MÉTODO PARA LA LOCALIZACIÓN DE FALLAS EN SISTEMAS DE DISTRIBUCIÓN DE ENERGÍA ELÉCTRICA BASADO EN REDES NEURONALES ARTIFICIALES A PARTIR DE MEDICIONES DE TENSIÓN Y CORRIENTE DE FALLA EN CABECERA DE LOS ALIMENTADORES

NICOLÁS ANDRÉS PLAZAS LUCENA

UNIVERSIDAD INDUSTRIAL DE SANTANDER FACULTAD DE INGENIERÍAS FÍSICOMECÁNICAS ESCUELA DE INGENIERÍA ELÉCTRICA, ELECTRÓNICA Y DE TELECOMUNICACIONES BUCARAMANGA

MÉTODO PARA LA LOCALIZACIÓN DE FALLAS EN SISTEMAS DE DISTRIBUCIÓN DE ENERGÍA ELÉCTRICA BASADO EN REDES NEURONALES ARTIFICIALES A PARTIR DE MEDICIONES DE TENSIÓN Y CORRIENTE DE FALLA EN CABECERA DE LOS ALIMENTADORES

NICOLÁS ANDRÉS PLAZAS LUCENA

Una tesis presentada en cumplimiento de los requisitos para el grado de Ingeniero Electricista.

Director:

Jairo Blanco Solano PhD en Ingeniería Eléctrica

UNIVERSIDAD INDUSTRIAL DE SANTANDER FACULTAD DE INGENIERÍAS FÍSICOMECÁNICAS ESCUELA DE INGENIERÍA ELÉCTRICA, ELECTRÓNICA Y DE TELECOMUNICACIONES BUCARAMANGA

Dedicatoria

A mi madre María Eugenia por todo el apoyo que me ha brindado. También gracias a todos mis familiares, amigos y el amor de mi vida por estar presentes y contribuir en mi proceso formativo y en todos los demás aspectos de la vida. Los amo.

Nicolas Andrés Plaza Lucena

Agradecimientos

A la Universidad Industrial de Santander por su papel en la sociedad, gracias a la universidad pública tuve la oportunidad de estudiar una carrera profesional de calidad. También gracias a todos los profesores, administrativos y estudiantes, por conformar y ser el pilar de la institución.

A mi director de proyecto, el doctor Jairo Blanco Solano, por guiarme en el desarrollo de este trabajo.

Al doctor Cesar Duarte Gualdrón, por su asesoría en temas fundamentales de este proyecto.

Tabla de contenido

Introducción	29
1. Planteamiento del problema	30
2. Objetivo general	33
2.1. Objetivos específicos	33
3. Fallas en sistemas de distribución	33
3.1. Ejemplo particular de un esquema de protección para un sistema de distribución radial	37
3.2. Respuesta del sistema de protección e incertidumbre asociada al punto de la falla	40
3.3. Posible respuesta del sistema de ejemplo ante algunas fallas	40
4. Métodos para la localización de fallas en sistemas de distribución	42
4.1. Panorama del tema de localización de fallas según algunos artículos de revisión	42
4.1.1. Interpretación del artículo: Review of fault location methods for distribution power syste	em
(Mirzaei et al., 2009)	43
4.1.2. Interpretación del artículo: A review on distribution grid fault location (Shafiullah & Abi	do,
2017)	45
4.1.3. Interpretación del artículo: A literatura Review on methodologies of fault location in the	;
distribution system with distributed generation(Kumar & Saxena, 2020)	48
4.1.4. Apreciación del tema de localización de fallas en sistemas de distribución a partir de lo	os
artículos de revisión analizados	51
4.2. Criterio de búsqueda de artículos para localización de fallas en sistemas de distribución	
basados en redes neuronales artificiales	52
4.2.1. Metodologías basadas en localización de puntos de falla	54
4.2.2. Metodología basada en localización de zonas de fallas (artículo guía seleccionado)	58
5. Fundamentos matemáticos de redes neuronales artificiales	63
5.1. Selección de entradas y salidas del modelo	66

5.2. Estructura y alimentación de la red neuronal artificial	67
5.2.1. Representación gráfica	67
5.2.2. Representación algebraica	68
5.2.3. Representación en forma de composición de funciones	70
5.3. Otros parámetros de la red neuronal artificial	71
5.4. Entrenamiento de red neuronal artificial	72
6. Implementación de la metodología de localización zonas de falla en el sistema IEEE 34	76
6.1. Modelado del sistema IEEE 34	76
6.2. Representaciones del sistema de prueba IEEE 34	76
6.3. Simulación de fallas en el sistema IEEE 34 barras	78
6.4. Construcción de patrones de entrenamiento de las redes neuronales artificiales	80
6.5. Criterio de división del sistema IEEE 34	81
6.5.1. Ejemplo de prueba de zonificación a partir del criterio de división por cada punto rama	al en
el sistema IEEE34	82
6.5.2. Inconveniente de la zonificación de prueba mediante el criterio de división a partir de	
cada punto ramal	83
6.5.3. Planteamiento para resolver el inconveniente de las clases desbalanceadas de la	
zonificación de propuesta en la Figura 23	84
6.5.4. Criterio de zonificación adoptado para el sistema IEEE34	86
6.6. Zonificación del sistema IEEE34 para falla tipo 1	87
6.7. Zonificación del sistema IEEE34 para la falla tipo 2	88
6.8. Zonificación del sistema IEEE para las fallas desde el tipo 3 al tipo 11	89
6.9. Resultado del modelo de red neuronal para fallas tipo 1 (AG)	90
6.10. Resultado del modelo de red neuronal para fallas tipo 2 (BG)	96
6.11. Resultado del modelo de red neuronal para fallas tipo 3 (CG)	100
6.12. Resultado del modelo de red neuronal para fallas tipo 4 (AB)	102

6.13. Resultado del modelo de red neuronal para fallas tipo 5 (BC)	104
6.14. Resultado del modelo de red neuronal para fallas tipo 6 (CA)	106
6.15. Resultado del modelo de red neuronal para fallas tipo 7 (ABG)	110
6.16. Resultado del modelo de red neuronal para fallas tipo 8 (BCG)	112
6.17. Resultado del modelo de red neuronal para fallas tipo 9 (CAG)	114
6.18. Resultado del modelo de red neuronal para fallas tipo 10 (ABC)	116
6.19. Resultado del modelo de red neuronal para fallas tipo 11 (ABCG)	121
7. Implementación de la metodología de localización zonas de falla en el sistema IEEE123	124
7.1. Modelado del sistema de prueba IEEE 123	125
7.2. Representaciones del sistema de prueba IEEE 123	125
7.3. Simulación de fallas en el sistema IEEE 123 barras	126
7.4. Construcción de patrones de entrenamiento de las redes neuronales artificiales	126
7.5. Criterio de división del sistema en partes	127
7.6. Resultado de modelo de red neuronal para fallas tipo 1 (AG)	131
7.7. Resultado de modelo de red neuronal para fallas tipo 2 (BG)	137
7.8. Resultado de modelo de red neuronal para fallas tipo 3 (CG)	142
7.9. Resultado de modelo de red neuronal para fallas tipo 4 (AB)	148
7.10. Resultado de modelo de red neuronal para fallas tipo 5 (BC)	154
7.11. Resultado de modelo de red neuronal para fallas tipo 6 (CA)	161
7.12. Resultado de modelo de red neuronal para fallas tipo 7 (ABG)	168
7.13. Resultado de modelo de red neuronal para fallas tipo 8 (BCG)	173
7.14. Resultado de modelo de red neuronal para fallas tipo 9 (CAG)	179
7.15. Resultado de modelo de red neuronal para fallas tipo 10 (ABC)	185
8. Conclusiones	190
9. Referencias bibliográficas	192
Apéndices	194

Apéndice A. Código de red neuronal artificial de ejemplo que modela superficie de un

paraboloide

Lista de Figuras

Figura 1 Modelo de circuito simplificado bajo condición de falla.	35
Figura 2 Sistema de ejemplo con algunos elementos de protección	40
Figura 3 Evolución de la zona afectada por mal coordinación de protecciones en	el sistema de
ejemplo	41
Figura 4 Estructura de los métodos de localización de fallas según artículo revisio	ón 1 45
Figura 5 Estructura de los métodos de localización de fallas según artículo revisió	in 2 47
Figura 6 Estructura de los métodos de localización de fallas según artículo revisió	in 3 50
Figura 7 Esquema resumen de las técnicas de localización de fallas en sistemas	de distribución
	51
Figura 8 Relación de algunos métodos de localización de fallas con el sistema d	de mediciones
	52
Figura 9 Metodología del artículo seleccionado que se basa en localización de	zonas de falla
	59
Figura 10 Sistema de prueba del artículo seleccionado que se basa en localizació	n de zonas de
falla	60
Figura 11 Metodología adoptada basada en artículo seleccionado de localización	n de zonas de
falla	63
Figura 12 superficie a modelar, $f(x, y) = 1 - x^2 - y^2$	64
Figura 13 Esquema de entrenamiento y operación de una red neuronal artificial	66
Figura 14 Representación gráfica de una red neuronal artificial	68
Figura 15 Función de activación sigmoidal, $f(x) = 1 / (1 + e - x)$	71
Figura 16 Función de coste en el proceso de entrenamiento de la red neuronal	artificial de la
Figura 14	74
Figura 17 Superficie modelada por la red neuronal artificial de la Figura ()	74

Figura 18 Error absoluto para cada punto (x,y) de la superficie modelada por la red neur	onal de
la Figura	74
Figura 19 Esquema de la red IEEE 34 barras	77
Figura 20 Tipo de conductores de la red IEEE 34 barras	77
Figura 21 Longitud de alimentadores de la red IEEE 34 barras a escala	78
Figura 22 Cálculo de componentes superpuestos	80
Figura 23 Ejemplo de prueba zonificación para fallas tipo 2 a partir de criterio de divis	ión por
cada punto ramal en el sistema IEEE34	82
Figura 24 Curvas de entrenamiento de la red neuronal artificial empleada para ejen	nplo de
zonificación de prueba de la Figura 23	84
Figura 25 Matriz de confusión para conjunto de prueba del ejemplo de zonificación de pru	ıeba de
la Figura 23	84
Figura 26 Curvas de entrenamiento de la red neuronal artificial empleada para e	emplo
zonificación prueba modificado de la Figura 23	85
Figura 27 Matriz de confusión para conjunto de prueba del ejemplo de zonificación mod	dificado
de la Figura 23	85
Figura 28 Zonificación del sistema IEEE34 para fallas tipo 1 (AG)	87
Figura 29 Curvas relacionadas al proceso de aprendizaje de red neuronal que clasific	a fallas
monofásicas (AG) en el sistema IEEE34	91
Figura 30 Matriz de confusión para el conjunto de prueba de la red neuronal que clasific	a fallas
monofásicas (AG) en el sistema IEEE 34	91
Figura 31 Puntos críticos en la clasificación de fallas para el modelo de anomalías AG del s	sistema
IEEE34	92
Figura 32 Curvas relacionadas al proceso de aprendizaje de red neuronal que clasific	a fallas
monofásicas (BG) en el sistema IEEE34	97

Figura 33 Matriz de confusión para el conjunto de prueba de la red neuronal que clasifica	a fallas
monofásicas (BG) en el sistema IEEE 34	97
Figura 34 Puntos críticos en la clasificación de fallas para el modelo de anomalías BG del s	istema
IEEE34	98
Figura 35 Curvas relacionadas al proceso de aprendizaje de red neuronal que clasifica	a fallas
monofásicas (CG) en el sistema IEEE34	101
Figura 36 Matriz de confusión para el conjunto de prueba de la red neuronal que clasifica	a fallas
monofásicas (CG) en el sistema IEEE 34	101
Figura 37 Curvas relacionadas al proceso de aprendizaje de red neuronal que clasifica	a fallas
bifásicas (AB) en el sistema IEEE34	103
Figura 38 Matriz de confusión para el conjunto de prueba de la red neuronal que clasifica	a fallas
bifásicas (AB) en el sistema IEEE 34	103
Figura 39 Curvas relacionadas al proceso de aprendizaje de red neuronal que clasifica	a fallas
bifásicas (BC) en el sistema IEEE34	105
Figura 40 Matriz de confusión para el conjunto de prueba de la red neuronal que clasifica	a fallas
bifásicas (BC) en el sistema IEEE 34	105
Figura 41 Curvas relacionadas al proceso de aprendizaje de red neuronal que clasifica	a fallas
bifásicas (CA) en el sistema IEEE34	107
Figura 42 Matriz de confusión para el conjunto de prueba de la red neuronal que clasifica	a fallas
bifásicas (CA) en el sistema IEEE 34	107
Figura 43 Puntos críticos en la clasificación de fallas para el modelo de anomalías AC del s	istema
IEEE34	108
Figura 44 Curvas relacionadas al proceso de aprendizaje de red neuronal que clasifica	a fallas
bifásicas a tierra (ABG) en el sistema IEEE34	111
Figura 45 Matriz de confusión para el conjunto de prueba de la red neuronal que clasifica	a fallas
bifásicas a tierra (ABG) en el sistema IEEE 34	111

Figura 46 Curvas relacionadas al proceso de aprendizaje de red neuronal que clasif	ica fallas
bifásicas a tierra (BCG) en el sistema IEEE34	113
Figura 47 Matriz de confusión para el conjunto de prueba de la red neuronal que clasif	ica fallas
bifásicas a tierra (BCG) en el sistema IEEE 34	113
Figura 48 Curvas relacionadas al proceso de aprendizaje de red neuronal que clasif	ica fallas
bifásicas a tierra (CAG) en el sistema IEEE34	115
Figura 49 Matriz de confusión para el conjunto de prueba de la red neuronal que clasif	ica fallas
bifásicas a tierra (CAG) en el sistema IEEE 34	115
Figura 50 Curvas relacionadas al proceso de aprendizaje de red neuronal que clasif	ica fallas
trifásicas (ABC) en el sistema IEEE34	117
Figura 51 Matriz de confusión para el conjunto de prueba de la red neuronal que clasif	ica fallas
trifásicas (ABC) en el sistema IEEE 34	117
Figura 52 Puntos críticos en la clasificación de fallas para el modelo de anomalías	ABC del
sistema IEEE34	118
Figura 53 Curvas relacionadas al proceso de aprendizaje de red neuronal que clasif	ica fallas
trifásicas a tierra (ABCG) en el sistema IEEE34	122
Figura 54 Matriz de confusión para el conjunto de prueba de la red neuronal que clasif	ica fallas
trifásicas a tierra (ABCG) en el sistema IEEE 34	122
Figura 55 Puntos críticos en la clasificación de fallas para el modelo de anomalías A	BCG del
sistema IEEE34	123
Figura 56 Esquema del sistema IEEE 123 con longitud de alimentadores a escala.	125
Figura 57 Ejemplo de zonificación con 10 áreas para fallas monofasicas (AG) en el siste	ma IEEE
123	128
Figura 58 Curvas del proceso de entrenamiento del ejemplo de zonificación con 10 ár	eas para
fallas monofasicas (AG) en el sistema IEEE 123	128

Figura 59 Matriz de confusión del conjuto de prueva del ejemplo de zonificación c	on 10 áreas
para fallas monofasicas (AG) en el sistema IEEE 123	129
Figura 60 Sistema de zonificación adoptado para el sistema IEEE123	129
Figura 61 Curvas relacionadas al proceso de aprendizaje de red neuronal que cla	asifica fallas
monofásicas (AG) en el sistema IEEE123	132
Figura 62 Matriz de confusión para el conjunto de prueba de la red neuronal que cl	asifica fallas
monofásicas (AG) en el sistema IEEE 123	132
Figura 63 Puntos críticos en la clasificación de fallas para el modelo de anomalías AG	del sistema
IEEE123	133
Figura 64 Curvas relacionadas al proceso de aprendizaje de red neuronal que cla	asifica fallas
monofásicas (BG) en el sistema IEEE123	138
Figura 65 Matriz de confusión para el conjunto de prueba de la red neuronal que cl	asifica fallas
monofásicas (BG) en el sistema IEEE 123	138
Figura 66 Puntos críticos en la clasificación de fallas para el modelo de anomalías BG	i del sistema
IEEE123	139
Figura 67 Curvas relacionadas al proceso de aprendizaje de red neuronal que cla	asifica fallas
monofásicas (CG) en el sistema IEEE123	143
Figura 68 Matriz de confusión para el conjunto de prueba de la red neuronal que cl	asifica fallas
monofásicas (CG) en el sistema IEEE 123	143
Figura 69 Puntos críticos en la clasificación de fallas para el modelo de anoma	lías CG del
sistema IEEE123	144
Figura 70 Curvas relacionadas al proceso de aprendizaje de red neuronal que cla	asifica fallas
bifásicas (AB) en el sistema IEEE123	149
Figura 71 Matriz de confusión para el conjunto de prueba de la red neuronal que cl	asifica fallas
bifásicas (AB) en el sistema IEEE 123	149

Figura 72 Puntos críticos en la clasificación de fallas para el modelo de anomalías A	B del sistema
IEEE123	150
Figura 73 Curvas relacionadas al proceso de aprendizaje de red neuronal que c	lasifica fallas
bifásicas (BC) en el sistema IEEE123	155
Figura 74 Matriz de confusión para el conjunto de prueba de la red neuronal que c	lasifica fallas
bifásicas (BC) en el sistema IEEE 123	155
Figura 75 Puntos críticos en la clasificación de fallas para el modelo de anomalías B	C del sistema
IEEE123	156
Figura 76 Curvas relacionadas al proceso de aprendizaje de red neuronal que o	lasifica fallas
bifásicas (CA) en el sistema IEEE123	162
Figura 77 Matriz de confusión para el conjunto de prueba de la red neuronal que o	lasifica fallas:
bifásicas (CA) en el sistema IEEE 123	162
Figura 78 Puntos críticos en la clasificación de fallas para el modelo de anomalías C	A del sistema
IEEE123	163
Figura 79 Curvas relacionadas al proceso de aprendizaje de red neuronal que o	lasifica fallas
bifásicas a tierra (ABG) en el sistema IEEE123	169
Figura 80 Matriz de confusión para el conjunto de prueba de la red neuronal que o	lasifica fallas:
bifásicas a tierra (ABG) en el sistema IEEE 123	169
Figura 81 Puntos críticos en la clasificación de fallas para el modelo de anoma	lías ABG del
sistema IEEE123	170
Figura 82 Curvas relacionadas al proceso de aprendizaje de red neuronal que o	lasifica fallas
bifásicas a tierra (BCG) en el sistema IEEE123	174
Figura 83 Matriz de confusión para el conjunto de prueba de la red neuronal que o	lasifica fallas
bifásicas a tierra (BCG) en el sistema IEEE 123	174
Figura 84 Puntos críticos en la clasificación de fallas para el modelo de anoma	lías BCG del
sistema IEEE123	175

Figura	a 85 Curvas relacionadas al proceso de aprendizaje de red neuronal que clasifica	fallas
	bifásicas a tierra (CAG) en el sistema IEEE123	180
Figura	a 86 Matriz de confusión para el conjunto de prueba de la red neuronal que clasifica	fallas
	bifásicas a tierra (CAG) en el sistema IEEE 123	180
Figura	a 87 Puntos críticos en la clasificación de fallas para el modelo de anomalías CA	G del
	sistema IEEE123	181
Figura	a 88 Curvas relacionadas al proceso de aprendizaje de red neuronal que clasifica	fallas
	trifásicas (ABC) en el sistema IEEE123	186
Figura	a 89 Matriz de confusión para el conjunto de prueba de la red neuronal que clasifica	fallas
	trifásicas (ABC) en el sistema IEEE 123	186
Figura	a 90 Puntos críticos en la clasificación de fallas para el modelo de anomalías AE	3C del
	sistema IEEE123	187

Lista de Tablas

Tabla 1	Tipos de fallas de aislamiento	37
Tabla 2	Distribución de frecuencia de fallas en relación con el número de fases implicadas	37
Tabla 3	Documentos de referencia para tener una idea sobre los métodos de localización	de
fa	allas en sistemas de distribución	43
Tabla 4	Registro de búsquedas de artículos de localización de fallas en redes de distribuci	ón
b	asados en redes neuronales artificiales	53
Tabla 5	Artículos que estiman el lugar de una falla como una distancia desde la subestación	ıа
tr	ravés de redes neuronales artificiales mediante las medidas registradas en	la
s	subestación	54
Tabla 6	Descripción de los artículos de la Tabla 2	55
Tabla 7	Alcance de los artículos de la Tabla 2	58
Tabla 8	Longitud total de los alimentadores de las zonas del sistema de la Figura 10	62
Tabla 9	Información de distribución de fallas en el sistema IEEE 34	78
Tabla 10) Cantidad de puntos para la simulación de falla el sistema IEEE 34	79
Tabla 11	l Valores de tensión y corriente registrados en la subestación para una anomalía AG	en
e	el nodo 808 con una impedancia de falla de 4 Ω	81
Tabla 12	2 Componentes superpuestos a partir de los valores de tensión y corriente registrac	los
е	en la subestación para una anomalía AG en el nodo 808 con una impedancia de falla	de
4	Ω	81
Tabla 13	3 Distribución de simulaciones para ejemplo de prueba de zonificación por cada pu	าto
ra	amal para fallas tipo 2 en el sistema IEEE34	83
Tabla 14	Distribución de simulaciones de falla para zonificación de anomalías tipo 1 en el sister	ma
IL	EEE34	87
Tabla 15	5 Distribución de simulaciones de falla para zonificación de anomalías tipo 2 en el siste	ma
IL	EEE34	88

Tabla 16 Distribución de simulaciones de falla para zonificación de anomalías desde	el tipo 3 al
tipo 11 en el sistema IEEE34	89
Tabla 17 Estructura de red neuronal artificial para clasificar fallas tipo 1 (AG)	90
Tabla 18 Fallas críticas de la zona 4 que fueron predichas en la zona 5 del m	odelo para
anomalías monofásicas AG en el sistema IEEE34	92
Tabla 19	93
Tabla 20 Fallas críticas de la zona 5 que fueron predichas en la zona 4 del m	odelo para
anomalías monofásicas AG en el sistema IEEE34	93
Tabla 21 Información de impedancias de fallas críticas de la zona 5 que fueron pred	lichas en la
zona 4 del modelo para anomalías monofásicas AG en el sistema IEEE34	94
Tabla 22 Fallas críticas de la zona 5 que fueron predichas en la zona 6 del m	odelo para
anomalías monofásicas AG en el sistema IEEE34	94
Tabla 23 Información de impedancias de fallas críticas de la zona 5 que fueron pred	lichas en la
zona 6 del modelo para anomalías monofásicas AG en el sistema IEEE34	95
Tabla 24 Fallas críticas de la zona 7 que fueron predichas en la zona 6 del m	odelo para
anomalías monofásicas AG en el sistema IEEE34	95
Tabla 25 Fallas críticas de la zona 7 que fueron predichas en la zona 5 del m	odelo para
anomalías monofásicas AG en el sistema IEEE34	95
Tabla 26 Estructura de red neuronal artificial para clasificar fallas tipo 2 (BG)	96
Tabla 27 Fallas críticas de la zona 8 que fueron clasificados en la zona 7 del modelo	para fallas
monofásicas BG en el sistema IEEE34	98
Tabla 28 Estructura de red neuronal artificial para clasificar fallas tipo 3 (CG)	100
Tabla 29 Estructura de red neuronal artificial para clasificar fallas tipo 4 (AB)	102
Tabla 30 Estructura de red neuronal artificial para clasificar fallas tipo 5 (BC)	104
Tabla 31 Estructura de red neuronal artificial para clasificar fallas tipo 6 (CA)	106

Tabla 32 Fallas críticas de la zona 6 que fueron predichas en la zona 7 del modelo para
anomalías bifásicas AC en el sistema IEEE34 108
Tabla 33 Información de impedancias de fallas críticas de la zona 6 que fueron predichas en la
zona 7 del modelo para anomalías bifásicas AC en el sistema IEEE34 109
Tabla 34 Estructura de red neuronal artificial para clasificar fallas tipo 7 (ABG)110
Tabla 35 Estructura de red neuronal artificial para clasificar fallas tipo 8 (BCG)112
Tabla 36 Estructura de red neuronal artificial para clasificar fallas tipo 9 (CAG)114
Tabla 37 Estructura de red neuronal artificial para clasificar fallas tipo 10 (ABC)116
Tabla 38 Fallas críticas de la zona 6 que fueron predichas en la zona 7 del modelo para
anomalías bifásicas AC en el sistema IEEE34 118
Tabla 39 Información de impedancias de fallas críticas de la zona 6 que fueron predichas en la
zona 7 del modelo para anomalías trifásicas ABC en el sistema IEEE34 119
Tabla 40 Fallas críticas de la zona 7 que fueron predichas en la zona 8 del modelo para
anomalías trifásicas ABC en el sistema IEEE34 119
Tabla 41 Fallas críticas de la zona 8 que fueron predichas en la zona 9 del modelo para
anomalías trifásicas ABC en el sistema IEEE34 119
Tabla 42 Fallas críticas de la zona 9 que fueron predichas en la zona 10 del modelo para
anomalías trifásicas ABC en el sistema IEEE34 120
Tabla 43 Información de impedancias de fallas críticas de la zona 9 que fueron predichas en la
zona 10 del modelo para anomalías trifásicas ABC en el sistema IEEE34 120
Tabla 44 Estructura de red neuronal artificial para clasificar fallas tipo 11 (ABCG)121
Tabla 45 Fallas críticas de la zona 9 que fueron predichas en la zona 10 del modelo para
anomalías trifásicas ABC en el sistema IEEE34 123
Tabla 46 Información de impedancias de las fallas críticas de la zona 9 que fueron predichas er
la zona 10 del modelo para anomalías trifásicas ABCG en el sistema IEEE34 124

