle desde C
    cD5 = detcoef(C,L,5);
    cD4 = detcoef(C,L,4);
    cD3 = detcoef(C,L,3);
    cD2 = detcoef(C,L,2);
    cD1 = detcoef(C,L,1);
    Datos(1,p)=10*log10(eps+mean(cA6.^2));
    Datos(2,p)=10*log10(eps+mean(cD6.^2));
    Datos(3,p)=10*log10(eps+mean(cD5.^2));
    Datos(4,p)=10*log10(eps+mean(cD4.^2));
    Datos(5,p)=10*log10(eps+mean(cD3.^2));
    Datos(6,p)=10*log10(eps+mean(cD2.^2));
```

```

Datos(7,p)=10*log10(eps+mean(cD1.^2));

figure,
subplot(2,3,1),plot(cD1)
title('Coeficiente de detalle para onda de corriente cD1')
subplot(2,3,2),plot(cD2)
title('Coeficiente de detalle para onda de corriente cD2')
subplot(2,3,3),plot(cD3)
title('Coeficiente de detalle para onda de corriente cD3')
subplot(2,3,4),plot(cD4)
title('Coeficiente de detalle para onda de corriente cD4')
subplot(2,3,5),plot(cD5)
title('Coeficiente de detalle para onda de corriente cD5')
subplot(2,3,6),plot(cD6)
title('Coeficiente de detalle para onda de corriente cD6')
figure,plot(ca6)
title('Coeficiente de aproximación para onda de corriente ca6')

% Transformada wavelet del voltaje

vlf=v1(ini:fin);
[Lo_D,Hi_D,Lo_R,Hi_R] = wfilters('db5');
[C,L]=wavedec(vlf,6,Lo_D,Hi_D);
ca6 = appcoef(C,L,'db5',6);%To extract the level 6 approximation
coefficients from C
cD6 = detcoef(C,L,6); %To extract detail coefficients from C,
cD5 = detcoef(C,L,5);
cD4 = detcoef(C,L,4);
cD3 = detcoef(C,L,3);
cD2 = detcoef(C,L,2);
cD1 = detcoef(C,L,1);
Datos(8,p)=10*log10(eps+mean(ca6.^2));
Datos(9,p)=10*log10(eps+mean(cD6.^2));
Datos(10,p)=10*log10(eps+mean(cD5.^2));
Datos(11,p)=10*log10(eps+mean(cD4.^2));
Datos(12,p)=10*log10(eps+mean(cD3.^2));
Datos(13,p)=10*log10(eps+mean(cD2.^2));
Datos(14,p)=10*log10(eps+mean(cD1.^2));

Datos(15,p)=x(1,3); % impedancia
Datos(16,p)=x(1,4); % ángulo
Datos(17,p)=x(1,5); % localización
% figure,plot(il)
% title('onda de corriente')

figure,
subplot(2,3,1),plot(cD1)
title('Coeficiente de detalle para onda de voltaje cD1')
subplot(2,3,2),plot(cD2)
title('Coeficiente de detalle para onda de voltaje cD2')

```

```

subplot(2,3,3),plot(cD3)
title('Coeficiente de detalle para onda de voltaje cD3')
subplot(2,3,4),plot(cD4)
title('Coeficiente de detalle para onda de voltaje cD4')
subplot(2,3,5),plot(cD5)
title('Coeficiente de detalle para onda de voltaje cD5')
subplot(2,3,6),plot(cD6)
title('Coeficiente de detalle para onda de voltaje cD6')
figure,
plot(cA6)
title('Coeficiente de aproximación para onda de voltaje cA6')
end

```

```

% Diseño de la Red Neuronal Tipo Perceptrón Multicapa

```

```

datos_entrada = zeros(14,160);
datos_prueba = zeros(14,20);

datos_entrada(1:14,:) = Datos(1:14,1:160);
datos_salida = Datos(17,1:160);

datos_prueba(1:14,:) = Datos(1:14,161:180);
datos_sal_prueba = Datos(17,161:180);

net = feedforwardnet([11 10], 'trainbr');
net = train(net,datos_entrada,datos_salida);
y1 = sim(net,datos_prueba);
error_absoluto = datos_sal_prueba - y1

error_relativo = abs(error_absoluto)./datos_sal_prueba*100
mean(error_relativo)

```