



UNIVERSIDAD NACIONAL DEL ALTIPLANO

ESCUELA DE POSGRADO

MAESTRÍA EN CIENCIAS DE LA INGENIERÍA MECÁNICA ELÉCTRICA



TESIS

CLASIFICACIÓN DE FALLAS EN LÍNEAS DE TRANSMISIÓN MEDIANTE LA UTILIZACIÓN DE REDES NEURONALES ARTIFICIALES

PRESENTADA POR:

ADHEMIR HOMERO GUTIERREZ GALLEGOS

PARA OPTAR EL GRADO ACADÉMICO DE:

**MAGÍSTER SCIENTIAE EN CIENCIAS DE LA INGENIERÍA MECÁNICA
ELÉCTRICA
CON MENCIÓN EN GESTIÓN DE OPERACIONES Y MANTENIMIENTO
DE SISTEMAS ELÉCTRICOS**

PUNO, PERÚ

2022



UNIVERSIDAD NACIONAL DEL ALTIPLANO

ESCUELA DE POSGRADO

MAESTRÍA EN CIENCIAS DE LA INGENIERÍA MECÁNICA ELÉCTRICA

TESIS

CLASIFICACIÓN DE FALLAS EN LÍNEAS DE TRANSMISIÓN MEDIANTE LA UTILIZACIÓN DE REDES NEURONALES ARTIFICIALES



PRESENTADA POR:

ADHEMIR HOMERO GUTIERREZ GALLEGOS

PARA OPTAR EL GRADO ACADÉMICO DE:

MAGÍSTER SCIENTIAE EN CIENCIAS DE LA INGENIERÍA MECÁNICA
ELÉCTRICA

CON MENCIÓN EN GESTIÓN DE OPERACIONES Y MANTENIMIENTO DE
SISTEMAS ELÉCTRICOS

APROBADA POR EL JURADO SIGUIENTE:

PRESIDENTE

Dr. MATEO ALEJANDRO SALINAS MENA

PRIMER MIEMBRO

M.Sc. OMAR CHAYÑA VELÁSQUEZ

SEGUNDO MIEMBRO

M.Sc. JULIO FREDY CHURA ACERO

ASESOR DE TESIS

M.Sc. JOSÉ MANUEL RAMOS CUTIPA

Puno, 19 de octubre de 2022

ÁREA: Ciencias de la Ingeniería Mecánica Eléctrica

TEMA: Clasificación de fallas en líneas de transmisión mediante la utilización de redes neuronales artificiales

LÍNEA: Ingeniería Eléctrica, Ingeniería de Control



DEDICATORIA

Dedicado a mis padres, mi esposa y en especial a mi hija, quienes han sido el soporte principal para este proyecto.



AGRADECIMIENTOS

Este proyecto no hubiera sido posible sin el interés y ánimo que me han proporcionado mi familia y amigos.



ÍNDICE GENERAL

	Pág.
DEDICATORIA	i
AGRADECIMIENTOS	ii
ÍNDICE GENERAL	iii
ÍNDICE DE TABLAS	v
ÍNDICE DE FIGURAS	vi
ÍNDICE DE ANEXOS	ix
RESUMEN	x
ABSTRACT	xi
INTRODUCCIÓN	1

CAPÍTULO I

REVISIÓN DE LITERATURA

1.1 Marco teórico	3
1.1.1 Sistemas de protección	3
1.1.2 Técnicas de localización de fallas en líneas de transmisión	4
1.1.3 Las redes neuronales	9
1.1.4 Modelo de una neurona	11
1.1.5 Redes de retroalimentación	13
1.1.6 Estrategias de aprendizaje	14
1.2 Antecedentes	19

CAPÍTULO II

PLANTEAMIENTO DEL PROBLEMA

2.1 Identificación del problema	24
2.2 Enunciados del problema	24
2.3 Justificación	24
2.4 Objetivos	25
2.4.1 Objetivo general	25
2.4.2 Objetivos específicos	25
2.5 Hipótesis	25
2.5.1 Hipótesis general	25
2.5.2 Hipótesis específicas	25

...



CAPÍTULO III

MATERIALES Y MÉTODOS

3.1	Lugar de estudio	27
3.2	Población	27
3.3	Muestra	27
3.4	Método de investigación	27
3.5	Descripción detallada de métodos por objetivos específicos	28
3.5.1	Modelado del sistema de línea de transmisión de energía	28
3.5.2	Ubicación de fallas en LT de energía uso de redes neuronales	28
3.5.3	Esquema del plan propuesto	30
3.5.1.	Preprocesamiento de datos	31
3.5.2.	Visión general del proceso de capacitación	33
3.5.4	Descripción general del proceso de prueba	35

CAPÍTULO IV

RESULTADOS Y DISCUSIÓN

4.1	Detección de fallas	37
4.1.1	Entrenamiento de la red neuronal de detección de fallas	37
4.1.2	Prueba de la red neuronal de detección de fallas	40
4.2	Clasificación de averías	43
4.2.1	Entrenamiento de la red neuronal del clasificador de fallas	43
4.2.2	Prueba de la red neuronal del clasificador de fallas	48
4.3	Localización de averías	52
4.3.1	Línea única - fallas a tierra	52
4.3.2	Falla línea - línea	63
4.3.3	Falla doble línea - tierra	71
4.3.4	Fallas trifásicas	82
	CONCLUSIONES	93
	RECOMENDACIONES	94
	BIBLIOGRAFÍA	95
	ANEXOS	100



ÍNDICE DE TABLAS

	Pág.
1. Muestra de Entradas a la red neuronal para varios casos de falla	33
2. Salidas de la RNA del clasificador de fallas para varias fallas	44
3. Porcentaje de errores en función de la distancia de falla y la resistencia de falla para la RNA elegida para la ubicación de falla de línea simple a tierra	63
4. Porcentaje de errores en función de la distancia de falla y la resistencia de falla para la RNA elegida para la localización de fallas línea - línea	71
5. Porcentaje de errores en función de la distancia de falla y la resistencia de falla para la RNA elegida para localización de falla doble línea - tierra	82
6. Porcentaje de errores en función de la distancia de falla y la resistencia de falla para la RNA elegida para la localización de fallas trifásicas	92

ÍNDICE DE FIGURAS

	Pág.
1. LT con falla que ilustra el método de reactancia simple	5
2. Circuito monofásico que ilustra el método de Takagi	6
3. Ubicación de la falla basada en ondas viajeras	7
4. Arquitectura básica de tres capas de una RNA de retroalimentación	9
5. Modelo típico de una neurona	11
6. Activación de la función de paso	12
7. Función de activación lineal por partes	12
8. Función de activación unipolar sigmoidea	12
9. Función de activación bipolar	13
10. Estructura de una red retroalimentación de dos capas	14
11. Esquema de aprendizaje supervisado	16
12. Estructura del algoritmo de propagación de errores inversos	18
13. Diagrama unifilar del sistema estudiado	28
14. Modelo estudiado en SimPowerSystems	29
15. Diagrama de flujo del esquema propuesto	31
16. Preprocesamiento de datos	32
17. Error cuadrático medio, configuración (6-10-1)	38
18. Error cuadrático medio, configuración (6-10-5-1)	39
19. Error cuadrático medio, configuración (6-10-5-3-1)	39
20. Ajuste de regresión de Salidas vs. Objetivos, configuración (6-10-5-3-1)	40
21. Matrices de confusión para Entrenamiento, Prueba y Validación	41
22. Resumen de la RNA, configuración (6-10-5-3-1) para detección de fallas	42
23. Estructura RNA para detección de fallas, configuración (6-10-5-3-1)	43
24. Error cuadrático medio, configuración (6-5-5-31-4)	45
25. Error cuadrático medio, configuración (6-5-31-4)	45
26. Error cuadrático medio, configuración (6-5-4)	46
27. Error cuadrático medio, configuración (6-10-4)	47
28. Error cuadrático medio, configuración (6-20-4)	47
29. Error cuadrático medio, configuración (6-35-4)	48
30. Ajuste de regresión Productos vs. Objetivos RNA, configuración (6-35-4)	49
31. Gradiente y validación de la RNA, configuración (6-35-4)	50



32. Resumen de la RNA, configuración (6-35-4) para clasificador de fallas	51
33. Estructura RNA para clasificación de fallas, configuración (6-35-4)	52
34. Ajuste de regresión de Productos vs. Objetivos, configuración (6-5-5-1)	54
35. Rendimiento de la Fase de Prueba, configuración (6-5-5-1)	54
36. Ajuste de regresión de Productos vs. Metas, configuración (6-25-1)	55
37. Rendimiento de la fase de prueba, configuración (6-25-1)	55
38. Ajuste de regresión de Productos vs. Metas, configuración (6-16-1)	56
39. Rendimiento de la fase de prueba, configuración (6-16-1)	56
40. Ajuste de regresión de Productos vs. Objetivos, configuración (6-7-1)	57
41. Rendimiento de la fase de prueba, configuración (6-7-1)	57
42. Resumen de la RNA, configuración (6-7-1)	58
43. Error cuadrático medio, configuración (6-7-1)	59
44. Gradiente y validación, configuración (6-7-1)	60
45. Regresión de las distintas fases de aprendizaje, configuración (6-7-1)	61
46. Estructura RNA para falla a tierra, configuración (6-7-1)	62
47. Error cuadrático medio, configuración (6-10-20-5-1)	64
48. Rendimiento de la fase de prueba, configuración (6-10-20-5-1)	65
49. Error cuadrático medio, configuración (6-10-1)	65
50. Desempeño de la Fase de Prueba, configuración (6-10-1)	66
51. Error cuadrático medio, configuración (6-10-5-1)	66
52. Rendimiento de la fase de prueba, configuración (6-10-5-1)	67
53. Resumen de la RNA para fallas línea a línea, configuración (6-10-5-1)	68
54. Ajuste de regresión de Productos vs. Metas, configuración (6-10-5-1)	68
55. Gradiente y validación, configuración (6-10-5-1)	69
56. Regresión de las distintas fases de aprendizaje, configuración (6-10-5-1)	70
57. Estructura RNA para línea - línea, configuración (6 - 10 - 5 - 1)	70
58. Error cuadrático medio, configuración (6-10-1)	73
59. Rendimiento de la Fase de Prueba, configuración (6-10-1)	74
60. Error cuadrático medio, configuración (6-20-1)	74
61. Rendimiento de la Fase de Prueba, configuración (6-20-1)	75
62. Error cuadrático medio, configuración (6-10-5-1)	76
63. Desempeño de la Fase de Prueba, configuración (6-10-5-1)	76
64. Error cuadrático medio, configuración (6-21-11-1)	77
65. Desempeño de la fase de prueba, configuración (6-21-11-1)	77

...



66. Resumen RNA para fallas dobles de línea a tierra, configuración (6-21-11-1)	78
67. Ajuste de regresión de Productos vs. Metas, configuración (6-21-11-1)	79
68. Gradiente y validación, configuración (6-21-11-1)	80
69. Regresión de fases de aprendizaje RNA, configuración (6-21-11-1)	80
70. Estructura RNA para doble línea - tierra, configuración (6-21-11-1)	81
71. Ajuste de regresión de las Salidas vs. Objetivos, configuración (6-21-10-1)	84
72. Rendimiento MSE, configuración (6-21-10-1)	84
73. Desempeño de la Fase de Prueba, configuración (6-21-10-1)	85
74. Rendimiento MSE, configuración (6-21-1)	85
75. Ajuste de regresión para las Salidas vs. Objetivos, configuración (6-21-1)	86
76. Desempeño de la Fase de Prueba, configuración (6-21-1)	87
77. Ajuste de regresión de Resultados vs. Objetivos, configuración (6-6-21-16-1)	87
78. Desempeño de la Fase de Prueba, configuración (6-6-21-16-1)	88
79. Resumen de la RNA para localización de fallas trifásicas	88
80. Error cuadrático medio, configuración (6-6-21-16-1)	89
81. Gradiente y validación de la red, configuración (6-6-21-16-1)	90
82. Regresión de las fases de aprendizaje RNA, configuración (6-6-21-16-1)	90
83. Estructura RNA para falla trifásica, configuración (6-6-21-16-1)	91



ÍNDICE DE ANEXOS

	Pág.
1. Modelo estudiado en SimPowerSystems	101



RESUMEN

La investigación está basada en un enfoque práctico en la detección, clasificación y localización de fallas en líneas de transmisión de energía eléctrica. Con el uso de redes neuronales artificiales RNA se puede detectar, organizar y ubicar fallas de LT para posteriormente hacer un análisis de los datos. La metodología es de tipo experimental para poder desarrollar el trabajo se han empleado redes de retroalimentación juntamente con algoritmos de retro propagación para cada una de las diferentes fases del proceso de localización de fallas. Con los datos obtenidos se procedió a hacer un análisis de redes neuronales con un número variable de capas ocultas y neuronas por capa oculta, para poder validar la elección de las redes neuronales en cada paso. Como resultado de la simulación en MATLAB se ha logrado un rendimiento satisfactorio por parte de todas las RNA propuestas en global. Como se ilustra más adelante, el tamaño de la RNA (número de capas ocultas, neuronas por cada capa oculta) es variable, cabe realzar la importancia de elegir la configuración RNA más adecuada para tener un rendimiento adecuado en la red. La frecuencia de muestreo adoptada para simular las formas de onda de V-I es aproximada a 700 Hz. Esto es de gran importancia porque, cuanto menor sea la frecuencia de muestreo, menor será la carga computacional en la PC que utiliza las redes neuronales por lo tanto un gran ahorro de energía, una gran parte de la cual se debe al muestreo continuo de formas de onda.

Palabras clave: Algoritmo de retro propagación, capas, MATLAB, redes de retroalimentación y Redes Neuronales Artificiales.



ABSTRACT

The research is based on a practical approach in the detection, classification and location of faults in power transmission lines. With the use of artificial neural networks ANN it is possible to detect, organize and locate faults of LT to later make an analysis of the data. The methodology is of experimental type in order to develop the work, feedback networks have been used together with back propagation algorithms for each of the different phases of the fault location process. With the data obtained we proceeded to make a neural network analysis with a variable number of hidden layers and neurons per hidden layer, in order to validate the choice of neural networks in each step. As a result of the simulation in MATLAB, a satisfactory performance was achieved by all the proposed ANNs in global. As illustrated below, the size of the ANN (number of hidden layers, neurons per hidden layer) is variable, it is important to highlight the importance of choosing the most appropriate ANN configuration to have an adequate performance in the network. The sampling frequency adopted to simulate the V-I waveforms is approximately 700 Hz. This is of great importance because, the lower the sampling frequency, the lower the computational load on the PC using the neural networks hence a large energy saving, a large part of which is due to the continuous sampling of waveforms.

Keywords: Artificial Neural Networks, Back propagation algorithm, feedback networks, layers and MATLAB.

INTRODUCCIÓN

En las últimas décadas, ha habido un rápido incremento de las redes eléctricas en todo el mundo, que eventualmente condujeron a la instalación de una gran cantidad de nuevas líneas de transmisión y distribución. Además, la introducción de nuevos conceptos de marketing como la desregulación ha aumentado la necesidad de un suministro de energía eléctrica confiable e ininterrumpido para los usuarios finales que son muy sensibles a los cortes de energía (Das y Novesel, 2015). Uno de los factores más importantes que dificultan el abastecimiento constante de energía eléctrica y potencia, es una falla en el sistema de potencia (IEEE, 2014). Cualquier flujo anormal de corriente en los elementos para un sistema eléctrico de potencia se denomina falla en el sistema de potencia. Estas fallas no se pueden evitar por completo ya que una parte de estas fallas también ocurren debido a razones naturales que no son posibles ser controladas por la mano humana. Es por eso, que es importante contar con un sistema de protección bien coordinado que detecte cualquier tipo de flujo anormal de corriente en el sistema eléctrico, identificar el tipo de falla y luego ubicar con precisión la posición de la falla en el sistema eléctrico. Las fallas generalmente son atendidas por dispositivos que detectan la ocurrencia de una falla y eventualmente aíslan la sección de falla del resto del sistema de energía.

Por lo tanto, algunos de los desafíos importantes para el suministro incesante de energía son la detección, clasificación y ubicación de fallas (Saha *et al.*, 2002). Las fallas pueden ser de varios tipos, como: fallas transitorias, persistentes, simétricas o asimétricas, y el proceso de detección de fallas para cada una de estas, es claramente único en el sentido de que no existe una técnica universal de localización de fallas para toda esta variedad de fallas. En alta tensión, las líneas de transmisión (que transmiten la energía generada de la planta generadora a las subestaciones de alta tensión) son más propensas al suceso de fallas que las de distribución local (que transmiten energía desde la subestación a los clientes comerciales y residenciales) porque no hay aislamiento alrededor de los cables de estas líneas a diferencia de las de distribución. El motivo de la ocurrencia de una falla en una línea de transmisión puede deberse a varias razones, como el contacto momentáneo de un árbol, un pájaro o un animal (Das y Novesel, 2015) o debido a otras razones naturales, como tormentas eléctricas o rayos.

La localización automática de fallas puede mejorar en gran medida la confiabilidad de los sistemas porque cuanto más rápido restauramos la energía, más dinero y tiempo valioso

ahorramos. Por lo tanto, muchas empresas de servicios públicos están implementando dispositivos de localización de fallas en sus sistemas de monitoreo de calidad de energía (IEEE, 2014) que están equipados con sistemas de información global para una fácil localización de estas fallas. Las técnicas de localización de fallas se pueden clasificar en términos generales en las siguientes categorías, de acuerdo con Saha *et al.* (2002):

- Procedimientos que se basan en la medición de la impedancia
- Procedimientos que se basan en el fenómeno de las ondas viajeras
- Procedimientos de generación de fallas en elementos de alta frecuencia (I y V)
- Procedimientos que usan inteligencia artificial

Desde hace bastantes años, se están utilizando métodos basados en inteligencia en el proceso de detección y localización de fallas. Las tres principales técnicas basadas en inteligencia artificial que se han utilizado ampliamente en la industria de la energía y la automatización son de acuerdo con (Alashter *et al.*, 2020):

- Técnicas basadas en sistemas expertos
- Técnicas basadas en redes neuronales artificiales
- Técnicas basadas en sistemas de lógica difusa

Entre estas técnicas disponibles, las Redes Neuronales Artificiales (RNA) se han utilizado ampliamente en esta tesis para la localización de fallas en líneas de transmisión de energía eléctrica. Estos métodos basados en RNA no requieren una base de conocimiento para la ubicación de fallas a diferencia de otros métodos basados en inteligencia artificial (Tang *et al.*, 2000).

CAPÍTULO I

REVISIÓN DE LITERATURA

1.1 Marco teórico

1.1.1 Sistemas de protección

De acuerdo con BlogSEAS (2019) un componente muy importante para un sistema protección de energía es el relé, que es un dispositivo que dispara los interruptores automáticos cuando las señales de entrada (I,V) corresponden a las condiciones de falla diseñadas para la operación del relé. Los relés en general se pueden clasificar en las siguientes categorías:

- a) **Relés direccionales:** estos relés responden a la diferencia de ángulo de fase entre dos entradas al relé.
- b) **Relés Diferenciales:** Estos relés responden a la magnitud de la suma algebraica de dos o más de sus entradas.
- c) **Relés de magnitud:** estos relés responden a la magnitud de la cantidad de entrada.
- d) **Relés piloto:** estos relés responden a las señales de entrada que se comunican al relé desde una ubicación remota.
- e) **Relés de Distancia:** Estos relés responden a la relación de dos señales fasoriales de entrada.

Entre los diversos relés que se utilizan para la protección de líneas eléctricas, los relés de distancia son los más relevantes para los localizadores de fallas. Por lo

general, se utiliza un par de estos relés de distancia para la protección de una línea de transmisión de dos terminales (Johns, 1993).

Uno de los factores más importantes que dificultan el abastecimiento constante de energía eléctrica y potencia, es una falla en el sistema de potencia (IEEE, 2014). La desregulación ha aumentado la necesidad de un suministro de energía eléctrica confiable e ininterrumpido para los usuarios finales que son muy sensibles a los cortes de energía (Das y Novesel, 2015).

Una falla en un circuito eléctrico es cualquier evento que interfiere con el flujo normal de corriente (Grainger y Stevenson, 1996). Los tipos de fallas que experimentan los sistemas de potencia se caracterizan en dos grandes grupos: serie y paralelo (Anderson, 1995).

1.1.2 Técnicas de localización de fallas en líneas de transmisión

Este sistema es idealmente diseñado para que la energía eléctrica sea de calidad y sin interrupciones. El sistema eléctrico de potencia comprende tres partes operativas fundamentales: la generación, la transmisión y la distribución (Kundur, 1994).

El proceso de localización de fallas en líneas de transmisión, como se mencionó anteriormente, ha sido investigado durante un tiempo y varios autores han propuesto y analizado varias técnicas innovadoras y eficientes. Estas técnicas pueden clasificarse ampliamente como métodos basados en impedancia, métodos basados en ondas viajeras y métodos basados en inteligencia artificial. Cada uno de estos métodos se analiza brevemente en las siguientes subsecciones.

1.1.2.1 Métodos basados en impedancia

En el caso de los métodos basados en la impedancia, la operación del relé de distancia depende en gran medida de la resistencia de falla y no tiene éxito en casos con una resistencia de falla muy alta (Eriksson *et al.*, 1985). Los métodos basados en la impedancia se pueden clasificar en métodos de un solo extremo y métodos de dos extremos según la cantidad de terminales en los que se recopilan los datos de voltaje y corriente.

La lógica básica detrás de localización de fallas, basado en la impedancia de solo un extremo es calcular la ubicación de la falla a partir de la “impedancia aparente” que se ve mirando hacia la línea desde un extremo. Los diversos métodos basados en impedancia disponibles en la literatura se analizan en las próximas subsecciones.

A) Método de reactancia simple

Las lecturas de V y I en el terminal se usan para calcular la impedancia de la línea a la posición de falla como se muestra en la ecuación (1). Una vez que se ha determinado la impedancia de línea por unidad de longitud, la distancia de falla se puede calcular en consecuencia como se ilustra en las ecuaciones (2) y (3) (Zimmerman y Costello, 2006).

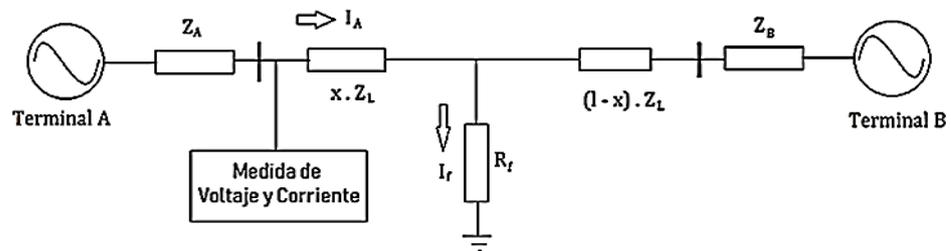


Figura 1. LT con falla que ilustra el método de reactancia simple

$$V_A = x \cdot Z_L \cdot I_A + V_f \quad (1)$$

Donde V_A es el voltaje en la terminal A,

x es la distancia de la falla al terminal A,

I_A es la corriente que sale del terminal A, V_f es el voltaje de falla

Z_L es la impedancia en la línea.

$$V_A = x \cdot Z_L \cdot I_A + R_f \cdot I_f \quad (2)$$

Donde I_f es la corriente de falla y R_f es la resistencia de falla como se muestra en la Fig. 1.

$$x = \frac{(V_A/I_A)}{Z_L} - \frac{R_f}{Z_L(I_A/I_f)} \quad (3)$$

B) Método Takagi

El método Takagi es una técnica de localización de fallas basada en impedancia de un solo extremo muy simple pero innovadora y se ilustra en la Fig. 2. Requiere datos previos a la falla y de falla y mejora el método de reactancia simple al minimizar el efecto de la resistencia de falla y reducir el efecto del flujo de carga (Takagi *et al.*, 1982).

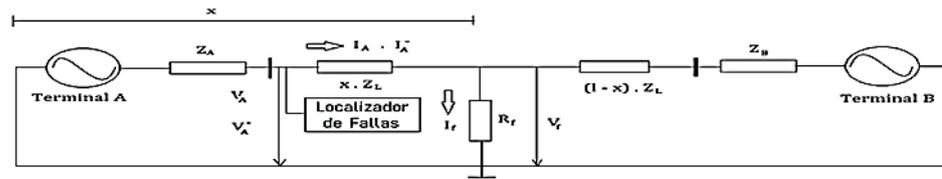


Figura 2. Circuito monofásico que ilustra el método de Takagi
Fuente: (Takagi *et al.*, 1982)

La resistencia de falla está dada por:

$$R_f = \frac{V_A - Z_C I_A \tanh \gamma x}{\left(\frac{V_A}{Z_C} \tanh \gamma x - I_A\right) \psi \epsilon^{j\theta}} \quad (4)$$

Donde V_A es el voltaje medido en el terminal A, I_A es el flujo que sale del terminal A, γ es la constante de propagación, Z_C es la impedancia característica, Z_L es la impedancia de línea, I_A'' es la corriente de superposición que es la diferencia entre la corriente de falla y la corriente de prefalla.

$$x = \frac{I_m(V_A I_A'')}{I_m(Z_L I_A I_A'')} \quad (5)$$

Es la distancia a la falla desde el terminal A.

Donde

$$Z_L = \gamma Z_C \quad (6)$$

C) Método Takagi modificado

El método de Takagi modificado, también llamado método de corriente de secuencia cero, no requiere datos previos a la falla porque utiliza corriente de secuencia cero en lugar de la corriente de superposición para fallas a

tierra (Schweicher, 1993) La ubicación de la falla en este método viene dada por x en la ecuación (7).

$$x = \frac{I_m(V_A I_R^* e^{-j\beta})}{I_m(Z_{1L} I_A I_R^* e^{-j\beta})} \quad (7)$$

Donde I_R es la corriente de secuencia cero y β es el ángulo de corriente de secuencia cero. La posición de la falla ' x ' viene dada por la ecuación (7); V_A es el voltaje medido en el terminal A, I_A es el flujo que sale del terminal A y Z_{1L} es la impedancia de la línea de secuencia positiva.

1.1.2.2 Métodos basados en ondas viajeras

Los métodos basados en ondas viajeras se han utilizado ampliamente Aurangzeb (2001) con el fin de localizar fallas y, por lo general, se basan en la correlación entre las ondas hacia adelante y hacia atrás que viajan a lo largo de la línea de transmisión, como se muestra en la Fig. 3. La idea básica es identificar sucesivamente la falla iniciada por ondas viajeras de alta frecuencia en el localizador de fallas (Saha *et al.*, 2002).

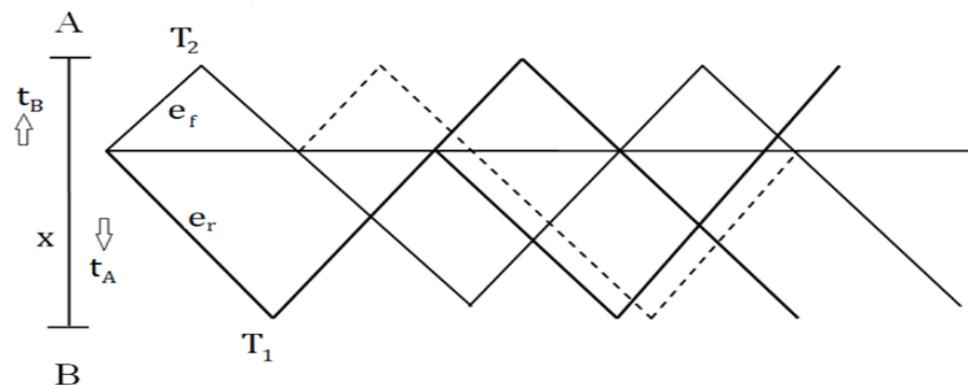


Figura 3. Ubicación de la falla basada en ondas viajeras

Fuente: (Saha *et al.*, 2002).

El tiempo que tardan las componentes de alta frecuencia en propagarse se utiliza para la ubicación de la falla. En la Figura 3, una línea de transmisión monofásica sin pérdidas de longitud ' l ' es considerado con una velocidad de onda viajera de v , capacitancia e inductancia por unidad longitud L' y C' y una impedancia característica de Z_C . Asumiendo la ocurrencia de una falla a una distancia de ' x ' del terminal A, los valores de voltaje y corriente están dados por (8) y (9).

$$\frac{\partial e}{\partial x} = -L' \frac{\partial i}{\partial t} \quad (8)$$

$$\frac{\partial i}{\partial x} = -C' \frac{\partial e}{\partial t} \quad (9)$$

Cuyas soluciones vienen dadas por (10) y (11).

$$e(x, t) = e_f(x - vt) + e_r(x + vt) \quad (10)$$

$$i(x, t) = \frac{1}{z_c} e_f(x - vt) + \frac{1}{z_c} e_r(x + vt) \quad (11)$$

Los tiempos que tardan las ondas en viajar desde la falla hasta la discontinuidad τ_A y τ_B se determinarán utilizando tecnología GPS. Una vez hecho esto, la ubicación de la falla (x) se puede determinar fácilmente mediante la siguiente ecuación (12).

$$x = \frac{l - c(\tau_A - \tau_B)}{2} \quad (12)$$

Donde: c es la velocidad de propagación de la onda de 299,79 m/seg.

1.1.2.3 Métodos basados en redes neuronales

Las redes neuronales se han puesto en uso para la localización de fallas recientemente (El-Sharkawi y Neibur, 1996) y han ganado una importancia significativa desde que Sobajic y Pao usaron redes neuronales para la predicción del tiempo crítico de limpieza (Dalstein y Kulicke, 1995). El amplio uso de las redes neuronales comenzó a aproximadamente a finales de 80 y comienzo de los 90. Las redes neuronales suelen utilizarse para lograr una mayor eficiencia en la detección, clasificación y localización de averías. Se han realizado muchas investigaciones y se ha publicado abundante literatura en el campo de la localización de fallas utilizando redes neuronales. Ciertas técnicas y resultados significativos que se han publicado se discuten brevemente aquí. La mayoría del trabajo mencionado aquí hizo uso de la técnica de perceptrón multicapa de alimentación hacia adelante. (Dalstein y Kulicke, 1995) utilizaron redes neuronales para la detección de fallas en las líneas de transmisión y también diferenciaron entre fallas con arco y sin arco. Una nueva técnica

para la detección y localización de fallas de alta velocidad utilizando redes neuronales ha sido propuesta (Kezunovic, 1997). Chen *et al.* (1999) han investigado ampliamente las técnicas de ubicación de fallas de un solo extremo basadas en redes neuronales, mientras que Song usó redes neuronales para la ubicación de fallas en líneas compensadas en serie.

1.1.3 Las redes neuronales

Una red neuronal artificial (RNA) puede describirse como un conjunto de neuronas elementales que generalmente están conectadas en arquitecturas inspiradas biológicamente y organizadas en varias capas (Cichocki y Unbehauen, 1993). La estructura de una RNA de avance, también llamada perceptrón, se muestra en la Fig. 4. Hay números N_i de neuronas en cada i -ésima capa y las entradas a estas neuronas están conectadas a las neuronas de la capa anterior. La capa de entrada se alimenta con las señales de excitación. En pocas palabras, una neurona elemental es como un procesador que produce una salida realizando una operación no lineal simple en sus entradas (Haykin, 2005). Se adjunta un peso a todas y cada una de las neuronas y entrenar una RNA es el proceso de ajustar diferentes pesos adaptados al conjunto de entrenamiento. Una red neuronal artificial aprende a producir una respuesta basada en las entradas proporcionadas ajustando los pesos de los nodos.

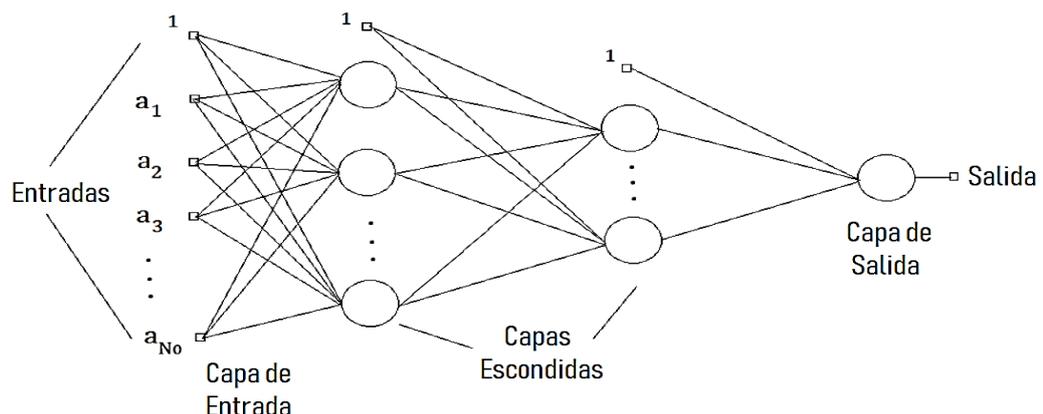


Figura 4. Arquitectura básica de tres capas de una RNA de retroalimentación
Fuente: (Haykin, 2005)

En la figura 4, $a_1, a_2 \dots a_{N_0}$ es el conjunto de entradas a la RNA. Debido a sus excelentes capacidades de reconocimiento de patrones, las RNA se utilizan para varios propósitos en una amplia variedad de campos, incluido el procesamiento

de señales, las computadoras y la toma de decisiones. Algunas notas importantes sobre las redes neuronales artificiales son según Kezunovic *et al.* (1996):

- Las características de la señal extraídas utilizando ciertos algoritmos de medición o incluso muestras sin procesar de las señales de entrada se alimentan a la RNA.
- La más reciente junto con algunas muestras más antiguas de las señales se alimentan a la RNA.
- La salida proporcionada por la red neuronal corresponde a la decisión en cuestión, que podría ser el tipo de falla, la existencia de una falla o la ubicación de una falla.
- El factor más importante que afecta la funcionalidad de la RNA es el patrón de entrenamiento que se emplea para la misma.
- También se pueden emplear técnicas de procesamiento previo y posterior para mejorar el proceso de aprendizaje y reducir el tiempo de capacitación de la RNA.