Tabla 47 Cantidad de puntos para la simulación de falla el sistema IEEE 34126

Tabla 48 Valores de tensión y corriente registrados en la subestación para una anomalía BC en
el nodo 72 con una impedancia de falla de 0.25Ω 127
Tabla 49 Componentes superpuestos a partir de los valores de tensión y corriente registrados
en la subestación para una anomalía BC en el nodo 72 con una impedancia de falla de
0.25 Ω 127
Tabla 50 Distribución de simulaciones de falla para sistema IEEE123130
Tabla 51 Estructura de red neuronal artificial para clasificar fallas tipo 1 (AG) en el sistema
IEEE123 131
Tabla 52 Fallas críticas de la zona 1 que fueron predichas en la zona 2 del modelo para
anomalías monofásicas AG en el sistema IEEE123 133
Tabla 53 Información de impedancias de fallas críticas de la zona 1 que fueron predichas en la
zona 2 del modelo para anomalías monofásicas AG en el sistema IEEE123 134
Tabla 54 Fallas críticas de la zona 1 que fueron predichas en la zona 3 del modelo para
anomalías monofásicas AG en el sistema IEEE123 134
Tabla 55 Información de impedancias de fallas críticas de la zona 1 que fueron predichas en la
zona 3 del modelo para anomalías monofásicas AG en el sistema IEEE123 135
Tabla 56 Fallas críticas de la zona 2 que fueron predichas en la zona 1 del modelo para
anomalías monofásicas AG en el sistema IEEE123 135
Tabla 57 Fallas críticas de la zona 2 que fueron predichas en la zona 3 del modelo para
anomalías monofásicas AG en el sistema IEEE123 135
Tabla 58 Fallas críticas de la zona 3 que fueron predichas en la zona 1 del modelo para
anomalías monofásicas AG en el sistema IEEE123 136
Tabla 59 Estructura de red neuronal artificial para clasificar fallas tipo 2 (BG) en el sistema
IEEE123 137
Tabla 60 Fallas críticas de la zona1 que fueron predichas en la zona 2 del modelo para anomalías

monofásicas BG en el sistema IEEE123

Tabla 61 Información de impedancias de fallas críticas de la zona 1 que fueron predichas en l
zona 2 del modelo para anomalías monofásicas BG en el sistema IEEE123 14
Tabla 62 Fallas críticas de la zona 1 que fueron predichas en la zona 3 del modelo par
anomalías monofásicas BG en el sistema IEEE123 14
Tabla 63 Fallas críticas de la zona 2 que fueron predichas en la zona 1 del modelo par
anomalías monofásicas BG en el sistema IEEE123 14
Tabla 64 Fallas críticas de la zona 2 que fueron predichas en la zona 3 del modelo par
anomalías monofásicas BG en el sistema IEEE123 14
Tabla 65 Estructura de red neuronal artificial para clasificar fallas tipo 3 (CG) en el sistem
IEEE123 14
Tabla 66 Fallas críticas de la zona 1 que fueron predichas en la zona 2 del modelo par
anomalías monofásicas CG en el sistema IEEE123 14
Tabla 67 Rango de impedancias de fallas críticas de la zona 1 que fueron predichas en la zon
2 del modelo para anomalías monofásicas CG en el sistema IEEE123 14
Tabla 68 Fallas críticas de la zona 1 que fueron predichas en la zona 3 del modelo par
anomalías monofásicas CG en el sistema IEEE123 14
Tabla 69 Información de impedancias de fallas críticas de la zona 1 que fueron predichas en l
zona 3 del modelo para anomalías monofásicas CG en el sistema IEEE123 14
Tabla 70 Fallas críticas de la zona 2 que fueron predichas en la zona 1 del modelo par
anomalías monofásicas CG en el sistema IEEE123 14
Tabla 71 Fallas críticas de la zona 2 que fueron predichas en la zona 3 del modelo par
anomalías monofásicas CG en el sistema IEEE123 14
Tabla 72 Estructura de red neuronal artificial para clasificar fallas tipo 4 (AB) en el sistem
IEEE123 14
Tabla 73 Fallas críticas de la zona 1 que fueron predichas en la zona 2 del modelo par
anomalías bifásicas AB en el sistema IEEE123 15

Tabla 74 Información de impedancias de fallas críticas de la zona 1 que fueron predichas e	n la
zona 2 del modelo para anomalías bifásicas AB en el sistema IEEE123	151
Tabla 75 Fallas críticas de la zona 1 que fueron predichas en la zona 3 del modelo p	oara
anomalías bifásicas AB en el sistema IEEE123	151
Tabla 76 Información de impedancias de fallas críticas de la zona 1 que fueron predichas e	en la
zona 3 del modelo para anomalías bifásicas AB en el sistema IEEE123	152
Tabla 77 Fallas críticas de la zona 2 que fueron predichas en la zona 1 del modelo p	oara
anomalías bifásicas AB en el sistema IEEE123	152
Tabla 78 Información de impedancias de fallas críticas de la zona 2 que fueron predichas e	en la
zona 1 del modelo para anomalías bifásicas AB en el sistema IEEE123	152
Tabla 79 Fallas críticas de la zona 2 que fueron predichas en la zona 3 del modelo p	oara
anomalías bifásicas AB en el sistema IEEE123	153
Tabla 80 Información de impedancias de fallas críticas de la zona 2 que fueron predichas e	en la
zona 3 del modelo para anomalías bifásicas AB en el sistema IEEE123	153
Tabla 81 Estructura de red neuronal artificial para clasificar fallas tipo 5 (BC) en el siste	əma
IEEE123	154
Tabla 82 Fallas críticas de la zona 1 que fueron predichas en la zona 2 del modelo p	oara
anomalías bifásicas BC en el sistema IEEE123	156
Tabla 83 Información de impedancias de fallas críticas de la zona 1 que fueron predichas e	n la
zona 2 del modelo para anomalías bifásicas BC en el sistema IEEE123	157
Tabla 84 Fallas críticas de la zona 1 que fueron predichas en la zona 3 del modelo p	oara
anomalías bifásicas BC en el sistema IEEE123	158
Tabla 85 Información de impedancias de fallas críticas de la zona 1 que fueron predichas e	n la
zona 3 del modelo para anomalías bifásicas BC en el sistema IEEE123	158
Tabla 86 Fallas críticas de la zona 2 que fueron predichas en la zona 1 del modelo p	oara
anomalías bifásicas BC en el sistema IEEE123	158

Tabla 87 Información de impedancias de fallas críticas de la zona 2 que fueron predichas en	la
zona 1 del modelo para anomalías bifásicas BC en el sistema IEEE123 15	59
Tabla 88 Información de impedancias de fallas críticas de la zona 2 que fueron predichas en	la
zona 3 del modelo para anomalías bifásicas BC en el sistema IEEE123 16	30
Tabla 89 Estructura de red neuronal artificial para clasificar fallas tipo 4 (AB) en el sistem	าล
IEEE123 16	31
Tabla 90 Fallas críticas de la zona 1 que fueron predichas en la zona 2 del modelo pa	ra
anomalías bifásicas CA en el sistema IEEE123 16	33
Tabla 91 Información de impedancias de fallas críticas de la zona 1 que fueron predichas en	la
zona 2 del modelo para anomalías bifásicas CA en el sistema IEEE123 16	34
Tabla 92 Fallas críticas de la zona 1 que fueron predichas en la zona 3 del modelo par	ra
anomalías bifásicas CA en el sistema IEEE123 16	35
Tabla 93 Información de impedancias de fallas críticas de la zona 1 que fueron predichas en	la
zona 3 del modelo para anomalías bifásicas CA en el sistema IEEE123 16	35
Tabla 94 Fallas críticas de la zona 2 que fueron predichas en la zona 1 del modelo par	ra
anomalías bifásicas CA en el sistema IEEE123 16	35
Tabla 95 Información de impedancias de fallas críticas de la zona 2 que fueron predichas en	la
zona 1 del modelo para anomalías bifásicas CA en el sistema IEEE123 16	36
Tabla 96 Fallas críticas de la zona 2 que fueron predichas en la zona 3 del modelo par	ra
anomalías bifásicas CA en el sistema IEEE123 16	36
Tabla 97 Información de impedancias de fallas críticas de la zona 2 que fueron predichas en	la
zona 3 del modelo para anomalías bifásicas CA en el sistema IEEE123 16	37
Tabla 98 Estructura de red neuronal artificial para clasificar fallas tipo 7 (ABG) en el sistem	าล
IEEE123 16	38
Tabla 99 Fallas críticas de la zona 1 que fueron predichas en la zona 2 del modelo par	ra
anomalías bifásicas ABG en el sistema IEEE123 17	70

Tabla 100 Información de impedancias de fallas críticas de la zona 1 que fueron predichas en la
zona 2 del modelo para anomalías bifásicas ABG en el sistema IEEE123 171
Tabla 101 Fallas críticas de la zona 2 que fueron predichas en la zona 1 del modelo para
anomalías bifásicas ABG en el sistema IEEE123 171
Tabla 102 Información de impedancias de fallas críticas de la zona 2 que fueron predichas en la
zona 1 del modelo para anomalías bifásicas ABG en el sistema IEEE123 172
Tabla 103 Fallas críticas de la zona 3 que fueron predichas en la zona 2 del modelo para
anomalías bifásicas ABG en el sistema IEEE123 172
Tabla 104 Estructura de red neuronal artificial para clasificar fallas tipo 8 (BCG) en el sistema
IEEE123 173
Tabla 105 Fallas críticas de la zona 1 que fueron predichas en la zona 2 del modelo para
anomalías bifásicas BCG en el sistema IEEE123 175
Tabla 106 Información de impedancias de fallas críticas de la zona 1 que fueron predichas en la
zona 2 del modelo para anomalías bifásicas BCG en el sistema IEEE123 176
Tabla 107 Fallas críticas de la zona 2 que fueron predichas en la zona 1 del modelo para
anomalías bifásicas BCG en el sistema IEEE123 176
Tabla 108 Información de impedancias de fallas críticas de la zona 2 que fueron predichas en la
zona 1 del modelo para anomalías bifásicas BCG en el sistema IEEE123 177
Tabla 109 Fallas críticas de la zona 2 que fueron predichas en la zona 3 del modelo para
anomalías bifásicas BCG en el sistema IEEE123 177
Tabla 110 Fallas críticas de la zona 3 que fueron predichas en la zona 1 del modelo para
anomalías bifásicas BCG en el sistema IEEE123 177
Tabla 111 Fallas críticas de la zona 3 que fueron predichas en la zona 2 del modelo para
anomalías bifásicas BCG en el sistema IEEE123 178
Tabla 112 Estructura de red neuronal artificial para clasificar fallas tipo 9 (CAG) en el sistema
IEEE123 179

anomalías bifásicas ABC en el sistema IEEE123 189

Tabla	126 Información de impedancias de fallas críticas de la zona 2 que fueron predichas	en la
	zona 1 del modelo para anomalías bifásicas ABC en el sistema IEEE123	189
Tabla	127 Fallas críticas de la zona 2 que fueron predichas en la zona 3 del modelo	para
	anomalías bifásicas ABC en el sistema IEEE123	189
Tabla	128 Resultados de modelos de localización de zonas de falla en el sistema IEEE34	190

Tabla 129 Resultados de modelos de localización de zonas de falla en el sistema IEEE123 191

Lista de apéndices

Apéndice A. Código de red neuronal artificial de ejemplo que modela la superficie de un paraboloide

Resumen

Título: Método para la localización de fallas en sistemas de distribución de energía eléctrica basado en redes neuronales artificiales a partir de mediciones de tensión y corriente de falla en cabecera de los alimentadores*

Autor: Nicolás Andrés Plazas Lucena**

Palabras clave: sistemas de distribución de energía eléctrica, localización de fallas, redes neuronales artificiales.

Descripción:

Las fallas en sistemas eléctricos provocan cortes en el suministro de energía. Esto genera pérdidas económicas significativas en varios sectores de la sociedad, por lo que es de gran interés agilizar los procesos de restauración del servicio de energía eléctrica, en caso de fallas de carácter permanente. En el escenario practico existen varios planteamientos de localización de fallas que tiene un nivel de desempeño satisfactorio. Sin embargo, las mejores técnicas requieren de infraestructura de medición avanzada, lo cual es una limitante para muchas redes de distribución de energía eléctrica en el mercado colombiano, especialmente para las redes rurales. Por otro lado, con el avance de la computación, muchas técnicas basadas en el aprendizaje de máquinas han cobrado relevancia, y pueden ser alternativas con buen grado de desempeño, adaptadas a la infraestructura de medición existente. En el presente trabajo de grado se implementa una metodología de localización de zonas de falla en los sistemas de prueba IEEE 34 nodos e IEEE 123 nodos, a través de redes neuronales artificiales, considerando solo las medidas de tensión y corriente trifásica en la subestación.

^{*} Trabajo de grado

^{**} Facultad de Ingenierías Físico-Mecánicas. Escuela de Ingeniería Eléctrica, Electrónica y Telecomunicaciones . Director: Jairo Blanco Solano, Ph.D. en Ingeniería.

Abstract

Title: Fault location method in electric power distribution systems based on artificial neural networks from feeder head-end fault voltage and current measurements*

Author: Nicolás Andrés Plazas Lucena**

Keywords: Electrical power distribution systems, fault location, artificial neural networks.

Description:

Failures in electrical systems cause power outages. This generates significant economic losses in several sectors of society, so it is of great interest to streamline the process of restoring power service in the event of permanent failures. In the practical scenario there are several fault location approaches that have a satisfactory level of performance. However, the best techniques require advanced metering infrastructure, which is a limitation for many electric power distribution networks in the Colombian market, especially for rural networks. On the other hand, with the advance of computation, many techniques based on machine learning have gained relevance, and can be alternatives with a good degree of performance, adapted to the existing measurement infrastructure. In this undergraduate project, a fault zone location methodology is implemented in IEEE 34 nodes and IEEE 123 nodes test systems, through artificial neural networks, considering only three-phase voltage and current measurements in the substation.

* Undergraduate project

^{**} Faculty of Physics-Mechanics Engineering. School of Electrical, Electronics and Telecomunications Engineering. Advisor: Jairo Blanco Solano, Ph.D. In Engineering

Introducción

Las fallas de aislamiento en sistemas eléctricos conducen a cortes de energía y a pérdidas económicas significativas. Ante un problema de esta naturaleza es necesario apresurar la restauración del servicio de energía en las partes afectas. Las técnicas computacionales basadas en el aprendizaje de máquinas pueden ser de ayuda a los operadores de red en tal propósito. En este trabajo de grado se prende implementar una metodología de localización de zonas de fallas, a través de redes neuronales artificiales, en los sistemas de prueba IEEE 34 nodos e IEEE 123 nodos, bajo la restricción de emplear únicamente las medidas disponibles en la subestación.

Este trabajo se compone de cuatro bloques dispuestos en 8 capítulos. En el primer bloque, se trata el tema del fenómeno físico de las fallas de aislamiento (cap. 1), la posible respuesta de los sistemas de protecciones (cap. 2), y la incertidumbre asociada al punto donde se encuentra una falla en un sistema de distribución (cap. 3). En el segundo bloque, se analizan tres artículos de revisión en el tema de localización de fallas para tener un panorama del asunto (cap. 4). Luego, se define los criterios de búsqueda del artículo de localización de fallas en sistemas de distribución a implementar, se expone los aspectos generales de los documentos candidatos y de describe el artículo seleccionado. En el tercer bloque, se mencionan los fundamentos matemáticos de una red neuronal densamente conectada, a mediante un ejemplo sencillo (cap. 5). En el último bloque se implementa en el sistema IEEE 34 una metodología adoptada a partir del artículo guía seleccionado (cap. 6). Después, se implementa la metodología en el sistema IEEE 123 (cap. 7). Por último, se expone las conclusiones (cap. 7).

1. Planteamiento del problema

Una falla puede considerarse como una acción imprevista que altera las condiciones normales de operación y funcionamiento de un sistema. En la industria eléctrica, las fallas pueden ocurrir por causas diversas (Bompard et al., 2013). La mayoría tienen lugar en la etapa de distribución(Gonen, 2014) y ocurren principalmente por el envejecimiento de equipos e intervención de objetos externos sobre elementos energizados. Independiente de la causa, su efecto provoca pérdida de aislamiento y en ocasiones la ruptura de conductores.

Las fallas son de naturaleza aleatoria y su impacto es severo. Por tal motivo, las protecciones son automáticas y deben aislar la sección alterada de forma efectiva. En caso de fallas momentáneas el servicio de energía eléctrica se puede restablecer con mecanismos de reconexión (Zapata & EPM, 2011). Pero en anomalías de carácter permanente se genera un problema en la continuidad del suministro, ya que las interrupciones prolongadas disminuyen la productividad de usuarios industriales (Abdisa, 2018). Así mismo se afectan los usuarios residenciales y se perjudican los índices de calidad del servicio de los operadores de red y su respectivo reconocimiento de cargo por uso conforme a la resolución CREG 015 de 2018. Por todos estos inconvenientes es de gran interés que el proceso de restauración del servicio de energía eléctrica sea eficiente.

En caso de una falla permanente, algunos sistemas reconFiguran la red para disminuir el número de clientes afectados. Sin embargo, este problema de optimización se aborda después de identificar la zona de falla en relación con los dispositivos de conmutación. (Zidan et al., 2017). Así mismo, la restauración completa del servicio ocurre posterior a la identificación y reparación del punto de falla. Por tanto, para una solución parcial o total del problema es indispensable determinar el lugar de la anomalía.

Existen métodos localización de fallas para las redes de transmisión que no resultan adecuados para los sistemas de distribución, por la diferencia sustancial en los principios de operación y funcionamiento.

En principio las redes de distribución se extienden sobre superficies grandes y por lo general su infraestructura de monitoreo y control es limitada. En tal situación, uno de los métodos convencionales para localizar fallas se basa en el registro de llamadas de clientes afectados, con lo cual se pretende delimitar la zona de búsqueda que debe realizar el equipo de inspección y reparación. La estrategia es simple y fácil de adoptar, sin embargo, completar la tarea de búsqueda de dicha forma requiere mucho tiempo, además el éxito depende de la experiencia de cada operador, por tanto, es un método difícil de sistematizar y va en contra de los principios e intereses de la automatización.

En cambio, planteamientos basados en la medida de impedancia presentan un mejor rendimiento. En general, estos métodos se componen de técnicas iterativas que requieren de información de la carga, topología e impedancia de la red para estimar la distancia del punto de falla desde los dispositivos de medición. Pese a que estos enfoques son prácticos, su alcance se ve limitado porque manifiestan el problema de múltiple estimación de puntos de falla, debido a la estructura ramificada de las redes y al número limitado de puntos de medida.(Mirzaei et al., 2009)

Por otro lado, es posible usar infraestructura de medición avanzada, que registre la dinámica del sistema a través de medidas sincronizadas, para localizar fallas en sistemas de distribución. La técnica consiste en el análisis transitorio de las formas de onda. A partir de las señales se determina la diferencia de tiempo en la recepción de frentes de onda y con su velocidad de propagación se estima el lugar donde hubo un cambio en la topología del sistema. También, este método es complementado con el análisis de la respuesta del sistema ante la inyección deliberada de señales. Por lo regular, este conjunto de técnicas representa las mejores

estrategias para la localización de fallas, entre otras virtudes, sin embargo, su implementación se ve restringida por el costo de los equipos requeridos.(Bo et al., 1999)

Por último, otro tipo de estrategias emergentes, como las técnicas basadas en el aprendizaje de máquinas, se han aplicado en el tema de localización de fallas en sistemas de potencia. Entre las cuales se destaca las redes neuronales artificiales por su capacidad para encontrar una relación funcional entre conjuntos numéricos de diferente naturaleza, siempre y cuando sean expuestas a una gran cantidad de ejemplos adecuados. Una de las aplicaciones de este tipo de máquinas es la conFiguración de modelos predictivos de fenómenos complejos, pero lograr un producto efectivo no es tan fácil y en cada caso de estudio es necesario identificar y seleccionar las variables apropiadas. En el caso específico de localización de fallas en redes de distribución, es posible usar como conjunto de entrada a magnitudes relacionadas con la tensión y corriente medidas en algún punto, y como salida del modelo una zona o punto donde ocurrió el evento de falla.(Kumar & Saxena, 2020)

Por lo tanto, en este trabajo de grado se busca implementar y evaluar el desempeño de un método de localización de fallas a través de redes neuronales artificiales, mediante las medidas de tensión y corriente registradas en cabecera de los alimentadores de unas redes de distribución de energía eléctrica.

2. Objetivo general

Implementar y evaluar el desempeño de un método basado en redes neuronales artificiales, propuesto en la literatura reciente, para estimar la zona de falla en un sistema de distribución de energía eléctrica, a partir de mediciones de tensión y corriente de falla registradas en cabecera del alimentador

2.1. Objetivos específicos

- Obtener la información de magnitudes eléctricas que se presentan ante diferentes tipos de fallas tipo paralelo en los sistemas de prueba IEEE de 34 barras y 123 barras.
- Seleccionar una metodología reportada en la literatura para la localización de fallas basada en redes neuronales artificiales.
- Implementar el método seleccionado en los sistemas de prueba mediante de las herramientas disponibles en el lenguaje programación python.
- Evaluar el desempeño del método según métricas de rendimiento en la clasificación de zonas de falla.

3. Fallas en sistemas de distribución

El consumo de energía eléctrica aumenta de forma progresiva tanto por el crecimiento de la población como por el desarrollo industrial. Responder a esta necesidad implica mejoras, actualizaciones y expansiones del sistema de energía eléctrica. Como el ritmo de cambio de la infraestructura de la red depende principalmente de la demanda, se espera que las modificaciones más importantes se realicen en las conexiones que impliquen directamente al

usuario final, por lo que la etapa de distribución recibe la mayor parte de los cambios y acumule la infraestructura más extensa. Este hecho condiciona la aparición de fallas en el sistema de distribución, ya que las anomalías surgen de la interacción con el medio, y por su extensión es más probable que ocurran en su interior. Se estima que alrededor del 70% de las fallas en un sistema de potencia suceden en el sistema de distribución (Gonen, 2014).

Las causas de las fallas de aislamiento son variadas. Este fenómeno ocurre principalmente por sobretensiones originadas en descargas atmosféricas sobre la red, también suceden en procesos normales de conmutación del sistema si existe deterioro o contaminación en los aisladores. Además, las redes áreas usualmente se componen de conductores expuestos y objetos ajenos pueden ser un puente de cortocircuito entre elementos energizados o entre algunas fases y el potencial de tierra. Incluso, anomalías al interior de máquinas conectadas al sistema resultan en corrientes de cortocircuito, como al energizar un motor eléctrico con el rotor bloqueado. Las fallas de aislamiento son de carácter estocástico y difíciles de evitar, no obstante, la mayoría de esos eventos desaparecen poco después de originarse, y se estima que del 70% al 80% de los casos se trata de fallas temporales (Zapata, 2011).

Independientemente de la causa, las fallas de aislamiento afectan la operación del sistema. La mayoría de las veces se modifica la corriente de alimentación desde valores en el rango nominal hacia magnitudes muy elevadas y la duración aproximada del transitorio está en el rango 0,5 ciclos a 3 ciclos de operación.

Figura 1

Modelo de circuito simplificado bajo condición de falla.



Nota. Modelo adaptado de un ejemplo de falla del capítulo 2 del libro "Electric distribution systems" (Abdelhay & Malik, 2011)

El modelo de la Figura 1 corresponde con un sistema monofásico de linea cortar y una carga de impedancia constante conectada en un extremo. En el momento t_f aparece una falla de cortocircuito sólido en algún lugar intermedio de la línea. La respuesta de corriente asociada con la ecuación la malla izquierda $e = R_1 i + L_1 \frac{di}{dt}$ es

$$i(t) = \frac{v_{max}}{\sqrt{(R_1)^2 + (\omega L_1)^2}} \sin(\omega t + \alpha - \phi) + e^{-tR_1/L_1} \left[I_0 \sin(\omega t_f) - \frac{v_{max}}{\sqrt{(R_1)^2 + (\omega L_1)^2}} \sin(\alpha - \phi) \right]$$

Tal corriente es la superposición entre un estado estable y una forma exponencial decreciente. Dicha variable depende de la tensión de alimentación, el valor de corriente inicial, el tiempo de ejecución del evento en relación con la fase de alimentación y la impedancia equivalente de la red en el punto de la anomalía. Incluso, la impedancia de falla es un factor importante, pero en este caso no aparece en la expresión porque se ha simplificado a un valor de cero. Sin embargo, tener en cuenta a este término permite considerar sobre el comportamiento subamoritguado que

podría tener la corriente de falla vista desde la subestación, porque la variable estaría sujeta a una ecuación diferencial ordinaria de segundo orden.

El ejemplo anterior es un circuito sencillo con diferencias en relación con un caso práctico. En un escenario más detallado, la respuesta del sistema es compleja. En primer lugar, el transitorio del sistema se vuelve más complejo si existen efectos capacitivos importantes, la dinámica del sistema pasa de ser de carácter exponencial decreciente una forma oscilatoria por la transferencia de energía entre elementos inductivos y capacitivos. Incluso la oscilación registrada puede manifestar ruido a causa del arco eléctrico del cortocircuito. Así mismo, el nivel de complejidad del fenómeno aumenta si existen otras fuentes de alimentación, ya que además de incrementar la intensidad del cortocircuito, también intervienen en forma de respuesta del sistema, como en el caso particular de las máquinas síncronas y sus efectos subtransitorios. Otro factor muy importante, es la cantidad de fases implicadas en la falla, pues en un mismo punto de un diagrama unifilar de un sistema trifásico aterrizado, pueden aparecer once tipos de anomalías, ver Tabla 1. La frecuencia estimada de aparición se indica en la Tabla 2.

Como conclusión, la forma de respuesta de un sistema eléctrico ante una falla es compleja. Sin embargo, vale la pena resaltar que este fenómeno es consecuencia de caminos indebidos para el flujo de cargas, y dichas rutas implican menor impedancia de red vista desde las fuentes de energía, por tal motivo se presenta el aumento de corriente. También, en la mayoría de los casos es correcto asociar las fallas con disminución en la magnitud de tensión en las fases implicadas por efectos de regulación, así como aumento de tensión en las fases restantes, producto de los desbalances.
Tabla 1

Tipos de fallas de aislamiento

Identificación	Tipo de falla
1	Monofásica entre la fase A y tierra
2	Monofásica entre la fase B y tierra
3	Monofásica entre la fase C y tierra
4	Bifásica entre las fases A y B
5	Bifásica entre las fases B y C
6	Bifásica entre las fases C y A
7	Bifásica entre las fases A, B y tierra
8	Bifásica entre las fases B, C y tierra
9	Bifásica entre las fases C, A y tierra
10	Trifásica
11	Trifásica y tierra

Tabla 2

Distribución de frecuencia de fallas en relación con el número de fases implicadas

Tipo de falla	Ocurrencia
Monofásica	85%
Bifásica	8%
Bifásica a tierra	5%
Trifásica	2%

Nota. Fuente: Fundamentos de protecciones eléctricas, (Carrillo Caicedo, 2019)

3.1. Ejemplo particular de un esquema de protección para un sistema de distribución radial

El papel de los sistemas de potencias es gestionar y dirigirá la energía eléctrica en aplicaciones de trabajo útil o simplemente en la producción de calor. Todos los procesos

implicados son peligrosos, ya que perder el control en la manipulación de grandes cantidades de energía resulta en daño o destrucción. Por tal motivo, Es necesario la existencia de protocolos emergencia y mecanismo de corte de suministro.

Las fallas de aislamiento en los sistemas eléctricos son caminos anormales por los que la energía fluye de forma descontrolada. Un problema de esta naturaleza se resuelve con el sistema de protecciones, el cual se constituye de un conjunto de dispositivos que deben reconocer una anomalía y ejecutar las maniobras de apertura necesarias en la parte afectada. En esencia, cada elemento de protección consta de tres partes: un sensor que mide las condiciones del sistema, un elemento lógico que distingue una situación de falla y un dispositivo de corte que realiza el aislamiento, aunque no siempre se trate de componentes independientes con propiedades modulares, como en el caso de los fusibles.

Un evento de falla modifica varias características eléctricas del sistema, por ejemplo, la intensidad de corriente, la magnitud de tensión, el grado de desbalance, el flujo de potencia, entre otros. A partir de dichas magnitudes se implementan diferentes estrategias de protección como la protección diferencial, la protección de distancia, la protección direccional, por mencionar algunas. En los sistemas de distribución, el enfoque de protección más difundido se basa en el aumento de corriente, el cual puede ser implementado a partir dispositivos simples como fusibles que se derriten y abren el circuito a una cierta intensidad, hasta dispositivos más elaborados como los interruptores controlados por relevador. Incluso, existen elementos de complejidad intermedia como los seccionalizadores que dependen de dispositivos reconectadores.

La selección y coordinación de los elementos que protegen a un sistema de potencia depende de muchos factores técnicos y económicos, no obstante, cualquier conFiguración debe ser confiable y segura, lo que significa actuar cuando se requiere, así como evitar desconexiones innecesarias (Carrillo Caicedo, 2019). Además, la acción no debe ser peligrosa para usuarios ni

la infraestructura. Por otro lado, un criterio igual de importante al corte oportuno tiene que ver con la continuidad del suministro. Idealmente se espera que las protecciones operen y desconecten solo a los elementos bajo falla sin afectar a las cargas, lo que en principio es posible en redes mallas bajo protección diferencial, pero dichas construcciones son costosas. Por otro lado, en sistemas de topología radial es imposible sacar de servicio un punto en condición de falla sin afectar a cargas conectadas aguas debajo, a menos que intervenga otra fuente de energía o se reconfigure la red. Ante tal limitación no queda de otra más que limitar el área de desconexión mediante criterios de selectividad.

Algunos de los criterios para la selección y ubicación de dispositivos de protección son el nivel de importancia de los alimentadores; el tiempo de respuesta para el corte; la frecuencia de aparición de fallas; la longitud de los alimentadores y la densidad de carga, ente otros. Además, debido al hecho de que la mayor parte de las fallas son momentáneas, se requiere equipos con capacidad de reconexión automática.

La Figura 2 representa a un sistema de distribución radial primario con algunos de sus elementos de protección. En esta red existe una jerarquía en los alimentadores y se clasifican en: un alimentador principal, cuatro alimentadores laterales y once alimentadores sublaterales.

El alimentador principal se protege con un interruptor controlado por relevador y un reconectador divide la red en dos partes en caso de ser necesario. En los alimentadores laterales se usa un reconectador, dos fusibles y un seccionalizador. Por último, la mayor parte de los tramos sublaterales están protegidos con fusibles y solo uno es protegido con seccionalizador. En esta red el flujo de potencia es unidireccional desde la subestación hacia las cargas. La protección de respaldo se establece en capas, tal que, la protección de cada alimentador de orden inferior cuenta con apoyo de la protección de los alimentadores de orden mayor a los que se encuentre conectado.

Figura 2

Sistema de ejemplo con algunos elementos de protección



3.2. Respuesta del sistema de protección e incertidumbre asociada al punto de la falla

Cada tipo de alimentador del sistema de distribución de la Figura 2 cuenta con un elemento de protección principal y por lo menos otro de respaldo. Cuando una falla permanente es despejada por la protección principal, el área de búsqueda para reparar el daño queda restringida a la longitud del alimentador en cuestión. Sin embargo, existe la posibilidad de que algunas fallas sean despejadas por el dispositivo de respaldo, con lo que se aumentaría el área de búsqueda. Incluso, la incertidumbre del lugar de la falla crece cuando los elementos de protección no disponen de canales de comunicación para informar su accionar a los centros de control.

3.3. Posible respuesta del sistema de ejemplo ante algunas fallas

En la Figura 3 se muestran cuatro fallas permanentes independientes. Se escogieron algunos ejemplos que no implican la acción del interruptor principal. En los casos expuestos se asume una situación desfavorable de mala coordinación de protecciones y ausencia de canales de comunicación para fusibles y seccionalizadores.

Figura 3

Evolución de la zona afectada por mal coordinación de protecciones en el sistema de ejemplo



En la falla 1, se propone un caso donde los contactos del seccionalizador quedan fijos y no puede abrir el circuito. En tal caso, el reconectador R1 despeja la falla y aunque este último pueda informar acerca del evento, la cuadrilla de reparación debe recorrer el alimentador lateral de R1 y el alimentador sublateral de S1. Respecto a la falla 4 ocurre algo similar, la anomalía evoluciona hasta comprometer el alimentador principal y deja fuera de servicio a la mitad de la red.

En la falla 2, a causa del deterioro, el fusible f3 actúa antes que el elemento f4 pueda fundirse. En tal caso, el área de búsqueda y reparación de la anomalía se hace mayor, pero antes de iniciar el proceso búsqueda, es indispensable identificar cuál fue el fusible que abrió el circuito,

y dicha tarea puede ser muy complicada, tanto así, que dependiendo la red de distribución la incertidumbre del lugar de falla puede cubrir la totalidad del sistema. Por otro lado, es posible disminuir el área de incertidumbre mediante el nivel de cortocircuito o las secuencias de apertura y cierre registradas en las señales, originadas por reconectadores instalados antes del lugar del fusible a identificar. Respeto a la falla 3, ocurre algo similar a la falla 2.

4. Métodos para la localización de fallas en sistemas de distribución

En esta sección primero se realiza un análisis de algunos artículos de revisión en el asunto de localización de fallas en sistemas de distribución, para tener un panorama del tema. Luego se exponen los criterios de búsqueda artículos basados en redes neuronales artificiales para la localización de fallas, y se menciona los aspectos generales de los artículos más relevantes, luego se selecciona un documento guía para ser implementado.

4.1. Panorama del tema de localización de fallas según algunos artículos de revisión

Para tener una idea sobre los métodos de localización de fallas en sistemas de distribución, se realizó una búsqueda de artículos de revisión en la plataforma de Google académico con las siguientes palabras clave : *"fault location"+"distribution"+"review"*. De todo el conjunto de opciones, solo se seleccionó tres artículos que son enumerados en la Tabla 3.

Tabla 3

Documentos de referencia para tener una idea sobre los métodos de localización de fallas en sistemas de distribución

Número	Año de	Título del artículo		
	publicación			
1	2009	Review of fault location methods for distribution power system		
2	2017	A review on distribution grid fault location		
2	2020	A literatura Review on methodologies of fault location in the		
3		distribution system with distributed generation		

4.1.1. Interpretación del artículo: Review of fault location methods for distribution power system (Mirzaei et al., 2009)

En dicho documento resaltan que la continua exigencia de los parámetros de la calidad del servicio ha impulsado la mejora de los métodos de localización de fallas en sistemas eléctricos. En la etapa de transmisión el problema está casi resuelto. En cuanto a los sistemas de distribución, el escenario es diferente y aún existen muchos retos por resolver.

Los autores clasifican las estrategias de localización en métodos basados en impedancia; métodos basados en propagación de ondas y en métodos basados en el conocimiento, estos últimos agrupados en métodos basados en inteligencia artificial y análisis estadístico; métodos basados en dispositivos distribuidos y métodos híbridos.

Los investigadores mencionan que tradicionalmente la localización de averías dependía de las llamadas de usuarios afectados. Sin embargo, tal estrategia acarrea inconvenientes, especialmente por su dependencia de fuentes de información externa sujeta a incertidumbre respecto a la capacidad de los usuarios para comunicar sobre las averías.

Los métodos basados en impedancia estiman la distancia de falla desde el bus donde se mide tensión y corriente de frecuencia fundamental hasta el lugar de la anomalía, mediante un análisis matemático. Para su aplicación primero es necesario distinguir el tipo de falla y las fases implicadas, después realizan cálculos iterativos hasta que los valores cumplan un rango de similitud. Cada método de impedancia en particular se diferencia en el modelado de las cargas e interpretación del nivel detalles de las redes. En general, estas técnicas se enfrentan al problema de la múltiple estimación de puntos de falla.

Los métodos de propagación de ondas se fundamentan en la transmisión y reflexión de pulsos generados en una falla. De los cuales se distingue velocidad de desplazamiento a un cierto rango de frecuencias y la diversidad de caminos que puede tomar las ondas, para estimar el sitio de la falla. Esta tecnología presenta mejores resultados que los métodos de impedancia. No obstante, su implementación es más costosa porque requiere de equipos registradores de fallas transitorias, sistemas de posicionamiento global y *software* de diagnóstico. Así mismo, otra dificultad inherente es la ubicación óptima de dispositivos por la complejidad que pueden tener los sistemas de distribución.

Por último, las **metodologías basadas en el conocimiento** se agrupadas en tres conjuntos. El primero, las **técnicas de inteligencia artificial** como las redes neuronales, lógica difusa, sistemas expertos y algoritmos genéticos pueden ser de ayuda para los operadores de red en la tarea de localización al reducir los tiempos de búsqueda. Estas técnicas cobran fuerza a medida que se desarrolla la computación. Por otro lado, el segundo conjunto de estrategias son los **métodos basados en dispositivos distribuidos.** Estos se fundamentan en el censado de varios puntos de la red y el conocimiento estructural del sistema. Algunos esquemas de gestión de fallas comparan la información medida con una base de datos simulada y el histórico de fallas registrado. Por último, **los métodos híbridos** combinan algunas de las virtudes de las técnicas

de procesamiento de señales con modelos basados en inteligencia artificial, incluso incorporan dispositivos registradores de falla.

Figura 4

Estructura de los métodos de localización de fallas según artículo revisión 1



4.1.2. Interpretación del artículo: A review on distribution grid fault location (Shafiullah & Abido, 2017)

En dicho documento, los autores clasifican las técnicas de localización de fallas en métodos basados en impedancia, en propagación de ondas y basados en el conocimiento. Mencionan que las técnicas tradicionales deben afrontar varios retos técnicos debido a la incorporación de fuentes de generación distribuida. Incluso, los esquemas de protección convencionales son afectados por los cambios en la intensidad de cortocircuitos y en la dirección de flujos de energía.

Las **técnicas basadas en impedancia** emplean la medida de tensión corriente en uno o dos extremos de la red y mediante análisis matemáticos, calculan la ubicación de fallas. Por lo común, estos métodos tienen el inconveniente de estimación múltiple de posibles lugares de falla. Los

autores comentan que dichas técnicas cuentan con mayor investigación en el área, sin embargo, aúnn presenta dificultades por factores como el desbalance; la heterogeneidad tanto de fases, como tipos de conductores; la cantidad de ramificaciones; la impedancia de falla y dinámica de la carga, entre otros. Los investigadores indican que muchas propuestas de investigación reducen el problema al escoger redes muy sencillas con modelos simples o ignorando algunos factores, como el desbalance y la diversidad de tipos de conductores.

Por otro lado, las técnicas basadas en la propagación de ondas son menos vulnerables a los problemas que afectan a las técnicas de impedancia. En principio, estos métodos aprovechan los pulsos de onda generados en una falla, que son captados por equipos de medición y comunicación avanzada. Los cuales usan los tiempos relativos de llegada de ondas para estimar la ubicación de las fallas. Existen métodos tanto en línea como fuera de línea, estos últimos se fundamentan en la inyección deliberada de señales. En general esto métodos presentan mejores resultados que las técnicas basadas en impedancia, sin embargo, su implementación requiere de una gran inversión por el costo de los equipos. Además, el comportamiento de la propagación de ondas es muy complejo y en ocasiones puede llevar a decisiones equivocadas respecto a su origen. Inclusive, las técnicas tienden a ser muy sensibles al ruido.

Metodologías de **localización de fallas basadas en el conocimiento** son planteamientos alternativos generalmente menos costosos y con una serie de méritos que los hacen muy llamativos. Entre los cuales se resalta el uso de redes neuronales artificiales y máquinas de soporte vectorial por su capacidad de reconocimiento de patrones complejos y su aplicación en problemas de optimización y clasificación. Dichas herramientas tienden a ser robustas, lo que es una ventaja frente a las características intrínsecas de los sistemas de distribución. Incluso, diferentes propuestas de inteligencia artificial se pueden combinar con técnicas de procesamiento de señales para conFigurar enfoques híbridos que aprovechan las virtudes de cada uno. Por otra parte, algunas técnicas se fundamentan en la observación del sistema a través

de medición distribuida. Con lo cual, la toma de decisiones respecto a la localización de fallas se fundamenta en la comparación de magnitudes medidas contra los valores simulados que conforman una base de datos. En cuanto a las dificultades de los enfoques basados en el conocimiento, se resalta la dependencia a la calidad y cantidad de datos para su funcionamiento. También misionan que la capacitación de modelos basados en inteligencia artificial es "un dolor de cabeza" y cambios en las características de la red implicarían nuevos procesos de entrenamiento.

Para finalizar, los investigadores resaltan que, hasta ahora, el diagnóstico y localización de fallas en sistemas de distribución no existe como un producto terminado. Hay retos en cuanto a la definición completa de las reglas de funcionamiento de las "redes inteligentes" y la generación distribuida. Además, los modelos de simulación deben mejorar para aumentar la garantía de confiabilidad y precisión de los métodos.

Figura 5

Estructura de los métodos de localización de fallas según artículo revisión 2



4.1.3. Interpretación del artículo: A literatura Review on methodologies of fault location in the distribution system with distributed generation(Kumar & Saxena, 2020)

En dicha investigación se indica que las nuevas regulaciones requieren que las fuentes de generación distribuida permanezcan conectadas en caso de una falla para mejorar la confiabilidad del sistema. Sin embargo, las fuentes distribuidas alteran el funcionamiento de los sistemas de protección y surgen algunos problemas como la dificultad para identificar fallas; falsos disparos de interruptores o acción innecesaria de fusibles. Por lo que, los sistemas convencionales optan por desconectar todas las fuentes distribuidas, pero, tal decisión va en contravía de los principios de continuidad y confiabilidad de las nuevas regulaciones, si es que la proporción de la generación distribuida es significativa.

Los autores clasifican las formas de localización de fallas en técnicas de protección adaptativa, métodos basados en impedancia, métodos basados en propagación de ondas, métodos basados en dispositivos distribuidos, Técnicas inteligentes y métodos híbridos.

En cuanto a las **técnicas de protección adaptativas**, no trata explícitamente sobre maneras de localización. En vez de ello, se refiere a estrategias que mejoran al sistema de protección, o por lo menos, sirven para afrontar los problemas originados por la presencia de generación distribuida. Los investigadores mencionan algunos planteamientos como cálculo continuo de los parámetros del sistema protección según las condiciones de la red, Incluso mencionan algunas estrategias relacionadas con el cambio del tipo de dispositivos de protección. Quizá, el propósito de estos planteamientos, en cuanto a la localización de fallas, es reducir la incertidumbre asociada a la ubicación de anomalías cuando son erradas las secuencias de protección.

El método basado en impedancia, distinguida como técnica tradicional. Con este enfoque se calcula la impedancia de una sección de línea y se usa para estimar una distancia. Se basan en la medida de tensión y corriente de frecuencia fundamental y los parámetros del sistema, para

ubicar anomalías. Los métodos pueden ser de uno o varios puntos de medición y no requiere canales de comunicación, pero si se aplican, la presión puede mejorar. Los investigadores resaltan algunos problemas, por ejemplo, con el uso exclusivo de la frecuencia industrial se ignora información valiosa contenida en distorsión y en los procesos transitorios. También se sugiere que estos métodos son sensibles a la impedancia de falla y la carga del sistema, que cambios en dichas variables inducen errores grandes en la estimación de distancia. Por último, en sistemas ramificados se presenta el problema de la estimación múltiple.

Los métodos basados en impedancia resultan en estimaciones inexactas ante variaciones en la carga y en el funcionamiento de la generación distribuida. Incluso su precisión es afectada por el tipo de falla, ángulo de inicio del evento o la impedancia de falla. Por otro lado, **las técnicas basadas en la propagación de ondas** son casi independientes de las variaciones del sistema. Más bien, su alcance está condicionado por la capacidad de los equipos de medida y sistemas de comunicaciones. La técnica en cuestión se fundamenta en la propagación de ondas electromagnéticas que se originan durante la falla. Los pulsos se desplazan hacia las terminales del sistema. Considerando su polaridad y los tiempos de recepción, es posible determinar la ubicación de la falla si se conoce la velocidad de desplazamiento de los frentes de onda. Para lograr su propósito, requiere medidas sincronizadas muy precisas en varios puntos de la red. Los autores mencionan que es un reto la conFiguración y ubicación óptima de los dispositivos detectores.

Métodos basados en dispositivos distribuidos consta de aumentar el grado de observación del estado del sistema a través de la ubicación óptima de unidades de medición fasorial, dispositivos electrónicos inteligentes o relevadores. Requieren infraestructura de comunicación avanzada. Entre sus aplicaciones, permite acelerar el proceso de localización de fallas mediante esquemas de protección de área amplia.

Las técnicas inteligentes se basan en herramientas de inteligencia artificial aplicadas en la detección y localización de fallas. Se resalta el uso de redes neuronales artificiales, sistemas difusos y modelos estadísticos, o técnicas de transformación de señales como la transformada *Wavelet*. En ellas existen algunas dificultades y limitaciones. Por ejemplo, las redes neuronales artificiales dependen en gran medida de la cantidad y calidad de datos para su entrenamiento. Así mismo, las máquinas de soporte vectorial tienen un desempeño menor cuando crece la dimensión del conjunto de entrada, por la dificultad de encontrar una solución óptima para grandes conjuntos de datos. Por último, en el caso de las técnicas de procesamiento de señales, específicamente la transformada *wavelet*, es difícil determinar la onda madre.

El enfoque de los **métodos Híbridos** pretende reunir los puntos fuertes de algunas técnicas inteligentes. Por ejemplo, combinar herramientas de procesamiento de señales con esquemas de inteligencia artificial. Los autores enfatizan que estos planteamientos deben basarse en modelados o simulaciones confiables, para generar datos sean representativos del problema.

Figura 6

Estructura de los métodos de localización de fallas según artículo revisión 3



4.1.4. Apreciación del tema de localización de fallas en sistemas de distribución a partir de los artículos de revisión analizados

Después de analizar los artículos de revisión sobre el tema de localización de fallas en sistemas de distribución, se plasma en la Figura 7 la idea concebida respeto a la organización de las técnicas empleadas. Respecto a los requisitos de medición de algunas metodologías, en la Figura 8 se muestra cuáles puede ser adaptar a la infraestructura existente y que otras requieren de dispositivos de medición adicionales.

Figura 7

Esquema resumen de las técnicas de localización de fallas en sistemas de distribución



Figura 8

Relación de algunos métodos de localización de fallas con el sistema de mediciones



4.2. Criterio de búsqueda de artículos para localización de fallas en sistemas de distribución basados en redes neuronales artificiales

En el caso específico de localización de fallas en sistemas eléctricos, los datos para la capacitación de redes neuronales están relacionados con las medidas eléctricas del sistema durante las fallas. Una de las ideas fundamentales respeto a dichos modelos es requieren de una gran cantidad de datos para su entrenamiento. Sin embargo, es poco probable que para cada red de distribución exista un conjunto de información de eventos de fallas registrado que sea significativo. Es decir, una base de datos de eventos que represente anomalías a través de todo el sistema con diferentes impedancias de falla. Por lo tanto, es necesario construir dicho conjunto de información mediante simulaciones.

Debido a que la cantidad de eventos de falla debe ser lo suficientemente grande para el entrenamiento de las redes neuronales artificiales. Además de la restricción de medición solo en la subestación, se opta por la búsqueda de artículos de localización de fallas en redes de distribución que se fundamenten en el valor estable de la falla. Porque así las simulaciones

pueden ser en el dominio de la frecuencia, con lo cual disminuye la carga computacional y los tiempos de simulación para un número determinado de eventos de falla.

En la Tabla 4 se muestra un registro de búsquedas en varias fuentes de información con sus respectivas palabras clave. Se encontraron 684 artículos en búsquedas avanzadas. Después de dos procesos de filtrado bajo la restricción de seleccionar artículos basados solamente en las medidas registradas en la subestación, se escogió 8 artículos para su estudio. De los cuales , 7 tiene que ver con la localización de fallas como una medida de distancia desde la subestación. Por otro lado, el artículo restante, asume la tarea de localización como la selección de la zona del sistema que se encuentra bajo falla.

Tabla 4

Registro de búsquedas de artículos de localización de fallas en redes de distribución basados en redes neuronales artificiales

Base de datos	Pablas clave en la búsqueda avanzada	Archivos en total	Primer filtro	Segundo filtro	Selección final
Web of sicence	"fault location"+ "distribution system"+ "artificial neural network"	25	11	-	-
Scopus	"fault location"+ "power distribution system"+ "artificial neural network"	26	12	6	-
Science Direct		62	14	8	-
IEEE		138	44	3	3
Taylor and Francis		12	3	2	2
Springer		20	5	2	-
Scielo		0	0	0	0
Redalyc		0	0	0	0
Dialnet		2	2	0	0

Google académico	"fault location"+ "distribution system"+ "artificial neural network"- "transmission"-"DC"	380	-	-	2
Bases datos biblioteca UIS	"fault location"+ "distribution system"+ "artificial neural network" -"Smart"-"DC"	19	1	1	1
Total		684	92	22	8

4.2.1. Metodologías basadas en localización de puntos de falla

Tabla 5

Artículos que estiman el lugar de una falla como una distancia desde la subestación a través de

redes neuronales artificiales mediante las medidas registradas en la subestación

	Año de	_//.	Tensión del
ID	publicación	l itulo del artículo	sistema [kV]
1	2020	Fault location in radial distribution network based on fault current profile and the artificial neural network	24.9
2	2017	Artificial neural network based fault location for power distribution lines using frequency spectra of fault data	34.5
3	2012	An alternative approach to fault location on power distribution feeders with ebedded remote-end power generation using artificial neural networks	34.5
4	2009	Estimation of fault location an fault resistence for single line-to-ground faults in multi-ring distribution network using artificial neural network	13.8
5	2008	Fault classification and fault location using ANN for medium voltage cables: desing an implementation	33
6	2005	Artificial neural network and support vector machine approoach for locating faults in radial distribution system	11

7

Fault location in multiring distribution network using artificial neural network

13.8

Tabla 6

Descripción de los artículos de la Tabla 2

2003

ID Descripción general del trabajo neuronales artificiales	ID	Descripción general del trabajo	Entradas de los modelos de redes neuronales artificiales
--	----	---------------------------------	---

Esta la investigación cuenta con una etapa de detección de falla y discriminación del ramal afectado después de estimar la distancia del lugar de la anomalía. La localización de fallas se sustenta en 10 modelos de redes neuronales artificiales, una para cada tipo de anomalía asimétrica y otro para las fallas simétricas. Las entradas de las redes neuronales se construyen a

partir de los fasores de tensión y corriente, no especifican si el valor eficaz de las señales contiene el transitorio de las fallas, tampoco informan cuántos ciclos emplearon. Respecto a la evaluación de los modelos, consideran el impacto de la impedancia de falla, inclusive observan la respuesta de localización ante cambios en la carga, contemplan tres estados, mitad de carga nominal, carga completa y sobrecarga del 50%.

El trabajo se desarrolla en un sistema de prueba que no tiene ramificaciones. Para la localización de fallas proponen 11 redes neuronales artificiales, una para cada tipo de falla. El conjunto de descriptores que capacita a los modelos se construye a partir de las señales tensión y corriente. Las formas de ondas

2 corresponden con dos ciclos en condición de falla. En la evaluación de los modelos consideran el efecto de la impedancia de falla y de una fuente de generación en un extremo. También, consideran el efecto del ángulo de inicio del evento en la localización de la falla, puesto que tienen en cuenta el transitorio.

3 Este es un trabajo previo a la investigación 2 de esta Tabla. En este mantiene varias similitudes

Cada modelo de red neuronal recibe las magnitudes de corriente, impedancia y ángulo de las fases implicadas en la falla.

- I magnitud de corriente de la fase implicada
- Z, magnitud impedancia aparente durante el cortocircuito
- θ , ángulo de corriente de falla de la fase con falla

Tanto para las tres señales de tensión, como para las de corriente. Se construyen las siguientes entradas por fase. Para un total de 36 descriptores.

- Magnitud del componente DC
- Magnitud del componente 25 Hz
- Magnitud del componente de
- frecuencia fundamental (50HZ)
- Valor eficaz de las señales en el rango de 75-200 Hz
- Valor eficaz de las señales en el rango de 225-500 Hz
- Valor eficaz de las señales en el rango de 525-110 Hz

De cada fasor de tensión y corriente trifásica de frecuencia

como la ventana de medición para el análisis de las señales o los 11 modelos de redes neuronales para la localización. Existe un cambio sustancial en el sistema de prueba y en los valores de entradas de las redes neuronales

El artículo se enfoca únicamente en anomalías monofásicas (AN). La metodología se desarrolla en sistema de tres alimentadores unidos en conFiguración anillada. Emplean una red neuronal artificial para estimar la distancia al punto de falla a través del alimentador, desde la subestación. También usan la red neuronal para estimar la impedancia de falla, por lo que el modelo tiene cuatro salidas en total. El sistema

de prueba trata de una industria de petróleo, la mayoría de las cargas son motores de bombas extractoras. En las simulaciones, las cargas operan a máxima capacidad y no se especifica algún comportamiento dinámico. Las entradas de la red neuronal se construyen con los valores previo a la falla, valores estado estable de la falla y las magnitudes después del despeje.

fundamental construyen dos entradas, no especifican si los valores ingresan en forma polar o rectangular

• V_a , V_b , V_c , magnitud de tensión

• δ_a , δ_b , δ_c , ángulo de tensión

• X/R, cociente reactancia y resistencia equivalente durante la falla

- $Isc\,A_k$, magnitud de corriente de falla de la fase "A" durante el cortocircuito

• θ sc A_k , magnitud de corriente de falla de la fase "A" durante el cortocircuito

- $\Delta \operatorname{Pic}_k$, pérdida de potencia activa entre el valor previo y posterior a la falla
- ΔQic_k , pérdida de potencia reactiva entre el valor previo y posterior a la falla
- CB_k , Entrada binaria sobre el estado de los interruptores
- *W_f* indica si alguna bomba extractora de petróleo está en condición de falla
- T_f indica si algún transformador que alimenta a alguna bomba extractora de petróleo está en condición de falla

El sistema de prueba es sencillo y se compone de una fuente, 80km de línea de alimentación y una sola carga conectada en el extremo. Estiman la distancia al punto de falla mediante 4 modelos de red neuronal artificial, uno para cada conjunto de tipo de falla. Es decir, una arquitectura para los tres tipos de fallas monofásicas, otro para las

5 bifásicas, uno más para las anomalías bifásicas con tierra y, por último, uno para eventos que impliquen a las tres fases. Las entradas de las redes neuronales son diferentes para cada tipo, y se construyen con los valores de tensión de fase , corriente de fase y neutro de frecuencia fundamental. Las fallas monofásicas reciben tres entradas: tensión y corriente de fase, y magnitud de corriente por el neutro. Los eventos bifásicos reciben cuatro entradas: dos de tensión y, de corriente, de las fases afectadas. Las anomalías bifásicas a tierra reciben cinco entradas: dos de tensión y, de corriente, más la corriente del neutro.