Uno de los mayores inconvenientes de las aplicaciones que hacen uso de redes neuronales artificiales es que no existe una guía bien definida que nos ayude a elegir el número ideal de capas ocultas a utilizar y el número de neuronas por cada capa oculta. Desde una perspectiva diferente, es ventajoso considerar la capacidad de generalizar (Cichocki y Unbehauen, 1993). Una característica vital de RNA es su dedicación a la computación paralela. Por lo tanto, puede producir una salida correcta correspondiente a cualquier entrada, incluso si la entrada en cuestión no se introdujo en la RNA durante el proceso de entrenamiento. Otro desafío en el desarrollo de aplicaciones basadas en RNA fue sintetizar el algoritmo para el proceso de aprendizaje adaptativo. El algoritmo de propagación de error inverso es el algoritmo básico en el que se calculan los pesos de las neuronas ajustados en pasos consecutivos para minimizar el error entre las salidas reales y las deseadas. Este proceso se conoce como aprendizaje supervisado.

Una red neuronal (RNA) es un procesador distribuido y con un gran número de elementos simples interconectados masivamente en una estructura paralela, con

una tendencia natural a almacenar y procesar conocimiento experimental, haciéndolo apto para su uso y de esta forma emular ciertas características propias de los humanos (López, 2012).

1.1.4 Modelo de una neurona

Cualquier modelo de neurona básico como se muestra en la figura 5. puede describirse mediante una función que calcula la salida como una función de entradas N_0 a la misma. La idea básica detrás de todo el modelo de neuronas, incluidas las funciones de activación que se ilustran a continuación, ha sido adoptada de (Saha *et al.*, 2002).

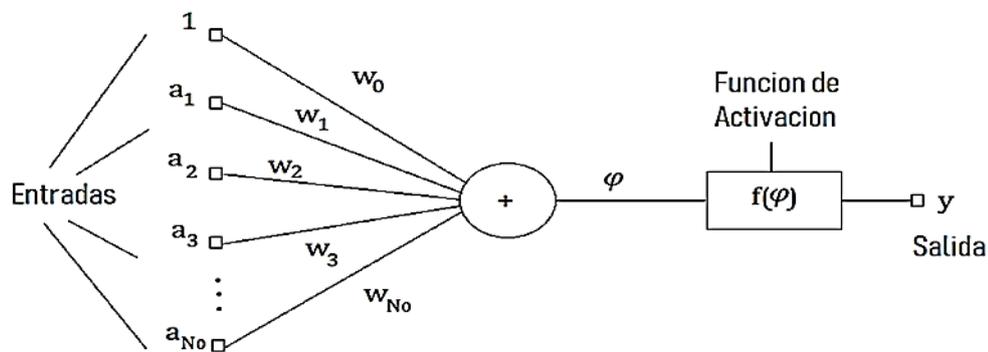


Figura 5. Modelo típico de una neurona
Fuente: (Saha *et al.*, 2002)

La salida de la neurona viene dada por:

$$y = f(\varphi) = f\left(\sum_{i=0}^{N_0} w_i a_i\right) \quad (13)$$

Donde: $w_0 a_0$ es el valor umbral (polarización), $f(\varphi)$ es la función de activación de la neurona, φ es la sumatoria de la señal de salida, y es la neurona de salida.

$$\varphi = W^T A \quad (14)$$

Donde:

$$W = [w_0 \ w_1 \ \dots \ w_{K_0}], \quad A = [a_0 \ a_1 \ \dots \ a_{N_0}]^T \quad (15)$$

Una función de activación decide cuán poderosa debe ser la salida de la neurona, en función de la suma de sus entradas. Dependiendo de los requisitos de la aplicación, se elige la función de activación más adecuada.

La función de activación $f(\varphi)$ puede tener diferentes formas, algunas de las cuales

se describen a continuación:

1.1.4.1 Función de paso

$$f(\varphi) = \begin{cases} 1 & \text{si } \varphi \geq 0 \\ 0 & \text{si } \varphi < 0 \end{cases}$$

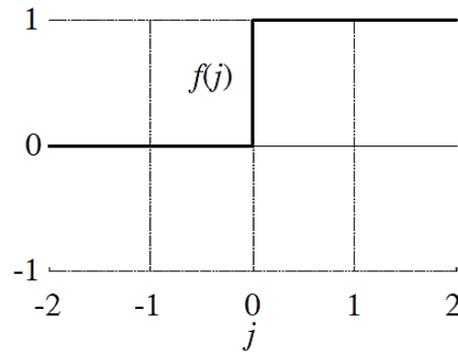


Figura 6. Activación de la función de paso

1.1.4.2 Función lineal por partes

$$f(\varphi) = \begin{cases} 1 & \text{si } \varphi > 1 \\ -1 & \text{si } \varphi < -1 \\ \varphi & \text{si } |\varphi| < 1 \end{cases}$$

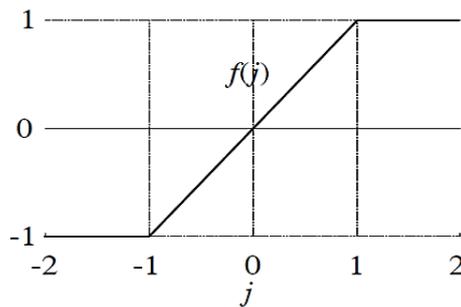


Figura 7. Función de activación lineal por partes

1.1.4.3 Función unipolar sigmoidea

$$f(\varphi) = \frac{1}{1 + e^{-\beta\varphi}}$$

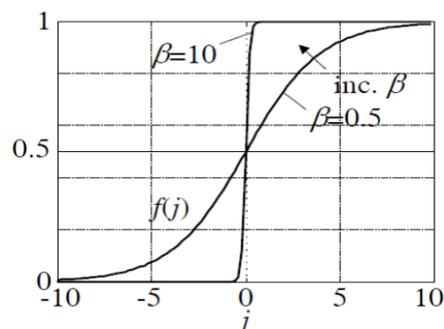


Figura 8. Función de activación unipolar sigmoidea

1.1.4.4 Función bipolar sigmoidea

$$f(\varphi) = \tanh \tanh (\beta \varphi) \frac{1 - e^{-2\beta\varphi}}{1 + e^{-2\beta\varphi}}$$

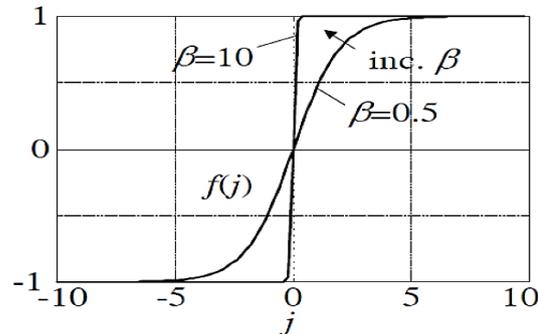


Figura 9. Función de activación bipolar

Según la forma en que las neuronas están interconectadas en un modelo, las redes neuronales se pueden clasificar en términos generales en dos tipos, redes de retroalimentación y de alimentación. Como sugiere el nombre, las redes de retroalimentación, a diferencia de las redes de avance, tienen una conexión de retroalimentación que se retroalimenta a la red junto con las entradas. Debido a su simplicidad y a la existencia de un algoritmo de aprendizaje bien definido, en esta tesis solo se han utilizado redes de retroalimentación para la simulación y, por lo tanto, se analizan brevemente en las próximas secciones.

1.1.5 Redes de retroalimentación

Las redes retroalimentación son las redes neuronales más simples en las que no hay una conexión de retroalimentación involucrada en la red y, por lo tanto, el viaje de la información es unidireccional (Haykin, 2005). En la figura 10 se muestra una red realimentada con señales de entrada N_0 y salida K_R . El proceso de cálculo en la i -ésima capa se puede describir mediante la siguiente ecuación (16).

$$p^{(i)} = f^{(i)}(W^{(i)}g^{(i-1)}) \quad (16)$$

Donde

$$p^{(i)} = [p_1^{(i)} p_2^{(i)} \dots p_{N_i}^{(i)}]^T$$

Es el vector de señal a la salida de la i -ésima capa.

$$W = \left(w_{10}^{(i)} \ w_{11}^{(i)} \ w_{20}^{(i)} \ w_{21}^{(i)} \ \dots \ w_{1N_{i-1}}^{(i)} \ w_{2N_{i-1}}^{(i)} \ \vdots \ \vdots \ w_{N_i0}^{(i)} \ w_{N_i1}^{(i)} \ \dots \ w_{N_iN_{i-1}}^{(i)} \right)$$

Es la matriz de ponderación entre la $(i-1)$ ésima y la i -ésima capa.

$$g^{((i-1))} = \{A, \text{ para } i=1 \ [1 \ p^{((i-1))}] \}, \text{ para } i=2,3,\dots,R \quad (17)$$

A es el vector que contiene las señales de entrada, $f^{(i)}(\cdot)$ es la función de activación de las neuronas en la i -ésima capa y R es el número de capas de procesamiento. Se supone que todas las neuronas en una capa en particular son similares en todos los aspectos y el número de capas ocultas puede ser más de uno y generalmente está determinado por el propósito de la red neuronal. La salida de la red neuronal procesada está representada por el vector de salida:

$$y = p^{(R)} = [y_1 \ y_2 \dots \ y_{N_R}]^T \quad (18)$$

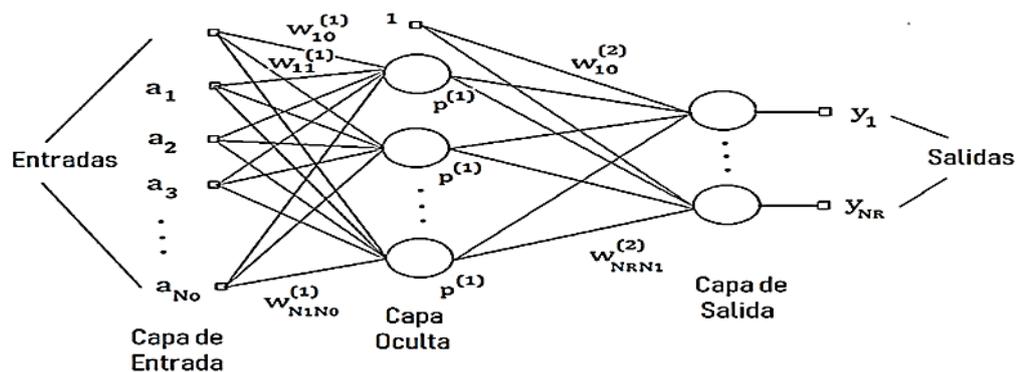


Figura 10. Estructura de una red retroalimentación de dos capas
Fuente: (Haykin, 2005).

1.1.6 Estrategias de aprendizaje

El concepto básico detrás de la aplicación exitosa de redes neuronales en cualquier campo es determinar los pesos para lograr el objetivo deseado y este proceso se llama aprendizaje o entrenamiento. Los dos mecanismos de aprendizaje diferentes que suelen emplearse son el aprendizaje supervisado y el no supervisado. En el caso del aprendizaje supervisado, los pesos de la red se modifican con el objetivo principal de minimizar el error entre un conjunto dado de entradas y sus correspondientes valores objetivo (Cichocki y Unbehauen, 1993). Por lo tanto, conocemos el conjunto de datos de entrenamiento, que es un conjunto de entradas

y los objetivos correspondientes que la red neuronal debería generar idealmente. Esto se llama aprendizaje supervisado porque tanto las entradas como los valores objetivo esperados se conocen antes del entrenamiento de RNA.

Por otro lado, en el caso del aprendizaje no supervisado, desconocemos la relación entre las entradas y los valores objetivo. Entrenamos la red neuronal con un conjunto de datos de entrenamiento en el que solo se conocen los valores de entrada. Por lo tanto, es muy importante elegir el conjunto correcto de ejemplos para un entrenamiento eficiente. Estos ejemplos generalmente se eligen usando algún tipo de principio de similitud (Haykin, 2005). Los algoritmos de aprendizaje no supervisado más utilizados son el Mapa autoorganizado (SOM) y la Teoría de la resonancia adaptativa (ART). La estrategia de aprendizaje empleada depende de la estructura de la red neuronal. Las redes retroalimentación se entrenan utilizando la estrategia de aprendizaje supervisado. La estrategia de aprendizaje supervisado para una red neuronal retroalimentación (Figura 10).

El conjunto de pares de entrada-salida (que se muestra en la figura 10) que se utilizan para entrenar la red neuronal se obtienen antes del proceso de entrenamiento, ya sea mediante el uso de medidas físicas o mediante la realización de algún tipo de simulación. La figura 11 muestra que el maestro enseña la red neuronal para modificar sus pesos según el error 'e' entre las salidas y los objetivos. Los pesos de la red neuronal luego se modifican iterativamente de acuerdo con la ecuación (19). La idea general detrás del aprendizaje supervisado y las matemáticas involucradas ha sido adoptada de (Saha *et al.*, 2002).

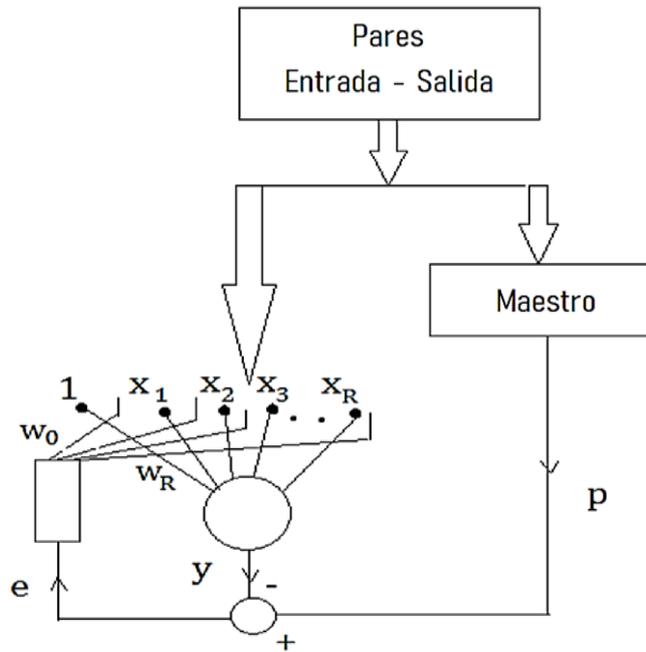


Figura 11. Esquema de aprendizaje supervisado
Fuente: (Saha *et al.*, 2002)

$$w_{ji}(n + 1) = w_{ji}(n) + \Delta w_{ji}(n) \tag{19}$$

Donde:

$$w_{ji}(n) \text{ y } w_{ji}(n+1)$$

son los pesos anterior y modificado conectados entre las capas contiguas *i*-ésima y *j*-ésima. $\Delta w_{ji}(n)$ representa el factor de corrección o modificación y *n* representa el número de la iteración. Si consideramos la *j*-ésima neurona en una red neuronal de una sola capa, la eficiencia del entrenamiento se mejora al minimizar el error entre la salida real de la *j*-ésima neurona y la salida dictada por el profesor. Sea $y_j(n)$ y $p_j(n)$ ser las salidas reales y solicitadas por el profesor para la *j*-ésima neurona en la *n*-ésima iteración. Entonces el valor de error de esa iteración viene dado por (20).

$$e_j(n) = p_j(n) - y_j(n) \tag{20}$$

El vector $e(n)$ que almacena los valores de todos los errores también es función de los pesos $w(n)$ para las entradas de las capas correspondientes. El valor por el cual cambian los coeficientes de pesaje (también llamado factor de corrección) viene dado por la siguiente ecuación (21).

$$\Delta w_{ji}(n) = \eta e_j(n) x_i(n) \quad (21)$$

Donde: x_i es la i -ésima señal de entrada y η es la velocidad a la que tiene lugar el proceso de aprendizaje. Como se mencionó anteriormente, el proceso de aprendizaje apunta a la minimización de la función de error. El mismo criterio también se puede lograr mediante el uso de un método de mínimos cuadrados (LSM). Por lo tanto, si hay L neuronas en una red particular, la función de costo que finalmente se minimizará viene dada por (22).

$$S_2(w) = \frac{1}{2} \sum_{j=1}^L (p_j - y_j)^2 \quad (22)$$

Si el número de pares de aprendizaje con un vector de entrada $x(n)$ y un vector de salida $d(n)$ de la forma $(x(n), d(n))$ son P en el conjunto de entrenamiento, entonces durante la n -ésima iteración del proceso de aprendizaje, tenemos:

$$S_2(w(n)) = \frac{1}{2} \sum_{n=1}^P \sum_{j=1}^L (p_j(n) - y_j(n))^2 \quad (23)$$

Dado que las funciones de activación que se emplean son a menudo no lineales, la minimización de la ecuación anterior (23) es un problema no lineal. Varios métodos numéricos que pueden manejar funciones no lineales de manera efectiva están disponibles y se basan en el método más empinado-decente. El método de descenso más pronunciado es una extensión del método de aproximación integral de Laplace, donde la integral de contorno en un plano complejo se deforma para acercarse a un punto estacionario en la dirección del descenso más pronunciado (El-Sharkawi y Neibur, 1996). La técnica de aprendizaje de propagación de errores inversos se basa en el método más empinado y decente y, por lo general, se aplica ampliamente en una versión conocida como el algoritmo de Levenberg-Marquardt.

El algoritmo de propagación de error inverso elige pesos aleatorios para los nodos de la red neuronal, alimenta un par de entrada y obtiene el resultado. Luego calculamos el error para cada nodo comenzando desde la última etapa y propagando el error hacia atrás. Una vez hecho esto, actualizamos los pesos y repetimos el proceso con todo el conjunto de pares de entrada y salida disponibles en el conjunto de datos de entrenamiento. Este proceso continúa hasta que la red converge con respecto a los objetivos deseados. La técnica de propagación de

errores inversos se usa ampliamente para varios propósitos, incluida su aplicación a funciones de error (que no sean la suma de errores al cuadrado) y para la evaluación de matrices jacobianas y hessianas. Los valores de corrección se calculan como funciones de errores estimados a partir de la minimización de la ecuación (23). Este proceso se lleva a cabo capa por capa en toda la red en dirección hacia atrás. Este algoritmo se representa pictóricamente en la figura 12.

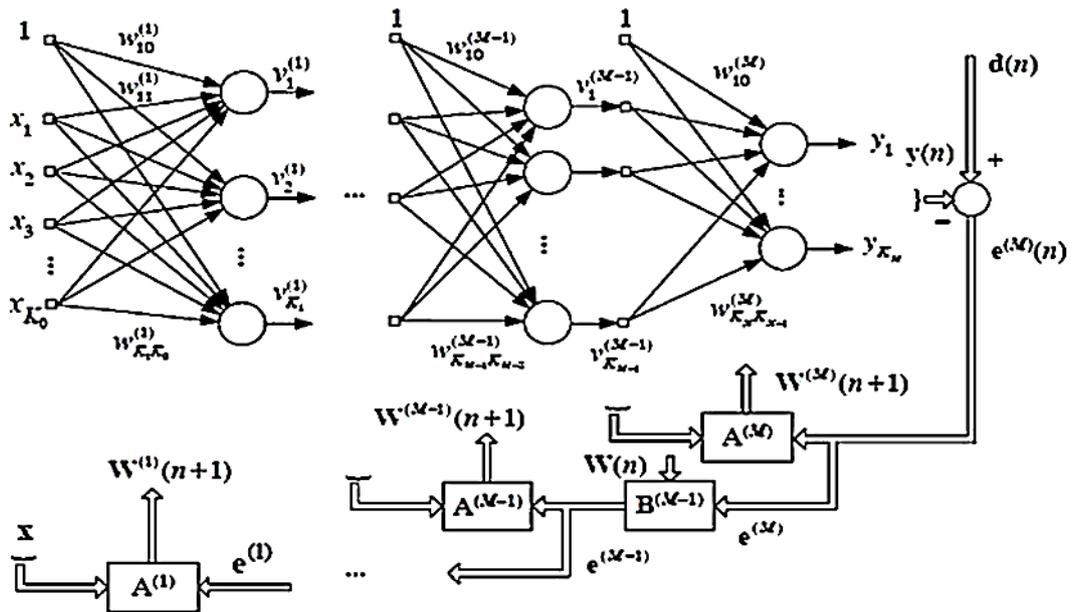


Figura 12. Estructura del algoritmo de propagación de errores inversos
Fuente: (Saha *et al.*, 2002)

Los vectores de pesaje correspondientes se muestran en los bloques $A^{(M)}, A^{(M-1)}, \dots, A^{(1)}$ y los errores que se propagan a las capas inferiores se calculan y almacenan en los bloques $B^{(M-1)}, B^{(M-2)}, \dots, B^{(2)}$. El algoritmo de propagación de errores inversos se ha implementado de muchas maneras, pero la idea básica sigue siendo la misma. Lo único que cambia en cada una de estas implementaciones es el método utilizado para el cálculo de los pesos que se actualizan iterativamente cuando se pasan de una capa a otra en la red neuronal. Las modificaciones involucradas también se utilizan en el proceso de entrenamiento de redes recurrentes. La velocidad a la que tiene lugar el proceso de aprendizaje se puede estimar controlando los valores de corrección en etapas sucesivas. El número total de iteraciones requeridas para lograr una tasa de convergencia satisfactoria depende de los siguientes factores:

- Tamaño de la red neuronal.

- Estructura de la red.
- El problema que se investiga.
- La estrategia de aprendizaje empleada.
- Tamaño del conjunto de entrenamiento/aprendizaje.

La eficiencia de una RNA elegida y la estrategia de aprendizaje empleada se pueden estimar utilizando la red entrenada en algunos casos de prueba con valores de salida conocidos. Este conjunto de prueba también es parte del conjunto de aprendizaje. Por lo tanto, todo el conjunto de datos consta del conjunto de datos de entrenamiento junto con el conjunto de datos de prueba. El primero se usa para entrenar la red neuronal y el segundo se usa para evaluar el rendimiento de la red neuronal artificial entrenada.

1.2 Antecedentes

Yadav y Swetapadma (2015) propone un esquema de detección y clasificación de fallas usando la transformada Wavelet y análisis discriminante lineal (LDA). El rendimiento del esquema basado en la propuesta se prueba mediante variaciones de parámetros como el tipo de falla, la ubicación, la resistencia de la falla, el ángulo de inicio de la falla y el ángulo del flujo de energía. Todas las fallas de derivación y las fallas en ubicaciones múltiples que ocurren en diferentes ubicaciones al mismo tiempo también son detectadas y clasificadas por el esquema propuesto dentro de un tiempo de ciclo. Sus resultados en la simulación muestran que el esquema propuesto no se ve afectado por la falla no lineal de alta impedancia.

Krishnanand *et al.* (2015) hace un enfoque de patrones para la transmisión diferencial de corriente de las líneas de transmisión de energía y plantea un método que utiliza información de energía espectral proporcionada a través de una nueva Transformada S discreta rápida (FDST) donde utiliza diferentes tipos de escalado de frecuencia, filtrado de paso de banda y técnicas de interpolación de un bajo costo computacional donde el nuevo algoritmo es adecuado para la implementación en tiempo real. El esquema propuesto se evalúa para la protección diferencial de corriente de una línea de transmisión alimentada desde ambos extremos para una variedad de fallas, resistencia de falla, ángulos de inicio y ruido significativo en la señal utilizando estudios de simulación por

computadora. Los resultados obtenidos del cómputo exhaustivo muestran la viabilidad del nuevo enfoque.

Calderón (2004) logra crear un algoritmo que puede detectar y clasificar dos tipos de falla como son: LIFs y HIFs, haciendo uso de ANFIS (Adaptive Network-based Fuzzy Inference System). Sus resultados demuestran que su modelo ANFIS puede hacer una detección y clasificación muy precisa de fallas, tanto (LIFs y HIFs) por supuesto desarrollado para un tiempo de medio ciclo.

Ramesh y Mohod (2021) desarrolla un algoritmo eficiente para detectar, clasificar y ubicar fallas asimétricas, en líneas de transmisión utilizando Redes Neuronales Artificiales (RNA), para poder implementarse en relés numéricos. Este algoritmo se implementa en el hardware y los resultados se lograron obtener mediante simulación.

Bashier y Tayeb (2013) presenta la arquitectura de red neuronal NN para detectar fallas en un sistema de línea de transmisión de energía. Su objetivo implementa un esquema completo para la protección a distancia que se subdivide en diferentes zonas de redes neuronales. Se consideran fallas monofásicas a tierra, bifásicas y bifásicas a tierra. En sus resultados, se realizó un sistema de relés de protección para los sistemas de líneas de transmisión de energía utilizando una arquitectura NNBP.

Shaik y Pulipaka (2015) describe la aplicación de transformadas Wavelet para la detección, clasificación y localización de fallas en líneas de transmisión. Utiliza un reloj GPS para sincronizar el muestreo de las señales de voltaje y corriente en ambos extremos de la línea de transmisión. Los coeficientes de detalle de las señales de corriente de ambos extremos se utilizan para calcular los índices de falla. Para localizar la falla se emplean Redes Neuronales Artificiales, las cuales hacen uso de descomposiciones aproximadas de las tensiones y corrientes de extremo local. El algoritmo propuesto se prueba con éxito para diferentes ubicaciones y tipos de fallas.

Según Jamil *et al.* (2015) el enfoque está en la detección y clasificación de fallas en LT de energía eléctrica utilizando redes neuronales artificiales. Se propone un esquema con las corrientes y tensiones trifásicas de un extremo como entradas. Con un análisis detallado de un número variable de capas ocultas para validar la elección de la red neuronal. Sus resultados para esta simulación concluyeron que el presente método basado en la red neuronal es eficiente para hacer una detección y clasificación de fallas en las

líneas de transmisión con desempeños satisfactorios. Las diversas simulaciones y análisis de señales se realizaron en entorno MATLAB®.

Torabi *et al.* (2017) diseña una estrategia robusta de diagnóstico de fallas para el aislamiento de fallas de interruptores abiertos en variadores multifásicos utilizando técnicas de aprendizaje automático. Se usa una red neuronal Wavelet autorrecurrente adaptativa como identificador de sistema no lineal proporciona una estimación de un modelo no lineal para generar síntomas de falla apropiados en función de las señales de puerta y las corrientes reales del motor. El método se aplica en sistemas controlados por corriente, controlados por velocidad y sin sensor de velocidad. La detección de fallas es seguida por un clasificador, para localizar la falla. Los resultados están respaldados por una instalación de laboratorio.

Babayomi *et al.* (2017) en su estudio hace el uso de técnicas difusas y neuro-difusas adaptativas para detectar, clasificar y ubicar fallas. Se aplicaron 10 tipos diferentes de fallas eléctricas en una LT. Sus resultados obtenidos registran un alto grado de precisión.

Además, la introducción de nuevos conceptos de marketing como la desregulación ha aumentado la necesidad de un suministro de energía eléctrica confiable e ininterrumpido para los usuarios finales que son muy sensibles a los cortes de energía (Das y Novesel, 2015). Uno de los factores más importantes que dificultan el abastecimiento constante de energía eléctrica y potencia, es una falla en el sistema de potencia (IEEE, 2014).

Padilla (2016) propone y diseña un prototipo de sistema para localización automática de fallas en líneas de transmisión, basándose en la utilización de diferentes métodos de localización de fallas desarrollados por diferentes autores. Para llegar a esto se analizó el principio matemático y se les realizaron pruebas a diversos métodos, permitiendo desarrollar por medio de la herramienta redes de Petri una metodología para la utilización de cada método de forma paralela.

Todo elemento de un sistema eléctrico de potencia está expuesto a fallas. En especial las líneas de transmisión, ya que debido al área geográfica que ocupan, están propensas a una mayor incidencia de cortocircuitos. Cuando ocurre una falla en una línea de transmisión los sistemas de protección deben operar de manera rápida para liberar la fallas y evitar así severos daños a los equipos o personal de campo (Huerta, 2014).

Liquinchana (2022) presenta un sistema de clasificación de fallas basado en redes neuronales artificiales (ANN). En este sentido, los tipos de fallas contempladas para la clasificación son: fase a tierra, fase a fase, trifásicas y fallas de doble línea a tierra. Desde otra perspectiva, para el entrenamiento de la ANN se edifica un conjunto de datos, que contiene valores RMS de voltajes, corrientes de falla y de secuencia cero, bajo diferentes parámetros de impedancia y localización de la falla.

Para resolver el problema del diagnóstico y clasificación de fallas se han propuesto algunos algoritmos basados en técnicas de inteligencia artificial tales como redes neuronales, redes neuro-difusas, etc. Estos algoritmos permiten manejar adecuadamente la incertidumbre ante situaciones de datos imprecisos, usar técnicas de aprendizaje para el modelamiento, adaptarse a los cambios en las condiciones de operación del sistema y usar el conocimiento del experto antes situaciones no definidas (Alvarado, 2012).

Para Calderón *et al.* (2008) El diagnóstico de fallas eléctricas en líneas de transmisión a alto voltaje es una tarea compleja no solo por la cantidad de información involucrada que puede provenir de diversas fuentes como SOE, SCADA y registradores, sino también por la variabilidad misma de las fallas. Dicha complejidad impacta en la oportunidad y certeza del diagnóstico, factores particularmente importantes para el análisis en tiempo real donde rápidamente deben tomarse pautas adecuadas para el restablecimiento del sistema eléctrico de potencia.

León (2017) describe de forma general el diseño e implementación de un modelo basado en Redes Neuronales para la localización de fallas de alta impedancia en líneas de transmisión eléctrica aéreas. Para la implementación de este modelo, se desarrolló una metodología basada principalmente en las siguientes etapas: caracterización del sistema eléctrico de potencia, extracción y/o adquisición de datos, preparación de los datos mediante técnicas de procesamiento de señales y diseño e implementación de una red neuronal para la localización de este tipo de falla.

Leon y Maldonado (2018) tuvieron por objetivo de crear un sistema de diagnóstico mediante la aplicación de un clasificador basado en redes neuronales artificiales, que permite detectar fallas mecánicas comunes, generadas en los motores de encendido provocado. En primera instancia para el desarrollo del sistema de diagnóstico, se procede a la obtención de las señales de los sensores MAP y CMP con una DAQ-6009 y el software Labview del motor Hyundai Sonata de 4 cilindros 2.0 cc a gasolina, el mismo



que se encuentra en una cámara Semi-Anecoica, con el objetivo de adquirir datos con una alta confiabilidad; en el motor se generan los diferentes tipos de anomalías mecánicas intencionadas, en sistemas y componentes como son: bobinas, inyectores, bujías, la presión de combustible y sistema de distribución.

En la actualidad, mantener los procesos o sistemas en control es una técnica que día a día se va haciendo más común en la mayoría de las empresas, esto por la gran necesidad de hacer sus procesos cada vez más autónomos, y con ello, el deseo de mantener una calidad constante en los productos y servicios, la cual pueda satisfacer los requerimientos que ya han sido establecidos por los clientes, estos requerimientos, se describen, como las características con las cuales debe cumplir el producto o servicio, y son dependientes de las variables que intervienen directamente en el proceso o sistema (Hernández, 2015).

Dentro de los equipos utilizados se encuentra una tarjeta de adquisición de datos EDIBON de bajo costo, que se conecta al equipo de control térmico para poder recibir las señales provenientes de los sensores de temperatura y caudal del equipo y llevarlas a un computador, en el cual se utilizó LabView para exportar los datos en Excel. Posteriormente mediante la utilización del software y lenguaje de programación de MatLab, se diseñó una interfaz donde se presenta la detección y diagnóstico de fallas de mediante una Red Neuronal (Rincon y Vargas, 2018).