Las fallas trifásicas reciben seis entradas: tres de tensión y tres de corriente. El sistema de prueba de esta investigación consta de 3 alimentadores radiales y 52 nodos. Los autores emplean máquinas de soporte vectorial y redes neuronales artificiales para estimar la reactancia al punto de falla y luego convierten dicha magnitud en un valor de distancia equivalente. La metodología consta de dos enfoques y ambos inician con la clasificación del tipo en anomalías monofásica, bifásica , bifásica a tierra o trifásica. El primer enfoque emplea 4 redes neuronales artificiales dependiendo de la

6 clasificación anterior y las salidas de estos modelos corresponde con la magnitud de reactancia. Por otro lado, en el segundo enfoque después de identificar el tipo de falla, realizan una clasificación adicional para estimar el rango del nivel de potencia del cortocircuito entre 7 opciones, y cada una tiene su conjunto de redes neuronales especializadas para cada tipo de falla. Las tareas de clasificación de tipo de falla y nivel de cortocircuito se realizan mediante máquinas de soporte vectorial.

Es un trabajo anterior de la investigación 4 de esta Tabla y emplean el mismo sistema de pruebas en conFiguración anillada con tres alimentadores. En este caso, se enfocan solo en

7 la localización de anomalías trifásicas de impedancia cero. Solo emplean una red neuronal artificial y sus salidas son tres valores que corresponden con la distancia al punto de falla a través de cada alimentador desde la subestación A partir de las 6 señales de tensión y corriente en estado estable de falla, se construyen 3 magnitudes de entrada mediante la técnica de análisis de componentes principales.

La red neuronal artificial recibe 17 entradas. k, subíndice para los alimentadores 1,2 y 3

- V tensión del barraje
- ∆Pik , pérdida de potencia activa entre el valor previo y durante la falla
- ∆Qik , pérdida de potencia reactiva entre el valor previo y durante la falla
- ΔPck , pérdida de potencia activa entre el valor previo y posterior a la falla
- ΔQck, pérdida de potencia reactiva entre el valor previo y posterior a la falla
- ΔCBk , entrada binaria sobre el estado de los interruptores
- *W_f* indica si alguna bomba extractora de petróleo está en condición de falla

Tabla 7

ID	Extensión máxima de los alimentadores [km]	Error máximo aproximado en localización de falla [m]	Relación entre error máximo y longitud del sistema	Impedancia de falla máxima [Ω]	Escenarios de falla simulados
1	57.7	800	1.4%	50	1500
2	14.8	500	3.4%	100	750
3	40	1200	3.0%	100	225
4	10	1600	16.0%	40	620
5	80	300	0.4%	10	-
6	56	300	0.5%	100	34272
7	10	2500	25.0%	0	146

Alcance de los artículos de la Tabla 2

Debido a que el enfoque de localización a través de una medida de distancia presenta el problema de múltiple estimación de puntos de falla, se opta por experimentar el enfoque alternativo de localización de zonas de falla.

4.2.2. Metodología basada en localización de zonas de fallas (artículo guía seleccionado)

Después del proceso de búsqueda solo se encontró un artículo de localización de zonas de falla que cumple con la condición de emplear solo las mediciones de tensión y corriente trifásica registradas en la subestación. El artículo en cuestión se titula "*Fault Location in Radial Distribution Networks Using ANN and Superimposed Components*" (Barra et al., 2019) y se ha seleccionado

como la metodología base a implementar en los sistemas IEEE 34 y el sistema IEEE 123. El documento es una conferencia publicada en el año 2019. Dicha publicación propone dividir el sistema de estudio en zonas, luego simular eventos de falla y estimar el sector de la anomalía a través de redes neuronales artificiales. El propósito es identificar la zona de afectada. Su metodología general se muestra en la Figura 9, y consta de dos partes. La primera se relaciona con el proceso de capacitación de las redes neuronales artificiales. Por otro lado, la segunda etapa tiene que ver con la integración de dichos modelos en el sistema de gestión de fallas.

Figura 9

Metodología del artículo seleccionado que se basa en localización de zonas de falla



Los investigadores desarrollan su trabajo en la red de distribución de la Figura 10, que consiste en dos alimentadores radiales trifásicos que operan a 20 kV. El sistema es modelado en el *software* PSCAD [™] / EMTDC [™]. La red está dividida en cuatro zonas, tres de las cuales están relacionadas con el alimentador de interés y la otra corresponde con un alimentador secundario. En cuanto a la simulación, se enfocan solo en anomalías monofásicas (AN) con valores de

impedancia de falla entre 0 Ω y 50 Ω , que son efectuadas cada 100 metros por todo el sistema. En total evalúan 2442 eventos de falla y en cada uno almacenan las señales de tensión y corriente trifásicas. La medición se realiza en la subestación a una taza de 256 muestras por ciclo. Las señales se procesan según técnica de componentes superpuestos, que consiste en restar las formas onda antes y después de la falla, luego se calcula el valor eficaz de la señal resultante. En el caso de estudio, emplean un ciclo completo de las señales antes de la falla y un periodo completo del estado estable de la falla, omiten las señales de los dos primeros ciclos después de detectar el evento.

Figura 10

Sistema de prueba del artículo seleccionado que se basa en localización de zonas de falla



Nota. Imagen tomada del artículo Fault Location in Radial Distribution Networks Using ANN and Superimposed Components.(Barra et al., 2019)

Los investigadores construyeron modelos de clasificación de zonas de fallas basados en dos enfoques. El primero trata sobre redes neuronales especializadas para cada zona, cuatro

arquitecturas con salida binaria que indica si hubo una falla. Las estructuras son: A1 (8-8-8-2); A2 (8-2-6-2); A3 (8-7-6-2) y A4 (8-2-2), cada dígito representa el número de neuronas por capa. El segundo enfoque es un planteamiento más general, trata redes neuronales con cuatro salidas, en la cual, cada está relacionada con una zona e indica en cuál de ellas ocurrió la falla. Diseñaron dos estructuras con topología (8-4-4) Y (8-3-3-4).

En el proceso de entrenamiento, el ajuste de parámetros de las redes neuronales fue manual y se modificó hasta producir resultados satisfactorios. Usaron función activación tangente hiperbólica en las neuronas de las capas ocultas. El algoritmo de optimización de los pesos sinápticos fue Levenberg-Marquardt. El tamaño de los conjuntos de entrenamiento y prueba fue de 27,3% y 76,7% respectivamente. Todo el proceso se realizó en el *software* MATLAB ® R2015a.

En cuanto a la implementación al sistema integral de gestión de fallas, los autores omiten las etapas de detección e identificación de tipo de anomalía y sugieren que estas partes tiene su propio campo de investigación, por lo que deciden no profundizar en ellas. No obstante, declaran que dichas funcionalidades se pueden añadir a su trabajo.

Vale la pena reflexionar sobre algunos aspectos del artículo seleccionado. En primer lugar, la secuencia de la metodología propone dividir el sistema en zonas y luego realizar simulaciones de fallas, sin embargo, estos pasos pueden ser independientes debido a que la distribución de anomalías sobre la red es homogénea y no está condicionada por la división de las zonas. Además, es preferible tener una Tabla de datos simulados y luego asignar las etiquetas de zona según convenga.

El criterio de división es un paso de gran interés. En el trabajo guía, los autores sugieren que han construido las áreas de clasificación a partir de cada punto de ramificación en la red, pero tal criterio es ambiguo, pues según este, el área A3 de la Figura 10 tiene un ramal de 1,7 km que

debería conformar un area independiente. Por otro lado, la formación de zonas no mantiene regularidad en cuanto a la extensión de tramos de líneas, como se muestra en la Tabla 8. Por tanto, el proceso de división de zonas podría ser arbitrario.

Tabla 8

Extensión[km]
7,2
2,7
4,4
7,9

Longitud total de los alimentadores de las zonas del sistema de la Figura 10

Por último, los autores emplean las señales de tensión y corriente para la formación de los componentes superpuestos (entradas de las redes neuronales). Pero se considera necesario simular en el dominio del tiempo para construir dichas magnitudes, debido a que los investigadores evitan el transitorio de las fallas y no mencionan si los modelos del sistema consideran cargas dinámicas o fuentes de distorsión. Por lo tanto, simular en el domino de la frecuencia reduce la carga computacional y en el contexto mencionado, los componentes superpuestos equivalen a la magnitud de la resta entre los fasores antes y después de la falla.

Por último, también se acoge la postura de que las fallas ya fueron detectadas y se sabe cuáles son las fases implicadas. Así mismo, solo se construirán modelos de localización basados en el segundo enfoque, el cual consta de arquitecturas de redes neuronales que tienen como salida de clasificación a todas las zonas, y se evita los modelos de salida binaria por cada zona, pues los autores indican que este último enfoque tiene un alcance limitado. La secuencia de trabajo a seguir se indica en la Figura 11.

Figura 11

Metodología adoptada basada en artículo seleccionado de localización de zonas de falla



5. Fundamentos matemáticos de redes neuronales artificiales

Existen varios tipos de redes neuronales artificiales que se diferencia en su estructura, forma de operar y propósito. En aplicaciones como el procesamiento de lenguaje natural, reconocimiento automático de voz y visión por computador (áreas de gran desarrollo e investigación) es común el uso de redes neuronales artificiales recurrentes, generativas y convolucionales. Dichas arquitecturas componen modelos bastante complejos, sin embargo, la esencia de gran parte de ellas se puede representar mediante la red clásica de estructura densamente conectada de alimentación directa. Este último tipo de red fue la que se implementó en los métodos de localización de fallas en sistemas de distribución de la Tabla 5. El propósito de este capítulo es mostrar el funcionamiento de redes neuronales artificiales artificiales densamente

comentadas de alimentación directa mediante un ejemplo sencillo de regresión. La idea es modelar la función de dos variables de la Figura 12.

Figura 12

superficie a modelar, $f(x, y) = 1 - x^2 - y^2$



El rango de la función es $D = \{(x, y) | |x| \le \sqrt{0.5}, |y| \le \sqrt{0.5}\}$. Pero antes de avanzar vale la pena aclarar que este ejemplo es en parte absurdo, ya que el objetivo es encontrar la imagen de la función mediante una red neuronal artificial a partir del conjunto de valores {x,y}. No obstante, para tal cometido solo basta evaluar en la función a cada punto del dominio, luego ¿Cuál es la ventaja de este modelo predictivo?

Por el momento podemos interpretar a las redes neuronales artificiales como una caja negra en la cual ingresa un conjunto de valores y arroja otros. Se supone que uno de los alcances de este tipo de arquitecturas es "encontrar" la relación funcional entre conjuntos numéricos, especialmente de aquellos fenómenos complejos donde es difícil establecer una relación entre variables mediante técnicas analíticas.

Para que las redes neuronales puedan predecir el comportamiento de una o un grupo de variables, primero debe pasar por un proceso de capacitación en la cual la red neuronal es expuesta a un número significativo de ejemplos.

Un conjunto de valores que ingresa a una red neuronal artificial pasa por una sucesión de ponderaciones con elementos llamados pesos sinápticos y composición de funciones. Si el valor de los pesos sinápticos es el adecuado, la red neuronal podrá mapear los valores del conjunto de entra hacia el conjunto de valores de salida. Por otro lado, si los pesos sinápticos no son los adecuado, la red no podrá predecir en lo absoluto. En tal caso, es fundamental tener un conjunto de salida preestablecido, para sistemas de aprendizaje supervisado, con el cual se ajustan los valores de los pesos sinápticos mediante técnicas de optimización a partir de la diferencia entre la salida esperada y la salida que arroja la red.

En relación con lo anterior, la ventaja del ejemplo del paraboloide de la Figura 12 es la sencilles para formar los conjuntos de entrada y salida para la capacitación del modelo. Además, se trata de una función sencilla que se puede representar gráficamente en tres dimensiones, y esto permite hacer una valoración cualitativa de la semejanza entre la superficie que genera la red neuronal y la superficie original.

El esquema de funcionamiento de una red neuronal artificial se muestra en la Figura 14. Pero antes de iniciar dicha etapa primero se debe aclara la forma en que ingresan los valores del conjunto {x,y}. En este tipo de aplicaciones, los datos deben ser tratados y por lo general reciben trasformaciones significativas. Así mismo, antes de iniciar el proceso de capacitación, es necesario definir unos parámetros relacionados con a la arquitectura de la red; las funciones de activación de las neuronas; la función de coste para medir la diferencia entre la salida real y la salida esperada; el algoritmo de optimización para ajustar los pesos sinápticos; la taza de modificación de los pesos sinápticos; los ciclos de entrenamiento y el tamaño de los conjuntos de entrada y salida en los ciclos de entrenamiento.

Figura 13

Esquema de entrenamiento y operación de una red neuronal artificial



5.1. Selección de entradas y salidas del modelo

Este es un punto clave en la construcción de modelos predictivos, en principio si no se elige las variables adecuadas todo el proceso de entrenamiento puede que no llegue a resultados satisfactorios. La selección y escalado de los valores de entrada de las redes neuronales artificiales es un área de investigación de gran interesante que se denomina ingeniería de descriptores. Sin embargo, en el ejemplo del paraboloide no se profundiza en este aspecto y no se especifica la razón por la cual se escogieron las siguientes entradas.

$$\mathbf{x}_1 = \mathbf{x} \tag{1}$$

$$\mathbf{x}_2 = \mathbf{y} \tag{2}$$

$$\mathbf{x}_3 = \mathbf{x} \cdot \mathbf{y} \tag{3}$$

$$\mathbf{x}_4 = \sqrt{\mathbf{x}^2 + \mathbf{y}^2} \tag{4}$$

Las ecuaciones desde la (1) a la (4) son las entradas de las redes neuronales. Para cada punto del plano del dominio ingresa las coordenadas horizontal y vertical, el producto entre estas y la distancia desde el origen al punto en cuestión. La normalización de la variable es un tema importante debido a que las magnitudes pueden estar en escalas muy diferentes. No obstante, las entradas y salidas del ejemplo propuesto están en el rango de cero a uno, por lo que el paso de normalización se puede omitir. En cuanto a salida de la red neuronal, esta será la imagen para cada punto del dominio.

5.2. Estructura y alimentación de la red neuronal artificial

El siguiente paso es definir la estructura de la red neuronal artificial a partir del número de entradas y salida. En este caso se eligió una red de 4 capas con {4, 4, 2, 1} neuronas respectivamente como se observa en la Figura 14, la cual es una representación grafica del sistema. No obstante, esta no es la única forma en que se puede representar una red neuronal artificial, pues también está la forma algebraica y la representación funcional.

5.2.1. Representación gráfica

Como ya se mencionó, una red neuronal transforma los valores de entrada en los valores de salida mediante un conjunto de ponderaciones y composición de funciones. En la red neuronal de la Figura 14, hay nueve neuronas, en cada una de ellas existe una etapa de ponderación con pesos sinápticos (punto intermedio entre conexiones) que luego pasa por una función de "activación". (de punto de llegada de conexiones a las circunferencias). El proceso es una secuencia en cascada tal que la salida de una neurona pasa a ser parte de la entrada de las neuronas de la siguiente capa. La función de activación, representada por las letras "a", es una función no lineal sencilla que genera una distorsión necesaria en los datos. Por otro lado, el "aprendizaje" de la red se almacena en los pesos sinápticos y en los sesgos , representados por las letras "w" y "b" respectivamente.

Figura 14

Representación gráfica de una red neuronal artificial



5.2.2. Representación algebraica

La secuencia desde la ecuación (5) a la ecuación (12) muestran en detalle lo que ocurre en la red neuronal de la Figura 14. Respecto a la nomenclatura, x_n se refiere a la entrada número "n". Así mismo, para la función de activación, a_p^m significa activación "m" de la neurona "p" en la capa "m+1", "m" inicia en cero y es la primera transformación que se hace a las entradas. Debido a que la activación da lugar a las ponderaciones alimentan a las neuronas de la capa siguiente, la numeración de las secuencias de activación es una unidad por debajo al número de la capa en cuestión. Para los pesos sinápticos, w_{pq}^{m+1} se refiere al factor de ponderación de la capa "m+1" en la conexión desde la neurona "p" en la capa "m+1" a la neurona "q" en a capa "m+2". Por otro lado, los sesgos b_q^{m+1} son el factor de desplazamiento del origen en la neurona "q". Por último, las ponderaciones z_p^{m+1} es la suma que ingresa a la neurona "q" para pasar por la función se activación se activación "m+1" de la capa "m+2".

En la red de la Figura 14, el conjunto de entrada pasa inmediatamente por una función de activación en la primera capa, por lo general se escoge el mismo tipo de función para toda la capa para facilitar los calculo. Cada entrada se transforma en a⁰_ny se refiere a la activación cero de la capa uno en la entrada n. En la red del paraboloide la función de activación de la entrada es lineal con pendiente uno y corte cero, lo que significa que no se modifican los valores, ver la ecuación (5). Luego, esa activación se multiplica por los pesos sinápticos de las conexiones de la capa. Seguido se suma lo sesgos y el resultado es el conjunto de ponderaciones de la capa uno. Dichas ponderaciones pasan por la función "f1" y se transforman en la activación uno, ver ecuación (6), Este nuevo conjunto de valores pasa a ser parte de la ponderación de la siguiente capa. La secuencia sigue hasta alcanza la última capa de la red. En cada capa se va modificando la dimensión de los elementos de salida para corresponda con la nueva entrada.

$$\begin{bmatrix} x_1 & x_2 & x_3 & x_4 \end{bmatrix} = \begin{bmatrix} a_1^0 & a_2^0 & a_3^0 & a_4^0 \end{bmatrix}$$
(5)

$$\begin{bmatrix} a_{1}^{0} & a_{2}^{0} & a_{3}^{0} & a_{4}^{0} \end{bmatrix} \begin{bmatrix} w_{11}^{1} & w_{12}^{1} & w_{13}^{1} & w_{14}^{1} \\ w_{21}^{1} & w_{22}^{1} & w_{23}^{1} & w_{24}^{1} \\ w_{31}^{1} & w_{32}^{1} & w_{33}^{1} & w_{33}^{1} \\ w_{41}^{1} & w_{42}^{1} & w_{43}^{1} & w_{44}^{1} \end{bmatrix} + \begin{bmatrix} b_{1}^{1} & b_{2}^{1} & b_{3}^{1} & b_{4}^{1} \end{bmatrix} = \begin{bmatrix} z_{1}^{1} & z_{2}^{1} & z_{3}^{1} & z_{4}^{1} \end{bmatrix}$$
(6)

$$f_1([z_1^1 \ z_2^1 \ z_3^1 \ z_4^1]) = [a_1^1 \ a_2^1 \ a_3^1 \ a_4^1]$$
(7)

$$\begin{bmatrix} a_{1}^{1} & a_{2}^{1} & a_{3}^{1} & a_{4}^{1} \end{bmatrix} \begin{bmatrix} w_{11}^{2} & w_{12}^{2} \\ w_{21}^{2} & w_{22}^{2} \\ w_{31}^{2} & w_{32}^{2} \\ w_{41}^{2} & w_{42}^{2} \end{bmatrix} + \begin{bmatrix} b_{1}^{2} & b_{2}^{2} \end{bmatrix} = \begin{bmatrix} z_{1}^{2} & z_{2}^{2} \end{bmatrix}$$
(8)

$$f_2([z_1^2 \ z_2^2]) = [a_1^2 \ a_2^2]$$
(9)

$$\begin{bmatrix} a_1^2 & a_2^2 \end{bmatrix} \begin{bmatrix} w_{11}^3 \\ w_{21}^3 \end{bmatrix} + \begin{bmatrix} b_1^3 \end{bmatrix} = \begin{bmatrix} z_1^3 \end{bmatrix}$$
(10)

$$f_3([z_1^3]) = [a_1^3]$$
(11)

$$[a_1^3] = [\bar{y}_1] \tag{12}$$

La forma de las ecuaciones anteriores dificulta la visibilidad y el papel de cada elemento de la red. Por otro lado, una forma compacta de las mismas ecuaciones permite observar la transformación que se efectúa en cada capa del sistema.

$$\mathbf{X} = \mathbf{A}^{\mathbf{0}} \tag{5}$$

$$A^{0}W^{1} + B^{1} = Z^{1}$$
(6)

$$\mathbf{f}_1(\mathbf{Z}^1) = \mathbf{A}^1 \tag{7}$$

$$\mathbf{A}^{1}\mathbf{W}^{2} + \mathbf{B}^{2} = \mathbf{Z}^{2} \tag{8}$$

$$\mathbf{f}_2(\mathbf{Z}^2) = \mathbf{A}^2 \tag{9}$$

$$A^2 W^3 + B^3 = Z^3$$
(10)

$$\mathbf{f}_3(\mathbf{Z}^3) = \mathbf{A}^3 \tag{11}$$

$$\mathbf{A}^3 = \mathbf{Y} \tag{12}$$

La ecuación (5) es la capa uno (entrada). Seguido, las ecuaciones (6) y (7) son la capa número dos. Así mismo, las ecuaciones (8) y (9) representan a la capa tres. Por último, las ecuaciones (10) y (11) son la capa de final, y la salida de la red se asigna mediante la ecuación (12).

5.2.3. Representación en forma de composición de funciones

Ya se trató la forma gráfica y algebraica de la red neuronal artificial. Ahora se plantea la forma funcional de la secuencia de alimentación de la red. Las siguientes expresiones, en esencias, son las mismas operaciones de las ecuaciones (5) - (12). Sin embargo, no se trata de redundancias, puesto que las nuevas expresiones permiten ver el orden de la composición de funciones, y este es un punto esclave para formular la regla de la cadena para el proceso de ajuste de los pesos sinápticos por medio del gradiente de la función de coste.

$\mathbf{X} = \mathbf{A}^{0}$	(13)
$Z^1(A^0, W^1, B^1)$	(14)
$A^1(Z^1)$	(15)
$Z^2(A^1, W^2, B^2)$	(16)
$A^2(Z^2)$	(17)
$Z^3(A^2, W^3, B^3)$	(18)
$A^3(Z^3)$	(19)
$A^3 = \overline{Y}$	(20)

5.3. Otros parámetros de la red neuronal artificial

En la sección anterior se definió la arquitectura de la red, cantidad de capas y neuronas. Además de esos parámetros también se debe definir la función de activación, que en la primera capa de la red es lineal y en todas la demás es función sigmoidal.

Figura 15

Función de activación sigmoidal, $f(x) = 1 / (1 + e^{-x})$



Incluso es fundamental decidir la función de coste para medir la diferencia entre la salida real y la salida esperada, en este caso se eligió la raíz media cuadráticas "MSE" por sus siglas en inglés. Respecto al algoritmo de optimización para ajustar los pesos sinápticos, se optó por el descenso del gradiente en lotes *Batch gradient decent*. El cual emplea todo el conjunto de entrenamiento para ajustar los pesos en cada ciclo de entrenamiento.

5.4. Entrenamiento de red neuronal artificial

Cuando se conFigura una red neuronal artificial, inicialmente los pesos sinápticos pueden ser de cualquier valor, de preferencia, cantidades cercanas a la unidad. En tal condición, al ingresar el conjunto de valores a la red, es casi seguro que la salida será muy diferente a la respuesta deseada. Luego, es necesario modificar los pesos sinápticos hacía unos valores que sí puedan transformar la entrada en la salida objetivo. Este proceso se realiza por medio del gradiente del error de la función de coste. Dicha función compara a la salida que produce la red con la salida de referencia inicial. Seguido se ajustan los pesos en cierta proporción al ritmo de cambio del error de la función de coste en relación con los pesos, la operación se conoce como el gradiente descendente. Aplicar tal algoritmo a una red de una sola capa es fácil. Por otro lado ,si la estructura de la red es de mayor complejidad, no es sencillo ajustar los pesos sinápticos por no es explicita la contribución de cada peso al error total. Este hecho frenó por varias décadas el desarrollo de las redes neuronales artificiales hasta que en la década de los 70 se planteó el algoritmo de retropropagación.

En una red neuronal artificial, para un conjunto de entrada y salida fijo, el error que arroja la red depende principalmente de los pesos sinápticos. En un principio, la estrategia implementada era modificar un peso a la vez y evaluar su impacto en la salida de la red para ajustar su valor. Dicho planteamiento es muy limitado y requiere de mucho calculo computacional. Por otro lado, con el algoritmo de retropropagación no se modifica a un solo peso por la vez, sino que se
modifica a todos los pesos de una capa, partiendo de capa de salida hacia la capa de entrada. Basado en las ecuaciones desde la (13) a la (20) se establece la regla de la cadena para la variación de la función de coste en relación con los pesos $\partial FC / \partial W^n$ de la capa "n". Ver desde la ecuación (21) a la ecuación (24). El negativo de estos términos multiplicado por la taza de aprendizaje es la magnitud que modifica a los pesos sinápticos. En esta ocasión no se escribió los términos que relacionan el ritmo de cambio del coste en relación con los sesgos "b". Estos también se deben considerar.

$$Error = FC(\overline{Y}, Y)$$
(21)

$$\frac{\partial FC}{\partial W^3} = \frac{\partial FC}{\partial A^3} \cdot \frac{\partial A^3}{\partial Z^3} \cdot \frac{\partial Z^3}{\partial W^3}$$
(22)

$$\frac{\partial FC}{\partial W^2} = \frac{\partial FC}{\partial A^3} \cdot \frac{\partial A^3}{\partial Z^3} \cdot \frac{\partial Z^3}{\partial A^2} \cdot \frac{\partial A^2}{\partial Z^2} \cdot \frac{\partial Z^2}{\partial W^2}$$
(23)

$$\frac{\partial FC}{\partial W^1} = \frac{\partial FC}{\partial A^3} \cdot \frac{\partial A^3}{\partial Z^3} \cdot \frac{\partial Z^3}{\partial A^2} \cdot \frac{\partial A^2}{\partial Z^2} \cdot \frac{\partial Z^2}{\partial A^1} \cdot \frac{\partial A^1}{\partial W^1}$$
(24)

La idea es distribuir el error desde la última capa hacia la capa de inicio de la red. En las expresiones las ecuaciones (22) – (24) los términos mantienen patrón que se repite en todas las capas y el algoritmo de retropropagación automatiza una generalización para modificar los parámetros de una red con cualquier número de capas y neuronas. Los detalles de tal secuencia no van a profundiza, sin embargo, en el apéndice se adjunta el cogido desarrollado en el lenguaje de programación python.

Respecto al "aprendizaje" del modelo, la curva de entrenamiento se muestra en la Figura 16, en esta se observa 300 ciclos de entrenamiento. Por último, la superficie que modela la red se muestra en la Figura 17 y el error absoluto comparado con la función original se grafica en la Figura 18.

Figura 16

Función de coste en el proceso de entrenamiento de la red neuronal artificial de la Figura 14



Figura 17

Superficie modelada por la red neuronal artificial de la Figura ()



Figura 18

Error absoluto para cada punto (x,y) de la superficie modelada por la red neuronal de la Figura



El ejemplo anterior es un caso de regresión en el cual el modelo predice una variable numérica a partir de un conjunto de valores de entrada. Este tipo de planteamiento se ajusta con los métodos de localización de fallas de la Tabla 5, de los cuales la mayoría estiman el punto de falla como una distancia desde la subestación a partir de las medidas de tensión y corriente. Por otro lado, en la metodología seleccionada abordan el problema de localización de falla como la identificación de la zona afecta. En dicho trabajo también construye modelos predictivos, sin embargo, no se trata de un problema de regresión, sino de un asunto de clasificación de categorías. En ese caso, para cada evento de falla, la salida de la red neuronal será un vector de tamaño igual al numero de zonas previamente establecidas. Cada elemento del vector está relacionado con una zona e Idealmente se espera que la zona afectada tenga el valor 1 y todos los demás elementos tengan un valor de cero. Para este tipo de problemas también aplican los criterios operativos de la rede neuronal que modela el paraboloide de la Figura 12. Sin embargo, en el caso de clasificación se debe ajustar el tipo y cantidad de neuronas última capa, así mismo se debe escoger una función de coste idónea. Un ejemplo puede ser función de activación *softmax* y función de perdida de entropía cruzada multiclase.

6. Implementación de la metodología de localización zonas de falla en el sistema IEEE 34

La metodología de la Figura 11, la cual consiste en : seleccionar el sistema de prueba, simular fallas, calcular los valores de entrada de las redes neuronales, dividir el sistema en parte, entrenar modelos de redes neuronales artificiales y por último la etapa de localización de fallas, fue implementada en el lenguaje de programación Python. El tratamiento de los datos fue a través de librerías de Numpy y Pandas y la conFiguración de los modelos de redes neuronales se realizó mediante la librería de Tensor Flow.

6.1. Modelado del sistema IEEE 34

El sistema de prueba IEEE 34 es una red de topología radial con tensión nominal de 24,9 kV. Tiene alrededor de 93 km de extensión de líneas y el alimentador principal tiene una longitud aproximada de 57 km, en el cual ha do reguladores de tensión. La mayoría de los tramos son trifásicos, aunque existe algunas secciones de alimentación monofásicas "AN" y "BN". Una parte del sistema opera a 4,16 kV. En cuanto a las cargas, el sistema es poco cargado y modela elemento tanto puntuales, como de carácter distribuido en las formas básicas de impedancia constante, potencia constante y demanda de corriente constante.

6.2. Representaciones del sistema de prueba IEEE 34

Esquema de la red IEEE 34 barras



Figura 20

Tipo de conductores de la red IEEE 34 barras



Longitud de alimentadores de la red IEEE 34 barras a escala



6.3. Simulación de fallas en el sistema IEEE 34 barras

Se efectuó fallas de aislamiento en 257 puntos en todo el sistema, dependiendo el lugar se simuló eventos de falla para cada tipo de anomalía con impedancias desde 0 Ω hasta 40 Ω en paso de 0.5 Ω . La Tabla 9 muestra la longitud e los alimentadores del sistema y la cantidad de puntos de simulación que hay en cada uno. La Tabla 10 muestra la distribución de puntos de falla para cada tipo de anomalía.

Tabla 9

Información de distribución de fallas en el sistema IEEE 34

Nodo inicial	Nodo final	longitud del alimentador [km]	Puntos de falla intermedios	Distancia entre puntos de falla [m]
800	802	0.786	1	393.2
802	806	0.527	1	263.7
806	808	9.824	24	392.9

808	810	1.769	4	353.8
808	812	11.430	28	394.1
812	814	9.062	22	394.0
814	850	0.003	-	-
850	816	0.094	-	-
816	818	0.521	1	260.6
818	820	14.676	36	396.7
820	822	4.188	10	380.7
816	824	3.112	7	389.0
824	826	0.924	2	307.8
824	828	0.256	1	128.0
828	830	6.230	15	389.4
830	854	0.158	-	-
854	856	7.111	17	395.1
854	852	11.226	28	387.1
852	832	0.003	-	-
832	888	0.001	-	-
888	890	3.219	8	357.6
832	858	1.494	3	373.4
858	864	0.494	1	246.9
858	834	1.777	4	355.4
834	842	0.085	-	-
842	844	0.411	1	205.7
844	846	1.109	2	369.8
846	848	0.162	1	80.8
834	860	0.616	1	307.8
860	836	0.817	2	272.3
836	862	0.085	-	-
862	838	1.481	3	370.3
836	840	0.262	1	131.1
Total		93.914 km	224	Promedio 320 m

Tabla 10

Cantidad de puntos para la simulación de falla el sistema IEEE 34

Tipo falla	Fases implicadas	Puntos de simulación de fallas	Simulaciones en total
1	AG	227	18306
2	BG	204	16524
3	CG	175	14175
4	AB	175	14175
5	BC	175	14175

,	,		,
		INO DE DIOTOU	
			21 17 17 18 181

6	CA	175	14175
7	ABG	175	14175
8	BCG	175	14175
9	CAG	175	14175
10	ABC	175	14175
11	ABCG	175	14175
Total		257	162486

6.4. Construcción de patrones de entrenamiento de las redes neuronales artificiales

Figura 22

Cálculo de componentes superpuestos



En este trabajo, debido a la ausencia de componentes de distorsión y estados transitorios, el cálculo de los componentes superpuesto se realizó en el dominio de la frecuencia. A cada fasor de tensión o corriente de estado estable de falla se le restó el fasor antes de la condición de falla, la norma del elemento resultante es el componente superpuesto, como se muestra en la Figura 22. Por cada evento de simulación se construyeron ocho valores, cuatro componentes para la tensión y cuatro componentes para la corriente, estos valores se relacionan con las magnitudes por cada fase y el neutro. Los componentes superpuestos fueron normalizados. Por cada columna, a cada elemento se les restó el valor mínimo y luego se dividió entre el máximo resultante. Como resultado, todas las columnas de los componentes superpuestos están en el rango de cero a uno. Los valores de un ejemplo de falla se muestran en la Tabla 11. Por otro

lado, los componentes superpuestos relacionados con dicho evento de falla se muestran en la Tabla 12.

Tabla 11

Valores de tensión y corriente registrados en la subestación para una anomalía AG en el nodo 808 con una impedancia de falla de 4Ω

Condición	Va	θ_{Va}	Vb	θ_{Vb}	Vc	θ_{Vc}	la	β_{la}	lb	βıb	lc	β _{lc}
Prefalla	14650.6	-4	14771.4	-124	14876.3	116.5	49.7	-16.1	43.8	-131.4	40.1	113.9
Posfalla	6975.6	-27.8	14625.3	-122	14673.8	115.7	432	-61.8	43.7	-126	33.5	108.7

Tabla 12

Componentes superpuestos a partir de los valores de tensión y corriente registrados en la subestación para una anomalía AG en el nodo 808 con una impedancia de falla de 4 Ω

Escala	CS_Va	CS_Vb	CS_Vc	CS_Vn	CS_la	CS_lb	CS_lc	CS_In
Magnitud real	8734.3	340.7	289.1	8182.4	398.5	4.1	7.4	408.8
Magnitud normalizada	0.60	0.02	0.02	0.59	0.61	0.01	0.01	0.58

6.5. Criterio de división del sistema IEEE 34

Las zonas de clasificación de falla del artículo seleccionado se construyen a partir de los puntos de ramificación. Una interpretación de tal criterio puede ser que el inicio y el final de un área está delimitado por una derivación.

Sin embargo, puede que sea contraproducente implementar la estrategia de zonificación mencionada en el sistema IEEE 34. La razón principal es la formación de conjuntos de

clasificación desbalanceados debido a que algunos alimentadores ramificados tienen una extensión muy pequeña comparada con otros tramos del y las simulaciones de eventos de fallas tienen una distribución más o menos homogénea en la red. En ese sentido, la cantidad de patrones de entrenamiento de cada zona depende de su extensión y debido a la diferencia en la proporción de los conjuntos de clasificación, el proceso de entrenamiento de las redes neuronales artificiales estaría sujeto a un sesgo de predicción.

6.5.1. Ejemplo de prueba de zonificación a partir del criterio de división por cada punto ramal en el sistema IEEE34

En la Figura 23 se muestran 13 zonas que fueron construidas bajo el criterio de división por cada punto ramal. La extensión de los tramos de línea que conforma a cada área es muy variada. La zona 13 tiene el menor tamaño y cuenta con alrededor de 100 metros de líneas. Por otro lado, la zona 3 tiene 23,3 km de extensión. Ante tal diferencia, la cantidad de eventos de falla para cada clase es muy desbalanceada, ver Tabla 13.

Figura 23

Ejemplo de prueba zonificación para fallas tipo 2 a partir de criterio de división por cada punto ramal en el sistema IEEE34



Tabla 13

Distribución de simulaciones para ejemplo de prueba de zonificación por cada punto ramal para

Zona	Extensión	Conjunto de entrenamiento	Conjunto de validación	Conjunto de prueba	Total
1	10.7	1790	106	453	2349
2	1.8	302	25	78	405
3	23.3	3700	244	997	4941
4	0.7	178	17	48	243
5	6	1148	79	312	1539
6	6.7	1070	86	302	1458
7	10.8	1803	126	501	2430
8	2.9	610	38	162	810
9	2.9	560	42	127	729
10	1.5	359	19	108	486
11	1.1	447	16	104	567
12	1.5	302	25	78	405
13	0.1	124	4	34	162
Total	70	12393	827	3304	16524

fallas tipo 2 en el sistema IEEE34

6.5.2. Inconveniente de la zonificación de prueba mediante el criterio de división a partir de cada punto ramal

Después de varios procesos de entrenamiento, el mejor resultado fue con una precisión en clasificación de 0,8234, y entropía cruzada para la función de pérdida de 0.4171. La matriz de confusión de la Figura 24 muestra la incapacidad del modelo para reconocer anomalías en las zonas de menor extensión.

Curvas de entrenamiento de la red neuronal artificial empleada para ejemplo de zonificación de



prueba de la Figura 23

Figura 25

Matriz de confusión para conjunto de prueba del ejemplo de zonificación de prueba de la Figura

23



6.5.3. Planteamiento para resolver el inconveniente de las clases desbalanceadas de la zonificación de propuesta en la Figura 23

El caso anterior es un ejemplo de sesgo en clasificación de zonas producto de conjuntos desbalanceados. Ahora se propone "resolver" dicho problema, repitiendo los eventos de las

clases de menor tamaño hasta igualar a la clase de la zona 3 (la de mayor tamaño). De tal forma cada zona tendrá 3700 patrones entrenamiento, 244 de validación y 997 de prueba. Para este nuevo caso, los ciclos de capacitación de la red neuronal empleada se muestran en la Figura 26. La precisión alcanzada es de 0,7128 y la función de pérdida es de 0,6263. En la Figura 27 se muestra la distribución de anomalías que relaciona la zona real de falla contra la zona que predice el modelo.

Figura 26

Curvas de entrenamiento de la red neuronal artificial empleada para ejemplo zonificación prueba modificado de la Figura 23



Figura 27

Matriz de confusión para conjunto de prueba del ejemplo de zonificación modificado de la

Figura 23



Aunque este nuevo modelo de clases "balanceadas" presenta menor precisión respeto al caso anterior, la matriz de confusión muestra una diagonal más definida, lo que indica una mejora cualitativa respecto al reconocimiento de anomalías. Incluso, se resolvió la incapacidad de había para reconocer fallas en las zonas 2 y 4. Por otro lado, el nuevo modelo presenta dificultades para identificar fallas en las zonas 10, 11, 12 y 13, quizá este grupo debe tratarse como una sola área.

6.5.4. Criterio de zonificación adoptado para el sistema IEEE34

A raíz de las observaciones del ejemplo anterior, se pretende una estrategia de zonificación diferente que permita construir clases más o menos balanceadas. También se considera que las ramificaciones de la sección del extremo remoto del sistema deben ser tratadas como una sola área.

Para cada tipo de falla, se formó un conjunto de 10 zonas con extensión similar en longitud de tramos de línea. Además, cada área debe ser un cuerpo compacto, lo que significa que una zona no admite partes discontinuas de diferentes secciones del sistema. recomienda formar las zonas desde los extremos del sistema.

6.6. Zonificación del sistema IEEE34 para falla tipo 1

Figura 28

Zonificación del sistema IEEE34 para fallas tipo 1 (AG)



Tabla 14

Distribución de simulaciones de falla para zonificación de anomalías tipo 1 en el sistema

Zona	Extensión [km]	Conjunto de entrenamiento	Conjunto de validación	Conjunto de prueba	Total
1	8.38	1321	94	367	1782
2	8.26	1379	92	311	1782
3	8.27	1320	101	361	1782
4	8.11	1363	77	423	1863
5	7.93	1258	84	359	1701
6	8.15	1335	86	361	1782
7	8.04	1426	101	336	1863
8	7.9	1402	99	362	1863
9	7.09	1291	73	337	1701
10	5	1630	111	446	2187
Total	77.13	13725	918	3663	18306

IEEE34



6.7. Zonificación del sistema IEEE34 para la falla tipo 2

Tabla 15

Distribución de simulaciones de falla para zonificación de anomalías tipo 2 en el sistema

Zona	Extensión [km]	Conjunto de entrenamiento	Conjunto de validación	Conjunto de prueba	Total
1	7.21	1168	73	298	1539
2	7.08	1163	70	306	1539
3	7.09	1140	86	313	1539
4	7.09	1141	80	318	1539
5	6.36	1117	61	280	1458
6	7.09	1274	94	333	1701
7	6.72	1070	86	302	1458
8	7.12	1196	91	333	1620
9	7.09	1332	80	370	1782
10	7.93	1792	106	451	2349
Total	70,78	12393	827	3304	16524

IEEE34



6.8. Zonificación del sistema IEEE para las fallas desde el tipo 3 al tipo 11

Tabla 16

Distribución de simulaciones de falla para zonificación de anomalías desde el tipo 3 al tipo 11

Zona	Extensión [km]	Conjunto de entrenamiento	Conjunto de validación	Conjunto de prueba	Total
1	6.03	989	66	241	1296
2	5.89	964	63	269	1296
3	5.91	976	60	260	1296
4	5.91	969	65	262	1296
5	5.9	963	75	258	1296
6	5.79	1137	88	314	1539
7	5.98	1056	67	254	1377
8	5.81	994	68	234	1296
9	5.54	1096	49	313	1458
10	6.44	1487	108	430	2025
Total	59.2	10631	709	2835	14175

en el sistema IEEE34

6.9. Resultado del modelo de red neuronal para fallas tipo 1 (AG)

La estructura de la red neuronal artificial empleada para clasificar el tipo de falla AG se muestra en la Tabla 17. La taza de aprendizaje en los ciclos de entrenamiento fue de 0.001 y el algoritmo de optimización de los pesos sinápticos fue *Adaptive moment estimation*.

Tabla 17

Número de capa	Tipo de capa	Número de neuronas	Función de activación
1	Entrada	24	ReLU
2	Oculta	16	ReLU
3	Oculta	12	ReLU
4	Oculta	10	ReLU
5	Salida	10	Softmax

Estructura de red neuronal artificial para clasificar fallas tipo 1 (AG)

Se obtuvo una precisión de 0,9293 al evaluar el conjunto de prueba. Así mismo, el menor valor para la función de pérdida fue de 0,1811. Las curvas del proceso de entrenamiento se muestran en la Figura 29. En la Figura 30 se muestra la distribución de anomalías que relaciona la zona real de falla contra la zona que predice el modelo.

Curvas relacionadas al proceso de aprendizaje de red neuronal que clasifica fallas monofásicas



(AG) en el sistema IEEE34

Figura 30

Matriz de confusión para el conjunto de prueba de la red neuronal que clasifica fallas monofásicas (AG) en el sistema IEEE 34



En el proceso de evaluación, 259 eventos de fallas relacionadas a 49 puntos de simulación fueron mal clasificados sobre un total de 3663 anomalías del conjunto de prueba. Sin embargo, con un análisis detallado se observó que solo 144 eventos relacionados a 32 puntos de simulación tuvieron una clasificación errónea crítica. Es decir, se trata de estimaciones lejanas a la zona real de ubicación de la falla. Por otro lado, los eventos restantes, aunque fueron mal

clasificados, estos corresponden con el primer o segundo punto de la zona adyacente, lo que significa que hacen parte de la región límite. Las secciones con mayor problema en la tarea de clasificación de fallas son la zona 4, zona 5 y zonas 7 .Los puntos críticos de clasificación se indica en la Figura 31. La información de dichos puntos se muestra en las Tablas 18-25.

Figura 31

Puntos críticos en la clasificación de fallas para el modelo de anomalías AG del sistema IEEE34



Tabla 18

Fallas críticas de la zona 4 que fueron predichas en la zona 5 del modelo para anomalías

Identificador de puntos de falla	Nodo inicial	Nodo final	Punto intermedio	Cantidad de fallas
8188201	818	820	1	12
8168181	816	818	1	11
816	816	816	0	10
818	816	816	0	9

850	850	850	0	9
8188202	818	820	2	8
8188203	818	820	3	8
81281422	812	814	22	7
Total				74

Tabla 19

Información de impedancias de fallas críticas de la zona 4 que fueron predichas en la zona 5

del modelo para anomalías monofásicas AG en el sistema IEEE34

Indicador	Cantidad
Falla en total	74
Media [Ω]	30.5
Std [Ω]	5.7
Min [Ω]	20.0
Ρ ₂₅ [Ω]	25.1
Ρ ₅₀ [Ω]	31.0
Ρ ₇₅ [Ω]	35.3
Max [Ω]	40.0

Tabla 20

Fallas críticas de la zona 5 que fueron predichas en la zona 4 del modelo para anomalías

Identificador de puntos de falla	Nodo inicial	Nodo final	Punto intermedio	Cantidad de fallas
8188209	818	820	9	7
81882011	818	820	11	5
8188208	818	820	8	5
81882016	818	820	16	5
81882013	818	820	13	4
81882010	818	820	10	3
81882012	818	820	12	3
81882015	818	820	15	2
81882018	818	820	18	1
81882014	818	820	14	1
Total				36

Tabla 21

Información de impedancias de fallas críticas de la zona 5 que fueron predichas en la zona 4 del modelo para anomalías monofásicas AG en el sistema IEEE34

Indicador	Cantidad
Fallas en total	36
Media [Ω]	3.8
Std [Ω]	3.3
Min [Ω]	0.0
Ρ ₂₅ [Ω]	1.4
Ρ ₅₀ [Ω]	3.0
Ρ ₇₅ [Ω]	6.1
Max [Ω]	12.0

Tabla 22

Fallas críticas de la zona 5 que fueron predichas en la zona 6 del modelo para anomalías

Identificador de puntos de falla	Nodo inicial	Nodo final	Punto intermedio	Cantidad de fallas
81882020	818	820	20	7
81882024	818	820	24	5
81882021	818	820	21	4
81882023	818	820	23	4
81882018	818	820	18	3
81882017	818	820	17	2
81882022	818	820	22	2
81882019	818	820	19	1
Total				28

Tabla 23

Información de impedancias de fallas críticas de la zona 5 que fueron predichas en la zona 6

Indicador	Cantidad
Fallas en total	28
Media [Ω]	35.3
Std [Ω]	3.2
Min [Ω]	28.0
Ρ ₂₅ [Ω]	33.0
Ρ ₅₀ [Ω]	36.0
Ρ ₇₅ [Ω]	37.5
Max [Ω]	39.5

del modelo para anomalías monofásicas AG en el sistema IEEE34

Tabla 24

Fallas críticas de la zona 7 que fueron predichas en la zona 6 del modelo para anomalías

monofásicas AG en el sistema IEEE34

Identificador de puntos de falla	Nodo inicial	Nodo final	Punto intermedio	Impedancia de falla [Ω]
8168241	816	824	1	38
8168241	816	824	1	40
8168241	816	824	1	35.5

Tabla 25

Fallas críticas de la zona 7 que fueron predichas en la zona 5 del modelo para anomalías

Identificador de puntos de falla	Nodo inicial	Nodo final	Punto intermedio	Impedancia de falla [Ω]
8168242	816	824	2	33
8168242	816	824	2	32.5
8168242	816	824	2	39

6.10. Resultado del modelo de red neuronal para fallas tipo 2 (BG)

La estructura de la red neuronal artificial empleada para clasificar el tipo de falla BG se muestra en la Tabla 26. La taza de aprendizaje en los ciclos de entrenamiento fue de 0.001 y el algoritmo de optimización de los pesos sinápticos fue *Adaptive moment estimation*.

Tabla 26

Número de capa	Tipo de capa	Número de neuronas	Función de activación
1	Entrada	24	ReLU
2	Oculta	48	ReLU
3	Oculta	32	ReLU
4	Oculta	24	ReLU
5	Oculta	16	ReLU
6	Salida	10	Softmax

Estructura de red neuronal artificial para clasificar fallas tipo 2 (BG)

Se obtuvo una precisión de 0,9570 al evaluar el conjunto de prueba. Así mismo, el menor valor para la función de pérdida fue de 0,1114. Las curvas del proceso de entrenamiento se muestran en la Figura 32. En la Figura 33 se muestra la distribución de anomalías que relaciona la zona real de falla contra la zona que predice el modelo.

Curvas relacionadas al proceso de aprendizaje de red neuronal que clasifica fallas monofásicas



(BG) en el sistema IEEE34

Figura 33

Matriz de confusión para el conjunto de prueba de la red neuronal que clasifica fallas monofásicas (BG) en el sistema IEEE 34



En el proceso de evaluación, 142 eventos de falla relacionadas a 27 puntos de simulación fueron mal clasificados sobre un total de 3304 anomalías del conjunto de prueba. Sin embargo, con un análisis detallado se observó que solo 10 eventos relacionados a 1 punto de simulación tuvieron una clasificación errónea crítica. Es decir, se trata de estimaciones lejanas a la zona real de ubicación de la falla. Por otro lado, los eventos restantes, aunque fueron mal clasificados,

estos corresponden con el primer o segundo puntos de la zona adyacente, lo que significa que hacen parte de la región límite. La sección con mayor problema en la tarea de clasificación de fallas es la zona 8, los puntos críticos se indica en la Figura 34. La información de dichos puntos se muestra en la Tabla 27.

Figura 34

Puntos críticos en la clasificación de fallas para el modelo de anomalías BG del sistema

IEEE34



Tabla 27

Fallas críticas de la zona 8 que fueron clasificados en la zona 7 del modelo para fallas

Identificador de puntos de falla	Nodo inicial	Nodo final	Punto intermedio	Impedancia de falla [Ω]
8548522	854	852	2	4.5
8548522	854	852	2	20.5
8548522	854	852	2	38.5
8548522	854	852	2	4
8548522	854	852	2	31
8548522	854	852	2	26.5
8548522	854	852	2	28
8548522	854	852	2	23.5

8548522	854	852	2	31.5
8548522	854	852	2	2.5

6.11. Resultado del modelo de red neuronal para fallas tipo 3 (CG)

La estructura de la red neuronal artificial empleada para clasificar el tipo de falla CG se muestra en la Tabla 28. La taza de aprendizaje en los ciclos de entrenamiento fue de 0.001 y el algoritmo de optimización de los pesos sinápticos fue *Adaptive moment estimation*.

Tabla 28

Número de capa	Tipo de capa	Número de neuronas	Función de activación
1	Entrada	24	ReLU
2	Oculta	48	ReLU
3	Oculta	32	ReLU
4	Oculta	24	ReLU
5	Oculta	16	ReLU
6	Salida	10	Softmax

Estructura de red neuronal artificial para clasificar fallas tipo 3 (CG)

Se obtuvo una precisión de 0,9718 al evaluar el conjunto de prueba. Así mismo, el menor valor para la función de pérdida fue de 0,075. Las curvas del proceso de entrenamiento se muestran en la Figura 35. En la Figura 36 se muestra la distribución de anomalías que relaciona la zona real de falla contra la zona que predice el modelo.

Curvas relacionadas al proceso de aprendizaje de red neuronal que clasifica fallas monofásicas



(CG) en el sistema IEEE34

Figura 36

Matriz de confusión para el conjunto de prueba de la red neuronal que clasifica fallas





En el proceso de evaluación, 80 eventos de falla relacionadas a 25 puntos de simulación fueron mal clasificados sobre un total de 2835 anomalías del conjunto de prueba. Sin embargo, la totalidad de dichos eventos corresponde con la región límite de las zonas, lo que quiere decir que se trata del primer o segundo punto del área adyacente, por lo que no se consideran puntos críticos erróneamente clasificados.

6.12. Resultado del modelo de red neuronal para fallas tipo 4 (AB)

La estructura de la red neuronal artificial empleada para clasificar el tipo de falla AB se muestra en la Tabla 29. La taza de aprendizaje en los ciclos de entrenamiento fue de 0.001 y el algoritmo de optimización de los pesos sinápticos fue *Adaptive moment estimation*.

Tabla 29

Número de capa	Tipo de capa	Número de neuronas	Función de activación
1	Entrada	24	ReLU
2	Oculta	48	ReLU
3	Oculta	32	ReLU
4	Oculta	24	ReLU
5	Oculta	16	ReLU
6	Salida	10	Softmax

Estructura de red neuronal artificial para clasificar fallas tipo 4 (AB)

Se obtuvo una precisión de 0,9672 al evaluar el conjunto de prueba. Así mismo, el menor valor para la función de pérdida fue de 0,0984. Las curvas del proceso de entrenamiento se muestran en la Figura 37. En la Figura 38 se muestra la distribución de anomalías que relaciona la zona real de falla contra la zona que predice el modelo.

Curvas relacionadas al proceso de aprendizaje de red neuronal que clasifica fallas bifásicas



(AB) en el sistema IEEE34

Figura 38

Matriz de confusión para el conjunto de prueba de la red neuronal que clasifica fallas bifásicas (AB) en el sistema IEEE 34



En el proceso de evaluación, 93 eventos de falla relacionadas a 21 puntos de simulación fueron mal clasificados sobre un total de 2835 anomalías del conjunto de prueba. Sin embargo, la totalidad de dichos eventos corresponde con la región límite de las zonas, lo que quiere decir que se trata del primer o segundo punto del área adyacente, por lo que no se consideran puntos críticos erróneamente clasificados.

6.13. Resultado del modelo de red neuronal para fallas tipo 5 (BC)

La estructura de la red neuronal artificial empleada para clasificar el tipo de falla Bc se muestra en la Tabla 30. La taza de aprendizaje en los ciclos de entrenamiento fue de 0.001 y el algoritmo de optimización de los pesos sinápticos fue *Adaptive moment estimation*.

Tabla 30

Número de capa	Tipo de capa	Número de neuronas	Función de activación
1	Entrada	24	ReLU
2	Oculta	48	ReLU
3	Oculta	32	ReLU
4	Oculta	24	ReLU
5	Oculta	16	ReLU
6	Salida	10	Softmax

Estructura de red neuronal artificial para clasificar fallas tipo 5 (BC)

Se obtuvo una precisión de 0,9926 al evaluar el conjunto de prueba. Así mismo, el menor valor para la función de pérdida fue de 0,0517. Las curvas del proceso de entrenamiento se muestran en la Figura 39. En la Figura 40 se muestra la distribución de anomalías que relaciona la zona real de falla contra la zona que predice el modelo.

Curvas relacionadas al proceso de aprendizaje de red neuronal que clasifica fallas bifásicas



(BC) en el sistema IEEE34

Figura 40

Matriz de confusión para el conjunto de prueba de la red neuronal que clasifica fallas bifásicas (BC) en el sistema IEEE 34



En el proceso de evaluación, 21 eventos de fallas relacionadas a 10 puntos de simulación fueron mal clasificados sobre un total de 2835 anomalías del conjunto de prueba. Sin embargo, la totalidad de dichos eventos corresponde con la región límite de las zonas, lo que quiere decir que se trata del primer o segundo punto del área adyacente, por lo que no se consideran puntos críticos erróneamente clasificados.