CAPÍTULO II

PLANTEAMIENTO DEL PROBLEMA

2.1 Identificación del problema

En ingeniería tenemos diferentes maneras de solucionar problemas y además de procesar estos resultados. Las Redes Neuronales podrían solucionar problemas de tipo complejo, no en una secuencia de operaciones, sino aprovechando una evolución de sistemas computacionales basados en la neuro ciencia del cerebro humano (inteligencia), Que no son otra cosa que la combinación de ciertos procesos simples interconectados que, al operar de forma paralela en múltiples estilos, pretenden resolver los problemas más complejos como son: la clasificación, reconocimiento de patrones reconocibles.

2.2 Enunciados del problema

El trabajo realizado en este proyecto propone el estudio de múltiples configuraciones basadas en RNA y además algunos algoritmos de entrenamiento y aprendizaje que calculan un pronóstico de variables intervinientes en las diferentes fallas en LT, se utiliza datos de tipo histórico que se genera en las mediciones realizadas en la línea como, por ejemplo: \emptyset tensión, corriente y \emptyset de corriente.

2.3 Justificación

Podíamos definir en la red eléctrica 3 grandes grupos, el grupo de generación, la distribución de la energía eléctrica y finalmente el consumo por parte del cliente. Dentro de esta organización, la ubicación de la generación de energía eléctrica se encuentra a grandes distancias del consumidor, en consecuencia, se necesita instalar sistemas de transporte de la energía eléctrica LT que puedan ser de tipo eficiente y fiable.

En los últimos años, ante el crecimiento exponencial de la industria y las ciudades se a multiplicado la potencia demandada a la red eléctrica por lo tanto se ha tenido que llevar al límite las líneas existentes. Además de que, la adopción de las energías renovables en la red da como resultado limitaciones al momento de los controles en la calidad de energía circulante en la red. En consecuencia, tenemos la necesidad de optimizar las formas de como circula la energía en la red mediante nuevas tecnologías de control, y de esta manera ofrecer una buena gestión de la calidad y estabilidad de esta.

2.4 Objetivos

2.4.1 Objetivo general

Reconocer y clasificar los diferentes de tipos de fallas en LT eléctrica, utilizando la tecnología de RNA (redes neuronales artificiales).

2.4.2 Objetivos específicos

- Definir las agrupaciones que se emplearan para las fases de entrenamiento, validación y prueba de las RNA haciendo un análisis de la data generada utilizando simulaciones de circuitos eléctricos.
- Diseñar una herramienta auxiliar con RNA que reconozca y ordene el tipo de falla utilizando algunas variables, como corriente y tensión.
- Integrar la herramienta auxiliar con RNA, mediante el software MATLAB utilizando su interfaz gráfica.

2.5 Hipótesis

2.5.1 Hipótesis general

Se reconoce y clasifica los diferentes tipos de fallas en LT eléctrica, utilizando la tecnología de redes neuronales artificiales RNA.

2.5.2 Hipótesis específicas

- Se definen las agrupaciones que se emplearan para las fases de entrenamiento, validación y prueba de las RNA con un análisis de la data generada utilizando simulaciones de circuitos eléctricos.



- Se diseña una herramienta auxiliar con RNA que reconoce y ordena el tipo de falla utilizando algunas variables, como corriente y tensión.
- Se integra una herramienta auxiliar con RNA, utilizando el software MATLAB con su interfaz gráfica.

CAPÍTULO III

MATERIALES Y MÉTODOS

3.1 Lugar de estudio

Dentro de las instalaciones de Universidad Nacional del Altiplano Puno – Perú, específicamente en el laboratorio de Control y Automatización, de la Escuela Profesional de Ingeniería Mecánica Eléctrica, se harán las simulaciones y pruebas de sistemas de líneas de transmisión eléctrica.

Además de utilizar el software MATLAB en las diferentes ubicaciones en el desarrollo de este trabajo de investigación.

3.2 Población

La data generada en el sistema de simulación que posteriormente se analiza y propone como un sistema RNA.

3.3 Muestra

La conforma las diferentes mediciones de corriente y tensión en tramos de la línea de transmisión, información que será recogida por un sistema de adquisición y almacenamiento para luego clasificar y agrupar.

3.4 Método de investigación

El método de investigación es de tipo experimental con simulaciones basadas en RNA mediante MATLAB.

3.5 Descripción detallada de métodos por objetivos específicos

3.5.1 Modelado del sistema de línea de transmisión de energía

Se ha utilizado un sistema de línea de transmisión de 500 kV para desarrollar e implementar la estrategia propuesta utilizando RNA. La figura 13 muestra un diagrama unifilar del sistema que se ha utilizado a lo largo de la investigación. El sistema consta de dos generadores de 500 kV cada uno ubicados en ambos extremos de la línea de transmisión junto con un simulador de fallas trifásico utilizado para simular fallas en varias posiciones de la línea de transmisión. La línea se ha modelado utilizando parámetros distribuidos para que describa con mayor precisión una línea de transmisión muy larga.

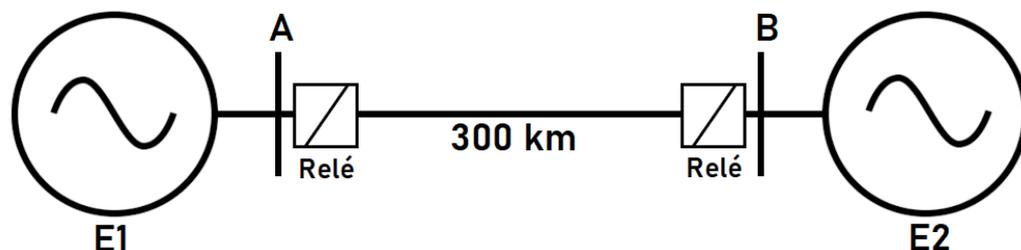


Figura 13. Diagrama unifilar del sistema estudiado

3.5.2 Ubicación de fallas en LT de energía uso de redes neuronales

Este sistema de energía fue simulado utilizando la caja de herramientas SimPowerSystems en Simulink por The MathWorks. En la figura 14 se muestra una instantánea del modelo utilizado para obtener los conjuntos de datos de entrenamiento y prueba. En la figura 14, ZP y ZQ son las impedancias de fuente de los generadores a cada lado. El bloque de medida trifásico VI se utiliza para medir las muestras de tensión y corriente en el terminal A. La línea de transmisión (línea 1 y línea 2 juntas) tiene una longitud de 300 km y el simulador de faltas trifásicas se utiliza para simular varios tipos de faltas. en diferentes lugares a lo largo de la línea de transmisión con diferentes resistencias de falla.

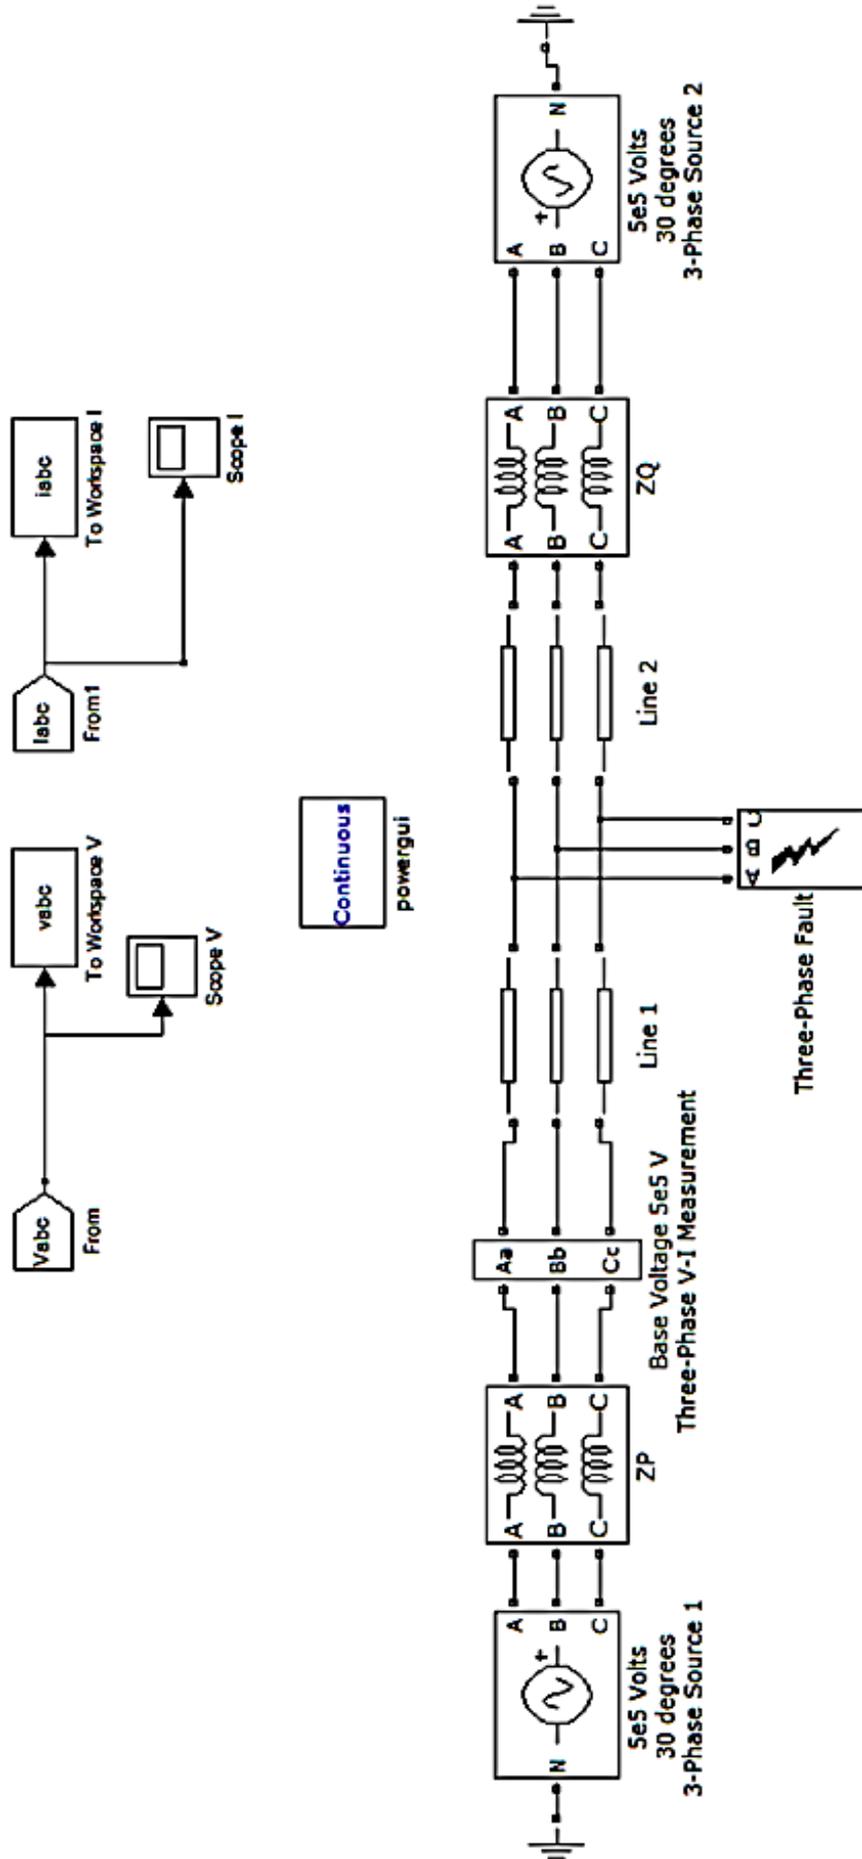


Figura 14. Modelo estudiado en SimPowerSystems

Los valores de las tensiones y corrientes trifásicas se miden y modifican en consecuencia y finalmente se introducen en la red neuronal como entradas. La caja de herramientas de SimPowerSystems se ha utilizado para generar el conjunto completo de datos de entrenamiento para la red neuronal tanto en casos de falla como de no falla.

Las fallas se pueden clasificar en términos generales en cuatro categorías diferentes:

- Fallas de línea a tierra.
- Fallas de línea a línea.
- Fallas de doble línea a tierra.
- Fallas trifásicas.

Se han simulado 1100 casos de fallas diferentes con el propósito de detección de fallas, 1100 casos de fallas diferentes simulados para la clasificación de fallas y un número variable de casos de fallas (según el tipo de falla) con el propósito de localizar fallas.

3.5.3 Esquema del plan propuesto

Tenemos que el concepto clásico detrás de los relés no varía en su definición, la actual tecnología tiene una influencia directa en la forma en cómo funcionan los relés además de ofrecer muchas mejoras en el tema de relés electromecánicos tradicionales.

El esquema propone diseñar, desarrollar, comprobar además de implementar una estrategia completa para el diagnóstico de fallas como se muestra en la Fig. 15. Inicialmente, la totalidad de data recopilada se ramifica en dos conjuntos, estos conjuntos de datos son: entrenamiento y prueba. El primer paso en el proceso es la de detectar las fallas. Una vez que sabemos que se ha producido una falla en la línea de transmisión, se procede a hacer una clasificación de fallas para las diferentes categorías mencionadas en función de las fases de la LT.

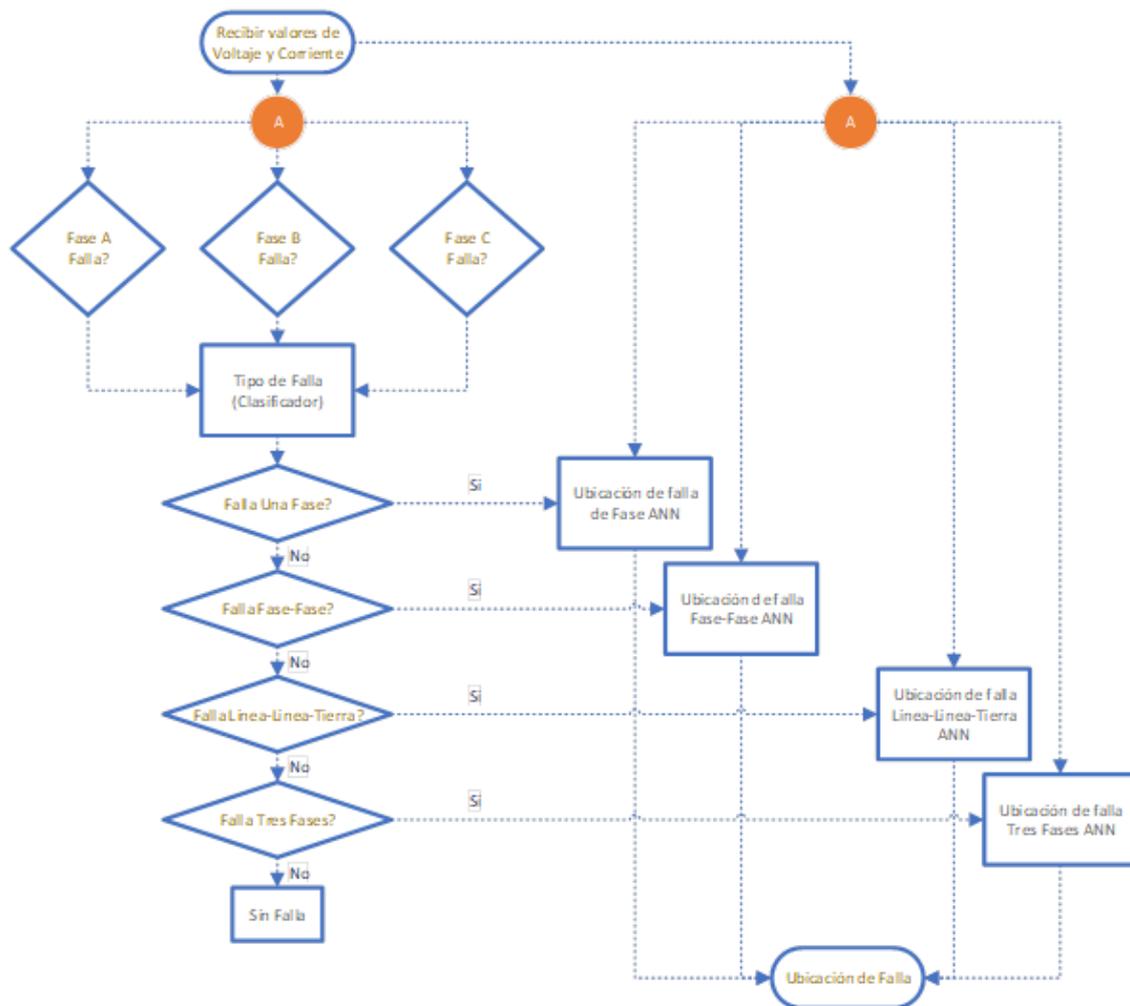


Figura 15. Diagrama de flujo del esquema propuesto

Luego, el tercer paso es señalar la posición de la falla en la línea de transmisión. El objetivo de esta tesis es proponer un método integrado para realizar cada una de estas tareas utilizando redes neuronales artificiales. Se ha utilizado una red neuronal basada en retropropagación para la detección de fallas y otra similar para la clasificación de fallas. Para cada uno de los diferentes tipos de fallas, se han empleado redes neuronales separadas con el fin de ubicar las fallas. Cada uno de estos pasos se ha representado en el diagrama de flujo que se muestra en la Fig. 15.

3.5.1. Preprocesamiento de datos

Una reducción en el tamaño de la red neuronal mejora el rendimiento de la misma y esto se puede lograr realizando una extracción de características. Al hacer esto, toda la información importante y relevante presente en las formas de onda de las

señales de voltaje y corriente se puede usar de manera efectiva. Se generaron formas de onda de voltaje y corriente y se muestrearon a una frecuencia de 720 Hz. Las muestras de voltaje y corriente de las tres fases se anotan junto con los valores previos a la falla correspondientes.

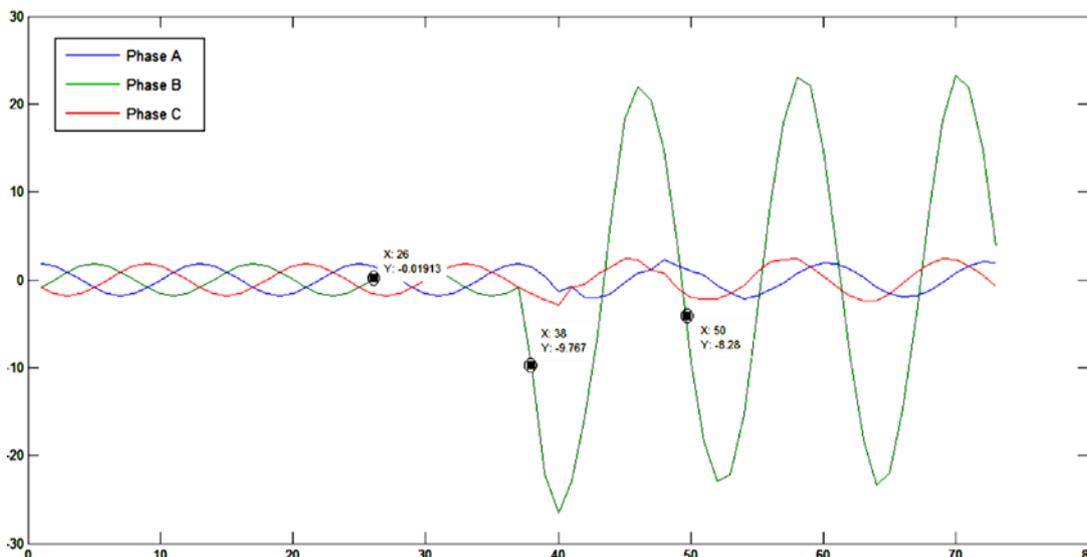


Figura 16. Preprocesamiento de datos

La Fig. 16 muestra la forma de onda actual de una Fase B - falla a tierra a una distancia de 60 km desde la terminal A en una línea de transmisión de 300 km. La forma de onda es la gráfica de las muestras tomadas a una frecuencia de 720 Hz. Por lo tanto, hay 12 muestras por cada ciclo. Ahora, de 50 muestras (la 12va muestra después de la ocurrencia de la falla) en la fase B junto con la muestra 26 (la 12va muestra antes de la ocurrencia de la falla, correspondiente a la muestra posterior a la falla considerada). Una vez hecho esto, las entradas a la red neuronal son las relaciones de las tensiones y corrientes en cada una de las fases antes y después de la ocurrencia de la falla como se muestra en la Tabla 1. Las entradas en formato matricial se muestran a continuación:

$$[V_a(n + 12)/V_a(n - 12) \ V_b(n + 12)/V_b(n - 12) \ V_c(n + 12)/V_c(n - 12) \ I_a(n + 12)/I_a(n - 12) \ I_b(n + 12)/I_b(n - 12) \ I_c(n + 12)/I_c(n - 12)]$$

Donde:

$n = 38'$ es la muestra en la que ocurre la falla.

Por lo tanto, hay un conjunto de seis entradas cada vez (3 para los voltajes de fase y 3 para las corrientes de fase) para todas las redes neuronales discutidas en este trabajo, para asegurarse de que el denominador de cada una de las entradas no sea cero. Si es cero, el valor de n se incrementa en 1 y se toma en consideración la siguiente muestra para todo el proceso. La ventaja de realizar este escalado es reducir el tiempo de cálculo del entrenamiento. A modo de ilustración, la Tabla 1 muestra los valores de tensión y corriente que se escalan con respecto a sus valores previos a la falla y se utilizan como parte del conjunto de entrenamiento. En la Tabla 1, V_a , V_b y V_c son los valores de muestra de voltaje y corriente posteriores a la falla y $V_a(pf)$, $V_b(pf)$ y $V_c(pf)$ son los valores previos a la falla correspondientes, como se ilustró anteriormente. La tabla dada muestra los valores para todos los diversos tipos de fallas y también durante el caso sin fallas. El fallo se ha simulado en una línea de transmisión de 300 km de longitud a una distancia de 100 km del terminal A.

Tabla 1
Muestra de Entradas a la red neuronal para varios casos de falla

N° caso:	Vector de entrada						Tipo de Falla
	$\frac{V_a}{V_a}(pf)$	$\frac{V_b}{V_b}(pf)$	$\frac{V_c}{V_c}(pf)$	$\frac{I_a}{I_a}(pf)$	$\frac{I_b}{I_b}(pf)$	$\frac{I_c}{I_c}(pf)$	
1	0.62	0.97	1.04	1.68	0.51	0.88	A a tierra
2	0.66	0.74	0.83	0.40	27.69	1.75	B a tierra
3	1.26	0.91	0.79	1.50	-1.52	-4.75	C a tierra
4	-0.19	0.60	1.00	4.90	20.68	0.99	A a B
5	1.00	0.55	0.33	1.00	33.82	-7.12	B a C
6	1.16	1.00	0.92	-1.60	1.00	-2.25	C a A
7	-0.13	0.58	0.90	2.97	30.42	1.47	A - B a tierra
8	0.94	0.51	0.38	0.93	35.30	-6.75	B - C a tierra
9	0.99	0.91	0.84	0.62	-1.29	-5.03	C - A a tierra
10	0.31	0.44	0.50	1.87	36.00	-6.58	A a B a C
11	1.00	1.00	1.00	1.00	1.00	0.99	Sin falla

3.5.2. Visión general del proceso de capacitación

Los 2 pasos importantes en la aplicación de RNA para cualquier propósito son el entrenamiento y la prueba. El primero de los dos pasos, el entrenamiento de la red

neuronal se analiza en esta sección. El entrenamiento es el proceso por el cual la red neuronal aprende de las entradas y actualiza sus pesos en consecuencia. Para entrenar la red neuronal, necesitamos un conjunto de datos llamado conjunto de datos de entrenamiento, que es un conjunto de pares de entrada y salida que se alimentan a la red neuronal. Por lo tanto, le enseñamos a la red neuronal cuál debe ser la salida, cuando esa entrada en particular se introduce en ella. La RNA aprende lentamente el conjunto de entrenamiento y desarrolla lentamente la capacidad de generalizar sobre estos datos y eventualmente podrá producir una salida cuando se le proporcionen nuevos datos. Durante el proceso de formación, los pesos de la red neuronal se actualizan con el objetivo principal de minimizar la función de rendimiento. Esta función de rendimiento puede ser definida por el usuario, pero por lo general las redes retroalimentación emplean el error cuadrático medio como función de rendimiento y se adopta lo mismo a lo largo de este trabajo.

Como ya se mencionó en el capítulo anterior, todos los voltajes y corrientes alimentados a la red neuronal se escalan con respecto a los valores de voltaje y corriente correspondientes antes de que ocurra la falla. Las salidas, según el propósito de la red neuronal, pueden ser la condición de falla, el tipo de falla o la ubicación de la falla en la línea de transmisión.

Para la tarea de entrenar las redes neuronales para las diferentes etapas, se ha adoptado la alimentación secuencial del par de entrada y salida. Con el fin de obtener un gran conjunto de entrenamiento para un desempeño eficiente, cada uno de los diez tipos de fallas ha sido simulado en diferentes ubicaciones a lo largo de la línea de transmisión considerada. En vista de todos estos problemas, se han simulado alrededor de 100 casos de fallas diferentes para cada uno de los 10 tipos de fallas.

Además del tipo de falla, las fases en falla y la distancia de la falla a lo largo de la LT, la resistencia de la falla también se ha variado para incluir varios escenarios posibles de falla en tiempo real.

- La resistencia de falla se varía de la siguiente manera:

0,25 Ω , 0,5 Ω , 0,75 Ω , 1 Ω , 5 Ω , 10 Ω , 25 Ω , 50 Ω .

- La distancia de falla se ha variado con un factor incremental de cada 3 km en una línea de transmisión de 300 km.

3.5.4 Descripción general del proceso de prueba

Como ya se mencionó en la sección anterior, el siguiente paso importante que se debe realizar antes de la aplicación de las redes neuronales es probar la red neuronal entrenada. Probar la red neuronal artificial es muy importante para asegurarse de que la red entrenada pueda generalizar bien y producir los resultados deseados cuando se le presenten nuevos datos.

Hay varias técnicas que se utilizan para probar el rendimiento de una red entrenada, algunas de las cuales se analizan en esta sección. Una de estas técnicas es trazar el mejor ajuste de regresión lineal entre las salidas de la red neuronal real y los objetivos deseados (Howard y Mark, 2004). Analizando la pendiente de esta recta nos da una idea del proceso de formación. Idealmente, la pendiente debería ser 1. Además, el coeficiente de correlación (r) de las salidas y los objetivos mide qué tan bien las salidas de RNA rastrean los objetivos deseados. Cuanto más cercano sea el valor de ' r ' a 1, mejor será el rendimiento de la red neuronal. Otra técnica empleada para probar la red neuronal es trazar la matriz de confusión y observar el número real de casos que han sido clasificados positivamente por la red neuronal (Howard y Mark, 2004). Idealmente, este porcentaje es 100, lo que significa que no ha habido confusión en el proceso de clasificación. Por lo tanto, si la matriz de confusión indica tasas de clasificación positivas muy bajas, indica que la red neuronal podría no funcionar bien. El último y muy obvio medio de probar la red neuronal es presentarle un conjunto de datos completamente nuevo con entradas y objetivos conocidos y calcular el porcentaje de error en la salida de las redes neuronales. Si el porcentaje de error promedio en la salida de la RNA es aceptable, la red neuronal ha pasado la prueba y se puede aplicar fácilmente para uso futuro.

La Toolbox Neural Network en Simulink (MathWorks) divide todo el conjunto de datos que se le proporciona en tres conjuntos diferentes, a saber, el conjunto de entrenamiento, el conjunto de validación y el conjunto de prueba. El conjunto de datos de entrenamiento como se indicó anteriormente se usa para entrenar la red calculando el gradiente y actualizando los pesos de la red. El conjunto de



validación se proporciona a la red durante el proceso de capacitación (solo las entradas sin las salidas) y el error en el conjunto de datos de validación se monitorea durante todo el proceso de capacitación. Cuando la red comienza a sobre ajustar los datos, los errores de validación aumentan y cuando el número de fallas de validación aumenta más allá de un valor particular, el proceso de entrenamiento se detiene para evitar un mayor sobreajuste de los datos y la red se devuelve con la cantidad mínima de errores de validación (Howard y Mark, 2004). El conjunto de prueba no se usa durante el proceso de entrenamiento, pero se usa para probar el rendimiento de la red entrenada. Si el conjunto de prueba alcanza el valor mínimo de MSE en una iteración significativamente diferente a la del conjunto de validación, entonces la red neuronal no podrá proporcionar un rendimiento satisfactorio.

CAPÍTULO IV

RESULTADOS Y DISCUSIÓN

4.1 Detección de fallas

Con el fin de detectar fallas, se han estudiado varias topologías de Perceptron multicapa. Los diversos factores que juegan un papel en la decisión de la topología ideal son el tamaño de la red, la estrategia de aprendizaje empleada y el tamaño del conjunto de datos de entrenamiento.

Tras un estudio exhaustivo, se ha decidido que el algoritmo de retro propagación es la topología ideal. Aunque el algoritmo básico de retro propagación es relativamente lento debido a las pequeñas tasas de aprendizaje empleadas, pocas técnicas pueden mejorar significativamente el rendimiento del algoritmo. Una de estas estrategias es utilizar la técnica de optimización de Levenberg-Marquardt. La selección del tamaño de la red adecuada es muy importante porque no solo reduce el tiempo de entrenamiento, sino que también mejora en gran medida la capacidad de la red neuronal para representar el problema en cuestión. Desafortunadamente, no existe una regla general que pueda dictar la cantidad de capas ocultas y la cantidad de neuronas por capa oculta en un problema determinado.

4.1.1 Entrenamiento de la red neuronal de detección de fallas

En la primera etapa que es la fase de detección de fallas, la red toma seis entradas a la vez, que son las tensiones y corrientes para las tres fases (escaladas con respecto a los valores previos a la falla) para diez fallas diferentes y también ninguna -caso de falla. Por lo tanto, el conjunto de entrenamiento constaba de alrededor de 1100 conjuntos de entrada y salida (100 para cada uno de los diez

fallos y 100 para el caso sin fallo) con un conjunto de seis entradas y una salida en cada par de entrada-salida. La salida de la red neuronal es solo un sí o un no (1 o 0) dependiendo de si ha detectado un fallo. Después de extensas simulaciones, se decidió que la red deseada tiene una capa oculta con 10 neuronas en la capa oculta. Con fines ilustrativos, se muestran varias redes neuronales (con un número variable de capas ocultas y neuronas por capa oculta) que lograron un rendimiento satisfactorio y se describe con más detalle la mejor red neuronal. Las Figuras 17 - 18 muestran los gráficos de rendimiento de errores de redes neuronales con 1 y 2 capas ocultas, respectivamente. La red elegida se ha representado en la Fig. 23 y las diversas gráficas de rendimiento de error se han mostrado en las Figuras 18 - 23.

La figura 17 muestra el gráfico de rendimiento de entrenamiento de la red neuronal 6-10-1 (6 neuronas en la capa de entrada, 1 capa oculta con diez neuronas y una neurona en la capa de salida). Se puede ver que la red no logró el objetivo de error cuadrático medio (MSE) deseado al final del proceso de entrenamiento.

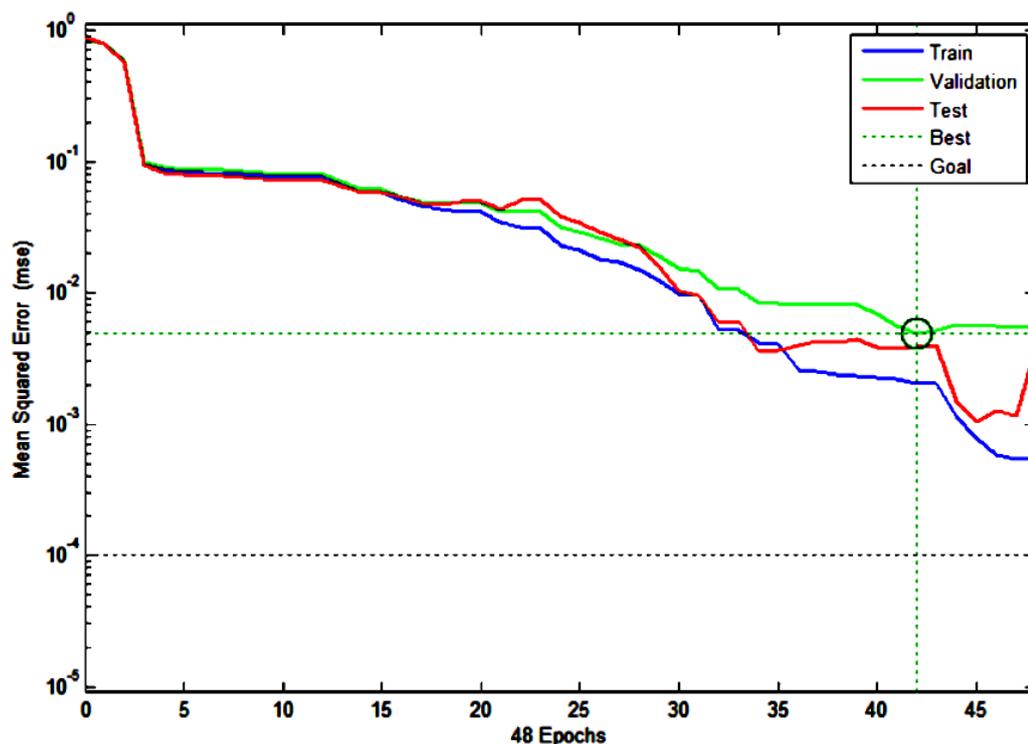


Figura 17. Error cuadrático medio, configuración (6-10-1)

La figura 18 muestra el gráfico de rendimiento de entrenamiento de la red neuronal con configuración 6-10-5-1 (6 neuronas en la capa de entrada, dos capas

ocultas con 10 y 5 neuronas respectivamente y una neurona en la capa de salida). Cabe señalar que la red neuronal no pudo alcanzar el objetivo de MSE de 0,0001 al final del proceso de entrenamiento.