6.14. Resultado del modelo de red neuronal para fallas tipo 6 (CA)

La estructura de la red neuronal artificial empleada para clasificar el tipo de falla CA se muestra en la Tabla 31. La taza de aprendizaje en los ciclos de entrenamiento fue de 0.001 y el algoritmo de optimización de los pesos sinápticos fue *Adaptive moment estimation*.

Tabla 31

Número de capa	Tipo de capa	Número de neuronas	Función de activación
1	Entrada	24	ReLU
2	Oculta	48	ReLU
3	Oculta	32	ReLU
4	Oculta	24	ReLU
5	Oculta	16	ReLU
6	Salida	10	Softmax

Estructura de red neuronal artificial para clasificar fallas tipo 6 (CA)

Se obtuvo una precisión de 0,9467 al evaluar el conjunto de prueba. Así mismo, el menor valor para la función de pérdida fue de 0,1302. Las curvas del proceso de entrenamiento se muestran en la Figura 41. En la Figura 42 se muestra la distribución de anomalías que relaciona la zona real de falla contra la zona que predice el modelo.

Curvas relacionadas al proceso de aprendizaje de red neuronal que clasifica fallas bifásicas



(CA) en el sistema IEEE34

Figura 42

Matriz de confusión para el conjunto de prueba de la red neuronal que clasifica fallas bifásicas

(CA) en el sistema IEEE 34



En el proceso de evaluación, 151 eventos de falla relacionadas a 35 puntos de simulación fueron mal clasificados sobre un total de 2835 anomalías del conjunto de prueba. Sin embargo, con análisis detallado se observó que solo 12 eventos relacionados a 4 puntos de simulación tuvieron una clasificación errónea crítica. Es decir, se trata de puntos lejanos de la zona de predicción. Por otro lado, los eventos restantes, aunque fueron mal clasificados, corresponden

con el primer o segundo puntos de la zona adyacente, lo que significa que hacen parte de la región límite. La sección con mayor problema en la tarea de clasificación de fallas es la zona 6, los puntos críticos se indican en la Figura 43. La información de dichos puntos se muestra en las Tablas 32-33.

Figura 43

Puntos críticos en la clasificación de fallas para el modelo de anomalías AC del sistema IEEE34



Tabla 32

Fallas críticas de la zona 6 que fueron predichas en la zona 7 del modelo para anomalías

bifásicas AC en el sistema IEEE34

Identificador de puntos de falla	Nodo inicial	Nodo final	Punto intermedio	Cantidad de fallas
8288302	828	830	2	5
8288303	828	830	3	4
8288304	828	830	4	2
8288301	828	830	1	1
Total				12
Tabla 33

Información de impedancias de fallas críticas de la zona 6 que fueron predichas en la zona 7 del modelo para anomalías bifásicas AC en el sistema IEEE34

Indicador	Cantidad
Fallas en total	12
Media [Ω]	20.4
Std [Ω]	2.7
Min [Ω]	17.0
Ρ ₂₅ [Ω]	18.8
Ρ ₅₀ [Ω]	19.8
Ρ ₇₅ [Ω]	22.9
Max [Ω]	24.5

6.15. Resultado del modelo de red neuronal para fallas tipo 7 (ABG)

La estructura de la red neuronal artificial empleada para clasificar el tipo de falla ABG se muestra en la Tabla 34. La taza de aprendizaje en los ciclos de entrenamiento fue de 0.001 y el algoritmo de optimización de los pesos sinápticos fue *Adaptive moment estimation*.

Tabla 34

Número de capa	Tipo de capa	Número de neuronas	Función de activación
1	Entrada	24	ReLU
2	Oculta	48	ReLU
3	Oculta	32	ReLU
4	Oculta	24	ReLU
5	Oculta	16	ReLU
6	Salida	10	Softmax

Estructura de red neuronal artificial para clasificar fallas tipo 7 (ABG)

Se obtuvo una precisión de 0,9700 al evaluar el conjunto de prueba. Así mismo, el menor valor para la función de pérdida fue de 0,0844. Las curvas del proceso de entrenamiento se muestran en la Figura 44. En la Figura 45 se muestra la distribución de anomalías que relaciona la zona real de falla contra la zona que predice el modelo.

Curvas relacionadas al proceso de aprendizaje de red neuronal que clasifica fallas bifásicas a tierra (ABG) en el sistema IEEE34



Figura 45

Matriz de confusión para el conjunto de prueba de la red neuronal que clasifica fallas bifásicas a tierra (ABG) en el sistema IEEE 34



En el proceso de evaluación, 85 eventos de falla relacionadas a 15 puntos de simulación fueron mal clasificados sobre un total de 2835 anomalías del conjunto de prueba. Sin embargo, la totalidad de dichos eventos corresponde con la región límite de las zonas, lo que quiere decir que se trata del primer o segundo punto del área adyacente, por lo que no se consideran puntos críticos erróneamente clasificados.

6.16. Resultado del modelo de red neuronal para fallas tipo 8 (BCG)

La estructura de la red neuronal artificial empleada para clasificar el tipo de falla BCG se muestra en la Tabla 35. La taza de aprendizaje en los ciclos de entrenamiento fue de 0.001 y el algoritmo de optimización de los pesos sinápticos fue *Adaptive moment estimation*.

Tabla 35

Número de capa	Tipo de capa	Número de neuronas	Función de activación
1	Entrada	24	ReLU
2	Oculta	16	ReLU
3	Oculta	12	ReLU
4	Oculta	10	ReLU
5	Salida	10	Softmax

Estructura de red neuronal artificial para clasificar fallas tipo 8 (BCG)

Se obtuvo una precisión de 0,9898 al evaluar el conjunto de prueba. Así mismo, el menor valor para la función de pérdida fue de 0,0479. Las curvas del proceso de entrenamiento se muestran en la Figura 46. En la Figura 47 se muestra la distribución de anomalías que relaciona la zona real de falla contra la zona que predice el modelo.

Curvas relacionadas al proceso de aprendizaje de red neuronal que clasifica fallas bifásicas a tierra (BCG) en el sistema IEEE34



Figura 47

Matriz de confusión para el conjunto de prueba de la red neuronal que clasifica fallas bifásicas a tierra (BCG) en el sistema IEEE 34



En el proceso de evaluación, 29 eventos de falla relacionadas a 9 puntos de simulación fueron mal clasificados sobre un total de 2835 anomalías del conjunto de prueba. Sin embargo, la totalidad de dichos eventos corresponde con la región límite de las zonas, lo que quiere decir que se trata del primer o segundo punto del área adyacente, por lo que no se consideran puntos críticos erróneamente clasificados.

6.17. Resultado del modelo de red neuronal para fallas tipo 9 (CAG)

La estructura de la red neuronal artificial empleada para clasificar el tipo de falla CAG se muestra en la Tabla 36. La taza de aprendizaje en los ciclos de entrenamiento fue de 0.001 y el algoritmo de optimización de los pesos sinápticos fue *Adaptive moment estimation*.

Tabla 36

Número de capa	Tipo de capa	Número de neuronas	Función de activación
1	Entrada	24	ReLU
2	Oculta	16	ReLU
3	Oculta	12	ReLU
4	Oculta	10	ReLU
5	Salida	10	Softmax

Estructura de red neuronal artificial para clasificar fallas tipo 9 (CAG)

Se obtuvo una precisión de 0,9771 al evaluar el conjunto de prueba. Así mismo, el menor valor para la función de pérdida fue de 0,0765. Las curvas del proceso de entrenamiento se muestran en la Figura 48. En la Figura 49 se muestra la distribución de anomalías que relaciona la zona real de falla contra la zona que predice el modelo.

Curvas relacionadas al proceso de aprendizaje de red neuronal que clasifica fallas bifásicas a tierra (CAG) en el sistema IEEE34



Figura 49

Matriz de confusión para el conjunto de prueba de la red neuronal que clasifica fallas bifásicas a tierra (CAG) en el sistema IEEE 34



En el proceso de evaluación, 65 eventos de falla relacionadas a 16 puntos de simulación fueron mal clasificados sobre un total de 2835 anomalías del conjunto de prueba. Sin embargo, la totalidad de dichos eventos corresponde con la región límite de las zonas, lo que quiere decir que se trata del primer o segundo punto del área adyacente, por lo que no se consideran puntos críticos erróneamente clasificados.

6.18. Resultado del modelo de red neuronal para fallas tipo 10 (ABC)

La estructura de la red neuronal artificial empleada para clasificar el tipo de falla ABC se muestra en la Tabla 37. La taza de aprendizaje en los ciclos de entrenamiento fue de 0.001 y el algoritmo de optimización de los pesos sinápticos fue *Adaptive moment estimation*.

Tabla 37

Número de capa	Tipo de capa	Número de neuronas	Función de activación
1	Entrada	24	ReLU
2	Oculta	16	ReLU
3	Oculta	12	ReLU
4	Oculta	10	ReLU
5	Salida	10	Softmax

Estructura de red neuronal artificial para clasificar fallas tipo 10 (ABC)

Se obtuvo una precisión de 0,9266 al evaluar el conjunto de prueba. Así mismo, el menor valor para la función de pérdida fue de 0,1843. Las curvas del proceso de entrenamiento se muestran en la Figura 50. En la Figura 51 se muestra la distribución de anomalías que relaciona la zona real de falla contra la zona que predice el modelo.

Curvas relacionadas al proceso de aprendizaje de red neuronal que clasifica fallas trifásicas



(ABC) en el sistema IEEE34

Figura 51

Matriz de confusión para el conjunto de prueba de la red neuronal que clasifica fallas trifásicas

(ABC) en el sistema IEEE 34



En el proceso de evaluación, 208 eventos de falla relacionadas a 40 puntos de simulación fueron mal clasificados sobre un total de 2835 anomalías del conjunto de prueba. Sin embargo, con análisis detallado se observó que solo 26 eventos relacionados a 11 puntos de simulación tuvieron una clasificación errónea crítica. Es decir, se trata de puntos lejanos de la zona de predicción. Por otro lado, los eventos restantes, aunque fueron mal clasificados, corresponden

con el primer o segundo puntos de la zona adyacente, lo que significa que hacen parte de la región límite. Las secciones con mayor problema en la tarea de clasificación de fallas son la zona 6; zona 7; zona 8; zona 9,los puntos críticos se indican en la Figura 52. La información de dichos puntos se muestra en las Tablas 38-43.

Figura 52

Puntos críticos en la clasificación de fallas para el modelo de anomalías ABC del sistema

IEEE34



Tabla 38

Fallas críticas de la zona 6 que fueron predichas en la zona 7 del modelo para anomalías

bifásicas AC en el sistema IEEE34

Identificador de puntos de falla	Nodo inicial	Nodo final	Punto intermedio	Cantidad de fallas
8288304	828	830	4	7
8288303	828	830	3	3
8288302	828	830	2	3
Total				13

Tabla 39

Información de impedancias de fallas críticas de la zona 6 que fueron predichas en la zona 7

del modelo para anomalías trifásicas ABC en el sistema IEEE34

Indicador	Cantidad
Fallas en total	13
Media [Ω]	20.8
Std [Ω]	19.1
Min [Ω]	0.0
Ρ ₂₅ [Ω]	1.0
Ρ ₅₀ [Ω]	34.0
Ρ ₇₅ [Ω]	38.5
Max [Ω]	40.0

Tabla 40

Fallas críticas de la zona 7 que fueron predichas en la zona 8 del modelo para anomalías

trifásicas ABC en el sistema IEEE34

Identificador de	Nodo inicial	Nodo final	Punto	Impedancia de
punto de falla		NOUO IIIIai	intermedio	falla [Ω]
8548522	854	852	2	38.5

Tabla 41

Fallas críticas de la zona 8 que fueron predichas en la zona 9 del modelo para anomalías

trifásicas ABC en el sistema IEEE34

Identificador de	Nodo inicial	Nodo final	Punto	Impedancia de
puntos de falla	NOUO INICIAI	NOUO IIInai	intermedio	falla [Ω]
85485218	854	852	18	40
85485218	854	852	18	37
85485219	854	852	19	39

Tabla 42

Fallas críticas de la zona 9 que fueron predichas en la zona 10 del modelo para anomalías

Identificador de puntos de falla	Nodo inicial	Nodo final	Punto intermedio	Cantidad de fallas
85485225	854	852	25	3
85485226	854	852	26	3
85485224	854	852	24	2
85485223	854	852	23	1
Total				9

trifásicas ABC en el sistema IEEE34

Tabla 43

Información de impedancias de fallas críticas de la zona 9 que fueron predichas en la zona 10

Indicador	Cantidad
Fallas en total	9
Media [Ω]	35.6
Std [Ω]	3.3
Min [Ω]	30.0
Ρ ₂₅ [Ω]	35.0
Ρ ₅₀ [Ω]	37.5
Ρ ₇₅ [Ω]	37.5
Max [Ω]	39.0

del modelo para anomalías trifásicas ABC en el sistema IEEE34

6.19. Resultado del modelo de red neuronal para fallas tipo 11 (ABCG)

La estructura de la red neuronal artificial empleada para clasificar el tipo de falla ABCG se muestra en la Tabla 44. La taza de aprendizaje en los ciclos de entrenamiento fue de 0.001 y el algoritmo de optimización de los pesos sinápticos fue *Adaptive moment estimation*.

Tabla 44

Número de capa	Tipo de capa	Número de neuronas	Función de activación
1	Entrada	24	ReLU
2	Oculta	16	ReLU
3	Oculta	12	ReLU
4	Oculta	10	ReLU
5	Salida	10	Softmax

Estructura de red neuronal artificial para clasificar fallas tipo 11 (ABCG)

Se obtuvo una precisión de 0,9414 al evaluar el conjunto de prueba. Así mismo, el menor valor para la función de pérdida fue de 0,1654. Las curvas del proceso de entrenamiento se muestran en la Figura 53. En la Figura 54 se muestra la distribución de anomalías que relaciona la zona real de falla contra la zona que predice el modelo.

Curvas relacionadas al proceso de aprendizaje de red neuronal que clasifica fallas trifásicas a tierra (ABCG) en el sistema IEEE34



Figura 54

Matriz de confusión para el conjunto de prueba de la red neuronal que clasifica fallas trifásicas a tierra (ABCG) en el sistema IEEE 34



En el proceso de evaluación, 166 eventos de falla relacionadas a 38 puntos de simulación fueron mal clasificados sobre un total de 2835 anomalías del conjunto de prueba. Sin embargo, con análisis detallado se observó que solo 8 eventos relacionados a 3 puntos de simulación tuvieron una clasificación errónea crítica. Es decir, se trata de puntos lejanos de la zona de predicción. Por otro lado, los eventos restantes, aunque fueron mal clasificados, corresponden

con el primer o segundo puntos de la zona adyacente, lo que significa que hacen parte de la región límite. La sección con mayor problema en la tarea de clasificación de fallas es la zona 9,los puntos críticos se indican en la Figura 55. La información de dichos puntos se muestra en las Tablas 45-46.

Figura 55

Puntos críticos en la clasificación de fallas para el modelo de anomalías ABCG del sistema

IEEE34



Tabla 45

Fallas críticas de la zona 9 que fueron predichas en la zona 10 del modelo para anomalías

Identificador de	Nodo inicial	Nodo final	Punto	Cantidad
puntos de falla		Nouo Illiai	intermedio	de fallas
85485226	854	852	26	4
85485225	854	852	25	3
85485224	854	852	24	1
Total				8

trifásicas ABC en el sistema IEEE34

Tabla 46

Información de impedancias de las fallas críticas de la zona 9 que fueron predichas en la zona

Indicador	Cantidad
Fallas en total	8
Media [Ω]	33.9
Std [Ω]	4.2
Min [Ω]	26.0
Ρ ₂₅ [Ω]	32.1
Ρ ₅₀ [Ω]	34.3
Ρ ₇₅ [Ω]	36.4
Max [Ω]	39.5

10 del modelo para anomalías trifásicas ABCG en el sistema IEEE34

7. Implementación de la metodología de localización zonas de falla en el sistema IEEE123

La metodología de la Figura 11, la cual consiste en : seleccionar el sistema de prueba, simular fallas, calcular los valores de entrada de las redes neuronales, dividir el sistema en parte, entrenar modelos de redes neuronales artificiales y por último la etapa de localización de fallas, fue implementada en el lenguaje de programación Python. El tratamiento de los datos fue a través de librerías de Numpy y Pandas y la conFiguración de los modelos de redes neuronales se realizó mediante la librería de Tensor Flow.

7.1. Modelado del sistema de prueba IEEE 123

El sistema de prueba IEEE 123 es una red con varios conmutadores que le permiten cambiar su topología. En este trabajo solo se utilizó la conFiguración de la Figura 56. La tensión nominal de operación es 4,16 kV. La red además de alimentadores trifásicos posee ramales monofásicos y bifásicos, en línea aérea y cables subterráneos. En el sistema hay reguladores y bancos de reactores. En cuanto a las cargas, solo hay modelos puntuales en la forma básica de potencia constante, corriente constante e impedancia constate.

7.2. Representaciones del sistema de prueba IEEE 123

Figura 56

Esquema del sistema IEEE 123 con longitud de alimentadores a escala.



7.3. Simulación de fallas en el sistema IEEE 123 barras

Se efectuó fallas de aislamiento en 171 puntos en todo el sistema, dependiendo el lugar, se simuló eventos de falla para cada tipo de anomalía con impedancias desde 0 Ω hasta 10 Ω en paso de 0.25 Ω . La Tabla 46 muestra la distribución de puntos de falla para cada tipo de anomalía.

Tabla 47

Tino falla	Fases implicadas	Puntos de	Simulaciones
		simulación de fallas	en total
1	AG	125	4794
2	BG	108	4092
3	CG	126	4889
4	AB	93	3813
5	BC	91	3749
6	CA	92	3772
7	ABG	93	3813
8	BCG	91	3713
9	CAG	92	3484
10	ABC	79	3239
Total		171	39358

Cantidad de puntos para la simulación de falla el sistema IEEE 34

7.4. Construcción de patrones de entrenamiento de las redes neuronales artificiales

En este trabajo, debido a la ausencia de componentes de distorsión y estados transitorios, el cálculo de los componentes superpuesto se realizó en el dominio de la frecuencia. A cada fasor de tensión o corriente de estado estable de falla se le restó el fasor antes de la condición de falla, la norma del elemento resultante es el componente superpuesto, como se muestra en la Figura 56. Por cada evento de simulación se construyeron ocho valores, cuatro componentes para la tensión y cuatro componentes para la corriente, estos valores se relacionan con las magnitudes por cada fase y el neutro. Los componentes superpuestos fueron normalizados. Por cada columna, a cada elemento se les restó el valor mínimo y luego se dividió entre el máximo

resultante. Como resultado, todas las columnas de los componentes superpuestos están en el rango de cero a uno. Los valores de un ejemplo de falla se muestran en la Tabla 48. Por otro lado, los componentes superpuestos relacionados con dicho evento de falla se muestran en la Tabla 49.

Tabla 48

Valores de tensión y corriente registrados en la subestación para una anomalía BC en el nodo 72 con una impedancia de falla de 0.25Ω

Condición	Va	θ_{Va}	Vb	θ_{Vb}	Vc	θ_{Vc}	la	β_{la}	lb	β _{lb}	Ic	β _{lc}
Prefalla	2494.6	-4.1	2547.5	-122.6	2531.3	116.7	640.8	-26.3	396.84	-141.2	499.81	98.3
Posfalla	2497.6	-34.2	2005.7	-170.1	1731.5	94.3	646.9	-55	2961.9	-172	2642.6	0.19

Tabla 49

Componentes superpuestos a partir de los valores de tensión y corriente registrados en la

subestación para una anomalía BC en el nodo 72 con una impedancia de falla de 0.25 Ω

Escala	CS_Va	CS_Vb	CS_Vc	CS_Vn	CS_la	CS_lb	CS_lc	CS_In
Magnitud real	1296.3	1899.7	1140.7	44.90	319.54	2705.8	2757.8	133
Magnitud normalizada	0.116	0.307	0.040	0.019	0.004	0.355	0.357	0.019

7.5. Criterio de división del sistema en partes

Basado en la experiencia de localización de fallas en el sistema IEEE34, también se probó un ejemplo con 10 zonas de clasificación de fallas para la falla tipo 1 (AG), la distribución de zonas se muestra en la Figura 57. Las curvas relacionadas al proceso de entrenamiento se muestran

en la Figura 58. El resultado no es muy bueno comparado con los modelos del sistema IEEE 34. En la Figura 59 se muestra la matriz de confusión, en ella se genera tres subregiones con los grupos {1,2,3 }, {4,5,6}, {7,8,9}, la formación de dicho patrón ayuda a descubrir un nuevo sistema de zonificación para el sistema, ver Figura 60.

Figura 57

Ejemplo de zonificación con 10 áreas para fallas monofasicas (AG) en el sistema IEEE 123



Figura 58

Curvas del proceso de entrenamiento del ejemplo de zonificación con 10 áreas para fallas monofasicas (AG) en el sistema IEEE 123



Figura 59

Matriz de confusión del conjuto de prueva del ejemplo de zonificación con 10 áreas para fallas monofasicas (AG) en el sistema IEEE 123



Figura 60

Sistema de zonificación adoptado para el sistema IEEE123



Tabla 50

Tipo de falla	Zona	Extensión [km]	Conjunto de entrenamiento	Conjunto de validación	Conjunto de prueba	Total
1	1	1.83	1054	75	305	1434
	2	1.83	1098	73	263	1434
	3	2.99	1445	88	393	1926
2	1	1.59	874	56	215	1145
	2	1.53	895	62	230	1187
	3	2.82	1304	84	372	1760
3	1	1.60	1058	77	262	1397
	2	1.58	940	68	266	1274
	3	3.59	1667	104	447	2218
4	1	1.51	969	65	237	1271
	2	1.35	722	56	206	984
	3	2.45	1168	70	320	1558
5	1	1.51	926	55	290	1277
	2	1.16	672	53	177	908
	3	2.45	1200	79	279	1564
6	1	1.61	971	56	244	1271
	2	1.24	795	52	219	1066
	3	2.31	1063	81	291	1435
7	1 2 3	1.15 1.43 2.53	963 727 1169	65 49 77	243 208 312	0 1271 984 1558
8	1	1.15	959	68	244	1265
	2	1.23	663	45	194	896
	3	2.45	1176	74	302	1552
9	1	1.15	731	59	194	984
	2	1.24	810	54	202	1066
	3	2.31	1069	63	302	1434
10	1	1.62	785	51	230	1066
	2	1.16	623	43	154	820
	3	2.31	1021	68	264	1353
	Total		29517	1970	7871	39358

Distribución de simulaciones de falla para sistema IEEE123

7.6. Resultado de modelo de red neuronal para fallas tipo 1 (AG)

La estructura de la red neuronal artificial empleada para clasificar el tipo de falla AG se muestra en la Tabla 51. La taza de aprendizaje en los ciclos de entrenamiento fue de 0.001 y el algoritmo de optimización de los pesos sinápticos fue *Adaptive moment estimation*.

Tabla 51

Número de capa	Tipo de capa	Número de neuronas	Función de activación
1	Entrada	16	ReLU
2	Oculta	8	ReLU
3	Oculta	6	ReLU
4	Oculta	3	ReLU
5	Salida	3	Softmax

Estructura de red neuronal artificial para clasificar fallas tipo 1 (AG) en el sistema IEEE123

Se obtuvo una precisión de 0,8512 al evaluar el conjunto de prueba. Así mismo, el menor valor para la función de pérdida fue de 0,3624. Las curvas del proceso de entrenamiento se muestran en la Figura 61. El detalle sobre la clasificación de los puntos de falla se muestra en la matriz de confusión de la Figura 62.

Curvas relacionadas al proceso de aprendizaje de red neuronal que clasifica fallas monofásicas



(AG) en el sistema IEEE123

Figura 62

Matriz de confusión para el conjunto de prueba de la red neuronal que clasifica fallas monofásicas (AG) en el sistema IEEE 123



En el proceso de evaluación, 143 eventos de falla relacionadas a 36 puntos de simulación fueron mal clasificados sobre un total de 961 anomalías del conjunto de prueba. Sin embargo, con análisis detallado se observó que solo 115 eventos relacionados a 27 puntos de simulación tuvieron una clasificación errónea crítica. Es decir, se trata de puntos lejanos de la zona de predicción. Por otro lado, los eventos restantes, aunque fueron mal clasificados, corresponden con el primer o segundo puntos de la zona adyacente, lo que significa que hacen parte de la

región límite. Los puntos críticos en la clasificación de zonas de fallas se muestran en la Figura

63. La información de dichos puntos se muestra en las Tablas desde número 52 al número 58.

Figura 63

Puntos críticos en la clasificación de fallas para el modelo de anomalías AG del sistema

IEEE123



Tabla 52

Fallas críticas de la zona 1 que fueron predichas en la zona 2 del modelo para anomalías

Identificador de puntos de falla	Cantidad de fallas
54	11
57601	11
57602	10
160	9

54571	8
57	8
56	7
60	7
60611	4
55	4
61	2
53	2
160671	1
67	1
Total	85

Tabla 53

Información de impedancias de fallas críticas de la zona 1 que fueron predichas en la zona 2

Identificador	Cantidad
Fallas en total	85
Media [Ω]	4.9
Std [Ω]	3.0
Min [Ω]	0.0
Ρ ₂₅ [Ω]	1.8
Ρ ₅₀ [Ω]	4.5
Ρ ₇₅ [Ω]	7.8
Max [Ω]	10.0

del modelo para anomalías monofásicas AG en el sistema IEEE123

Fallas de la zona 1 predichas en la zona 3

Tabla 54

Fallas críticas de la zona 1 que fueron predichas en la zona 3 del modelo para anomalías

Identificador de puntos de falla	Cantidad de fallas
70	8
71	7
61	2
Total	17

Tabla 55

Información de impedancias de fallas críticas de la zona 1 que fueron predichas en la zona 3 del modelo para anomalías monofásicas AG en el sistema IEEE123

Identificador de puntos de falla	Cantidad
Fallas en total	17
Media [Ω]	4.8
Std [Ω]	3.4
Min [Ω]	0.3
Ρ ₂₅ [Ω]	1.5
Ρ ₅₀ [Ω]	5.3
Ρ ₇₅ [Ω]	7.8
Max [Ω]	9.8

Tabla 56

Fallas críticas de la zona 2 que fueron predichas en la zona 1 del modelo para anomalías

Identificador de puntos de falla	Impedancia de falla [Ω]
50	0.25
51	1.25
151	5
511511	1.75

monofásicas AG en el sistema IEEE123

Fallas de la zona 2 predicha en la zona 3

Tabla 57

Fallas críticas de la zona 2 que fueron predichas en la zona 3 del modelo para anomalías

Identificador de puntos de falla	impedancia de falla [Ω]
250	0.5

50	0.5
30	0
51	0.5
151	1.5
36	0.75
511511	0

Tabla 58

Fallas críticas de la zona 3 que fueron predichas en la zona 1 del modelo para anomalías

Identificador de puntos de falla	impedancia de falla [Ω]
76771	10
98991	9.75

7.7. Resultado de modelo de red neuronal para fallas tipo 2 (BG)

La estructura de la red neuronal artificial empleada para clasificar el tipo de falla BG se muestra en la Tabla 59. La taza de aprendizaje en los ciclos de entrenamiento fue de 0.001 y el algoritmo de optimización de los pesos sinápticos fue *Adaptive moment estimation*.

Tabla 59

Número de capa	Tipo de capa	Número de neuronas	Función de activación
1	Entrada	16	ReLU
2	Oculta	8	ReLU
3	Oculta	6	ReLU
4	Oculta	3	ReLU
5	Salida	3	Softmax

Estructura de red neuronal artificial para clasificar fallas tipo 2 (BG) en el sistema IEEE123

Se obtuvo una precisión de 0,8225 al evaluar el conjunto de prueba. Así mismo, el menor valor para la función de pérdida fue de 0,3566. Las curvas del proceso de entrenamiento se muestran en la Figura 64. El detalle sobre la clasificación de los puntos de falla se muestra en la matriz de confusión de la Figura 65.

Curvas relacionadas al proceso de aprendizaje de red neuronal que clasifica fallas monofásicas



(BG) en el sistema IEEE123

Figura 65

Matriz de confusión para el conjunto de prueba de la red neuronal que clasifica fallas monofásicas (BG) en el sistema IEEE 123



En el proceso de evaluación, 145 eventos de falla relacionadas a 32 puntos de simulación fueron mal clasificados sobre un total de 817 anomalías del conjunto de prueba. Sin embargo, con análisis detallado se observó que solo 87 eventos relacionados a 24s puntos de simulación tuvieron una clasificación errónea crítica. Es decir, se trata de puntos lejanos de la zona de predicción. Por otro lado, los eventos restantes, aunque fueron mal clasificados, corresponden con el primer o segundo puntos de la zona adyacente, lo que significa que hacen parte de la

región límite. Los puntos críticos en la clasificación de zonas de fallas se muestran en la Figura

63. La información de dichos puntos se muestra en las Tablas desde número 60 al número 64.

Figura 66

Puntos críticos en la clasificación de fallas para el modelo de anomalías BG del sistema

IEEE123



Tabla 60

Fallas críticas de la zona1 que fueron predichas en la zona 2 del modelo para anomalías

Identificador de puntos de falla	Cantidad de fallas
57601	10
59	9
58	8
57602	8
57	7
56	6
54571	5

61	5
55	4
54	3
60611	3
52	1
Total	69

Tabla 61

Información de impedancias de fallas críticas de la zona 1 que fueron predichas en la zona 2

Indicador	Cantidad
Fallas en total	70
Media [Ω]	6
Std [Ω]	2.9
Min [Ω]	0.0
Ρ ₂₅ [Ω]	3.3
Ρ ₅₀ [Ω]	6.1
Ρ ₇₅ [Ω]	8.3
Max [Ω]	10.0

del modelo para anomalías monofásicas BG en el sistema IEEE123

Tabla 62

Fallas críticas de la zona 1 que fueron predichas en la zona 3 del modelo para anomalías

Identificador de puntos de falla	impedancia de falla [Ω]
60611	7.5
60611	7
60611	7.75
61	4.25
61	6.5
61	7

monofásicas BG en el sistema IEEE123

Tabla 63

Fallas críticas de la zona 2 que fueron predichas en la zona 1 del modelo para anomalías

monofásicas BG en el sistema IEEE123

Identificador de puntos de falla	impedancia de falla [Ω]
23	7.25
23	6.25
23	2
40	2
21221	2
35	2.25
25	7

Tabla 64

Fallas críticas de la zona 2 que fueron predichas en la zona 3 del modelo para anomalías

Identificador de puntos de falla	impedancia de falla [Ω]
51	5.25
51	5
151	8.25
151	6.5
50	6.5

7.8. Resultado de modelo de red neuronal para fallas tipo 3 (CG)

La estructura de la red neuronal artificial empleada para clasificar el tipo de falla CG se muestra en la Tabla 65. La taza de aprendizaje en los ciclos de entrenamiento fue de 0.001 y el algoritmo de optimización de los pesos sinápticos fue *Adaptive moment estimation*.

Tabla 65

Número de capa	Tipo de capa	Número de neuronas	Función de activación
1	Entrada	12	ReLU
2	Oculta	9	ReLU
3	Oculta	6	ReLU
4	Oculta	3	ReLU
5	Salida	3	Softmax

Estructura de red neuronal artificial para clasificar fallas tipo 3 (CG) en el sistema IEEE123

Se obtuvo una precisión de 0,8564 al evaluar el conjunto de prueba. Así mismo, el menor valor para la función de pérdida fue de 0,3136. Las curvas del proceso de entrenamiento se muestran en la Figura 67. El detalle sobre la clasificación de los puntos de falla se muestra en la matriz de confusión de la Figura 68.

Curvas relacionadas al proceso de aprendizaje de red neuronal que clasifica fallas monofásicas



(CG) en el sistema IEEE123

Figura 68

Matriz de confusión para el conjunto de prueba de la red neuronal que clasifica fallas monofásicas (CG) en el sistema IEEE 123



En el proceso de evaluación, 140 eventos de falla relacionadas a 28 puntos de simulación fueron mal clasificados sobre un total de 975 anomalías del conjunto de prueba. Sin embargo, con análisis detallado se observó que solo 91 eventos relacionados a 23 puntos de simulación tuvieron una clasificación errónea crítica. Es decir, se trata de puntos lejanos de la zona de predicción. Por otro lado, los eventos restantes, aunque fueron mal clasificados, corresponden con el primer o segundo puntos de la zona adyacente, lo que significa que hacen parte de la

región límite. Los puntos críticos en la clasificación de zonas de fallas se muestran en la Figura

69. La información de dichos puntos se muestra en las Tablas desde número 66 al número 71.

Figura 69

Puntos críticos en la clasificación de fallas para el modelo de anomalías CG del sistema

IEEE123



Tabla 66

Fallas críticas de la zona 1 que fueron predichas en la zona 2 del modelo para anomalías

Identificador de puntos de falla	Cantidad de fallas
57602	11
57	10
54	7
56	7
160	6
55	6
54571	6
--------	---
57601	5
160671	4
60	4
60611	2
15171	1
53	1
Total	

Tabla 67

Rango de impedancias de fallas críticas de la zona 1 que fueron predichas en la zona 2 del

Indicador	Cantidad
Fallas en total	70
Media [Ω]	5.0
Std [Ω]	3.1
Min [Ω]	0.0
Ρ ₂₅ [Ω]	2.3
Ρ ₅₀ [Ω]	5.0
Ρ ₇₅ [Ω]	7.9
Max [Ω]	10.0

modelo para anomalías monofásicas CG en el sistema IEEE123

Tabla 68

Fallas críticas de la zona 1 que fueron predichas en la zona 3 del modelo para anomalías

monofásicas CG en el sistema IEEE123

Identificador de puntos de falla	Cantidad de fallas
61	13
60611	7

Tabla 69

Información de impedancias de fallas críticas de la zona 1 que fueron predichas en la zona 3

Indicador	Cantidad
Fallas en total	20
Media [Ω]	3.6
Std [Ω]	2.7
Min [Ω]	0.3
Ρ ₂₅ [Ω]	1.4
Ρ ₅₀ [Ω]	3.0
Ρ ₇₅ [Ω]	6.0
Max [Ω]	8.8

del modelo para anomalías monofásicas CG en el sistema IEEE123

Tabla 70

Fallas críticas de la zona 2 que fueron predichas en la zona 1 del modelo para anomalías

monofásicas	CG	en e	l sistema	IEEE	123

Identificador de puntos de falla	impedancia de falla [Ω]
151	7.75
151	1.5
511511	3.25
511511	1.5
25	6.75
40	6
51	9
25261	8

Tabla 71

Fallas críticas de la zona 2 que fueron predichas en la zona 3 del modelo para anomalías

Identificador de puntos de falla	impedancia de falla [Ω]
151	3
151	4.25
151	8
151	8.5
151	0.5

monofásicas CG en el sistema IEEE123

151	0.75
151	7.5
511511	5.75
511511	6.5
511511	6.25
511511	8

7.9. Resultado de modelo de red neuronal para fallas tipo 4 (AB)

La estructura de la red neuronal artificial empleada para clasificar el tipo de falla BG se muestra en la Tabla 72. La taza de aprendizaje en los ciclos de entrenamiento fue de 0.001 y el algoritmo de optimización de los pesos sinápticos fue *Adaptive moment estimation*.

Tabla 72

Estructura de red neuronal artificial para clasificar fallas tipo 4 (AB) en el sistema IEEE123

Número de capa	Tipo de capa	Número de neuronas	Función de activación
1	Entrada	16	ReLU
2	Oculta	14	ReLU
3	Oculta	12	ReLU
4	Oculta	8	ReLU
5	Oculta	6	ReLU
6	Oculta	3	ReLU
7	Salida	3	Softmax

Se obtuvo una precisión de 0,8388 al evaluar el conjunto de prueba. Así mismo, el menor valor para la función de pérdida fue de 0,3429. Las curvas del proceso de entrenamiento se muestran en la Figura 70. El detalle sobre la clasificación de los puntos de falla se muestra en la matriz de confusión de la Figura 71.

Figura 70

Curvas relacionadas al proceso de aprendizaje de red neuronal que clasifica fallas bifásicas



(AB) en el sistema IEEE123

Figura 71

Matriz de confusión para el conjunto de prueba de la red neuronal que clasifica fallas bifásicas (AB) en el sistema IEEE 123



En el proceso de evaluación, 123 eventos de falla relacionadas a 35 puntos de simulación fueron mal clasificados sobre un total de 763 anomalías del conjunto de prueba. Sin embargo, con análisis detallado se observó que solo 112 eventos relacionados a 34 puntos de simulación tuvieron una clasificación errónea crítica. Es decir, se trata de puntos lejanos de la zona de predicción. Por otro lado, los eventos restantes, aunque fueron mal clasificados, corresponden con el primer o segundo puntos de la zona adyacente, lo que significa que hacen parte de la

región límite. Los puntos críticos en la clasificación de zonas de fallas se muestran en la Figura

72. La información de dichos puntos se muestra en las Tablas desde número 73 al número 80.

Figura 72

Puntos críticos en la clasificación de fallas para el modelo de anomalías AB del sistema

IEEE123



Tabla 73

Fallas críticas de la zona 1 que fueron predichas en la zona 2 del modelo para anomalías

bifásicas AE	l en el	sistema	IEEE123
--------------	---------	---------	---------

Identificador de puntos de falla	Cantidad de fallas
57	9
54571	8
56	8
57601	8
53	7

6
5
4
4
3
3
3
3
1
1
73

Tabla 74

Información de impedancias de fallas críticas de la zona 1 que fueron predichas en la zona 2 del modelo para anomalías bifásicas AB en el sistema IEEE123

Indicador	Cantidad
Fallas en total	73
Media [Ω]	4.9
Std [Ω]	2.6
Min [Ω]	0.0
Ρ ₂₅ [Ω]	3.3
Ρ ₅₀ [Ω]	4.5
Ρ ₇₅ [Ω]	7.0
Max [Ω]	9.8

Tabla 75

Fallas críticas de la zona 1 que fueron predichas en la zona 3 del modelo para anomalías

bifásicas AB en el sistema IEEE123

Identificador de puntos de falla	Cantidad de fallas
64651	4
64	3
66	2
65	2
Total	11

Tabla 76

Información de impedancias de fallas críticas de la zona 1 que fueron predichas en la zona 3

Indicador	Cantidad
Fallas en total	11
Media [Ω]	1.5
Std [Ω]	1.1
Min [Ω]	0.0
Ρ ₂₅ [Ω]	0.5
Ρ ₅₀ [Ω]	1.8
Ρ ₇₅ [Ω]	2.4
Max [Ω]	3.0

del modelo para anomalías bifásicas AB en el sistema IEEE123

Tabla 77

Fallas críticas de la zona 2 que fueron predichas en la zona 1 del modelo para anomalías

bifásicas AB en el sistema IEEE123

Identificador de puntos de falla	Cantidad de fallas
49	3
50	2
47	2
30	1
151	1
28	1
36	1
250	1
29	1
Total	13

Tabla 78

Información de impedancias de fallas críticas de la zona 2 que fueron predichas en la zona 1

del modelo para anomalías bifásicas AB en el sistema IEEE123

Indicador	Cantidad
Fallas en total	13

Media [Ω]	1.8
Std [Ω]	1.2
Min [Ω]	0.5
Ρ ₂₅ [Ω]	1.0
Ρ ₅₀ [Ω]	1.3
Ρ ₇₅ [Ω]	2.5
Max [Ω]	4.5

Tabla 79

Fallas críticas de la zona 2 que fueron predichas en la zona 3 del modelo para anomalías

Identificador de puntos de falla	Cantidad de fallas
511511	4
50	3
250	3
151	2
51	2
30	1
Total	15

bifásicas AB en el sistema IEEE123

Tabla 80

Información de impedancias de fallas críticas de la zona 2 que fueron predichas en la zona 3

del modelo para anomalías bifásicas AB en el sistema IEEE123

Indicador	Cantidad
Fallas en total	15
Media [Ω]	1.4
Std [Ω]	1.0
Min [Ω]	0.0
Ρ ₂₅ [Ω]	0.6
Ρ ₅₀ [Ω]	1.3
Ρ ₇₅ [Ω]	2.3
Max [Ω]	3.0

7.10. Resultado de modelo de red neuronal para fallas tipo 5 (BC)

La estructura de la red neuronal artificial empleada para clasificar el tipo de falla BG se muestra en la Tabla 81. La taza de aprendizaje en los ciclos de entrenamiento fue de 0.001 y el algoritmo de optimización de los pesos sinápticos fue *Adaptive moment estimation*.

Tabla 81

Número de capa	Tipo de capa	Número de neuronas	Función de activación
1	Entrada	16	ReLU
2	Oculta	14	ReLU
3	Oculta	12	ReLU
4	Oculta	8	ReLU
5	Oculta	6	ReLU
6	Oculta	3	ReLU
7	Salida	3	Softmax

Estructura de red neuronal artificial para clasificar fallas tipo 5 (BC) en el sistema IEEE123

Se obtuvo una precisión de 0,7735 al evaluar el conjunto de prueba. Así mismo, el menor valor para la función de pérdida fue de 0,4534. Las curvas del proceso de entrenamiento se muestran en la Figura 73. El detalle sobre la clasificación de los puntos de falla se muestra en la matriz de confusión de la Figura 74.

Figura 73

Curvas relacionadas al proceso de aprendizaje de red neuronal que clasifica fallas bifásicas



(BC) en el sistema IEEE123

Figura 74

Matriz de confusión para el conjunto de prueba de la red neuronal que clasifica fallas bifásicas (BC) en el sistema IEEE 123



En el proceso de evaluación, 169 eventos de falla relacionadas a 45 puntos de simulación fueron mal clasificados sobre un total de 764 anomalías del conjunto de prueba. Sin embargo, con análisis detallado se observó que solo 133 eventos relacionados a 53 puntos de simulación tuvieron una clasificación errónea crítica. Es decir, se trata de puntos lejanos de la zona de predicción. Por otro lado, los eventos restantes, aunque fueron mal clasificados, corresponden con el primer o segundo puntos de la zona adyacente, lo que significa que hacen parte de la

región límite. Los puntos críticos en la clasificación de zonas de fallas se muestran en la Figura

75. La información de dichos puntos se muestra en las Tablas desde número 82 al número 88.

Figura 75

Puntos críticos en la clasificación de fallas para el modelo de anomalías BC del sistema

IEEE123



Tabla 82

Fallas críticas de la zona 1 que fueron predichas en la zona 2 del modelo para anomalías

bifásicas BC en el sistema IEEE123

Identificador de puntos de falla	Cantidad de fallas
63641	7
53	5
54571	5

160	4
66	4
62	4
56	4
60	3
57	3
60611	3
52	3
61	3
57602	3
65	2
160671	2
64651	2
54	2
64	2
63	2
55	2
Total	65

Tabla 83

Información de impedancias de fallas críticas de la zona 1 que fueron predichas en la zona 2

del modelo para anomalías bifásicas BC en el sistema IEEE123

Indicador	Cantidad
Fallas en total	65
Media [Ω]	4.9
Std [Ω]	2.7
Min [Ω]	0.0
Ρ ₂₅ [Ω]	2.8
Ρ ₅₀ [Ω]	5.3
Ρ ₇₅ [Ω]	6.8
Max [Ω]	10.0

Tabla 84

Fallas críticas de la zona 1 que fueron predichas en la zona 3 del modelo para anomalías

Identificador de puntos de falla	Cantidad de fallas
65	4
61	3
64	2
66	1
63641	1
610	1
Total	12

bifásicas BC en el sistema IEEE123

Tabla 85

Información de impedancias de fallas críticas de la zona 1 que fueron predichas en la zona 3

Indicador	Cantidad
Fallas en total	12
Media [Ω]	0.6
Std [Ω]	0.5
Min [Ω]	0.0
Ρ ₂₅ [Ω]	0.3
Ρ ₅₀ [Ω]	0.6
Ρ ₇₅ [Ω]	0.8
Max [Ω]	1.5

del modelo para anomalías bifásicas BC en el sistema IEEE123

Tabla 86

Fallas críticas de la zona 2 que fueron predichas en la zona 1 del modelo para anomalías

bifásicas BC en el sistema IEEE123

Identificador de puntos de falla	Cantidad de fallas
35	5
40	5
28	4

151	4
29301	3
25	3
23	3
511511	2
29	2
44	2
48	1
51	1
50	1
49	1
250	1
30	1
42	1
Total	40

Tabla 87

Información de impedancias de fallas críticas de la zona 2 que fueron predichas en la zona 1

del modelo para anomalías bifásicas BC en el sistema IEEE123

Indicador	Cantidad
Fallas en total	40
Media [Ω]	4.8
Std [Ω]	2.559046
Min [Ω]	0.5
Ρ ₂₅ [Ω]	2.75
Ρ ₅₀ [Ω]	4.125
Ρ ₇₅ [Ω]	6.1875
Max [Ω]	9.75

Tabla e

Fallas críticas de la zona 2 que fueron predichas en la zona 3 del modelo para anomalías

bifásicas BC en el sistema IEEE123

Identificador de puntos de falla Cantidad de fallas

49	3
30	2
50	2
51	2
48	2
29301	2
250	1
511511	1
151	1
Total	16

Tabla 88

Información de impedancias de fallas críticas de la zona 2 que fueron predichas en la zona 3

Indicador	Cantidad
Fallas en total	16
Media [Ω]	1.0
Std [Ω]	0.6
Min [Ω]	0.0
Ρ ₂₅ [Ω]	0.7
Ρ ₅₀ [Ω]	1.0
Ρ ₇₅ [Ω]	1.6
Max [Ω]	2.0

del modelo para anomalías bifásicas BC en el sistema IEEE123

7.11. Resultado de modelo de red neuronal para fallas tipo 6 (CA)

La estructura de la red neuronal artificial empleada para clasificar el tipo de falla CA se muestra en la Tabla 89. La taza de aprendizaje en los ciclos de entrenamiento fue de 0.001 y el algoritmo de optimización de los pesos sinápticos fue *Adaptive moment estimation*.

Tabla 89

Estructura de red neuronal artificial para clasificar fallas tipo 4 (AB) en el sistema IEEE123

Número de capa	Tipo de capa	Número de neuronas	Función de activación
1	Entrada	12	ReLU
2	Oculta	6	ReLU
3	Oculta	3	ReLU
4	Salida	3	Softmax

Se obtuvo una precisión de 0,7772 al evaluar el conjunto de prueba. Así mismo, el menor valor para la función de pérdida fue de 0,4753. Las curvas del proceso de entrenamiento se muestran en la Figura 76. El detalle sobre la clasificación de los puntos de falla se muestra en la matriz de confusión de la Figura 77.

Figura 76

Curvas relacionadas al proceso de aprendizaje de red neuronal que clasifica fallas bifásicas



(CA) en el sistema IEEE123

Figura 77

Matriz de confusión para el conjunto de prueba de la red neuronal que clasifica fallas bifásicas (CA) en el sistema IEEE 123



En el proceso de evaluación, 168 eventos de falla relacionadas a 43 puntos de simulación fueron mal clasificados sobre un total de 754 anomalías del conjunto de prueba. Sin embargo, con análisis detallado se observó que solo 144 eventos relacionados a 40 puntos de simulación tuvieron una clasificación errónea crítica. Es decir, se trata de puntos lejanos de la zona de predicción. Por otro lado, los eventos restantes, aunque fueron mal clasificados, corresponden con el primer o segundo puntos de la zona adyacente, lo que significa que hacen parte de la

región límite. Los puntos críticos en la clasificación de zonas de fallas se muestran en la Figura 78. La información de dichos puntos se muestra en las Tablas desde número 90 al número 97.

Figura 78

Puntos críticos en la clasificación de fallas para el modelo de anomalías CA del sistema

IEEE123



Tabla 90

Fallas críticas de la zona 1 que fueron predichas en la zona 2 del modelo para anomalías

bifásicas CA en el sistema IEEE123

Identificador de puntos de falla

Cantidad de fallas

56	13
57602	10
55	9
54571	8
57601	6
57	5
53	5
60	4
160	4
63	3
54	3
62	2
52	2
152	1
60611	1
610	1
160671	1
Total	78

Tabla 91

Información de impedancias de fallas críticas de la zona 1 que fueron predichas en la zona 2

del modelo para anomalías bifásicas CA en el sistema IEEE123

Indicador	Cantidad
Fallas en total	78
Media [Ω]	4.4
Std [Ω]	3.5
Min [Ω]	0.0
Ρ ₂₅ [Ω]	0.8
Ρ ₅₀ [Ω]	3.8
Ρ ₇₅ [Ω]	7.4
Max [Ω]	10.0

Tabla 92

Fallas críticas de la zona 1 que fueron predichas en la zona 3 del modelo para anomalías

Identificador de puntos de falla	Cantidad de fallas
66	3
64	2
65	1
610	1
61	1
64651	1
Total	9

bifásicas CA en el sistema IEEE123

Tabla 93

Información de impedancias de fallas críticas de la zona 1 que fueron predichas en la zona 3

Indicador	Cantidad
Fallas en total	9
Media [Ω]	1.8
Std [Ω]	1.7
Min [Ω]	0.0
Ρ ₂₅ [Ω]	0.0
Ρ ₅₀ [Ω]	2.0
Ρ ₇₅ [Ω]	3.3
Max [Ω]	4.0

del modelo para anomalías bifásicas CA en el sistema IEEE123

Tabla 94

Fallas críticas de la zona 2 que fueron predichas en la zona 1 del modelo para anomalías

bifásicas CA en el sistema IEEE123

Cantidad de fallas
7

7
5
5
4
4
4
3
2
1
1
1
1
45

Tabla 95

Información de impedancias de fallas críticas de la zona 2 que fueron predichas en la zona 1

Indicador	Cantidad
Fallas en total	45
Media [Ω]	5.5
Std [Ω]	3.0
Min [Ω]	0.0
Ρ ₂₅ [Ω]	2.8
Ρ ₅₀ [Ω]	6.0
Ρ ₇₅ [Ω]	8.0
Max [Ω]	9.5

del modelo para anomalías bifásicas CA en el sistema IEEE123

Tabla 96

Fallas críticas de la zona 2 que fueron predichas en la zona 3 del modelo para anomalías

Identificador de puntos de falla	Cantidad de fallas
151	5
51	3
50	2
511511	2

bifásicas CA en el sistema IEEE123

Total	12

Tabla 97

Información de impedancias de fallas críticas de la zona 2 que fueron predichas en la zona 3

Indicador	Cantidad
Fallas en total	12
Media [Ω]	1.1
Std [Ω]	0.8
Min [Ω]	0.0
Ρ ₂₅ [Ω]	0.4
Ρ ₅₀ [Ω]	1.3
Ρ ₇₅ [Ω]	1.8
Max [Ω]	2.3

del modelo para anomalías bifásicas CA en el sistema IEEE123

7.12. Resultado de modelo de red neuronal para fallas tipo 7 (ABG)

La estructura de la red neuronal artificial empleada para clasificar el tipo de falla ABG se muestra en la Tabla 98. La taza de aprendizaje en los ciclos de entrenamiento fue de 0.001 y el algoritmo de optimización de los pesos sinápticos fue *Adaptive moment estimation*.

Tabla 98

Número de capa	Tipo de capa	Número de neuronas	Función de activación
1	Entrada	12	ReLU
2	Oculta	9	ReLU
3	Oculta	8	ReLU
4	Oculta	6	ReLU
5	Oculta	3	ReLU
6	Salida	3	Softmax

Estructura de red neuronal artificial para clasificar fallas tipo 7 (ABG) en el sistema IEEE123

Se obtuvo una precisión de 0,8611 al evaluar el conjunto de prueba. Así mismo, el menor valor para la función de pérdida fue de 0,3146. Las curvas del proceso de entrenamiento se muestran en la Figura 79. El detalle sobre la clasificación de los puntos de falla se muestra en la matriz de confusión de la Figura 80.

Figura 79

Curvas relacionadas al proceso de aprendizaje de red neuronal que clasifica fallas bifásicas a tierra (ABG) en el sistema IEEE123



Figura 80

Matriz de confusión para el conjunto de prueba de la red neuronal que clasifica fallas bifásicas a tierra (ABG) en el sistema IEEE 123



En el proceso de evaluación, 106 eventos de falla relacionadas a 31 puntos de simulación fueron mal clasificados sobre un total de 763 anomalías del conjunto de prueba. Sin embargo, con análisis detallado se observó que solo 77 eventos relacionados a 20 puntos de simulación tuvieron una clasificación errónea crítica. Es decir, se trata de puntos lejanos de la zona de predicción. Por otro lado, los eventos restantes, aunque fueron mal clasificados, corresponden con el primer o segundo puntos de la zona adyacente, lo que significa que hacen parte de la

región límite. Los puntos críticos en la clasificación de zonas de fallas se muestran en la Figura

81. La información de dichos puntos se muestra en las Tablas desde número 99 al número 103.

Figura 81

Puntos críticos en la clasificación de fallas para el modelo de anomalías ABG del sistema

IEEE123



Tabla 99

Fallas críticas de la zona 1 que fueron predichas en la zona 2 del modelo para anomalías

Identificador de puntos de falla	Cantidad de fallas
57	10
54	8
55	8
56	8
53	7

bifásicas ABG en el sistema IEEE123

52	6
54571	6
57601	4
57602	3
13	1
61	1
Total	62

Tabla 100

Información de impedancias de fallas críticas de la zona 1 que fueron predichas en la zona 2

Indicador	Cantidad
Fallas en total	62
Media [Ω]	4.9
Std [Ω]	3.4
Min [Ω]	0.0
Ρ ₂₅ [Ω]	1.6
Ρ ₅₀ [Ω]	5.3
Ρ ₇₅ [Ω]	8.0
Max [Ω]	10.0

del modelo para anomalías bifásicas ABG en el sistema IEEE123

Tabla 101

Fallas críticas de la zona 2 que fueron predichas en la zona 1 del modelo para anomalías

bifásicas ABG en el sistema IEEE123

Identificador de puntos de falla	Cantidad de fallas
511511	3
151	3
35	2
30	1
250	1
50	1
51	1
Total	12

Tabla 102

Información de impedancias de fallas críticas de la zona 2 que fueron predichas en la zona 1

Indicador	Cantidad
Fallas en total	12
Media [Ω]	4.3
Std [Ω]	3.7
Min [Ω]	0.8
Ρ ₂₅ [Ω]	1.4
Ρ ₅₀ [Ω]	2.4
Ρ ₇₅ [Ω]	7.4
Max [Ω]	10.0

del modelo para anomalías bifásicas ABG en el sistema IEEE123

Tabla 103

Fallas críticas de la zona 3 que fueron predichas en la zona 2 del modelo para anomalías

bifásicas ABG en el sistema IEEE123

Identificador de puntos de falla	impedancia de falla [Ω]
197	0
197	0.25
67	0.5

7.13. Resultado de modelo de red neuronal para fallas tipo 8 (BCG)

La estructura de la red neuronal artificial empleada para clasificar el tipo de falla BCG se muestra en la Tabla 104. La taza de aprendizaje en los ciclos de entrenamiento fue de 0.001 y el algoritmo de optimización de los pesos sinápticos fue *Adaptive moment estimation*.