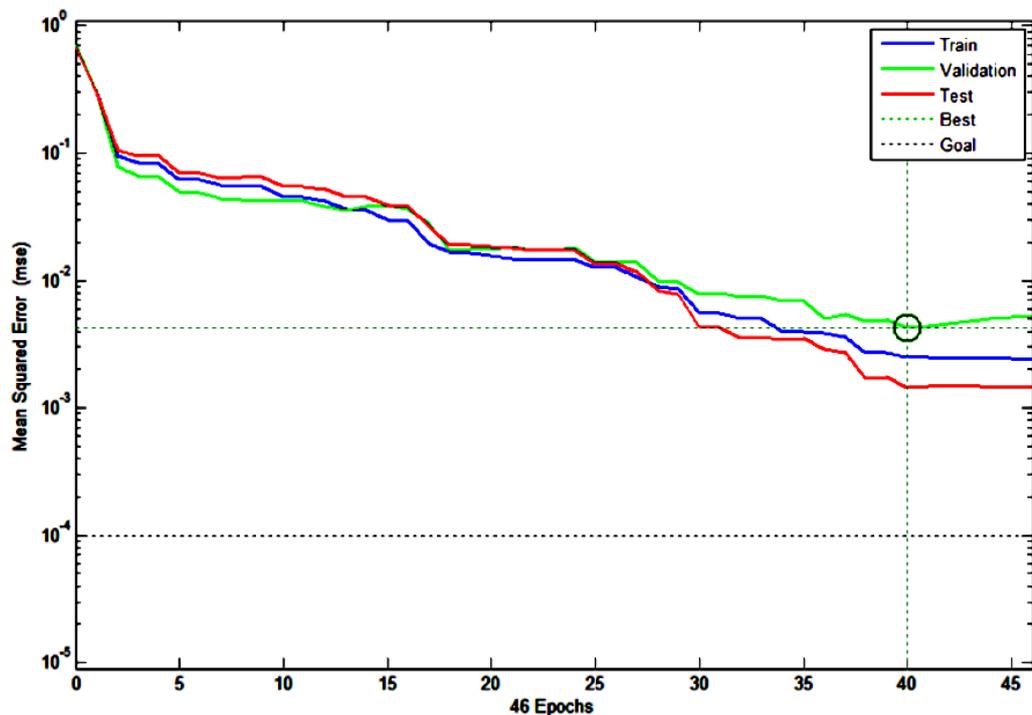


Figura 18. Error cuadrático medio, configuración (6-10-5-1)

La figura 19 muestra el proceso de entrenamiento de la red neuronal con configuración 6-10-5-3-1 (6 neuronas en la capa de entrada, 3 capas ocultas con 10, 5 y 3 neuronas respectivamente y una neurona en la capa de salida).

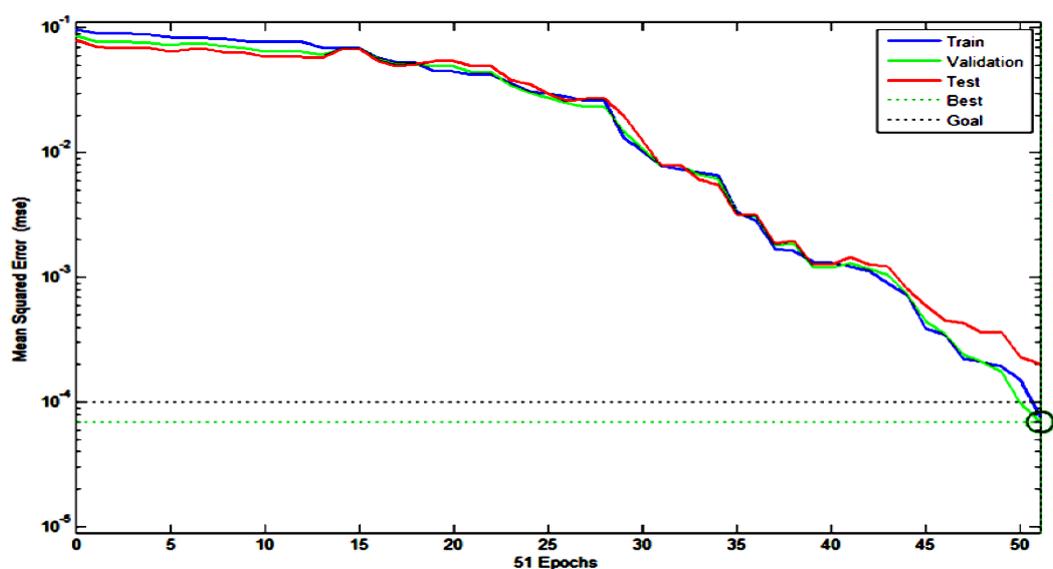


Figura 19. Error cuadrático medio, configuración (6-10-5-3-1)

De los gráficos de rendimiento de entrenamiento anteriores, cabe señalar que la red neuronal ha logrado un rendimiento de entrenamiento muy satisfactorio con la configuración 6-10-5-3-1 (6 neuronas en la capa de entrada, 3 capas ocultas con 10, 5 y 3 neuronas en ellos respectivamente y una neurona en la capa de salida). El MSE general de la red neuronal entrenada está muy por debajo del valor de 0,0001 y en realidad es $6,978 \times 10^{-5}$ al final del proceso de entrenamiento. Por lo tanto, esta ha sido elegida como la RNA ideal para el propósito de detección de fallas.

4.1.2 Prueba de la red neuronal de detección de fallas

Una vez que la red neuronal ha sido entrenada, su rendimiento ha sido probado por tres factores diferentes. El primero de ellos consiste en trazar la mejor regresión lineal que relacione los objetivos con los resultados, como se muestra en la figura 20.

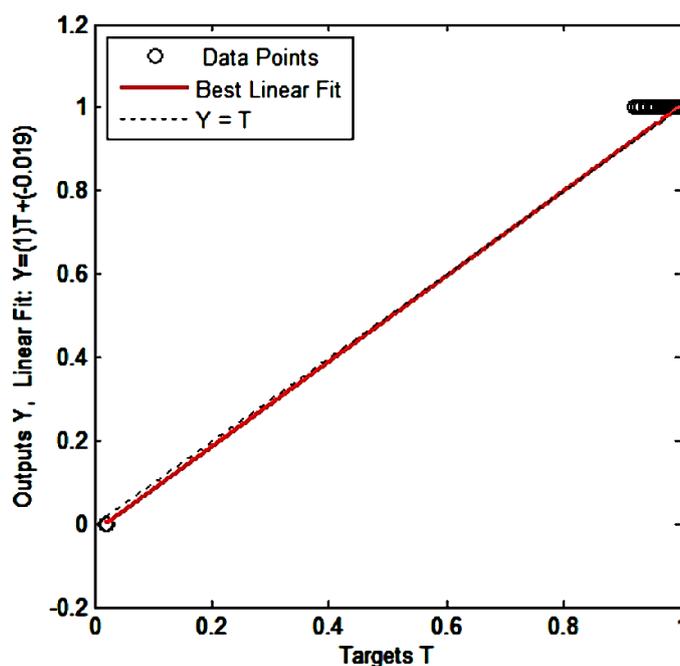


Figura 20. Ajuste de regresión de Salidas vs. Objetivos, configuración (6-10-5-3-1)

El coeficiente de correlación (r) es una medida de qué tan bien los objetivos de la red neuronal pueden rastrear las variaciones en los resultados (siendo 0 ninguna correlación y 1 una correlación completa). Se ha encontrado que el coeficiente de correlación en este caso es 0,99967, lo que indica una excelente correlación.

El segundo medio de probar el rendimiento de la red neuronal es trazar las matrices de confusión para los diversos tipos de errores que ocurrieron en la red neuronal entrenada. La figura 21 traza la matriz de confusión para las tres fases de entrenamiento, prueba y validación. Las celdas diagonales en verde indican el número de casos que han sido clasificados correctamente por la red neuronal y las celdas fuera de la diagonal que están en rojo indican el número de casos que han sido clasificados incorrectamente por la RNA. La última celda en azul de cada una de las matrices indica el porcentaje total de casos que se han clasificado correctamente en verde y viceversa en rojo. Se puede ver que la red neuronal elegida tiene un 100 por ciento de precisión en la detección de fallas.

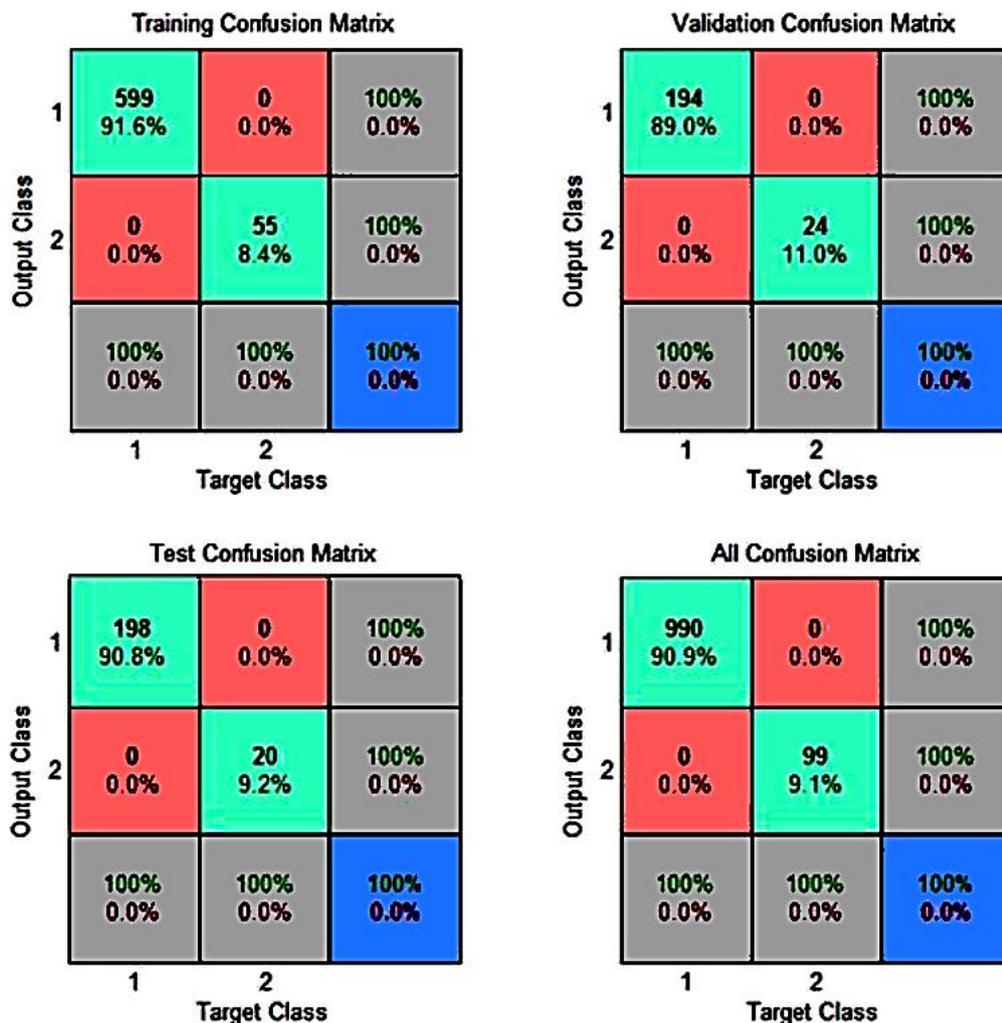


Figura 21. Matrices de confusión para Entrenamiento, Prueba y Validación

El tercer paso en el proceso de prueba es crear un conjunto separado de datos llamado conjunto de prueba para analizar el rendimiento de la red neuronal

entrenada. Se han simulado un total de 300 casos de prueba diferentes con 200 casos correspondientes a diferentes tipos de fallas (alrededor de 20 casos para cada una de las diez fallas donde se ha variado la resistencia de falla y la ubicación de falla en cada caso). El resto de los 100 casos corresponden a la situación sin falla.

Una vez que el conjunto de prueba se introdujo en la red neuronal y se obtuvieron los resultados, se observó que la eficiencia de la red neuronal en términos de su capacidad para detectar la ocurrencia de una falla es del 100 por ciento. Por lo tanto, la red neuronal puede, con la máxima precisión, diferenciar una situación normal de una condición de falla en una línea de transmisión.

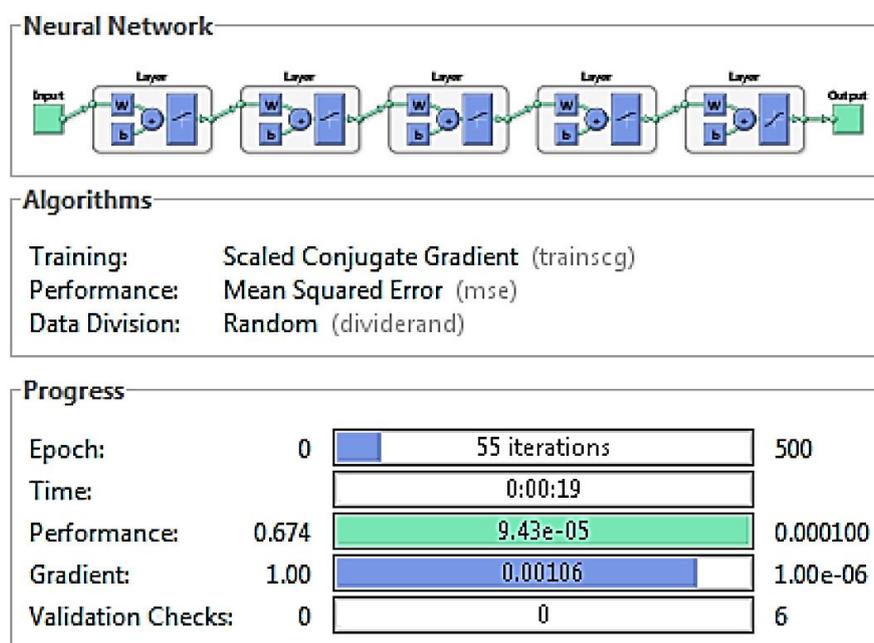


Figura 22. Resumen de la RNA, configuración (6-10-5-3-1) para detección de fallas

La Figura 22 presenta una captura de la RNA entrenada con la configuración 6-10-5-3-1 y se debe notar que el número de iteraciones requeridas para el proceso de entrenamiento (55 iteraciones). Se puede ver que el error cuadrático medio en la detección de fallas lograda al final del proceso de entrenamiento fue $9.43e-5$ y que el número de fallas en la verificación de validación fue cero al final del proceso de entrenamiento.

La estructura de la red neuronal elegida para la detección de fallas se muestra en la Figura 23 con la capa de entrada, las capas ocultas y la capa de salida etiquetadas. Cabe señalar que hay 6 neuronas en la capa de entrada, 3 capas ocultas

con 10, 5 y 3 neuronas respectivamente y una neurona en la capa de salida.

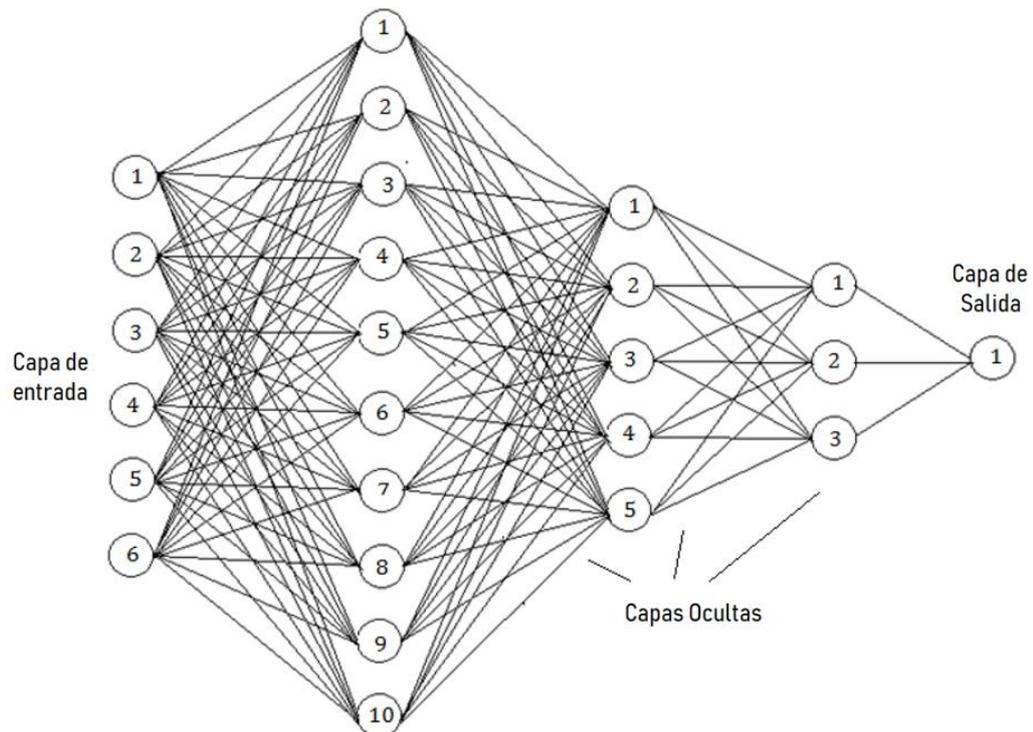


Figura 23. Estructura RNA para detección de fallas, configuración (6-10-5-3-1)

4.2 Clasificación de averías

Una vez que se ha detectado una falla en la línea eléctrica, el siguiente paso es identificar el tipo de falla. En esta sección se presenta un análisis de la fase de clasificación de fallas utilizando redes neuronales. Se proporciona una revisión de las diferentes redes neuronales que se analizaron, seguida de la red elegida.

Los clasificadores de fallas basados en redes neuronales se propusieron y utilizaron ampliamente en el pasado y casi todos estos clasificadores utilizaron redes neuronales de perceptrón multicapa y emplearon la estrategia de aprendizaje de propagación hacia atrás. Aunque la estrategia de aprendizaje de retro propagación es inherentemente lenta en el aprendizaje y plantea dificultades para elegir el tamaño óptimo de la red, sin duda es la estrategia ideal para emplear cuando hay un gran conjunto de entrenamiento disponible porque el algoritmo de retro propagación puede proporcionar un tamaño muy compacto. representación distribuida de conjuntos de datos complejos.

4.2.1 Entrenamiento de la red neuronal del clasificador de fallas

El proceso es el mismo que se empleó anteriormente, en cuanto al diseño y

desarrollo de la red neuronal clasificadora. La red diseñada admite conjuntos de seis entradas (los valores trifásicos de tensión y corriente escalados con respecto a sus correspondientes valores previos a la falla). La red neuronal tiene cuatro salidas, cada una de ellas correspondiente a la condición de falla de cada una de las tres fases y una salida para la línea de tierra. Por lo tanto, las salidas son 0 o 1 que indican la ausencia o presencia de una falla en la línea correspondiente (A, B, C o G donde A, B y C denotan las tres fases de la línea de transmisión y G denota la tierra). Por lo tanto, las diversas permutaciones posibles pueden representar cada una de las diversas fallas respectivamente. La red neuronal propuesta debería ser capaz de distinguir con precisión entre las diez posibles categorías de fallas. La tabla de verdad que representa las fallas y la salida ideal para cada una de las fallas se ilustra en la Tabla 2.

Tabla 2

Salidas de la RNA del clasificador de fallas para varias fallas

Tipo de Falla	Salidas de red			
	A	B	C	G
Falla A-G	1	0	0	1
Falla B-G	0	1	0	1
Falla C-G	0	0	1	1
Falla A-B	1	1	0	0
Falla B-C	0	1	1	0
Falla C-A	1	0	1	0
Falla A-B-G	1	1	0	1
Falla B-C-G	0	1	1	1
Falla C-A-G	1	0	1	1
Falla A-B-C	1	1	1	0

Por lo tanto, el conjunto de entrenamiento constaba de alrededor de 1100 conjuntos de entrada y salida (100 para cada uno de los diez fallos y 100 para el caso sin fallo) con un conjunto de seis entradas y una salida en cada par de entrada-salida. Se han analizado redes de retro propagación con una variedad de combinaciones de capas ocultas y el número de neuronas por capa oculta. De estos, los que lograron un rendimiento satisfactorio se muestran seguidos de la mejor red neuronal que se ha descrito con más detalle. Las Figuras 24 - 28 muestran los gráficos de rendimiento de error de redes neuronales con 1 y 2 capas

ocultas respectivamente. La red elegida se ha representado en la figura 33 y las diversas gráficas de rendimiento de error se han mostrado en las figuras 29 a 34.

La Fig. 24 muestra el gráfico de rendimiento de entrenamiento de la red neuronal 6-5-5-31-4 (6 neuronas en la capa de entrada, 3 capas ocultas con 5, 5 y 31 neuronas respectivamente y cuatro neuronas en la capa de salida). Se puede observar que el mejor desempeño de validación en términos del Error Cuadrático Medio (MSE) al final del proceso de entrenamiento es 0.01289.

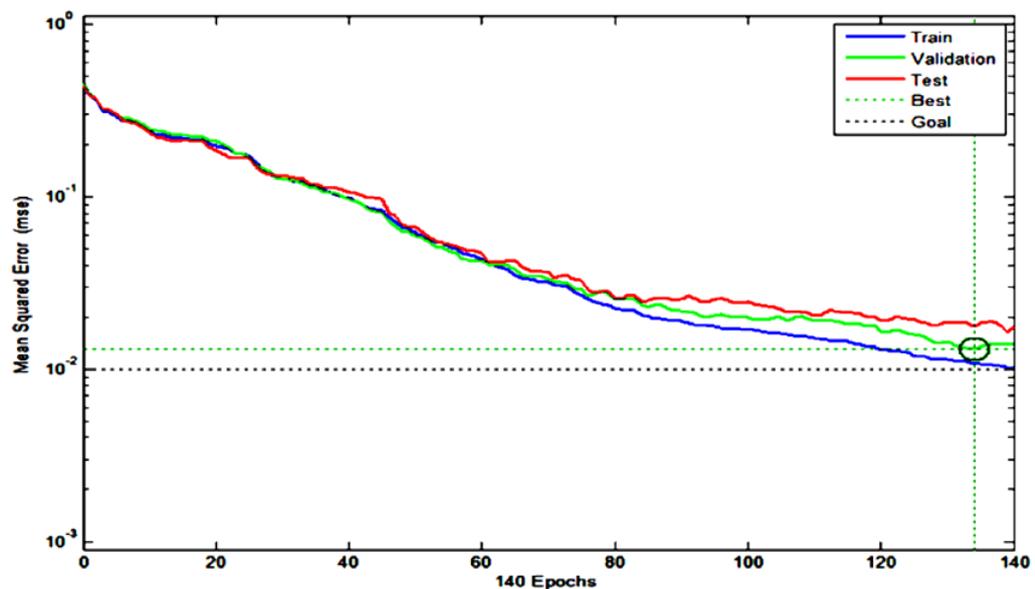


Figura 24. Error cuadrático medio, configuración (6-5-5-31-4)

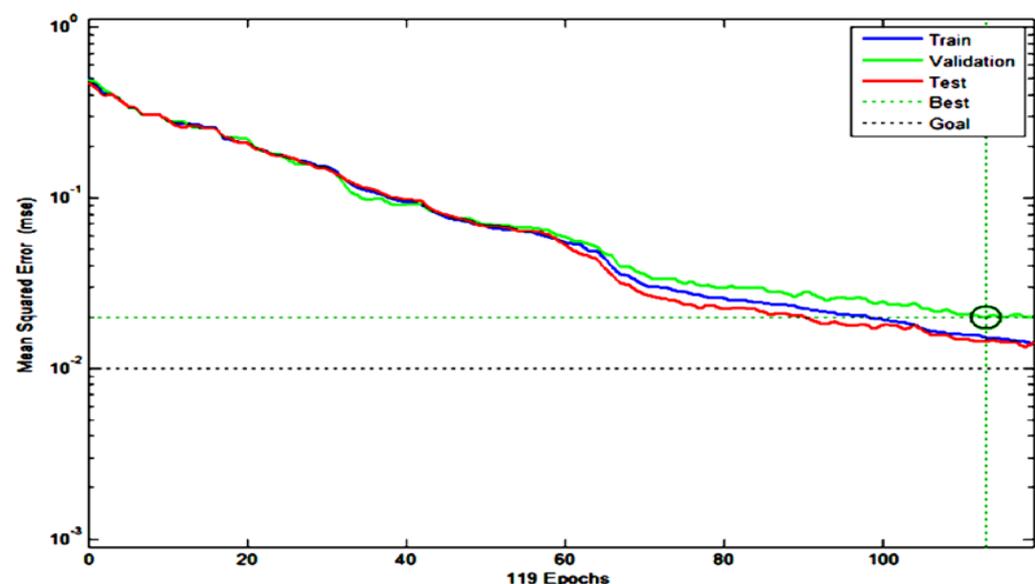


Figura 25. Error cuadrático medio, configuración (6-5-31-4)

La figura 25 muestra el gráfico de rendimiento de entrenamiento de la red neuronal 6-5-31-4 (6 neuronas en la capa de entrada, 2 capas ocultas con 5 y 31 neuronas respectivamente y cuatro neuronas en la capa de salida). Se puede observar que el mejor desempeño de validación en términos del Error Cuadrático Medio (MSE) al final del proceso de entrenamiento es 0.019773.

La figura 26 muestra el gráfico de rendimiento de entrenamiento de la red neuronal 6-5-4 (6 neuronas en la capa de entrada, 1 capa oculta con 5 neuronas y cuatro neuronas en la capa de salida). Se puede observar que el mejor desempeño de validación en términos del Error Cuadrático Medio (MSE) al final del proceso de entrenamiento en este caso es 0.029578.

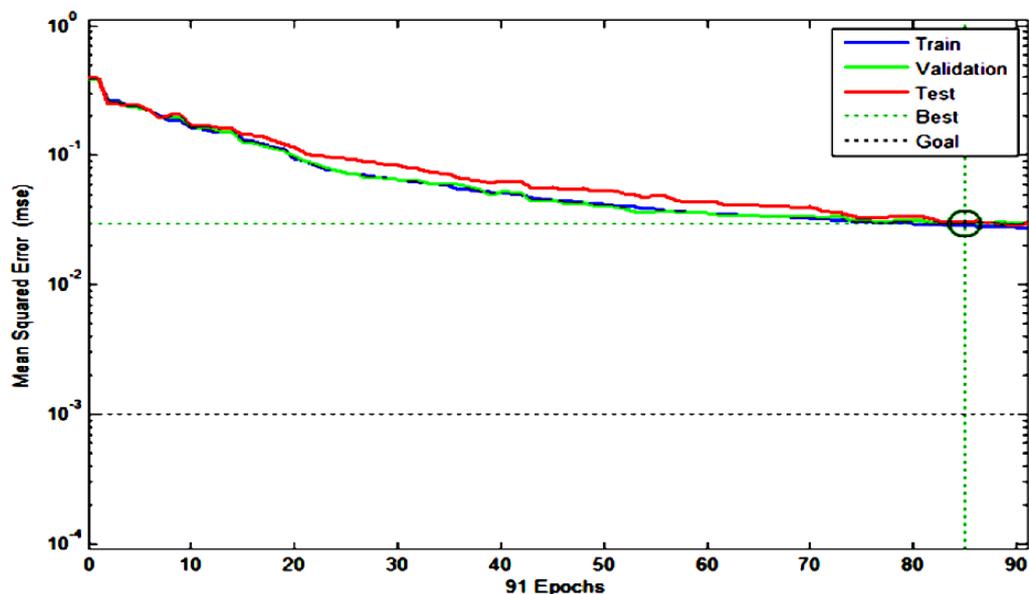


Figura 26. Error cuadrático medio, configuración (6-5-4)

La figura 27 muestra el gráfico de rendimiento de entrenamiento de la red neuronal 6-10-4 (6 neuronas en la capa de entrada, 1 capa oculta con 10 neuronas y cuatro neuronas en la capa de salida). Se puede observar que el mejor desempeño de validación en términos del Error Cuadrático Medio (MSE) al final del proceso de entrenamiento en este caso es 0.0077.

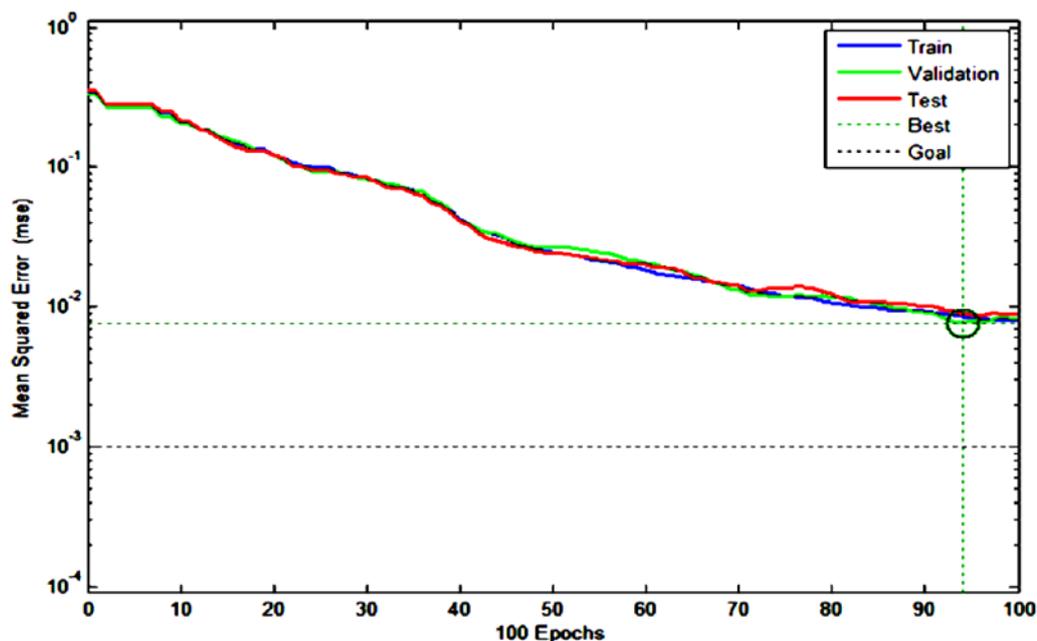


Figura 27. Error cuadrático medio, configuración (6-10-4)

La figura 28 muestra el gráfico de rendimiento de entrenamiento de la red neuronal 6-20-4 (6 neuronas en la capa de entrada, 1 capa oculta con 20 neuronas y cuatro neuronas en la capa de salida). Se puede observar que el mejor desempeño de validación en términos del Error Cuadrático Medio (MSE) al final del proceso de entrenamiento en este caso es 0.0093975.

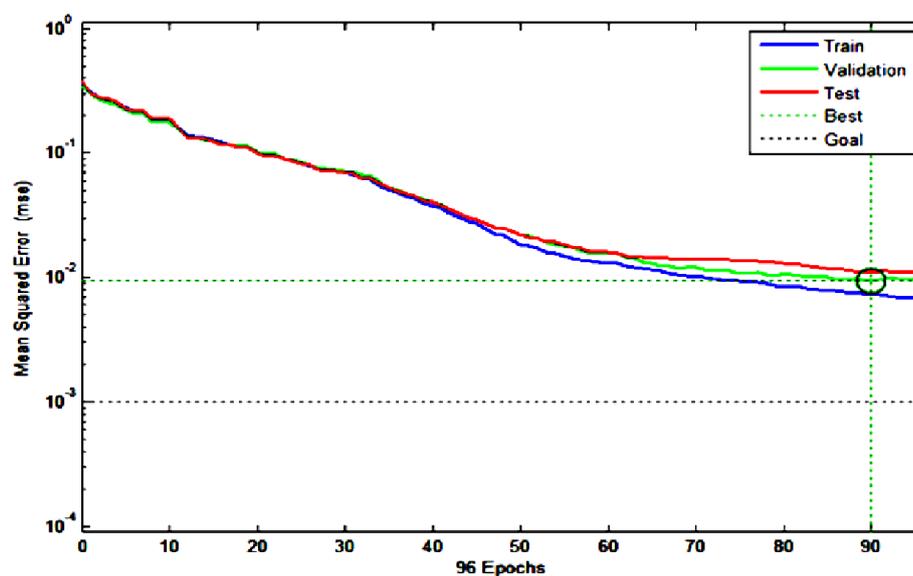


Figura 28. Error cuadrático medio, configuración (6-20-4)

La figura 29 muestra el gráfico de rendimiento de entrenamiento de la red neuronal 6-35-4 (6 neuronas en la capa de entrada, 1 capa oculta con 35 neuronas

y cuatro neuronas en la capa de salida). Se puede observar que el mejor desempeño de validación en términos del Error Cuadrático Medio (MSE) al final del proceso de entrenamiento en este caso es 0.00359.

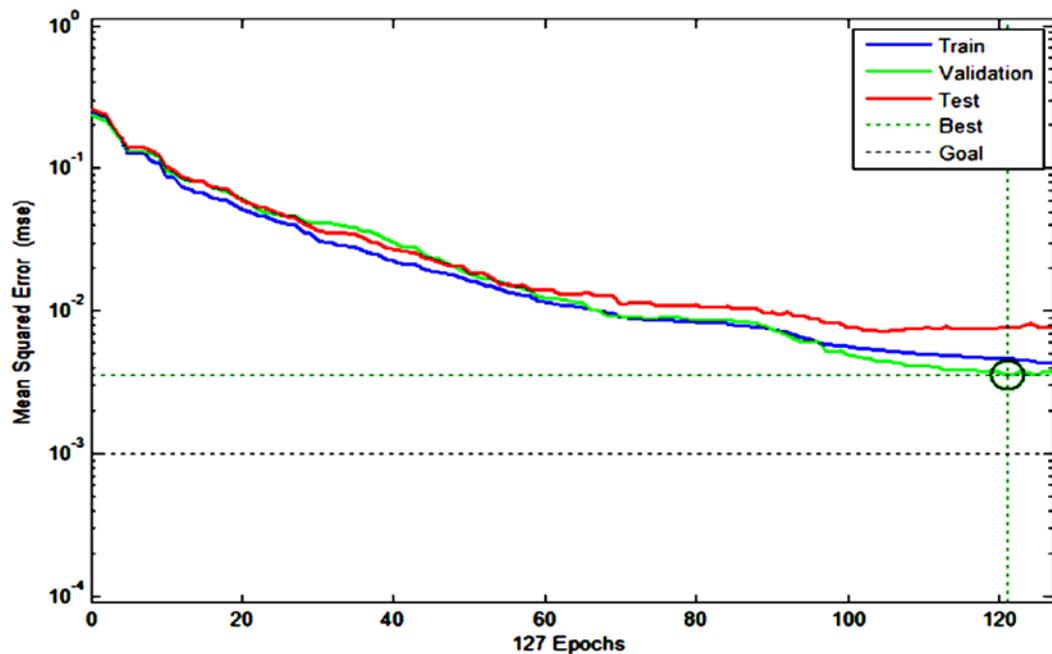


Figura 29. Error cuadrático medio, configuración (6-35-4)

De los gráficos de rendimiento de entrenamiento anteriores, cabe señalar que la red neuronal ha logrado un rendimiento de entrenamiento satisfactorio con la configuración 6-35-4 (6 neuronas en la capa de entrada, 35 neuronas en la capa oculta y una neurona en la capa oculta). capa de salida). El MSE general de la red neuronal entrenada es 0.0035986 y se puede ver en la figura 29 que las curvas de prueba y validación tienen características similares, lo que es una indicación de entrenamiento eficiente. Por lo tanto, esta ha sido elegida como la RNA ideal para la clasificación de fallas.

4.2.2 Prueba de la red neuronal del clasificador de fallas

Una vez que se ha entrenado la red neuronal, se ha probado su rendimiento teniendo en cuenta tres factores diferentes. El primero de ellos consiste en trazar la mejor regresión lineal que relacione los objetivos con los resultados, como se muestra en la figura 30. El coeficiente de correlación en este caso resultó ser 0,98108, lo que indica una correlación satisfactoria entre los objetivos y los resultados. La línea de puntos en la figura indica el ajuste de regresión ideal y la

línea continua roja indica el ajuste real de la red neuronal. Se puede ver que ambas líneas se rastrean muy de cerca, lo que es una indicación de un muy buen desempeño de la red neuronal.

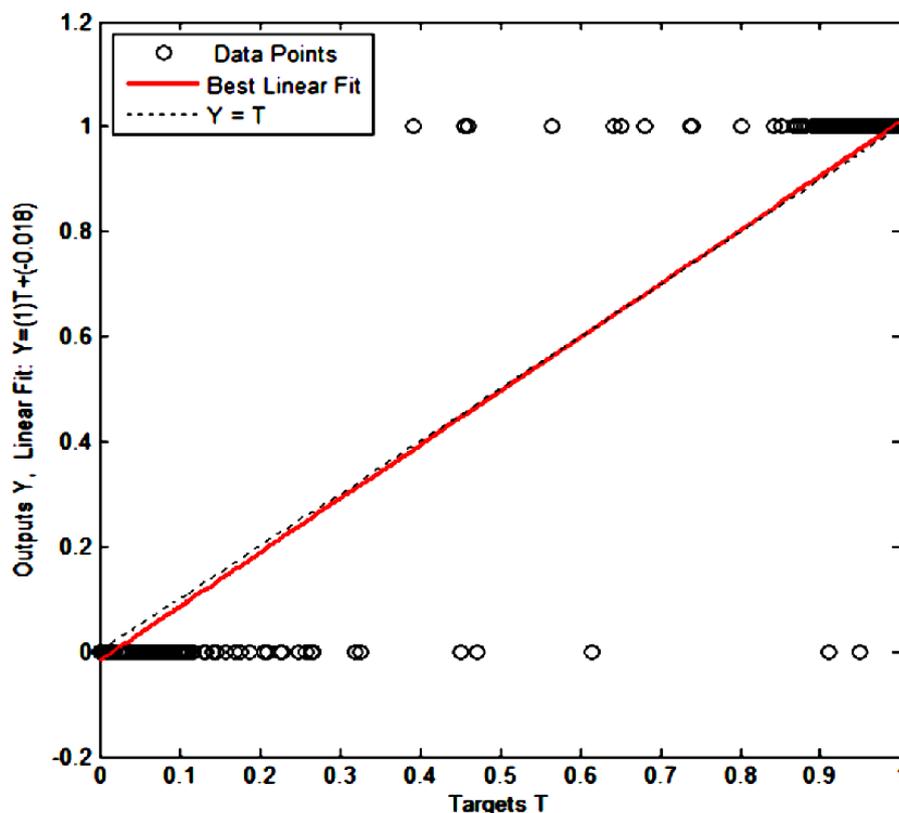


Figura 30. Ajuste de regresión Productos vs. Objetivos RNA, configuración (6-35-4)

El segundo factor en el proceso de prueba es trazar el funcionamiento del receptor curva de características (ROC). Las curvas ROC para cada una de las fases de entrenamiento, prueba y validación se muestran en la Fig. 31 junto con la curva ROC general. Las curvas ROC son en realidad gráficos entre las tasas de verdaderos positivos (tasa de clasificación positiva) y las tasas de falsos positivos (tasa de clasificación incorrecta) del clasificador de red neuronal. Por lo tanto, una curva ROC ideal mostraría puntos solo en la esquina superior izquierda porque eso es una indicación de 100 por ciento de positividad verdadera y 0 por ciento de positividad falsa en la clasificación. Cabe señalar que las curvas ROC trazadas en la figura 31 son casi perfectas ya que todas tienen las líneas en la esquina superior izquierda.

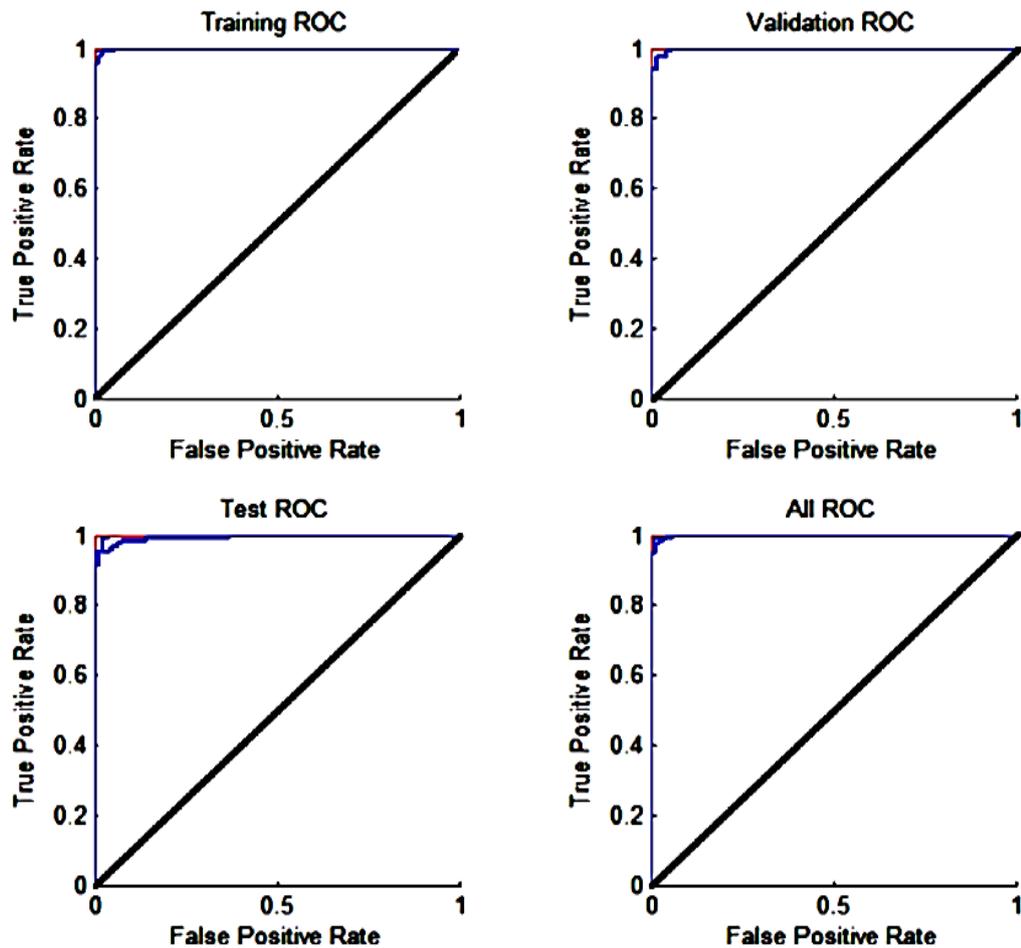


Figura 31. Gradiente y validación de la RNA, configuración (6-35-4)

El tercer paso en el proceso de prueba es crear un conjunto separado de datos llamado conjunto de prueba para analizar el rendimiento de la red neuronal entrenada. Se han simulado un total de 300 casos de prueba diferentes con 550 casos correspondientes a diferentes tipos de fallas (alrededor de 50 casos para cada una de las diez fallas donde se ha variado la resistencia de falla y la ubicación de falla en cada caso). El resto de los 50 casos corresponden a la situación sin falla.

Una vez que el conjunto de prueba se introdujo en la red neuronal y se obtuvieron los resultados, se observó que la eficiencia de la red neuronal en términos de su capacidad para identificar el tipo de falla es del 100 por ciento. Por lo tanto, la red neuronal puede, con la mayor precisión, diferenciar entre los diez posibles tipos de fallas en una línea de transmisión.

La figura 32 proporciona una descripción general de la red neuronal y es una captura de pantalla de la ventana de entrenamiento simulada con la caja de herramientas de red neuronal artificial en Simulink. Las cosas importantes a tener

en cuenta son que el proceso de entrenamiento convergió en alrededor de 144 iteraciones y que el rendimiento en términos de error cuadrático medio logrado al final del proceso de entrenamiento fue $6.26e-3$.

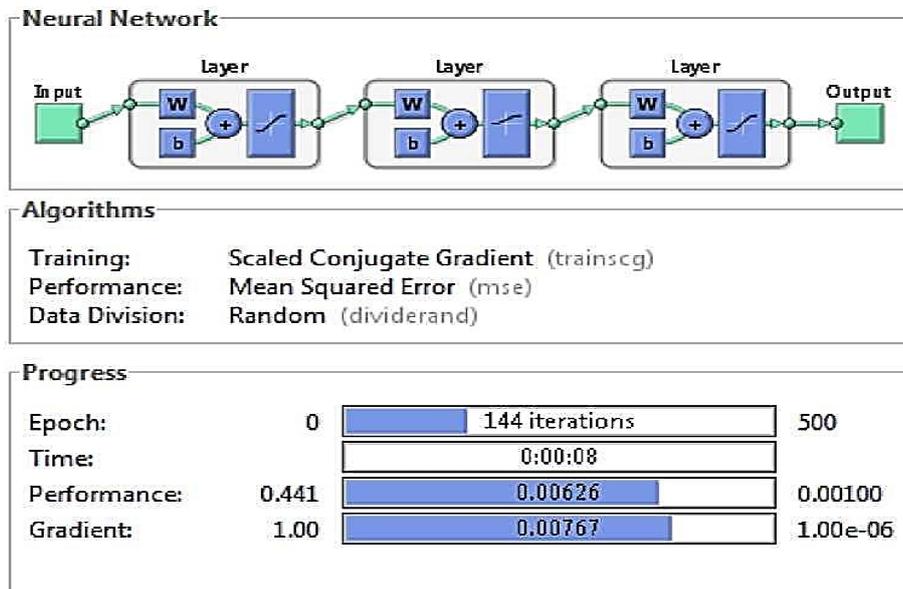


Figura 32. Resumen de la RNA, configuración (6-35-4) para clasificador de fallas

La Fig. 33 muestra la estructura de la RNA elegida para la clasificación de fallas, tiene 6 neuronas en la capa de entrada, 35 neuronas en la capa oculta y 4 neuronas en la capa de salida, como se muestra. Cada una de las neuronas en la capa de salida indicaría la condición de falla en cada una de las tres fases (A, B y C) y la cuarta neurona identificará si la falla es una falla a tierra. Una salida de 0 no corresponde a ningún fallo, mientras que una salida de 1 indica que la fase está en falla.

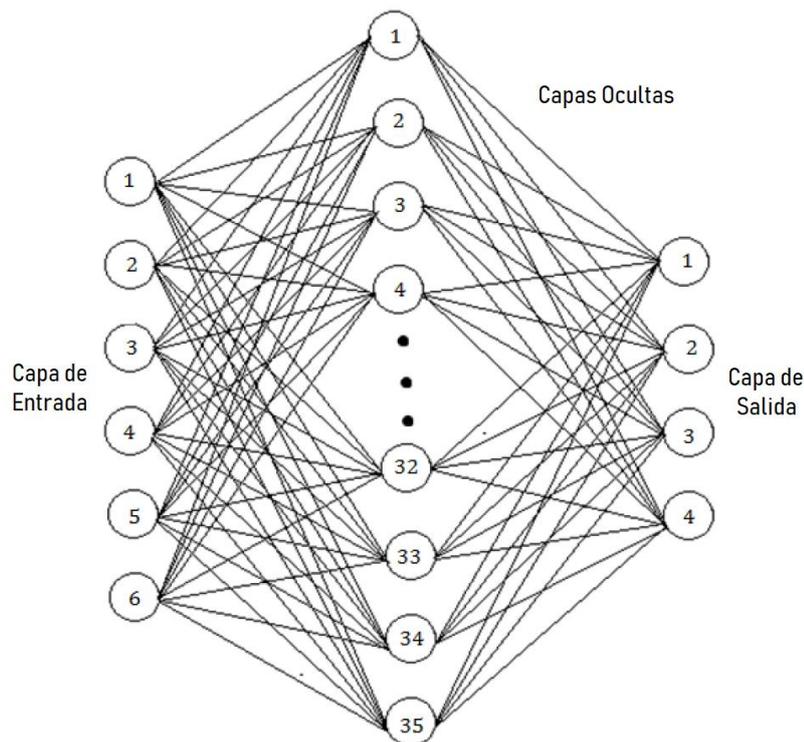


Figura 33. Estructura RNA para clasificación de fallas, configuración (6-35-4)

4.3 Localización de averías

Esta sección habla sobre el diseño, desarrollo e implementación de los localizadores de fallas basados en redes neuronales para cada uno de los diversos tipos de fallas. Esto constituye el tercer paso en todo el proceso de localización de fallas después del inicio de la falla. Las siguientes subsecciones tratan los diversos tipos de fallas y sus características de error individualmente.

4.3.1 Línea única - fallas a tierra

Ahora que podemos detectar la ocurrencia de una falla en una línea de transmisión y también clasificar la falla en varias categorías de fallas, el siguiente paso es identificar la ubicación de la falla desde cualquiera de los extremos de la línea de transmisión. Existen tres posibles fallas a tierra de una sola línea (AG, BG, CG), correspondientes a cada una de las tres fases (A, B o C) en falta.

4.3.1.1 Entrenamiento de la red neuronal para línea – tierra

a. Localización de falla

Retroalimentando hacia adelante - las redes neuronales de propagación

han sido estudiadas para la ubicación de falla línea – tierra, principalmente debido a la disponibilidad de suficientes datos relevantes para el entrenamiento. Para entrenar la red neuronal, se han simulado varias fallas monofásicas en el modelo de línea de transmisión. Para cada una de las tres fases, se han simulado fallas cada 3 Km en una línea de transmisión de 300 Km de longitud. Junto con la distancia de falla, la resistencia de falla se ha variado como se mencionó anteriormente en la sección 4.4. Así, se han simulado un total de 2400 casos (100 para cada una de las tres fases con cada una de las ocho resistencias de falla diferentes como 0.25, 0.5, 0.75, 1, 5, 10, 25 y 50 ohm respectivamente). En cada uno de estos casos, las muestras de tensión y corriente para las tres fases (escaladas con respecto a sus valores previos a la falla) se proporcionan como entradas a la red neuronal. La salida de la red neuronal es la distancia a la falla desde el terminal A. En primer lugar, se presentan algunas de las diversas redes neuronales (con una combinación variable de capas ocultas y número de neuronas por capa oculta) que funcionaron razonablemente bien junto con sus respectivos rendimientos de error y luego se muestra la red neuronal elegida con todas sus características representadas en detalle. La eficiencia de cada una de las redes entrenadas se analiza en función de su rendimiento de regresión y su rendimiento en la fase de prueba. Los gráficos de rendimiento de la prueba se obtienen simulando varias fallas en diferentes fases en diferentes ubicaciones y calculando el error en la salida producida por la red neuronal. Las Figuras 34 - 41 muestran el rendimiento de error y los gráficos de regresión de redes neuronales con 1 y 2 capas ocultas. La red elegida se ha representado en la figura 46 y sus diversas gráficas de rendimiento de error se muestran en las figuras 42 a 47.

La Fig. 34 traza el mejor ajuste de regresión lineal entre las salidas y los objetivos de la red neuronal con 6 neuronas en la capa de entrada, 2 capas ocultas con 5 y 5 neuronas respectivamente y 1 neurona en la capa de salida (6-5-5 -1). El coeficiente de correlación (r), como se mencionó anteriormente, es una medida de qué tan bien la red neuronal relaciona los resultados y los objetivos. Cuanto más cerca esté el valor de r de 1, mejor será el rendimiento de la red neuronal. Se encuentra que el valor de r en

este caso es 0.99799. Para probar el rendimiento de esta red, se han simulado 12 fallas monofásicas diferentes en diferentes fases con la distancia de falla incrementada en 25 Km en cada caso y se ha calculado el porcentaje de error en la salida calculada. La figura 35 muestra los resultados de esta prueba realizada en la red neuronal (6-5-5-1). Se puede observar que el error máximo es de casi el 4.5 %.

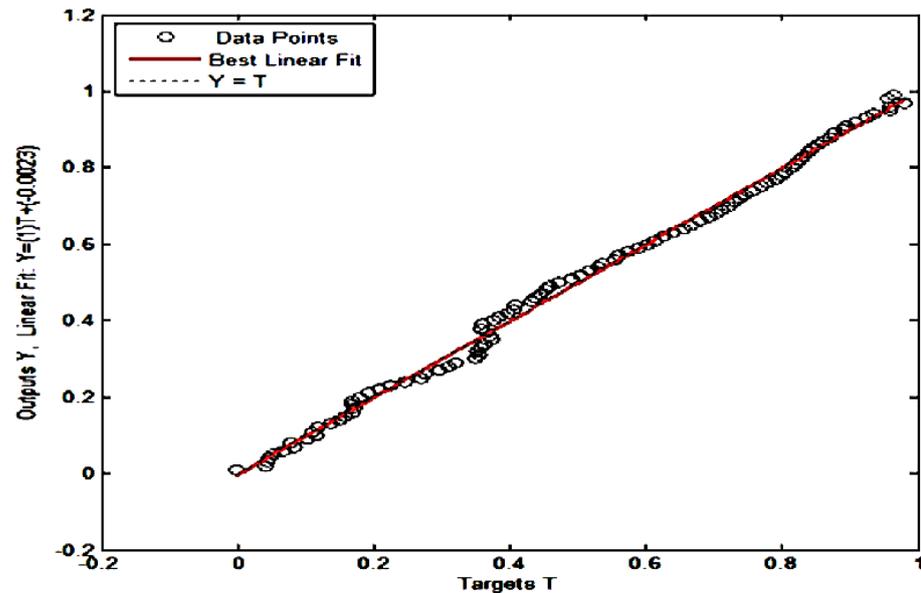


Figura 34. Ajuste de regresión de Productos vs. Objetivos, configuración (6-5-5-1)

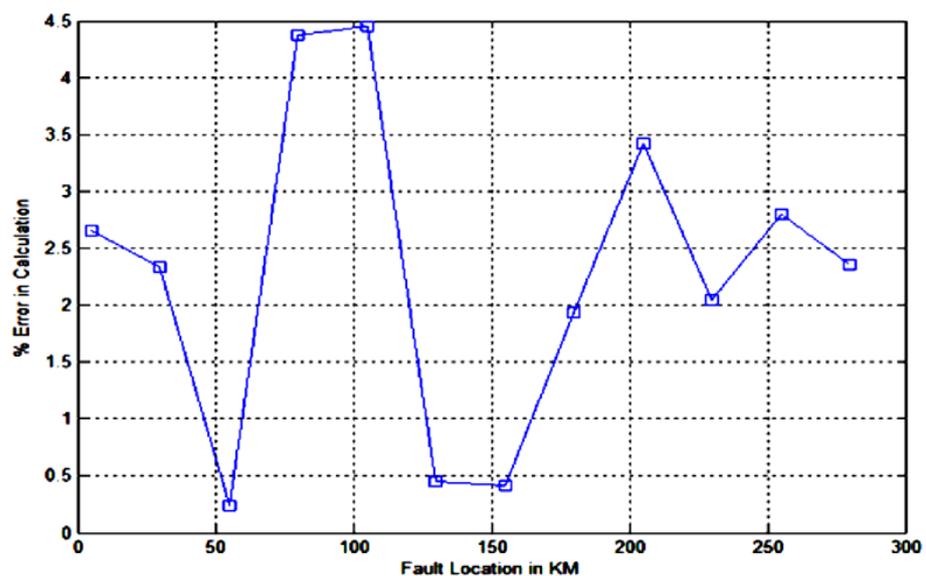


Figura 35. Rendimiento de la Fase de Prueba, configuración (6-5-5-1)

La figura 36 representa el mejor ajuste de regresión lineal entre las salidas y los objetivos de la red neuronal con 6 neuronas en la capa de entrada, 25 neuronas en la capa oculta y 1 neurona en la capa de salida (6-25-1). Se encuentra que el valor del coeficiente de correlación r en este caso es 0.996. Para probar el rendimiento de esta red, se han simulado 12 fallas monofásicas diferentes en diferentes fases con la distancia de falla incrementada en 25 Km en cada caso y se ha calculado el porcentaje de error en la salida calculada. La figura 37 muestra los resultados de esta prueba realizada en la red neuronal (6-25-1). Se puede ver que el error máximo es de alrededor del 7 por ciento, lo que no es muy satisfactorio.

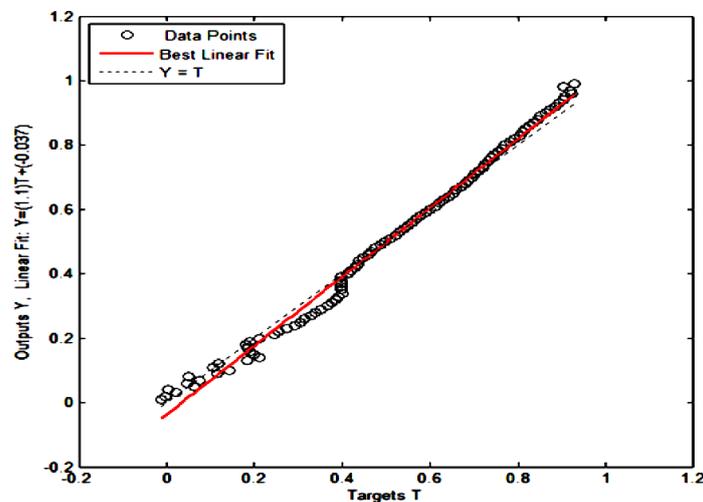


Figura 36. Ajuste de regresión de Productos vs. Metas, configuración (6-25-1)

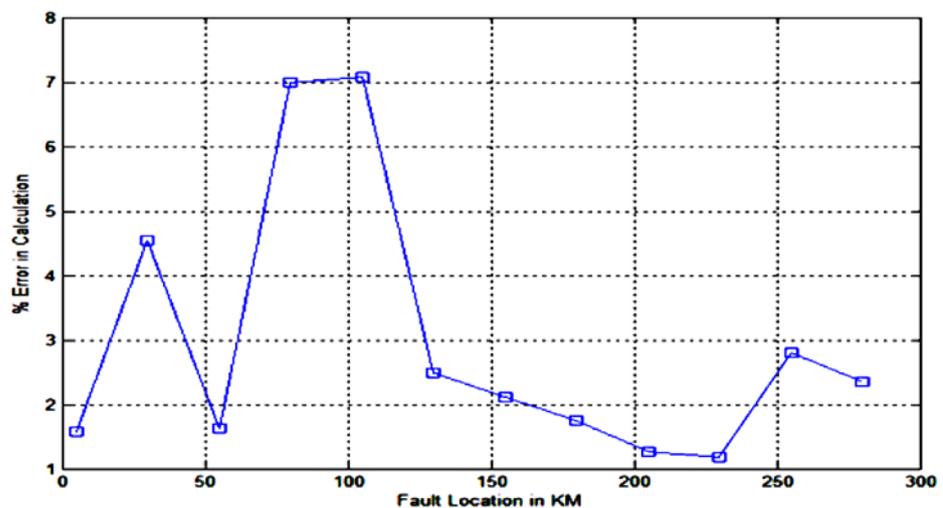


Figura 37. Rendimiento de la fase de prueba, configuración (6-25-1)

La figura 38 traza el mejor ajuste de regresión lineal entre las salidas y los objetivos de la red neuronal con 6 neuronas en la capa de entrada, 16 neuronas en la capa oculta y 1 neurona en la capa de salida (6-16-1). Se encuentra que el valor del coeficiente de correlación r en este caso es 0.99906.

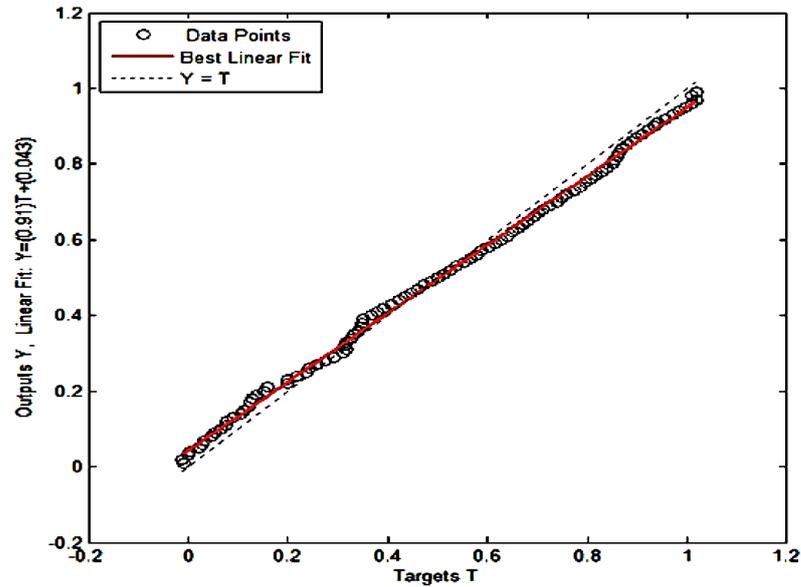


Figura 38. Ajuste de regresión de Productos vs. Metas, configuración (6-16-1)

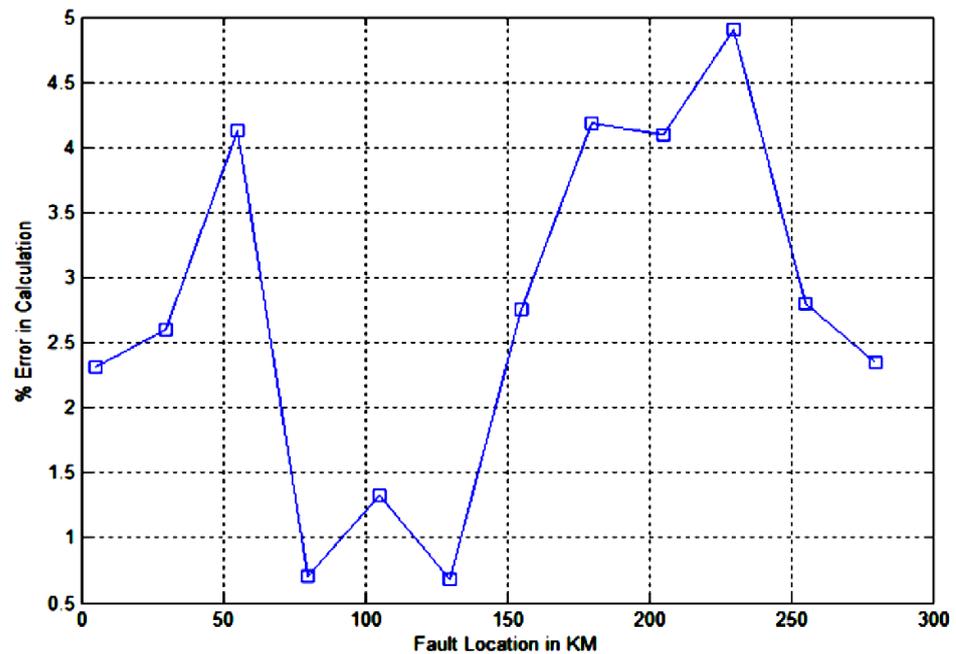


Figura 39. Rendimiento de la fase de prueba, configuración (6-16-1)

Para probar el rendimiento de esta red, se han simulado 12 fallas

monofásicas diferentes en diferentes fases con la distancia de falla incrementada en 25 Km en cada caso y se ha calculado el porcentaje de error en la salida calculada. La figura 39 muestra los resultados de esta prueba realizada en la red neuronal (6-16-1). Se puede observar que el error máximo es de alrededor del 4.75 %.

La figura 40 representa el mejor ajuste de regresión lineal entre las salidas y los objetivos de la red neuronal con 6 neuronas en la capa de entrada, 7 neuronas en la capa oculta y 1 neurona en la capa de salida (6-7-1). Se encuentra que el valor del coeficiente de correlación r en este caso es 0,99924, que es con mucho el mejor y el más cercano a uno.