Tabla 104

Número de capa	Tipo de capa	Número de neuronas	Función de activación
1	Entrada	16	ReLU
2	Oculta	8	ReLU
3	Oculta	6	ReLU
4	Oculta	3	ReLU
5	Salida	3	Softmax

Estructura de red neuronal artificial para clasificar fallas tipo 8 (BCG) en el sistema IEEE123

Se obtuvo una precisión de 0,8405 al evaluar el conjunto de prueba. Así mismo, el menor valor para la función de pérdida fue de 0,4035. Las curvas del proceso de entrenamiento se muestran en la Figura 82. El detalle sobre la clasificación de los puntos de falla se muestra en la matriz de confusión de la Figura 83.

Figura 82

Curvas relacionadas al proceso de aprendizaje de red neuronal que clasifica fallas bifásicas a tierra (BCG) en el sistema IEEE123



Figura 83

Matriz de confusión para el conjunto de prueba de la red neuronal que clasifica fallas bifásicas a tierra (BCG) en el sistema IEEE 123



En el proceso de evaluación, 119 eventos de falla relacionadas a 39 puntos de simulación fueron mal clasificados sobre un total de 746 anomalías del conjunto de prueba. Sin embargo, con análisis detallado se observó que solo 81 eventos relacionados a 33 puntos de simulación tuvieron una clasificación errónea crítica. Es decir, se trata de puntos lejanos de la zona de predicción. Por otro lado, los eventos restantes, aunque fueron mal clasificados, corresponden con el primer o segundo puntos de la zona adyacente, lo que significa que hacen parte de la

región límite. Los puntos críticos en la clasificación de zonas de fallas se muestran en la Figura

84. La información de dichos puntos se muestra en las Tablas desde número 105 al número 111.

Figura 84

Puntos críticos en la clasificación de fallas para el modelo de anomalías BCG del sistema

IEEE123



Tabla 105

Fallas críticas de la zona 1 que fueron predichas en la zona 2 del modelo para anomalías

Identificador de puntos de falla	Cantidad de fallas
57	11
54571	7
56	7
55	6
57601	4
57602	3
52	2
53	2

bifásicas BCG en el sistema IEEE123

160	1
60	1
160671	1
54	1
Total	46

Tabla 106

Información de impedancias de fallas críticas de la zona 1 que fueron predichas en la zona 2

Indicador	Cantidad
Fallas en total	46
Media [Ω]	4.7
Std [Ω]	2.9
Min [Ω]	0.0
Ρ ₂₅ [Ω]	2.3
Ρ ₅₀ [Ω]	4.0
Ρ ₇₅ [Ω]	7.0
Max [Ω]	10.0

del modelo para anomalías bifásicas BCG en el sistema IEEE123

Tabla 107

Fallas críticas de la zona 2 que fueron predichas en la zona 1 del modelo para anomalías

bifásicas BCG en el sistema IEEE123

Identificador de puntos de falla	Cantidad de fallas
29301	4
35	3
40	2
151	2
50	2
511511	2
51	2
23	1
30	1
250	1
47	1
48	1

29	1
Total	23

Tabla 108

Información de impedancias de fallas críticas de la zona 2 que fueron predichas en la zona 1

del modelo pa	ra anomalías	bifásicas	BCG en	el sistema	IEEE123
---------------	--------------	-----------	--------	------------	---------

Indicador	Cantidad
Fallas en total	23
Media [Ω]	3.7
Std [Ω]	2.7
Min [Ω]	0.3
Ρ ₂₅ [Ω]	1.3
Ρ ₅₀ [Ω]	3.5
Ρ ₇₅ [Ω]	5.5
Max [Ω]	8.8

Tabla 109

Fallas críticas de la zona 2 que fueron predichas en la zona 3 del modelo para anomalías

Identificador de puntos de falla	impedancia de falla [Ω]
151	1.5
151	1.75
50	1.25
50	0
30	0
250	0.5
511511	1

bifásicas BCG en el sistema IEEE123

Tabla 110

Fallas críticas de la zona 3 que fueron predichas en la zona 1 del modelo para anomalías

bifásicas BCG en el sistema IEEE123

Identificador de puntos de falla impedancia de falla [Ω]

76	1
76	0.25
76	0.75
98	1

Tabla 111

Fallas críticas de la zona 3 que fueron predichas en la zona 2 del modelo para anomalías

bifásicas BCG en el sistema IEEE123

Identificador de puntos de falla	impedancia de falla [Ω]
67	0
67	0.75
67	0.25

7.14. Resultado de modelo de red neuronal para fallas tipo 9 (CAG)

La estructura de la red neuronal artificial empleada para clasificar el tipo de falla CAG se muestra en la Tabla 112. La taza de aprendizaje en los ciclos de entrenamiento fue de 0.001 y el algoritmo de optimización de los pesos sinápticos fue *Adaptive moment estimation*.

Tabla 112

Estructura de red neuronal artificial para clasificar fallas tipo 9 (CAG) en el sistema IEEE123

Número de capa	Tipo de capa	Número de neuronas	Función de activación
1	Entrada	16	ReLU
2	Oculta	8	ReLU
3	Oculta	6	ReLU
4	Oculta	3	ReLU
5	Salida	3	Softmax

Se obtuvo una precisión de 0,8238 al evaluar el conjunto de prueba. Así mismo, el menor valor para la función de pérdida fue de 0,3618. Las curvas del proceso de entrenamiento se muestran en la Figura 85. El detalle sobre la clasificación de los puntos de falla se muestra en la matriz de confusión de la Figura 86.

Figura 85

Curvas relacionadas al proceso de aprendizaje de red neuronal que clasifica fallas bifásicas a tierra (CAG) en el sistema IEEE123



Figura 86

Matriz de confusión para el conjunto de prueba de la red neuronal que clasifica fallas bifásicas a tierra (CAG) en el sistema IEEE 123



En el proceso de evaluación, 123 eventos de falla relacionadas a 19 puntos de simulación fueron mal clasificados sobre un total de 698 anomalías del conjunto de prueba. Sin embargo, con análisis detallado se observó que solo 111 eventos relacionados a 16 puntos de simulación tuvieron una clasificación errónea crítica. Es decir, se trata de puntos lejanos de la zona de predicción. Por otro lado, los eventos restantes, aunque fueron mal clasificados, corresponden con el primer o segundo puntos de la zona adyacente, lo que significa que hacen parte de la
región límite. Los puntos críticos en la clasificación de zonas de fallas se muestran en la Figura

87. La información de dichos puntos se muestra en las Tablas desde número 113 al número 120.

Figura 87

Puntos críticos en la clasificación de fallas para el modelo de anomalías CAG del sistema

IEEE123



Tabla 113

Fallas críticas de la zona 1 que fueron predichas en la zona 2 del modelo para anomalías

Identificador de puntos de falla	Cantidad de fallas
56	11
60	10
57601	10
57602	10
160	8

bifásicas CAG en el sistema IEEE123

57	8
55	7
160671	6
54	6
54571	6
53	5
60611	4
61	2
Total	93

Tabla 114

Información de impedancias de fallas críticas de la zona 1 que fueron predichas en la zona 2

Indicador	Cantidad
Fallas en total	93
Media [Ω]	4.5
Std [Ω]	2.7
Min [Ω]	0.0
Ρ ₂₅ [Ω]	2.5
Ρ ₅₀ [Ω]	4.3
Ρ ₇₅ [Ω]	6.5
Max [Ω]	9.8

del modelo para anomalías bifásicas CAG en el sistema IEEE123

Tabla 115

Fallas críticas de la zona 1 que fueron predichas en la zona 3 del modelo para anomalías

bifásicas CAG en el sistema IEEE123

Identificador de puntos de falla	impedancia de falla [Ω]
61	6.5
61	7
61	4.5
61	7.75
61	4.75

Tabla 116

Fallas críticas de la zona 2 que fueron predichas en la zona 1 del modelo para anomalías

Identificador de puntos de falla	impedancia de falla [Ω]
151	4
511511	3
51	1
151	8.5
151	7.25
151	7.75
151	6.5
511511	6.75
511511	7
511511	7.75
51	7.75

bifásicas CAG en el sistema IEEE123

Tabla 117

.

Información de impedancias de fallas críticas de la zona 2 que fueron predichas en la zona 1

del modelo para anomalías bifásicas CAG en el sistema IEEE123

Indicador	Cantidad
Fallas en total	8
Media [Ω]	7.4
Std [Ω]	0.7
Min [Ω]	6.5
Ρ ₂₅ [Ω]	6.9
Ρ ₅₀ [Ω]	7.5
Ρ ₇₅ [Ω]	7.8
Max [Ω]	8.5

Tabla 118

Fallas críticas de la zona 2 que fueron predichas en la zona 3 del modelo para anomalías

Identificador de puntos de falla	Impedancia de falla [Ω]
151	6
511511	2
51	1.25
151	0.5
151	2
151	5.5
151	1.75
151	6
511511	2.25
511511	0.25

bifásicas CAG en el sistema IEEE123

Tabla 119

Información de impedancias de fallas críticas de la zona 2 que fueron predichas en la zona 3

del modelo para anomalías bifásicas CAG en el sistema IEEE123

Indicador	Cantidad
Fallas en total	8
Media [Ω]	2.4
Std [Ω]	2.2
Min [Ω]	0.3
Ρ ₂₅ [Ω]	1.1
Ρ ₅₀ [Ω]	1.9
Ρ ₇₅ [Ω]	3.1
Max [Ω]	6.0

Tabla 120

Fallas críticas de la zona 3 que fueron predichas en la zona 2 del modelo para anomalías

bifásicas CAG en el sistema IEEE123

Identificador de puntos de falla	impedancia de falla [Ω]
67	5
67	0

7.15. Resultado de modelo de red neuronal para fallas tipo 10 (ABC)

La estructura de la red neuronal artificial empleada para clasificar el tipo de falla ABC se muestra en la Tabla 121. La taza de aprendizaje en los ciclos de entrenamiento fue de 0.001 y el algoritmo de optimización de los pesos sinápticos fue *Adaptive moment estimation*.

Tabla 121

Número de capa	Tipo de capa	Número de neuronas	Función de activación
1	Entrada	16	ReLU
2	Oculta	12	ReLU
3	Oculta	8	ReLU
4	Oculta	6	ReLU
5	Oculta	3	ReLU
6	Salida	3	Softmax

Estructura de red neuronal artificial para clasificar fallas tipo 10 (ABC) en el sistema IEEE123

Se obtuvo una precisión de 0,8704 al evaluar el conjunto de prueba. Así mismo, el menor valor para la función de pérdida fue de 0,3195. Las curvas del proceso de entrenamiento se muestran en la Figura 88. El detalle sobre la clasificación de los puntos de falla se muestra en la matriz de confusión de la Figura 89.

Figura 88

Curvas relacionadas al proceso de aprendizaje de red neuronal que clasifica fallas trifásicas



(ABC) en el sistema IEEE123

Figura 89

Matriz de confusión para el conjunto de prueba de la red neuronal que clasifica fallas trifásicas

(ABC) en el sistema IEEE 123



En el proceso de evaluación, 84 eventos de falla relacionadas a 24 puntos de simulación fueron mal clasificados sobre un total de 648 anomalías del conjunto de prueba. Sin embargo, con análisis detallado se observó que solo 67 eventos relacionados a 19 puntos de simulación tuvieron una clasificación errónea crítica. Es decir, se trata de puntos lejanos de la zona de predicción. Por otro lado, los eventos restantes, aunque fueron mal clasificados, corresponden con el primer o segundo puntos de la zona adyacente, lo que significa que hacen parte de la

región límite. Los puntos críticos en la clasificación de zonas de fallas se muestran en la Figura

90. La información de dichos puntos se muestra en las Tablas desde número 122 al número 127.

Figura 90

Puntos críticos en la clasificación de fallas para el modelo de anomalías ABC del sistema

IEEE123



Tabla 122

Fallas críticas de la zona 1 que fueron predichas en la zona 2 del modelo para anomalías

bifásicas ABC en el sistema IEEE123

Identificador de puntos de falla	Cantidad de fallas
54571	8
56	7
57	6

54	6
57601	5
53	4
57602	4
55	4
Total	44

Tabla 123

Información de impedancias de fallas críticas de la zona 1 que fueron predichas en la zona 2

Indicador	Cantidad
Fallas en total	44
Media [Ω]	5.7
Std [Ω]	2.6
Min [Ω]	0.5
Ρ ₂₅ [Ω]	3.9
Ρ ₅₀ [Ω]	5.8
Ρ ₇₅ [Ω]	7.8
Max [Ω]	9.5

del modelo para anomalías bifásicas ABC en el sistema IEEE123

Tabla 124

Fallas críticas de la zona 1 que fueron predichas en la zona 3 del modelo para anomalías

bifásicas	ABC en	el sistema	IEEE123
-----------	--------	------------	---------

Identificador de puntos de falla	impedancia de falla [Ω]		
65	2.5		
65	3.75		
65	2.75		
66	3.5		
66	2.5		

Tabla 125

Fallas críticas de la zona 2 que fueron predichas en la zona 1 del modelo para anomalías

Identificador de puntos de falla	Cantidad de fallas
49	3
250	3
151	2
511511	2
29301	2
50	2
23	1
30	1
Total	16

bifásicas ABC en el sistema IEEE123

Tabla 126

Información de impedancias de fallas críticas de la zona 2 que fueron predichas en la zona 1

del modelo para anomalías bifásicas ABC en el sistema IEEE123

Indicador	Cantidad	
Fallas en total	16	
Media [Ω]	1.9	
Std [Ω]	1.7	
Min [Ω]	0.0	
Ρ ₂₅ [Ω]	1.2	
Ρ ₅₀ [Ω]	1.8	
Ρ ₇₅ [Ω]	2.1	
Max [Ω]	7.3	

Tabla 127

Fallas críticas de la zona 2 que fueron predichas en la zona 3 del modelo para anomalías

bifásicas ABC en el sistema IEEE123

Identificador de puntos de falla impedancia de falla [Ω]

151	1.75
511511	2

8. Conclusiones

Los modelos de localización de zonas de fallas para el sistema IEEE 34 tuvieron un rendimiento alrededor de 96%. Tal resultado es bueno teniendo en cuenta la restricción de emplear solo un punto de media. Pero, el alcance puede ser mejor si se modifica las zonas de clasificación de fallas con un aumento de un kilómetro en extensión de líneas, producto de solapar los límites entre secciones se alcanza un rendimiento alrededor del 99%. Ver Tabla 128. La metodología desarrollada puede ser viable en sistemas de distribución de energía eléctrica que presenten características similares a la red IEEE34,es decir, un alimentador largo poco cargado con un numero pequeño de ramificaciones.

Tabla 128

Tipo de falla	Fases implicadas	Fallas del conjunto de evaluación	Eventos mal clasificados	Precisión	Eventos mal clasificados después de solapar zonas	Precisión después de solapar zonas
1	A-G	3663	259	92.9%	144	96.1%
2	B-G	3034	142	95.7%	10	99.7%
3	C-G	2835	80	97.2%	0	100%
4	A-B	2835	93	96.7%	0	100%
5	B-C	2835	21	99.3%	0	100%
6	C-A	2835	151	94.7%	12	99.6%
7	A-B-G	2835	85	97.0%	0	100%
8	B-C-G	2835	29	99.0%	0	100%
9	C-A-G	2835	65	97.7%	0	100%
10	A-B-C	2835	208	92.7%	26	99.1%
11	A-B-C-G	2835	166	94.1%	8	99.7%
	Total	32212	1299	Promedio 96.1%	200	Promedio 99.5%

Resultados de modelos de localización de zonas de falla en el sistema IEEE34

Por otro lado, para el sistema IEEE 123, la precisión de clasificación de zonas de falla de los modelos fue alrededor del 83%, no tan buena como la de los modelos del sistema anterior. Incluso después de aplicar el solapamiento entre los límites de las zonas, la precisión promedio solo aumento al 87%. Ver Tabla 129. En conclusión, el sistema 123 nodos tiene un gran número de ramificaciones, y ante tal condición es más probable que putos diferentes del sistema en condición de falla , generen magnitudes de tensión y corriente muy similares, visto desde los dispositivos de medición. Puede que para este sistema se requiera un punto de medición auxiliar para mejora la localización de zonas de fallas.

Tabla 129

Tipo de falla	Fases implicadas	Fallas del conjunto de evaluación	Eventos mal clasificados	Precisión	Eventos mal clasificados después de solapar zonas	Precisión después de solapar zonas
1	A-G	961	143	85.1%	115	88.0%
2	B-G	817	145	82.3%	88	89.2%
3	C-G	975	140	85.6%	91	90.7%
4	A-B	763	123	83.9%	112	85.3%
5	B-C	746	169	77.9%	133	82.6%
6	C-A	754	168	77.7%	144	80.9%
7	A-B-G	763	106	86.1%	77	89.9%
8	B-C-G	746	119	84.0%	83	88.9%
9	C-A-G	698	123	82.4%	111	84.1%
10	A-B-C	648	84	87.0%	67	89.7%
	Total	7871	1320	Promedio 83.2%	1021	Promedio 86.9%

Resultados de modelos de localización de zonas de falla en el sistema IEEE123

9. Referencias bibliográficas

Abdelhay, S., & Malik, O. P. (2011). Electric Distribution Systems. In A john Wiley & Sons, INC.

- Abdisa, L. T. (2018). Power outages, economic cost, and firm performance: Evidence from Ethiopia. *Utilities Policy*, 53. https://doi.org/10.1016/j.jup.2018.06.009
- Barra, P. H. A., Pessoa, A. L. D. S., Menezes, T. S., Santos, G. G., Coury, D. V., & Oleskovicz,
 M. (2019). Fault Location in Radial Distribution Networks Using ANN and Superimposed
 Components. 2019 IEEE PES Conference on Innovative Smart Grid Technologies, ISGT
 Latin America 2019. https://doi.org/10.1109/ISGT-LA.2019.8895335
- Bo, Z. Q., Weller, G., & Redfern, M. A. (1999). Accurate fault location technique for distribution system using fault-generated high-frequency transient voltage signals. *IEE Proceedings: Generation, Transmission and Distribution, 146*(1), 73–79. https://doi.org/10.1049/ip-gtd:19990074
- Bompard, E., Huang, T., Wu, Y., & Cremenescu, M. (2013). Classification and trend analysis of threats origins to the security of power systems. *International Journal of Electrical Power and Energy Systems*, *50*(1). https://doi.org/10.1016/j.ijepes.2013.02.008
- Carrillo Caicedo, G. (2019). Fundamentos de protecciones eléctricas. Editorial acádemica española.
- Gonen, T. (2014). *Electric Power Distribution Engineering* (third). CRC Press Taylor & Francis Group.
- Kumar, R., & Saxena, D. (2020). A Literature Review on Methodologies of Fault Location in the Distribution System with Distributed Generation. *Energy Technol*, *1901093*, 1–12.

https://doi.org/10.1002/ente.201901093

- Mirzaei, M., Ab Kadir, M. Z. A., Moazami, E., & Hizam, H. (2009). Review of fault location methods for distribution power system. *Australian Journal of Basic and Applied Sciences*, *3*(3), 2670– 2676.
- Zapata Castrillón, W. H., & Empresas públicas de Medellin E.S.P. (2011). Coordinación de protecciones en sistemas de distribución de energía, Manual de referencia y fundamentos (1a.).
- Zidan, A., Khairalla, M., Abdrabou, A. M., Khalifa, T., Shaban, K., Abdrabou, A., El Shatshat, R.,
 & Gaouda, A. M. (2017). Fault Detection, Isolation, and Service Restoration in Distribution
 Systems: State-of-the-Art and Future Trends. *IEEE Transactions on Smart Grid*, *8*(5).
 https://doi.org/10.1109/TSG.2016.2517620

Apéndices

Apéndice A. Código de red neuronal artificial de ejemplo que modela la superficie de un

paraboloide

Librerías import numpy as np import matplotlib.pyplot as plt from mpl_toolkits import mplot3d

```
# Función a modelar z = 1 - x^2 - y^2
a = np.sqrt(1/2)
x1 = np.linspace(-a,a,100)
y1 = x1
X_f,Y_f = np.meshgrid(x1,y1)
Z_f = 1-(X_f**2)-(Y_f**2)
```

```
# Función para graficar superficie
def grafica_3d(X,Y,Z,xlabel='x',ylabel='y',zlabel='z',title =None,zise=(12,9),Color ='viridis'):
    fig = plt.figure(figsize = zise)
    ax = plt.axes(projection='3d')
    ax.plot_surface(X,Y,Z, cmap = Color, edgecolor = 'none')
```

```
#Poner el eje, título
ax.set_xlabel(xlabel)
ax.set_ylabel(ylabel)
ax.set_zlabel(zlabel)
ax.set_title(title)
```

```
#Ajuste el ángulo de observación
ax.view_init(20, 25)
# Entradas y salidas de la red neuronal artificial
x1 = np.reshape(X_f,(X_f.shape[0]*X_f.shape[1],1))
x2 = np.reshape(Y_f,(Y_f.shape[0]*Y_f.shape[1],1))
x3 = x1*x2
x4 = (x1*x1+x2*x2)**0.5
```

Entradas de la red neronal Entradas =np.concatenate((x1,x2,x3,x4),axis=1)

```
# Salidas
Salidas_objetivo = np.reshape(Z_f,(Z_f.shape[0]*Z_f.shape[1],1))
```

```
# Funciones de activación sigmoidal
def sigmoid(x,derivada=False):
```

```
# Derivada de la función empleada en el ajsute de pesos sinápticos if derivada:
```

```
return np.exp(-x)/((1+np.exp(-x))**2)
```

else:

Evalua la función par un punto x

return 1/(1+np.exp(-x))

```
# Función de activación lineal
def lineal(x,derivada=False):
 # Derivada de la función empleada en el ajsute de pesos sinápticos
 if derivada:
  x=1
  return 1
 else:
  # Evalua la función par un punto x
  return x
# Gráfica de función sigmoidal
xp = np.linspace(-4,4,100)
yp = sigmoid(xp,False)
plt.plot(xp,yp)
plt.grid()
# Función de coste raíz media cuadrática (mse)
def mse(y real,y predicha,derivada=False):
 if derivada:
  return 2*(y_predicha-y_real)
 else:
  return np.mean((y_predicha-y_real)**2)
# Función que crea las matrices de la red a partir de una lista
# con la cantidad de neuronas por capa inicialmente los
# valores de los pesos sinapticos son aleatorios entre -1 y 1
def inicializador(neuronas por capa):
 pesos sinapticos={}
 L= len(neuronas_por_capa)
 for I in range(0,L-1):
  pesos sinapticos['W'+str(I+1)]
=(np.random.rand(neuronas por capa[l],neuronas por capa[l+1])*2)-1
  pesos_sinapticos['b'+str(l+1)] =(np.random.rand(1,neuronas_por_capa[l+1])*2)-1
 return pesos sinapticos
# Función que modela y entrena una red neuronal
def Red_neuronal_artificial(X,Y,fun_coste,activacion_capas,Ir,params,training=True):
 # Alimentación de la red neuronal artificial para producir una salida
 params['A0']=X
 L= len(neuronas por capa)
 for p in range(0,L-1):
  params['Z'+str(p+1)] = params['A'+str(p)]@params['W'+str(p+1)] + params['b'+str(p+1)]
  params['A'+str(p+1)] = globals()[activacion_capas[p+1]](params['Z'+str(p+1)])
```

```
salida= params['A'+str(L-1)]
```

```
# Proceso de entrenamiento
 if training:
  params['dZ'+str(L-1)] = fun coste(Y,salida,True)*globals()[activacion capas[L-
1]](params['Z'+str(L-1)],True)
  params['dW'+str(L-1)] = params['A'+str(L-1-1)].T @params['dZ'+str(L-1)]
  y = list(range(1,L-1))
  y.reverse()
  # Retropropagación del error de la función de coste en los elementos de las capas restantes
  for n in y:
   params['dZ'+str(n)] = params['dZ'+str(n+1)]@params['W'+str(n+1)].T *
globals()[activacion capas[n]](params['Z'+str(n)],True)
   params['dW'+str(n)] = params['A'+str(n-1)].T@params['dZ'+str(n)]
  # Ajuste de pesos sinápticos y sesgos
  x = list(range(1,L))
  x.reverse()
  for m in x:
   params['W'+str(m)] = params['W'+str(m)] - params['dW'+str(m)]*Ir
   params['b'+str(m)] = params['b'+str(m)] -
np.mean(params['dZ'+str(m)],axis=0,keepdims=True)* Ir
 return salida
# Definición del modelo
neuronas por capa = [4,4,2,1]
function activation por capa = ['lineal','sigmoid','sigmoid','sigmoid']
parametros = inicializador(neuronas por capa)
ciclos entrenamiento = 300
Taza aprendizaje=0.001
# Entrenamiento
error prediccion =[]
for n in range(ciclos entrenamiento):
 Salidas predichas =
Red neuronal artificial(Entradas, Salidas objetivo, mse, funcion activacion por capa, Taza apr
endizaie.parametros.training=True)
 error_prediccion.append(mse(Salidas_objetivo,Salidas_predichas))
# Curva del proceso de aprendizaje
plt.figure(figsize=(10,6))
plt.plot(error prediccion)
plt.title("Función de perdida por ciclo de entrenamiento")
plt.ylabel('Error cuarático medio')
plt.xlabel('Ciclo')
plt.grid()
plt.show()
# Función base
grafica_3d(X_f,Y_f,Z_f,Color = 'jet')
# Función modelada por la red neuronal
```

Z_predicha = np.reshape(Salidas_predichas,Z_f.shape) grafica_3d(X_f,Y_f,Z_predicha,Color = 'jet') # Error absoluto entre la función base Z_error = abs(Z_f-Z_predicha) grafica_3d(X_f,Y_f,Z_error,Color = 'jet')