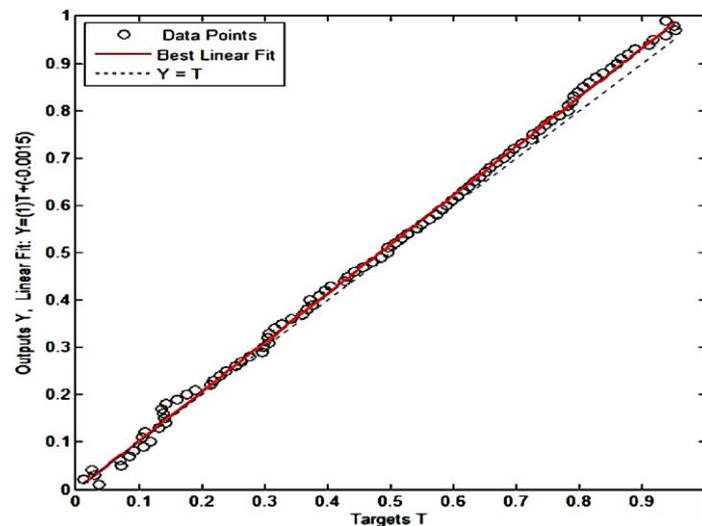


Figura 40. Ajuste de regresión de Productos vs. Objetivos, configuración (6-7-1)

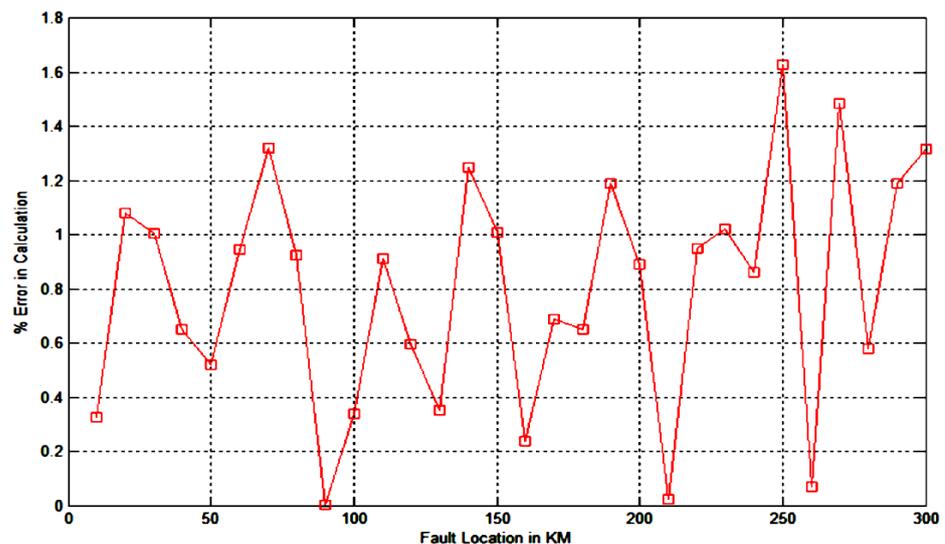


Figura 41. Rendimiento de la fase de prueba, configuración (6-7-1)

Para probar el rendimiento de esta red, se han simulado 100 fallas monofásicas diferentes en diferentes fases con la distancia de falla incrementada en 10 Km en cada caso y se ha calculado el porcentaje de error en la salida calculada. La figura 41 muestra los resultados de esta prueba realizada en la red neuronal (6-7-1). Se puede observar que el error máximo ronda el 1,65 por ciento lo cual es muy satisfactorio. Cabe señalar que el error promedio en la ubicación de fallas es solo del 0.89 %.

La figura 42 muestra una descripción general de la RNA elegida y se puede ver que el algoritmo de entrenamiento utilizado es el algoritmo de Levenberg - Marquardt. La función de rendimiento elegida para el proceso de entrenamiento es el error cuadrático medio. La figura 43 traza el error cuadrático medio como una función del tiempo durante el proceso de aprendizaje y se puede ver que el MSE logrado es de aproximadamente 0,0005056, que está muy por debajo del objetivo de MSE de 0.01.

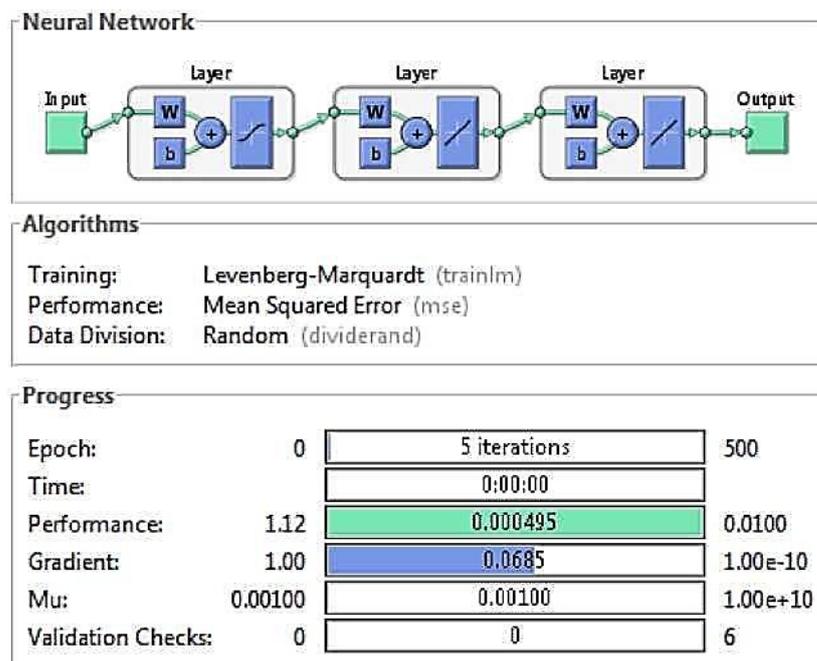


Figura 42. Resumen de la RNA, configuración (6-7-1)

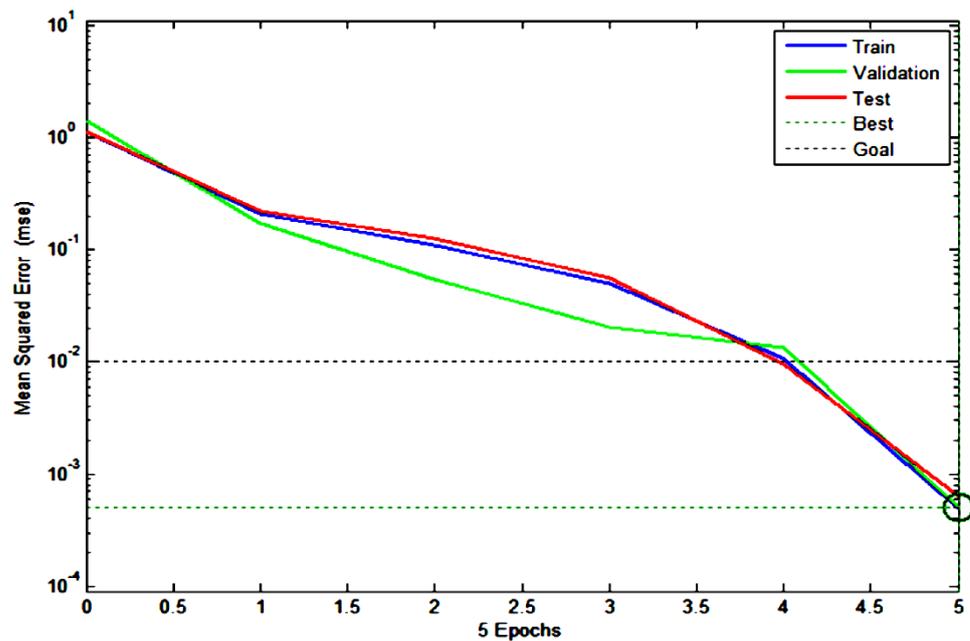


Figura 43. Error cuadrático medio, configuración (6-7-1)

4.3.1.2 Prueba de la red neuronal para línea – tierra

a. Localización de falla

Se han considerado varios factores al probar el rendimiento de las redes neuronales. Un factor principal que evalúa la eficiencia de la RNA es el rendimiento de la fase de prueba ya ilustrado en la figura 43. Como ya se mencionó, los porcentajes de error promedio y máximo se encuentran en rangos tolerables y, por lo tanto, el rendimiento de las redes se considera satisfactorio. La figura 46 proporciona otra forma de análisis, que es la gráfica de rendimiento de gradiente y validación. Se puede ver que hay una disminución constante en el gradiente y también que el número de errores de validación es 0 durante todo el proceso, lo que indica un entrenamiento fluido y eficiente.

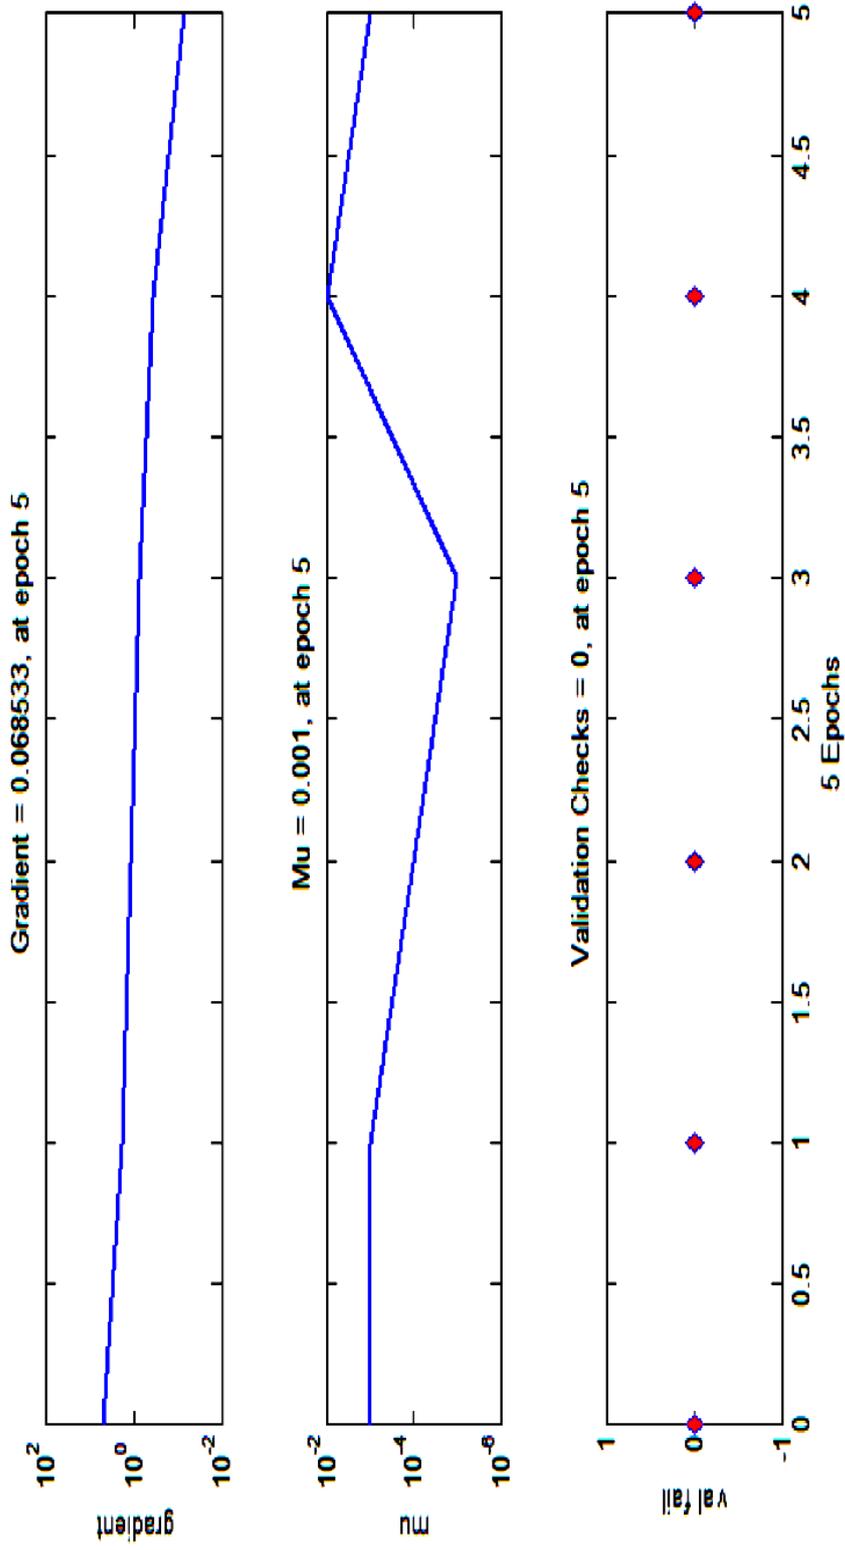


Figura 44. Gradiente y validación, configuración (6-7-1)

El tercer factor que se considera al evaluar el desempeño de la red es el coeficiente de correlación de cada una de las diversas fases de entrenamiento, validación y prueba. La figura 45 muestra los gráficos de regresión de las diversas fases, como entrenamiento, prueba y validación. Se puede ver que el mejor ajuste lineal coincide muy de cerca con el caso ideal con un coeficiente de correlación global de 0,99924.

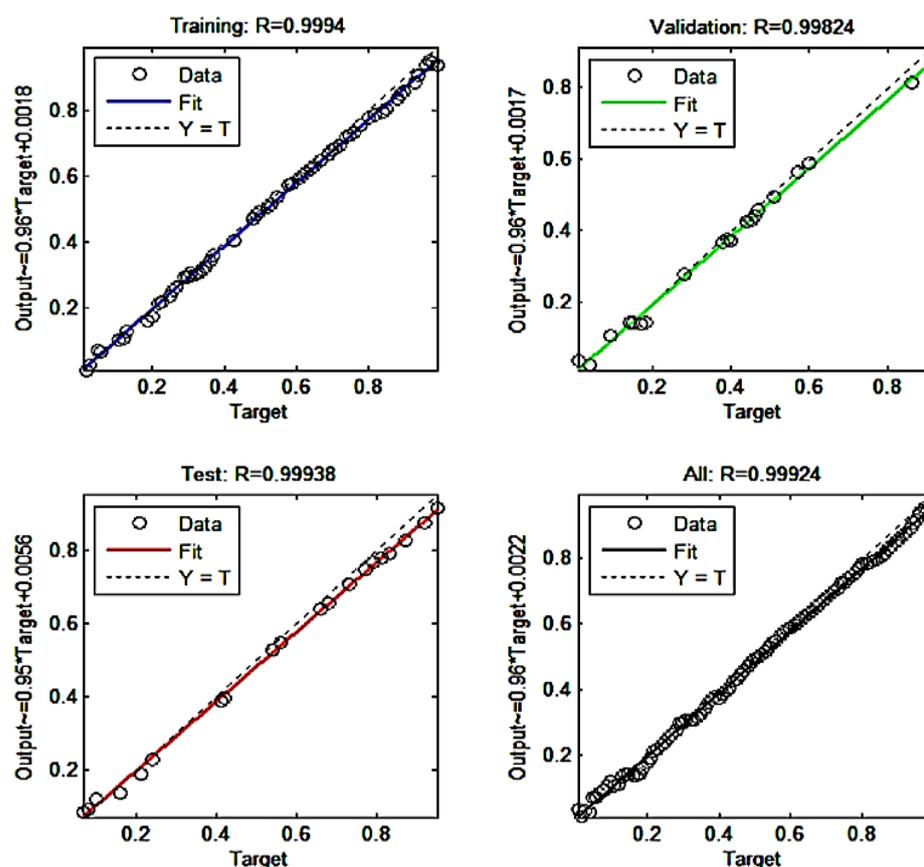


Figura 45. Regresión de las distintas fases de aprendizaje, configuración (6-7-1)

La figura 46 muestra la estructura de la RNA elegida para fallas a tierra de una sola línea con 6 neuronas en la capa de entrada, 7 neuronas en la capa oculta y 1 neurona en la capa de salida (6-7-1).

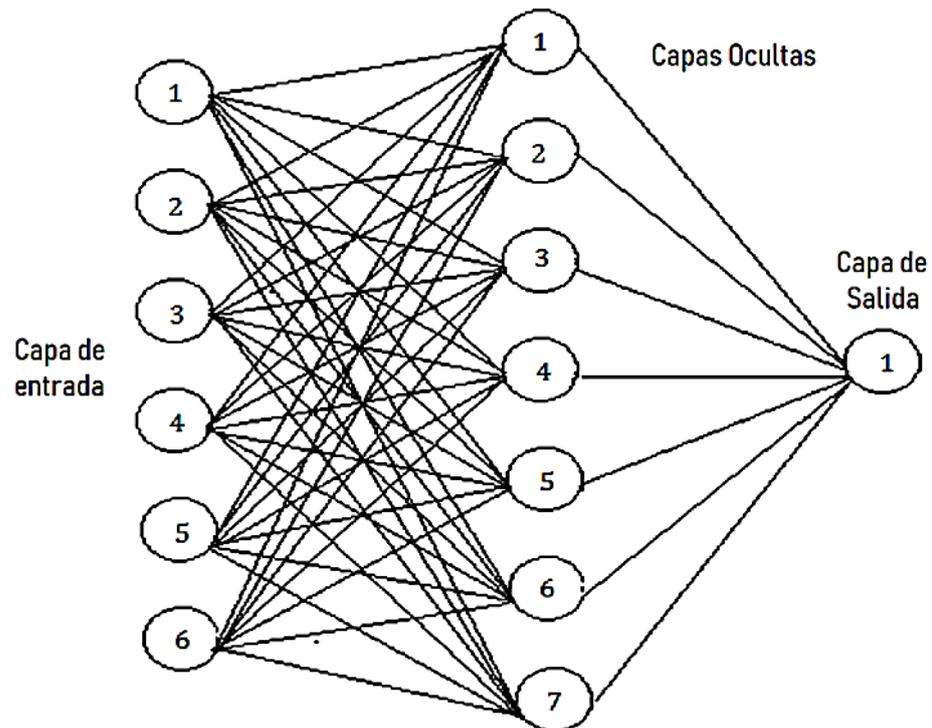


Figura 46. Estructura RNA para falla a tierra, configuración (6-7-1)

La Tabla 3 ilustra los errores porcentuales en la ubicación de fallas en función de la distancia de falla y la resistencia de falla. Se han considerado dos casos diferentes (mostrados en columnas adyacentes), uno con una resistencia de falla de 20 ohmios y otro con una resistencia de falla de 60 ohmios. Cabe señalar que la resistencia de 20 ohmios se utilizó como parte del conjunto de datos de entrenamiento y, por lo tanto, el porcentaje de error promedio en la ubicación de fallas en este caso es solo 0.1646 %. El segundo caso ilustra lo mismo con una resistencia de falla diferente de 60 ohmios que es relativamente muy alta y no forma parte del conjunto de entrenamiento. Por lo tanto, el rendimiento de la red neuronal en este caso ilustra su capacidad para generalizar y reaccionar ante nuevos datos. Cabe señalar que el error medio en este caso es de tan solo un 0,878 %, lo que es muy satisfactorio.

Tabla 3

Porcentaje de errores en función de la distancia de falla y la resistencia de falla para la RNA elegida para la ubicación de falla de línea simple a tierra

N° de serie	% Error vs. Distancia de falla (resistencia de falla = 20 Ω)			% Error vs. Distancia de falla (resistencia de falla = 60 Ω)		
	Resistencia de falla (Ω)	Ubicación de Medida de Falla	Porcentaje Error	Falla Distancia (Km)	Ubicación de Medida de Falla	Porcentaje Error
1	25	25.49	0.163	50	51.56	0.52
2	75	75.58	0.287	100	101.02	0.34
3	125	125.12	0.04	150	153.03	1.01
4	175	175.09	0.03	200	202.67	0.89
5	225	225.91	0.303	250	254.89	1.63

4.3.2 Falla línea - línea

El diseño, desarrollo y desempeño de redes neuronales con el propósito de localización de fallas línea - línea se discuten en esta sección. Ahora que podemos detectar la ocurrencia de una falla en una línea de transmisión y también clasificar la falla en varias categorías de fallas, el siguiente paso es identificar la ubicación de la falla desde cualquiera de los extremos de la línea de transmisión. Existen tres posibles faltas línea - línea (A-B, B-C, C-A), correspondientes a cada una de las tres fases (A, B o C) en falla.

4.3.2.1 Entrenamiento de la red neuronal para línea - localización de fallas en línea

Las redes neuronales de propagación retroalimentada se han estudiado con el fin de localizar fallas, línea - línea, debido a la disponibilidad de datos suficientes para entrenar la red. Para entrenar la red neuronal se han simulado varias fallas línea - línea sobre el modelo de línea de transmisión. Para cada par formado por las tres fases se han simulado fallos cada 3 Km en una línea de transmisión de 300 Km de longitud. Junto con la distancia de falla, la resistencia de falla se ha variado en 0.25, 0.5, 0.75, 1, 5, 10, 25 y 50 ohmios, respectivamente. Por tanto, se han simulado un total de 2400 casos (100 para cada una de las tres fases con cada una de las ocho resistencias de defecto diferentes). En cada uno de estos casos, las muestras de tensión y corriente para las tres fases (escaladas con respecto a sus valores previos a la falla) se proporcionan como entradas a la red

neuronal. La salida de la red neuronal es la distancia a la falla desde el terminal A. Por lo tanto, cada par de entrada y salida consta de seis entradas y una salida. Se ha realizado un estudio exhaustivo de varias redes neuronales variando el número de capas ocultas y el número de neuronas por capa oculta. Ciertas redes neuronales que lograron un rendimiento satisfactorio se presentan primero junto con sus gráficos de rendimiento de error. La RNA más adecuada se elige en función de su rendimiento de error cuadrático medio y el coeficiente de regresión de las salidas frente a los objetivos. Las figuras 47 - 48 muestran los gráficos de rendimiento de la fase MSE y de prueba de las redes neuronales 6 - 10 - 20 - 5 - 1 con 3 capas ocultas. Las Figuras 49 - 50 muestran los gráficos de rendimiento de la fase MSE y de prueba de la red neuronal 6 - 10 - 1 con 1 capa oculta.

La figura 47 muestra el rendimiento de la red neuronal (en términos de entrenamiento, prueba y validación) con 6 neuronas en la capa de entrada, 3 capas ocultas con 10, 20 y 5 neuronas respectivamente y 1 neurona en la capa de salida (6 - 10 - 20 - 5 - 1). Se puede ver que el mejor rendimiento de MSE de esta red neuronal es 0,0073438, que está por debajo del objetivo de MSE de 0,01. Se encontró que el coeficiente de correlación entre los productos y las metas fue de 0,98469 en este caso.

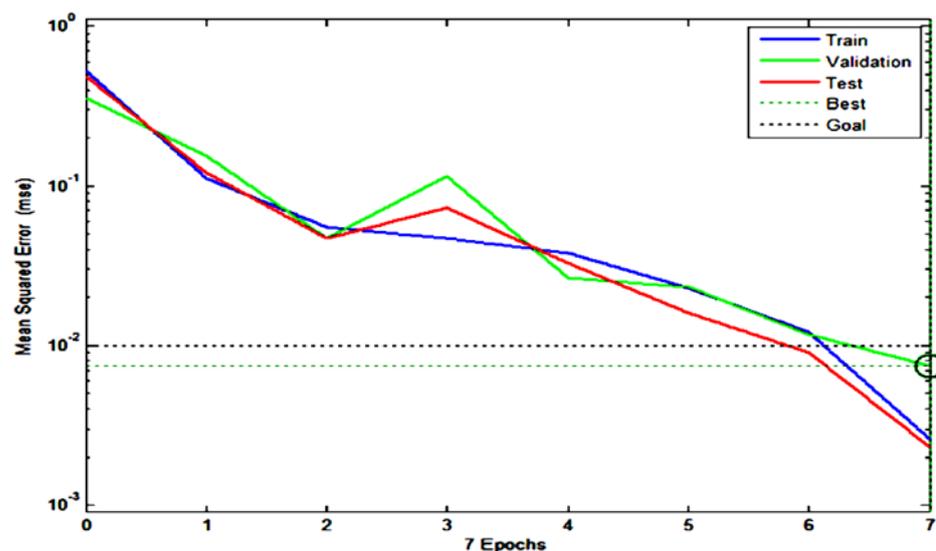


Figura 47. Error cuadrático medio, configuración (6-10-20-5-1)

Para probar el rendimiento de esta red, se han simulado 12 fallas línea a línea diferentes en diferentes fases incrementando la distancia de falla en

25 Km en cada caso y se ha calculado el porcentaje de error en la salida calculada. La figura 48 muestra los resultados de esta prueba realizada en la red neuronal (6-10-20-5-1). Se puede observar que el error máximo es de alrededor del 2,75 %.

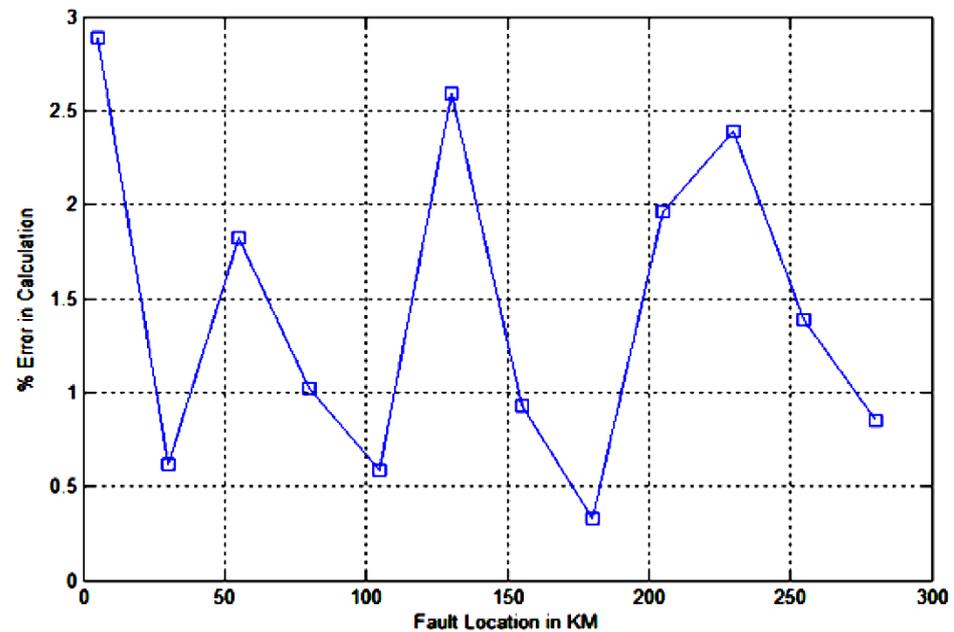


Figura 48. Rendimiento de la fase de prueba, configuración (6-10-20-5-1)

La figura 49 muestra el rendimiento de la red neuronal (en términos de entrenamiento, prueba y validación) con 6 neuronas en la capa de entrada, 10 neuronas en la capa oculta y 1 neurona en la capa de salida (6 - 10 - 1). Se puede ver que el mejor rendimiento de MSE de esta red neuronal es 0,004554, que está por debajo del objetivo de MSE de 0,01. Se encontró que el coeficiente de correlación entre las salidas y los objetivos fue de 0,983 para esta red neuronal.

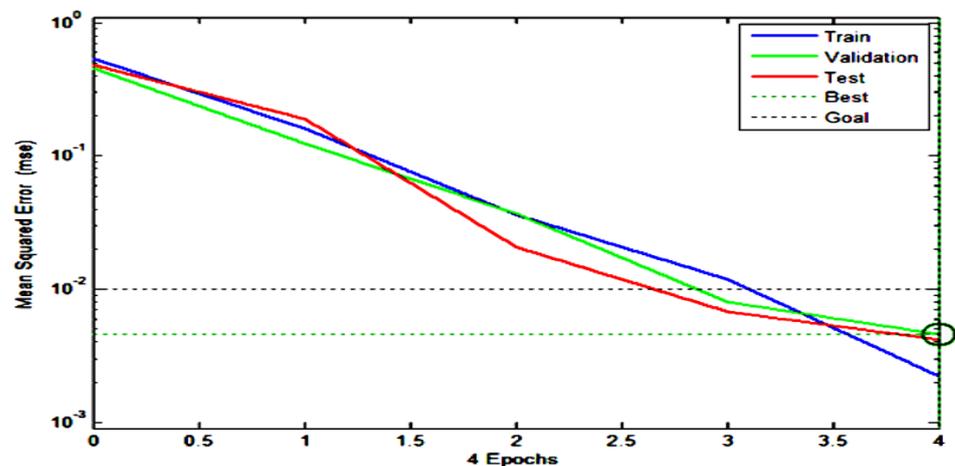


Figura 49. Error cuadrático medio, configuración (6-10-1)

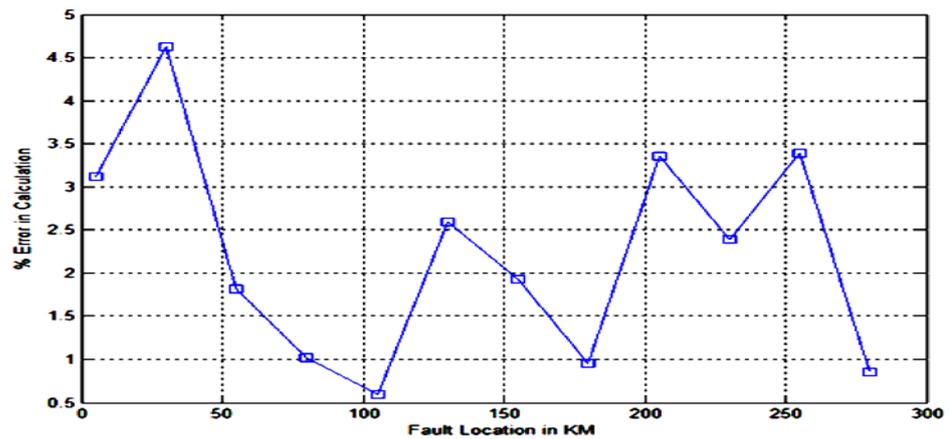


Figura 50. Desempeño de la Fase de Prueba, configuración (6-10-1)
Para probar el rendimiento de esta red, se han simulado 12 fallas línea a línea diferentes en diferentes fases incrementando la distancia de falla en 25 Km en cada caso y se ha calculado el porcentaje de error en la salida calculada. La figura 50 muestra los resultados de esta prueba realizada en la red neuronal (6-10-1). Se puede ver que el error máximo es de alrededor del 4,65 por ciento, lo cual es inaceptable.

La figura 51 muestra el rendimiento de la red neuronal (en términos de entrenamiento, prueba y validación) con 6 neuronas en la capa de entrada, 2 capas ocultas con 10 y 5 neuronas respectivamente y 1 neurona en la capa de salida (6-10- 5-1). Se puede ver que el mejor rendimiento de MSE de esta red neuronal es 0.002089, que está por debajo del objetivo de MSE de 0,01. Se encontró que el coeficiente de correlación entre las salidas y los objetivos fue de 0,98648.

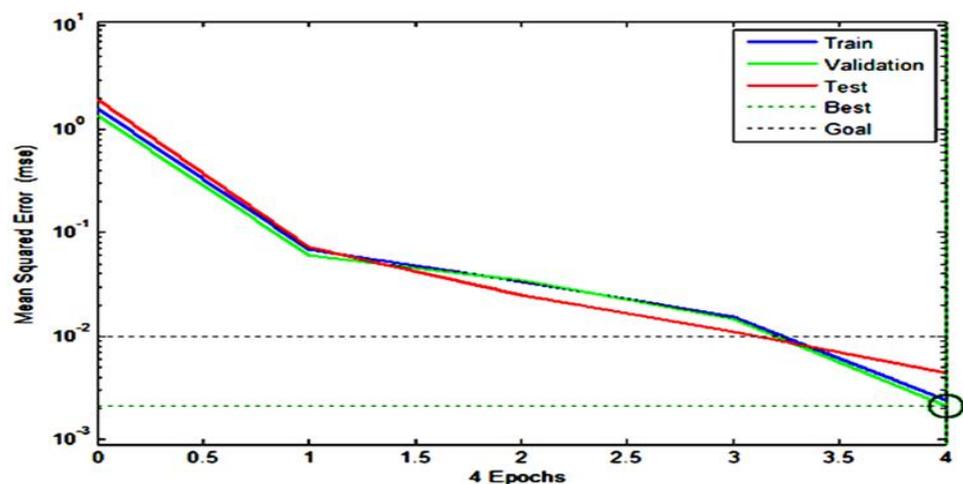


Figura 51. Error cuadrático medio, configuración (6-10-5-1)

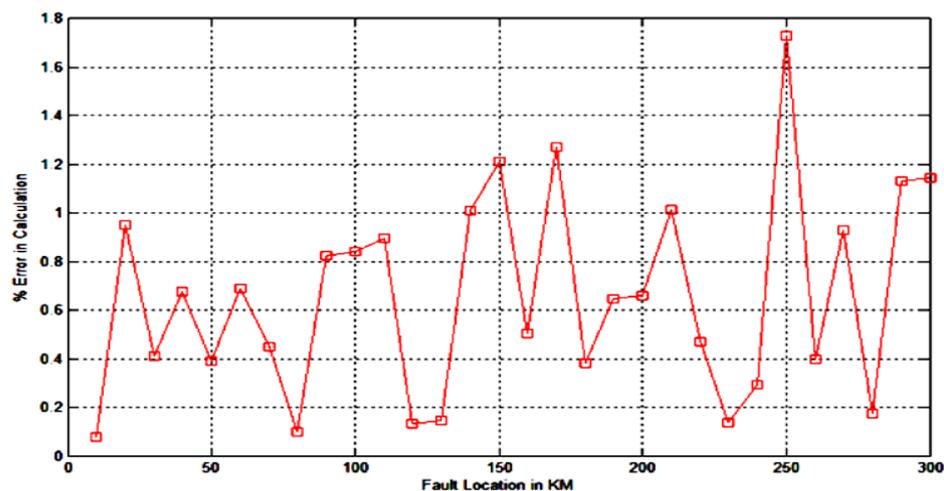


Figura 52. Rendimiento de la fase de prueba, configuración (6-10-5-1)

Para probar el rendimiento de esta red, se simularon 100 fallas de fase a fase diferentes en diferentes fases con la distancia de falla incrementada en 10 Km en cada caso y se calculó el porcentaje de error en la salida calculada. La figura 52 muestra los resultados de esta prueba realizada en la red neuronal (6-10-5-1). Se puede observar que el error máximo ronda el 1,7 % lo cual es muy satisfactorio. Cabe señalar que el error promedio en la ubicación de fallas es solo del 0,97 %. Por lo tanto, esta red neuronal ha sido elegida como la red ideal para la localización de fallas línea a línea en las LT.

La figura 53 muestra una descripción general de la RNA elegida y se puede ver que el algoritmo de entrenamiento utilizado es el algoritmo de Levenberg - Marquardt. La función de rendimiento elegida para el proceso de entrenamiento es el error cuadrático medio. La figura 54 representa el mejor ajuste de regresión lineal entre los resultados y los objetivos y se ha encontrado que el coeficiente de correlación para el mismo es 0.9865, que es un ajuste de regresión decentemente bueno.

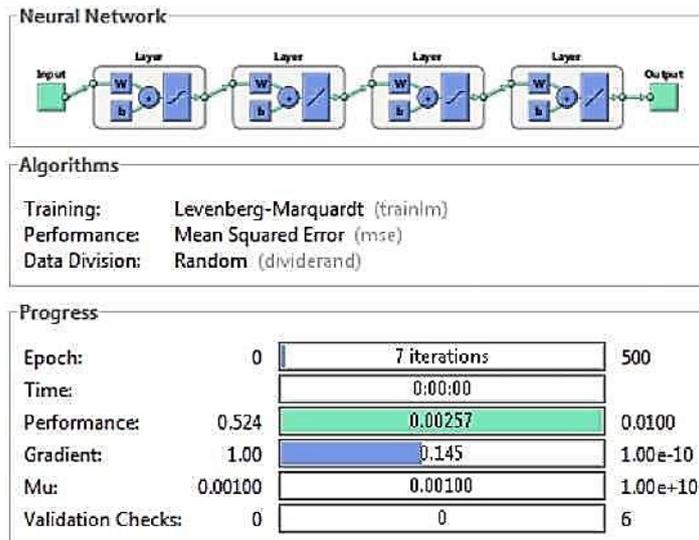


Figura 53. Resumen de la RNA para fallas línea a línea, configuración (6-10-5-1)

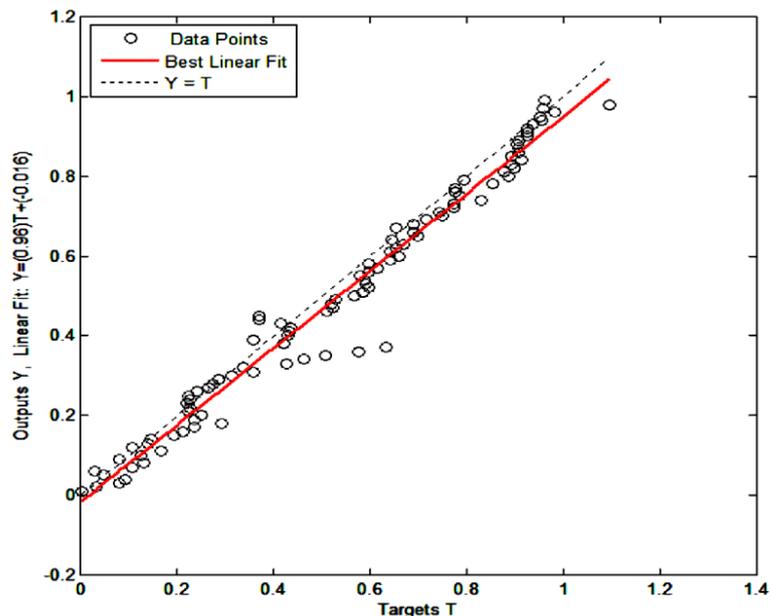


Figura 54. Ajuste de regresión de Productos vs. Metas, configuración (6-10-5-1)

4.3.2.2 Prueba de la red neural para línea - ubicación de fallas en la línea

Se han considerado varios factores al probar el rendimiento de la red neuronal elegida. Un factor principal que evalúa la eficiencia de la RNA es el gráfico de rendimiento de la fase de prueba que ya se ilustra en la figura 54 Como ya se mencionó, los porcentajes de error promedio y máximo se encuentran en rangos tolerables y, por lo tanto, el rendimiento

de la red se considera satisfactorio. La Fig. 57 proporciona otro medio para evaluar la RNA, que es la gráfica de rendimiento de gradiente y validación.

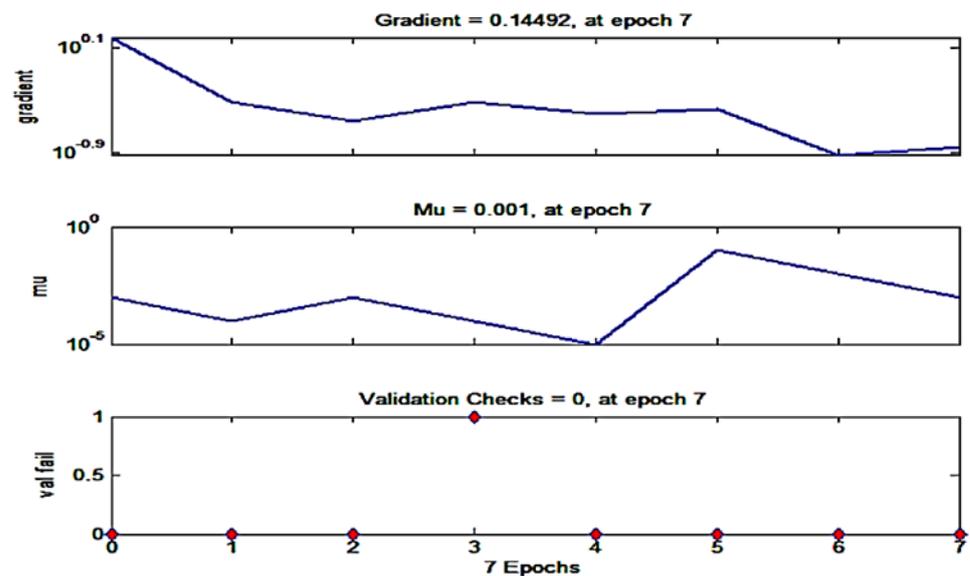


Figura 55. Gradiente y validación, configuración (6-10-5-1)

El tercer factor que se considera al evaluar el desempeño de la red es el coeficiente de correlación de cada una de las diversas fases de entrenamiento, validación y prueba. La figura 56 muestra los gráficos de regresión de las diversas fases, como entrenamiento, prueba y validación. Puede verse que el mejor ajuste lineal coincide muy de cerca con el caso ideal con un coeficiente de correlación global de 0,98648.

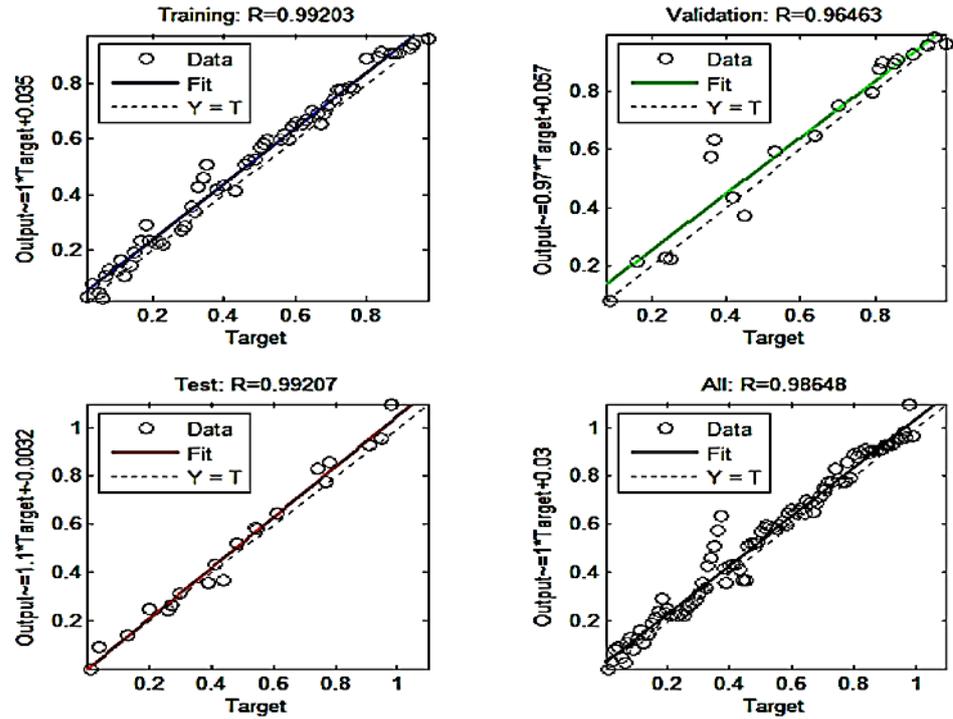


Figura 56. Regresión de las distintas fases de aprendizaje, configuración (6-10-5-1)

La Figura 57 muestra la estructura de la RNA elegida para fallas línea - línea con 6 neuronas en la capa de entrada, 2 capas ocultas con 10 y 5 neuronas en ellas respectivamente y 1 neurona en la capa de salida (6-10-5-1).

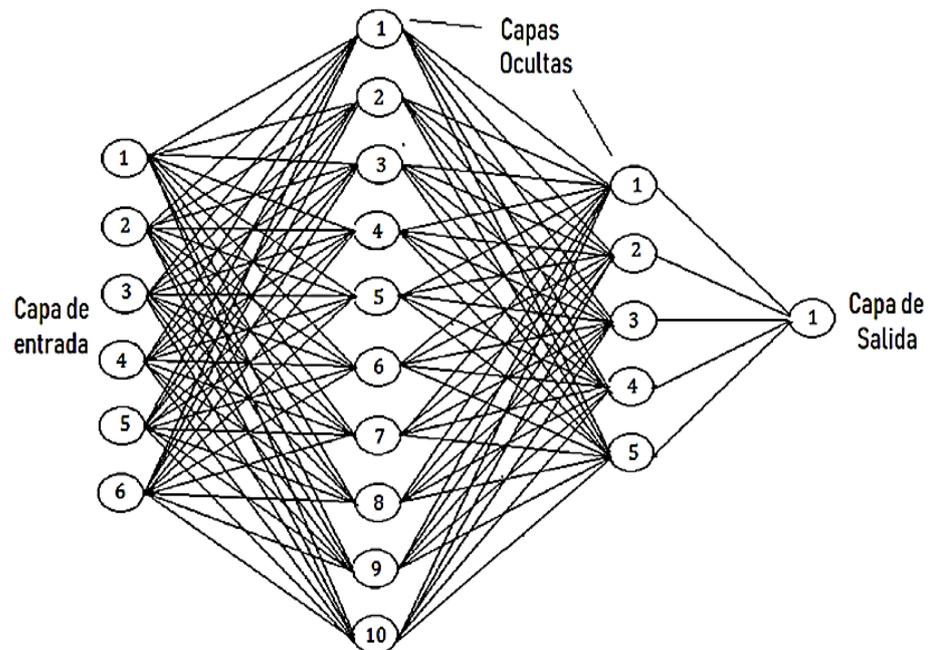


Figura 57. Estructura RNA para línea - línea, configuración (6-10-5-1)

La Tabla 4 ilustra los errores porcentuales en la ubicación de fallas en función de la distancia de falla y la resistencia de falla. Se han considerado dos casos diferentes (mostrados en columnas adyacentes), uno con una resistencia de falla de 20 ohmios y otro con una resistencia de falla de 60 ohmios. Cabe señalar que la resistencia de 20 ohmios se utilizó como parte del conjunto de datos de entrenamiento y, por lo tanto, el porcentaje de error promedio en la ubicación de fallas en este caso es solo 0.1386 %. El segundo caso ilustra lo mismo con una resistencia de falla diferente de 60 ohmios que es relativamente muy alta y no forma parte del conjunto de entrenamiento. Por lo tanto, el rendimiento de la red neuronal en este caso ilustra su capacidad para generalizar y reaccionar ante nuevos datos. Cabe señalar que el error promedio en este caso es solo 0,966 %, que es sigue siendo muy satisfactoria. Por lo tanto, el rendimiento de las redes neuronales se considera satisfactorio y se puede utilizar con el fin de localizar fallas línea a línea.

Tabla 4

Porcentaje de errores en función de la distancia de falla y la resistencia de falla para la RNA elegida para la localización de fallas línea - línea

Serie No:	% de error frente a distancia de falla (resistencia de falla = 20 Q)			% de error frente a distancia de falla (resistencia de falla = 60 Q)		
	Falla Distancia (Km)	Medido Falla Ubicación	Porcentaje Error	Falla Distancia (Km)	Medido Falla Ubicación	Porcentaje Error
1	25	25.03	0.01	50	51.17	0.39
2	75	75.39	0.13	100	102.52	0.84
3	125	125.67	0.223	150	153.63	1.21
4	175	175.14	0.047	200	201.98	0.66
5	225	225.85	0.283	250	255.19	1.73

4.3.3 Falla doble línea - tierra

El diseño, el desarrollo y el rendimiento de las redes neuronales con el propósito de la ubicación de fallas a tierra de línea doble se analizan en esta sección. La tercera categoría de fallas es la línea doble: fallas a tierra. Existen tres posibles fallas de doble línea a tierra que se denotan como ABG, BCG y ACG (según las cuales dos de las tres fases A, B y C están falladas).

4.3.3.1 Entrenamiento de red neuronal para localizar fallas doble línea - tierra

Retroalimentación: el algoritmo de propagación se usó una vez más con el propósito de doble línea: ubicación de fallas a tierra en las líneas de transmisión. La razón para hacerlo, como ya se mencionó, es que estas redes funcionan de manera muy eficiente cuando hay disponibilidad de un conjunto de datos de entrenamiento suficientemente grande. Con el fin de entrenar la red neuronal, se han simulado varias fallas de doble línea a tierra en la línea de transmisión modelada en cada una de las tres fases. Los diversos factores que variaron fueron la distancia de falla (incrementada en 3 km cada vez), la resistencia de falla (una de las ocho resistencias de falla diferentes elegidas) y las fases en falla. Se simularon alrededor de 100 casos de falla para cada fase con cada una de las ocho resistencias diferentes como 0.25, 0.5, 0.75, 1, 5, 10, 25 y 50 ohms respectivamente. Por lo tanto, se simularon un total de 2400 casos de fallas en la línea de transmisión. En cada uno de estos casos, las muestras de voltaje y corriente en las tres fases (escaladas con respecto a sus valores previos a la falla) se alimentan como entradas a la red neuronal. La salida de la red neuronal es la distancia a la falla desde el terminal A. Por lo tanto, cada par de entrada y salida alimentado a la red neuronal tiene un conjunto de seis entradas y una salida.

Se ha realizado un estudio exhaustivo de varias redes neuronales variando el número de capas ocultas y el número de neuronas por capa oculta. En primer lugar, se presentan algunas redes neuronales que lograron un rendimiento satisfactorio junto con sus gráficos de rendimiento de errores. De estas RNA, la RNA más adecuada se elige en función de su rendimiento de error cuadrático medio y el coeficiente de regresión de las salidas frente a los objetivos. Las figuras 58 - 61 muestran los gráficos de rendimiento de la fase MSE y de prueba de las redes neuronales 6-10-1 y 6-20-1 con 1 capa oculta. Las Figuras 62 - 65 muestran los gráficos de rendimiento de la fase MSE y de prueba de la red neuronal 6-10-5-1 y 6-21-11-1 con 2 capas ocultas.

La figura 58 muestra el rendimiento de la red neuronal (en términos de entrenamiento, prueba y validación) con 6 neuronas en la capa de entrada, 10 neuronas en la capa oculta y 1 neurona en la capa de salida (6 - 10 - 1). Se puede ver que el mejor rendimiento de MSE de esta red neuronal es 0,0047967, que está por debajo del objetivo de MSE de 0,01 (indicado por la línea de puntos negra). Se encontró que el coeficiente de correlación entre los productos y las metas fue de 0,98193 en este caso.

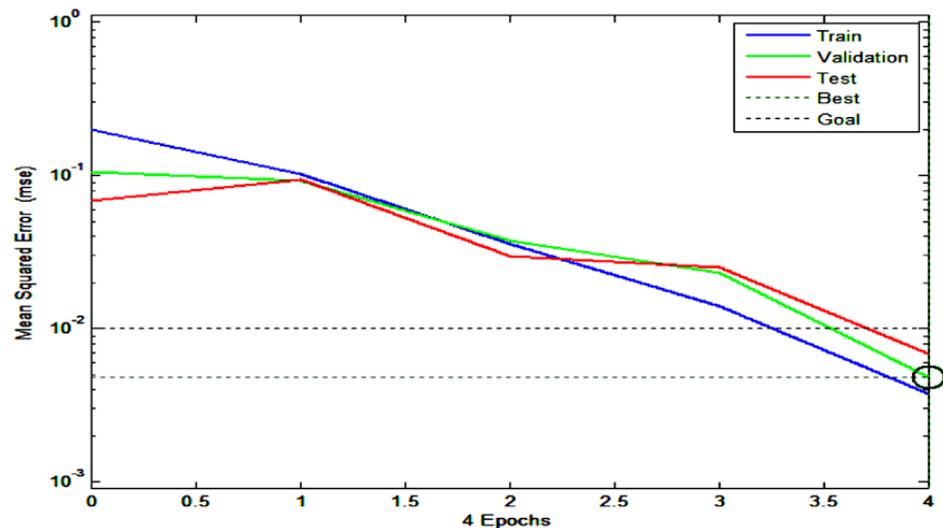


Figura 58. Error cuadrático medio, configuración (6-10-1)

Para probar el rendimiento de esta red, se han simulado 12 fallas de doble línea a tierra diferentes en diferentes fases con la distancia de falla incrementada por 25 Km en cada caso y se ha calculado el porcentaje de error en la salida de RNA. La figura 59 muestra los resultados de esta prueba realizada en la red neuronal (6-10-1). Se puede ver que el error máximo es superior al 5 por ciento, que es exorbitantemente alto.

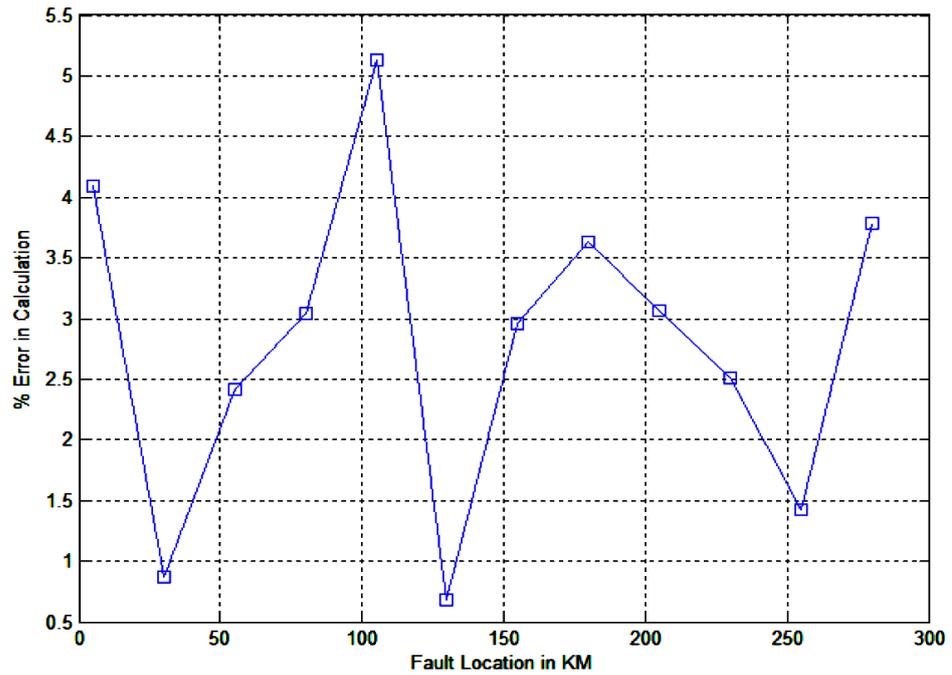


Figura 59. Rendimiento de la Fase de Prueba, configuración (6-10-1)

La figura 60 muestra el rendimiento de la red neuronal (en términos de entrenamiento, prueba y validación) con 6 neuronas en la capa de entrada, 20 neuronas en la capa oculta y 1 neurona en la capa de salida (6-20-1). Se puede ver que el mejor rendimiento de MSE de esta red neuronal es 0,0013561, que está por debajo del objetivo de MSE de 0,01 (indicado por la línea de puntos negra en la figura). Se encontró que el coeficiente de correlación entre las salidas y los objetivos fue de 0,98804 para esta red neuronal.

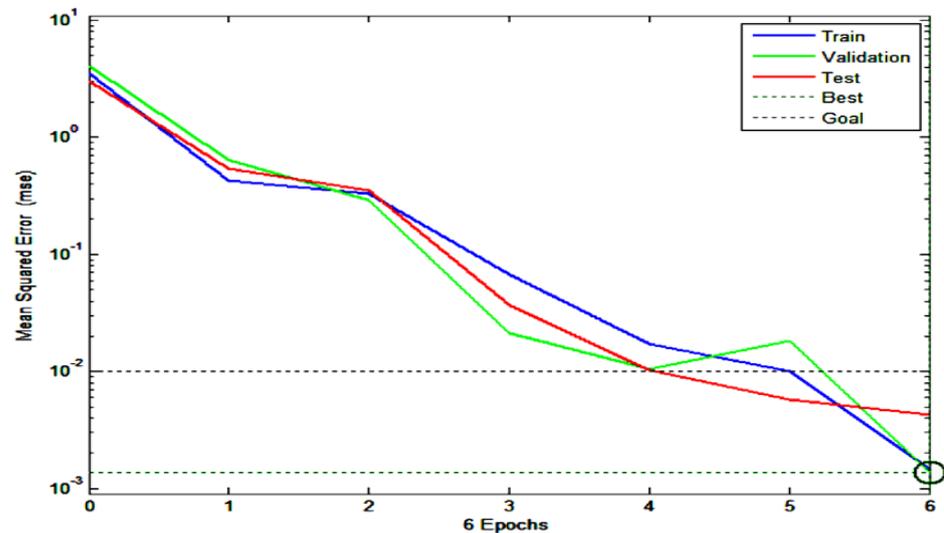


Figura 60. Error cuadrático medio, configuración (6-20-1)

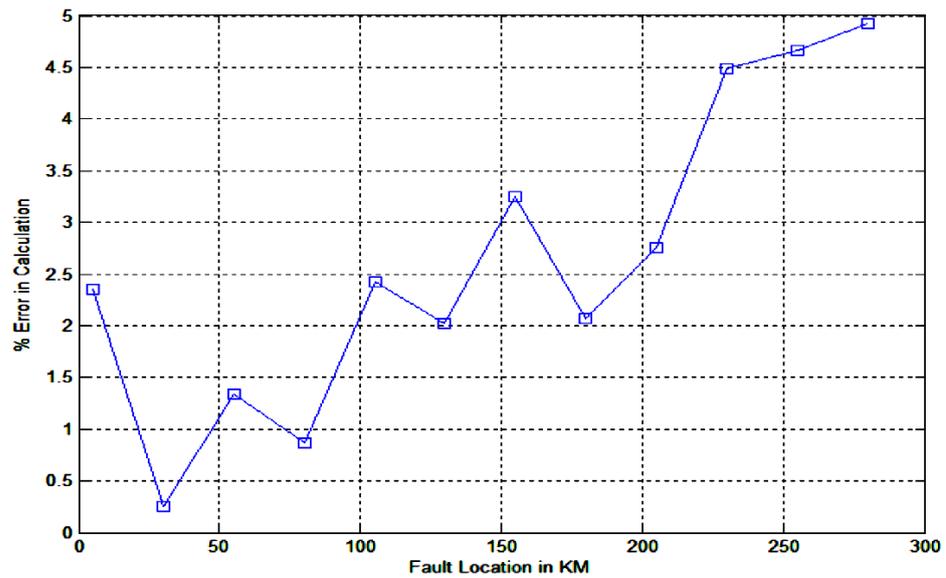


Figura 61. Rendimiento de la Fase de Prueba, configuración (6-20-1)

Para probar el rendimiento de esta red se sigue el mismo método adoptado para el caso anterior. Se han simulado 12 fallas de doble línea - tierra diferentes en diferentes fases con la distancia de falla incrementada en 25 Km en cada caso y se ha calculado el porcentaje de error en la salida de RNA. La figura 61 muestra los resultados de esta prueba realizada en la red neuronal (6-20-1). Cabe señalar que el error máximo es superior al 4,75 por ciento, que es demasiado alto para este propósito.

La figura 62 muestra el rendimiento de la red neuronal (en términos de entrenamiento, prueba y validación) con 6 neuronas en la capa de entrada, 2 capas ocultas con 10 y 5 neuronas respectivamente y 1 neurona en la capa de salida (6 - 10 - 5 - 1). Puede verse que el mejor rendimiento de MSE de esta red neuronal es 0,00338785, que está por debajo del objetivo de MSE de 0,01 (indicado por la línea de puntos negra en la figura). Se encontró que el coeficiente de correlación entre las salidas y los objetivos fue de 0,98913 para esta red neuronal.

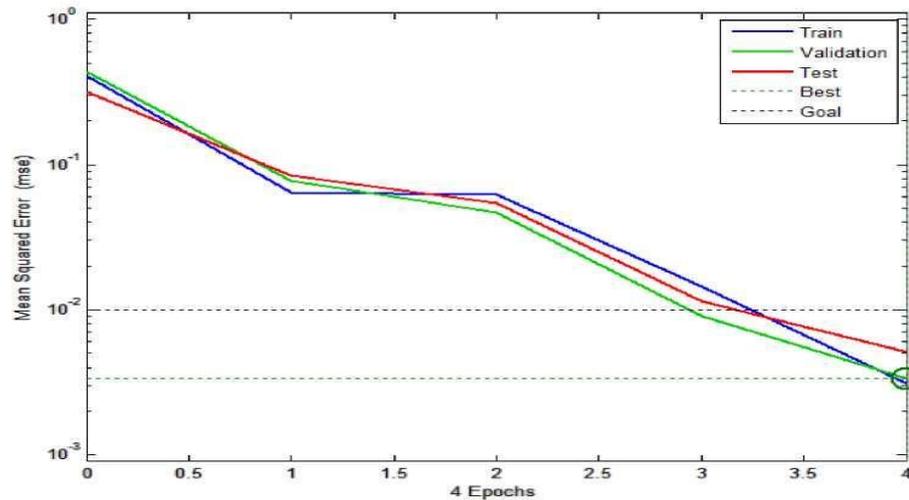


Figura 62. Error cuadrático medio, configuración (6-10-5-1)

Para probar el rendimiento de esta red se sigue el mismo método adoptado para el caso anterior. Se han simulado 12 fallas de doble línea - tierra diferentes en diferentes fases con la distancia de falla incrementada en 25 Km en cada caso y se ha calculado el porcentaje de error en la salida de RNA. La figura 63 muestra los resultados de esta prueba realizada en la red neuronal (6-10-5-1). Cabe señalar que el error máximo es superior al 3,5 por ciento, lo que todavía no es satisfactorio para este propósito.

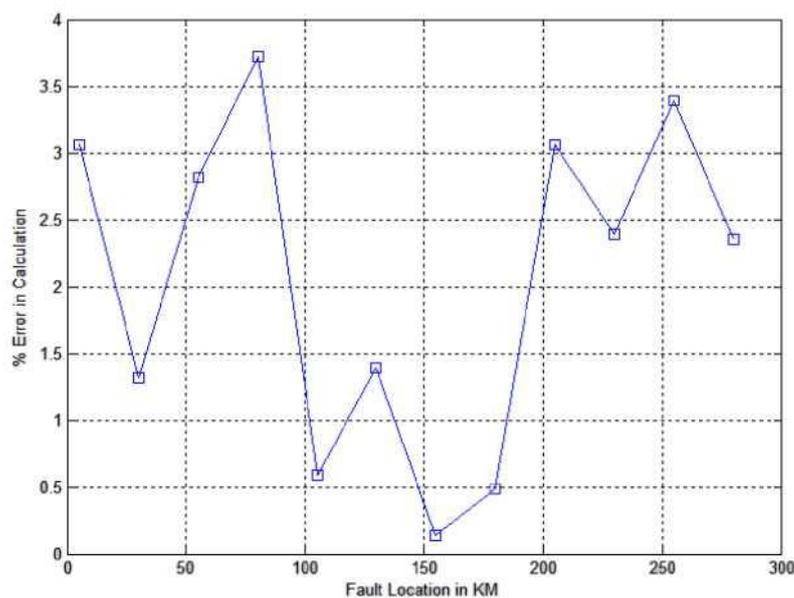


Figura 63. Desempeño de la Fase de Prueba, configuración (6-10-5-1)

La figura 64 muestra el rendimiento de la red neuronal (en términos de entrenamiento, prueba y validación) con 6 neuronas en la capa de entrada, 2 capas ocultas con 21 y 11 neuronas respectivamente y 1 neurona en la

capa de salida (6-21-11-1). Puede verse que el mejor rendimiento de MSE de esta red neuronal es 0,00159395, que está por debajo del objetivo de MSE de 0,01 (indicado por la línea de puntos negra en la figura). Se encontró que el coeficiente de correlación entre los resultados y los objetivos fue de 0,99329 para esta red neuronal, lo que indica un ajuste de regresión muy bueno.

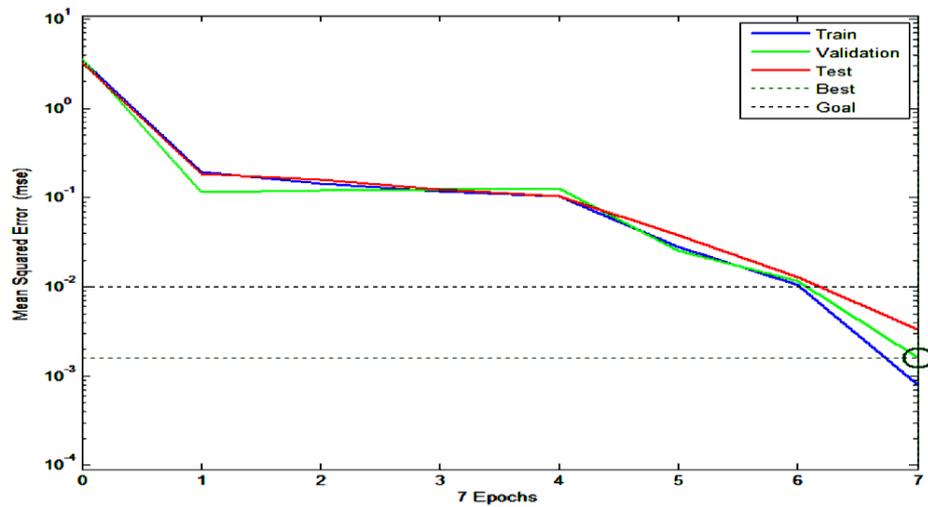


Figura 64. Error cuadrático medio, configuración (6-21-11-1)

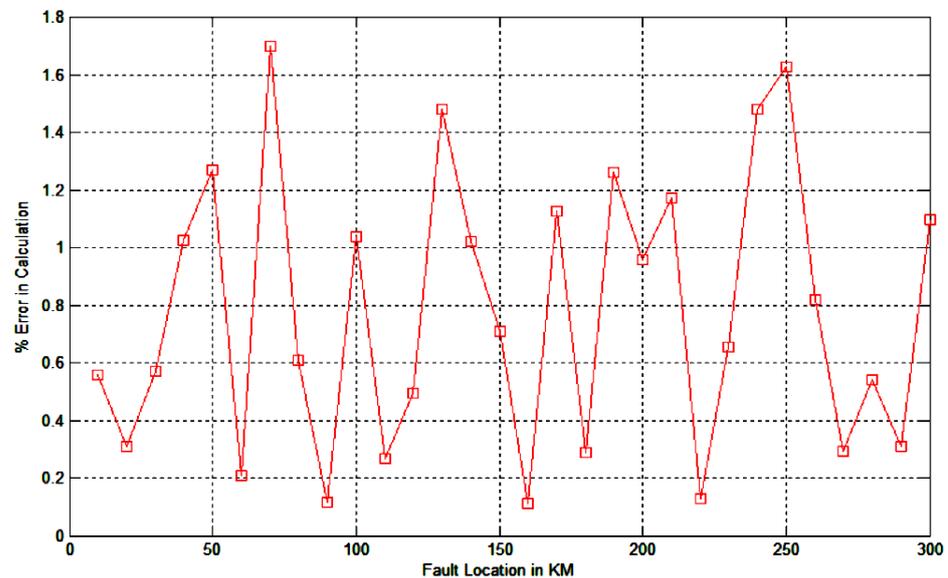


Figura 65. Desempeño de la fase de prueba, configuración (6-21-11-1)

Para probar el rendimiento de esta red, se han simulado 100 fallas de doble línea - tierra diferentes en diferentes fases con la distancia de falla incrementada en 10 Km en cada caso y se ha calculado el porcentaje de

error en la salida calculada. La figura 65 muestra los resultados de esta prueba realizada en la red neuronal (6-21-11-1). Se puede observar que el error máximo está en torno al 1,71 por ciento lo cual es muy satisfactorio. Cabe señalar que el error promedio en la ubicación de fallas es solo 0.863 por ciento. Por lo tanto, esta red neuronal ha sido elegida como la red ideal para el propósito de localización de fallas a tierra de doble línea en líneas de transmisión.

La figura 66 muestra una descripción general de la RNA elegida y se puede ver que el algoritmo de entrenamiento utilizado es el algoritmo de Levenberg - Marquardt. La función de rendimiento elegida para el proceso de entrenamiento es el error cuadrático medio. La figura 67 traza el mejor ajuste de regresión lineal entre los resultados y los objetivos. Como ya se mencionó, el coeficiente de correlación en este caso resulta ser 0.9933, lo cual es muy bueno.

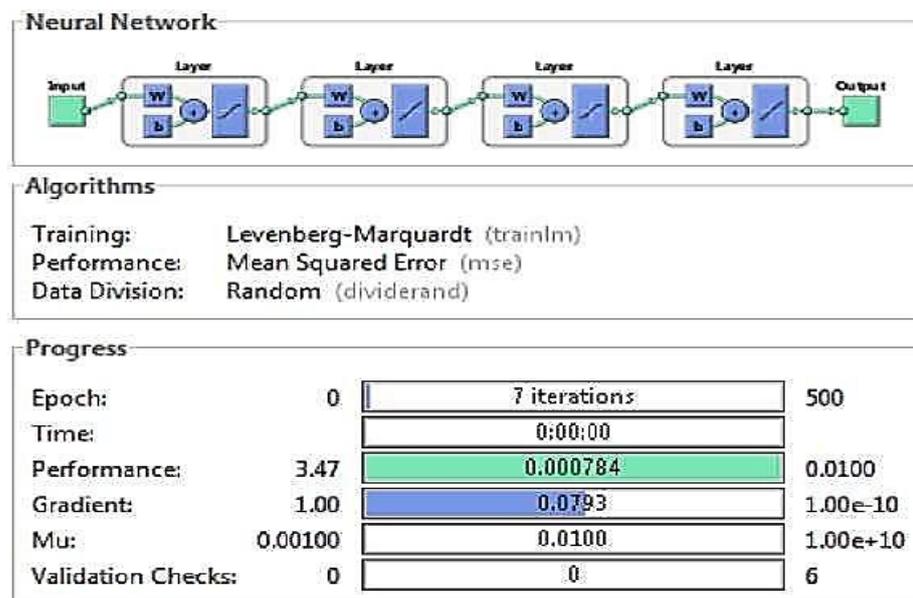


Figura 66. Resumen de la RNA para fallas dobles de línea a tierra, configuración (6-21-11-1)

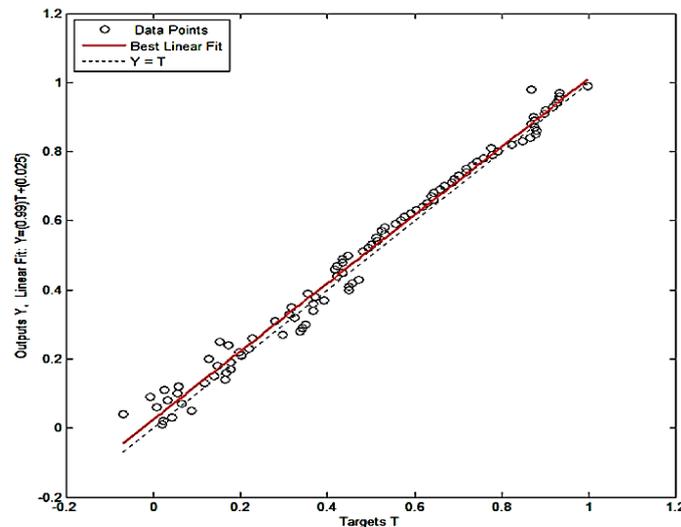


Figura 67. Ajuste de regresión de Productos vs. Metas, configuración (6-21-11-1)

4.3.3.2 Prueba de la red neuronal para localización doble línea - tierra

Ahora que se ha entrenado la red neuronal, el siguiente paso importante es analizar el rendimiento de esta red, lo que se denomina prueba. Los métodos y medios por los cuales se ha probado esta red neuronal se analizan a continuación. Un factor importante que ayuda a probar la red es el gráfico de rendimiento de la fase de prueba, como se muestra en la figura 67. Cabe señalar que tanto el porcentaje de error medio como el máximo se encuentran en niveles aceptables y por tanto el rendimiento de las redes es satisfactorio. Otro medio para determinar la eficiencia de una red neuronal entrenada es verificar el gradiente y el gráfico de rendimiento de validación como se muestra en la figura 70. Se puede ver que hay una disminución constante en el gradiente y también que el número máximo de fallas de validación es 3 durante el proceso de formación. Esto indica un entrenamiento eficiente porque la fase de validación sigue de cerca a la fase de prueba si el número de errores de validación es bajo. Esto implica además que la red neuronal puede generalizar los nuevos datos que se le alimentan de manera más efectiva.

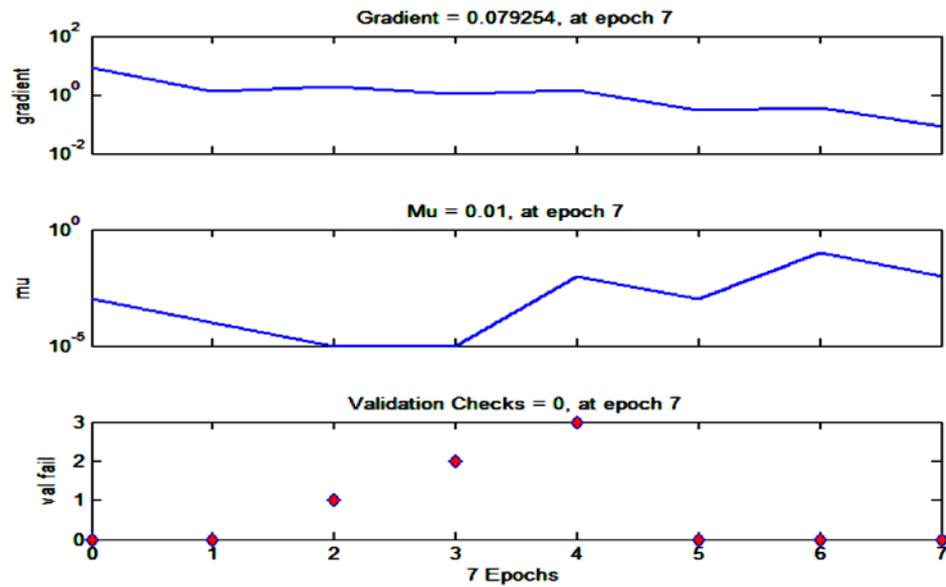


Figura 68. Gradiente y validación, configuración (6-21-11-1)

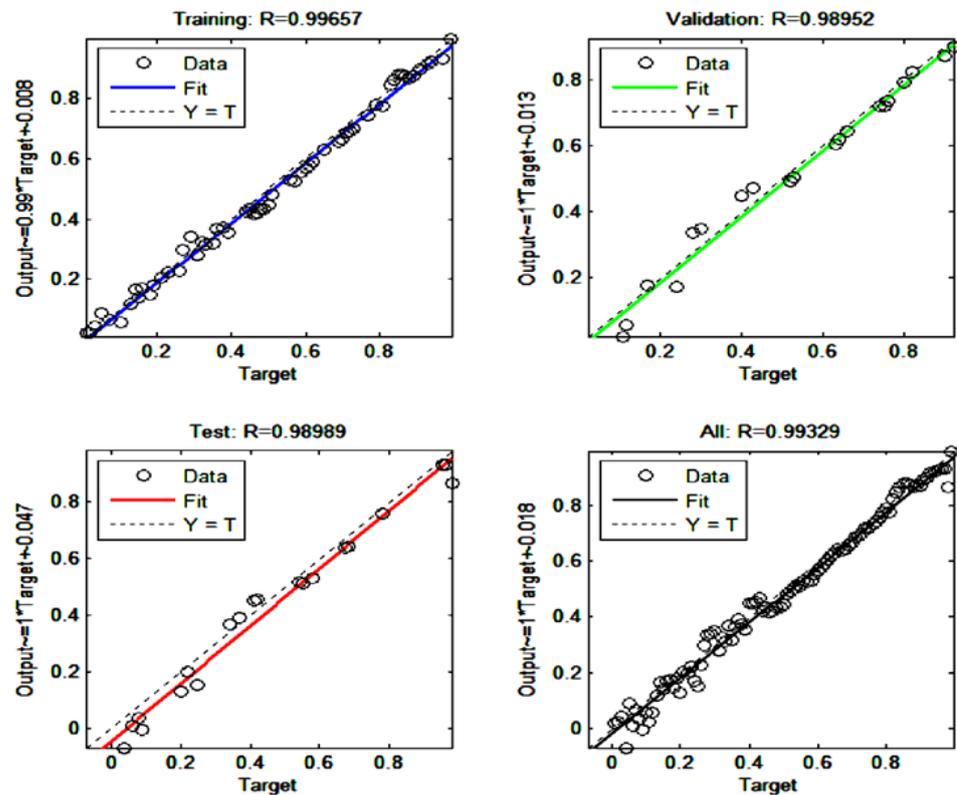


Figura 69. Regresión de las distintas fases de aprendizaje RNA, configuración (6-21-11-1)

El tercer factor que se considera al evaluar el desempeño de la red es el coeficiente de correlación de cada una de las diversas fases de entrenamiento, validación y prueba. La figura 69 muestra los gráficos de regresión de las diversas fases, como entrenamiento, prueba y validación. Se puede ver que el mejor ajuste lineal coincide muy de cerca con el caso

ideal con un coeficiente de correlación global de 0,9933.

La figura 70 muestra la estructura de la RNA elegida para la ubicación de falla a tierra de doble línea con 6 neuronas en la capa de entrada, 2 capas ocultas con 21 y 11 neuronas respectivamente y 1 neurona en la capa de salida (6-21-11-1).

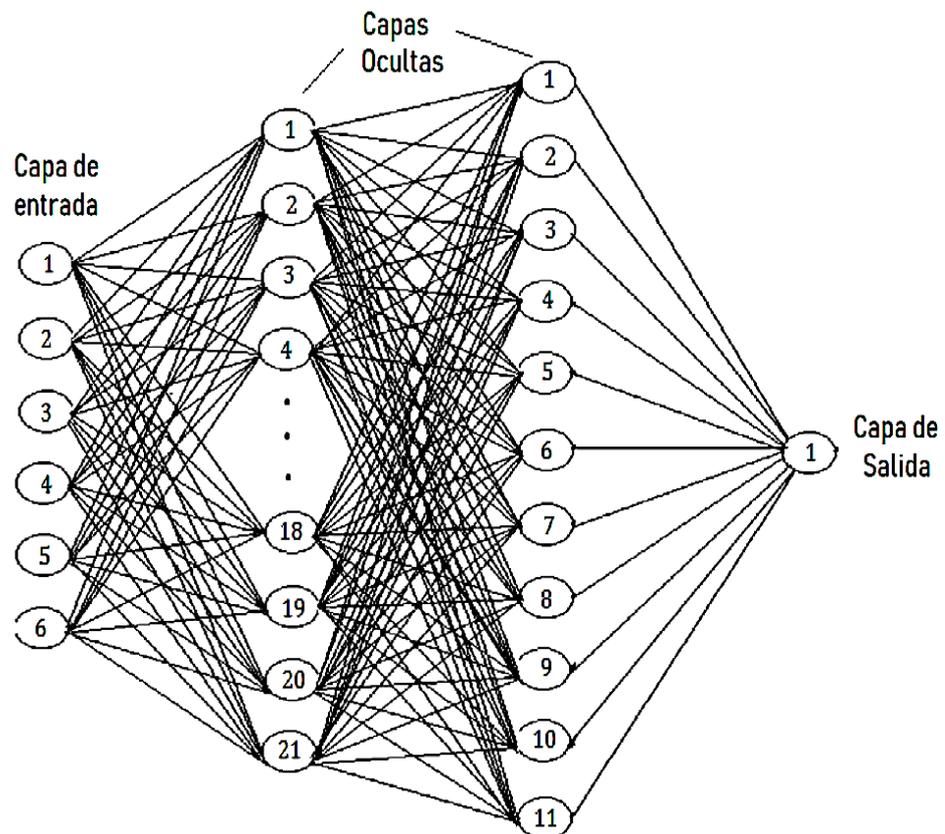


Figura 70. Estructura RNA para doble línea - tierra, configuración (6-21-11-1)

La Tabla 5 ilustra los errores porcentuales en la ubicación de fallas en función de la distancia de falla y la resistencia de falla. Se han considerado dos casos diferentes (mostrados en columnas adyacentes), uno con una resistencia de falla de 20 ohmios y otro con una resistencia de falla de 60 ohmios. Cabe señalar que la resistencia de 20 ohmios se utilizó como parte del conjunto de datos de entrenamiento y, por lo tanto, el porcentaje de error promedio en la ubicación de fallas en este caso es solo 0,091 %. El segundo caso ilustra lo mismo con una resistencia de falla diferente de 60 ohmios que es relativamente muy alta y no forma parte del conjunto de entrenamiento. Por lo tanto, el rendimiento de la red neuronal en este caso

ilustra su capacidad para generalizar y reaccionar ante nuevos datos. Cabe señalar que el error promedio en este caso es solo del 1,122 %, lo que sigue siendo aceptable.

Tabla 5

Porcentaje de errores en función de la distancia de falla y la resistencia de falla para la RNA elegida para localización de falla doble línea - tierra

Serie No:	% de error frente a distancia de falla (resistencia de falla = 20 Q)			% de error frente a distancia de falla (resistencia de falla = 60 Q)		
	Falla Distancia (Km)	Medido Falla Ubicación	Porcentaje Error	Falla Distancia (Km)	Medido Falla Ubicación	Porcentaje Error
1	25	25.53	0.177	50	53.81	1.27
2	75	75.18	0.06	100	103.12	1.04
3	125	125.11	0.037	150	152.13	0.71
4	175	175.16	0.053	200	202.88	0.96
5	225	225.39	0.13	250	254.89	1.63

4.3.4 Fallas trifásicas

El diseño, desarrollo y desempeño de las redes neuronales con el propósito de localizar fallas trifásicas se discuten en esta sección. La cuarta y última categoría de fallas son las fallas trifásicas. Existe solo un tipo de fallas trifásicas que se denota como falla ABC donde en todas las tres fases A, B y C están falladas.

4.3.4.1 Entrenamiento de la red neuronal para localización de fallas trifásicas

Realimentación hacia atrás: el algoritmo de propagación se utilizó una vez más con el propósito de localizar fallas trifásicas en las líneas de transmisión. La razón para hacerlo, como ya se mencionó, es que estas redes funcionan de manera muy eficiente cuando hay disponibilidad de un conjunto de datos de entrenamiento suficientemente grande. Con el fin de entrenar la red neuronal, se han simulado varias fallas trifásicas en la línea de transmisión modelada. Los diversos factores que variaron fueron la distancia de falla (incrementada en 3 km cada vez) y la resistencia de falla (una de las ocho resistencias de falla diferentes elegidas). Se simularon alrededor de 100 casos de fallas con cada una de las ocho resistencias

diferentes como 0.25, 0.5, 0.75, 1, 5, 10, 25 y 50 ohms respectivamente. Por lo tanto, se simularon un total de 800 casos de fallas en la línea de transmisión. En cada uno de estos casos, las muestras de voltaje y corriente en las tres fases (escaladas con respecto a sus valores previos a la falla) se alimentan como entradas a la red neuronal. La salida de la red neuronal es la distancia a la falla desde el terminal A. Por lo tanto, cada par de entrada y salida alimentado a la red neuronal tiene un conjunto de seis entradas y una salida. Se ha realizado un estudio exhaustivo de varias redes neuronales variando el número de capas ocultas y el número de neuronas por capa oculta. En primer lugar, se presentan algunas redes neuronales que lograron un rendimiento satisfactorio junto con sus gráficos de rendimiento de errores. De estas RNA, la RNA más adecuada se elige en función de su rendimiento de error cuadrático medio y el coeficiente de regresión de las salidas frente a los objetivos. Figuras 71 - 73 muestran los gráficos de rendimiento de la fase MSE y de prueba de la red neuronal 6-21-10-1 con 2 capas ocultas. Las Figuras 74 - 76 muestran los gráficos de rendimiento de la fase MSE y de prueba de la red neuronal 6-21-1 con 1 capa oculta.

La figura 71 traza el mejor ajuste de regresión lineal entre las salidas y los objetivos de la red neuronal, con 6 neuronas en la capa de entrada, 2 capas ocultas con 21 y 10 neuronas respectivamente y 1 neurona en la capa de salida (6-21-10-1). El coeficiente de correlación, como se mencionó anteriormente, es una medida de qué tan bien la red neuronal relaciona los resultados y los objetivos. Cuanto más cercano sea el valor de r a 1, mejor será el rendimiento de la red neuronal. Se encuentra que el valor de r en este caso es 0.99706.

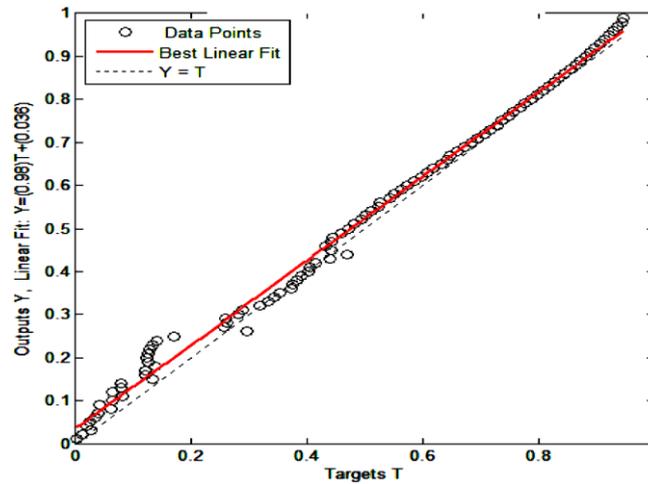


Figura 71. Ajuste de regresión de las Salidas vs. Objetivos, configuración (6-21-10-1)

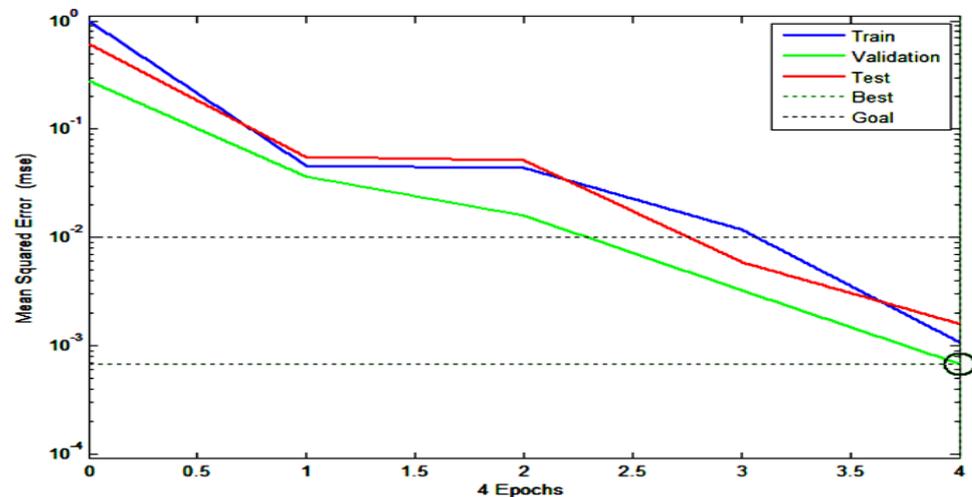


Figura 72. Rendimiento MSE, configuración (6-21-10-1)

La figura 72 muestra el rendimiento de la red neuronal (en términos de entrenamiento, prueba y validación) con 6 neuronas en la capa de entrada, 2 capas ocultas con 21 y 10 neuronas respectivamente y 1 neurona en la capa de salida (6-21-10-1). Se puede ver que el mejor rendimiento de MSE de esta red neuronal es 0,00067433 (indicado por la línea verde punteada), que está por debajo del objetivo de MSE de 0,01 (indicado por la línea negra).

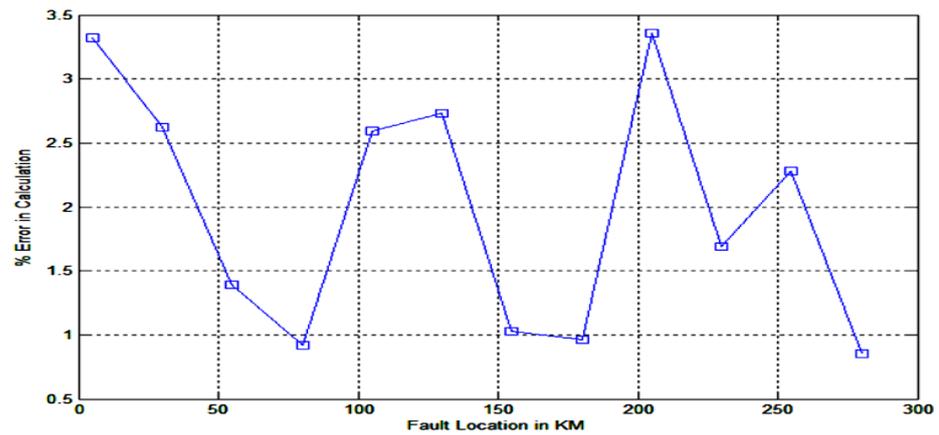


Figura 73. Desempeño de la Fase de Prueba, configuración (6-21-10-1)

Para probar el rendimiento de esta red, se han simulado 12 fallas trifásicas diferentes en la línea de transmisión, incrementando la distancia de falla en 25 Km en cada caso y se ha calculado el porcentaje de error en la salida de RNA. La figura 73 muestra los resultados de esta prueba realizada en la red neuronal (6-21-10-1). Se puede observar que el error máximo es superior al 3 por ciento, lo que es bastante satisfactorio. Sin embargo, las redes neuronales que pueden funcionar mejor son más deseables.

La figura 74 muestra el rendimiento de la red neuronal (en términos de entrenamiento, prueba y validación) con 6 neuronas en la capa de entrada, 1 capa oculta con 21 neuronas y 1 neurona en la capa de salida (6 - 21 - 1). Puede verse que el mejor rendimiento de MSE de esta red neuronal es 0,00076875 (indicado por la línea verde punteada), que está por debajo del objetivo de MSE de 0,01 (indicado por la línea punteada negra).

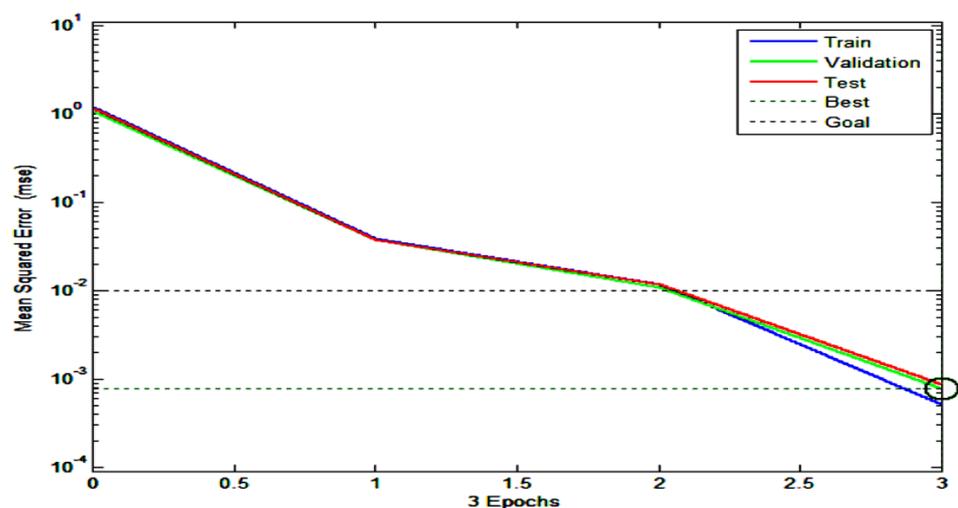


Figura 74. Rendimiento MSE, configuración (6-21-1)

La figura 70 traza el mejor ajuste de regresión lineal entre las salidas y los objetivos de la red neuronal con 6 neuronas en la capa de entrada, 1 capa oculta con 21 neuronas y 1 neurona en la capa de salida (6-21-1). El coeficiente de correlación (r), como se mencionó anteriormente, es una medida de qué tan bien la red neuronal relaciona los resultados y los objetivos. Cuanto más cercano sea el valor de r a 1, mejor será el rendimiento de la red neuronal. Se encuentra que el valor de r en este caso es 0,99804, que es una mejora con respecto al caso anterior (6-21-10-1).

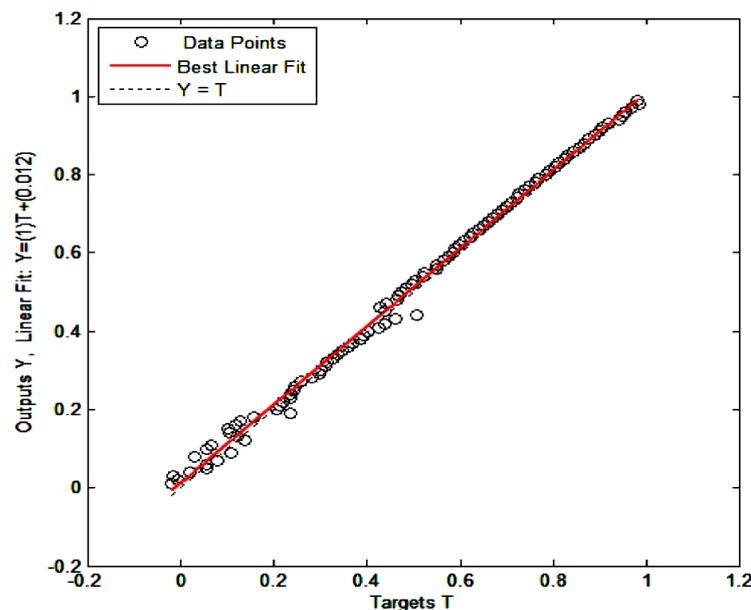


Figura 75. Ajuste de regresión para las Salidas vs. Objetivos, configuración (6-21-1)

Para probar el rendimiento de esta red, se han simulado 12 fallas trifásicas diferentes en la línea de transmisión, incrementando la distancia de falla en 25 Km en cada caso y se ha calculado el porcentaje de error en la salida de RNA. La figura 76 muestra los resultados de esta prueba realizada en la red neuronal (6-21-1). Puede ser visto que el error máximo es apenas inferior al 3 por ciento, lo que es una mejora significativa con respecto al caso anterior.

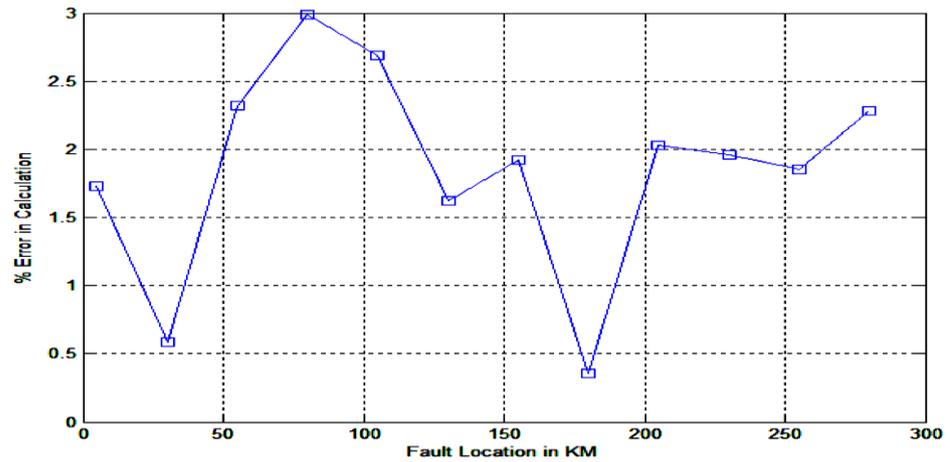


Figura 76. Desempeño de la Fase de Prueba, configuración (6-21-1)

La figura 72 traza el mejor ajuste de regresión lineal entre las salidas y los objetivos de la red neuronal con 6 neuronas en la capa de entrada, 3 capas ocultas con 6, 21 y 16 neuronas respectivamente y 1 neurona en la capa de salida (6 - 6 - 21 - 16 - 1). El coeficiente de correlación (r), como se mencionó anteriormente, es una medida de qué tan bien la red neuronal relaciona los resultados y los objetivos. Cuanto más cercano sea el valor de r a 1, mejor será el rendimiento de la red neuronal. Se encuentra que el valor de r en este caso es 0,99897, que está muy cerca de 1.

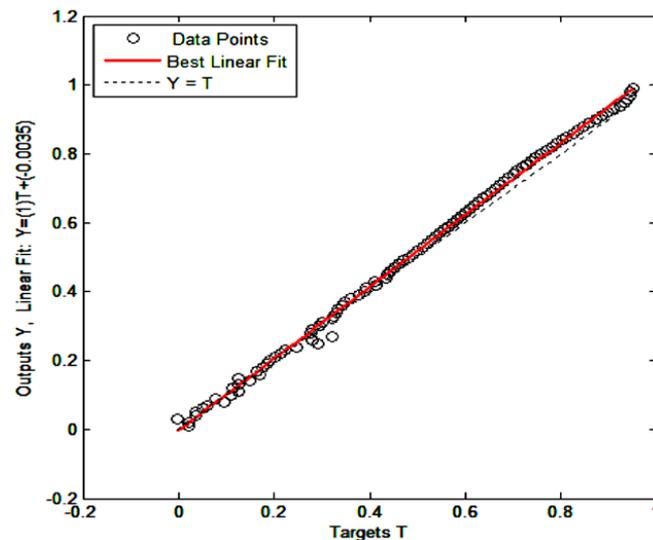


Figura 77. Ajuste de regresión de Resultados vs. Objetivos, configuración (6-6-21-16-1)

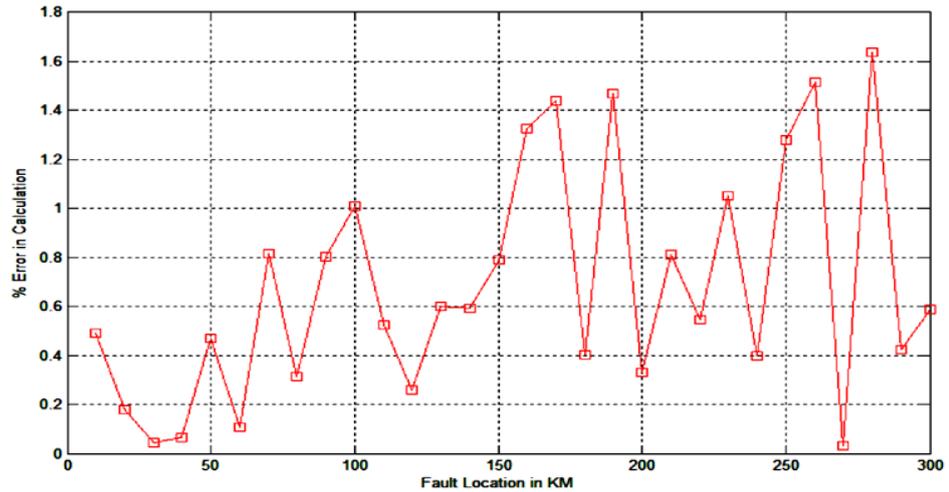


Figura 78. Desempeño de la Fase de Prueba, configuración (6-6-21-16-1)

Para probar el rendimiento de esta red, se han simulado 100 fallas trifásicas diferentes en la línea de transmisión, incrementando la distancia de falla en 10 Km en cada caso y se ha calculado el porcentaje de error en la salida de RNA. La figura 78 muestra los resultados de esta prueba realizada en la red neuronal (6-6-21-16-1). Se ve que el error máximo ronda el 1,62 por ciento lo cual es muy satisfactorio. Cabe señalar que el error promedio en la ubicación de fallas es solo 0.677 por ciento. Por lo tanto, esta red neuronal se ha elegido como la red ideal para la localización de fallas trifásicas en las líneas de transmisión.

La figura 79 muestra una descripción general de la RNA elegida y se puede ver que el algoritmo de entrenamiento utilizado es el algoritmo de Levenberg - Marquardt. La función de rendimiento elegida para el proceso de entrenamiento es el error cuadrático medio.

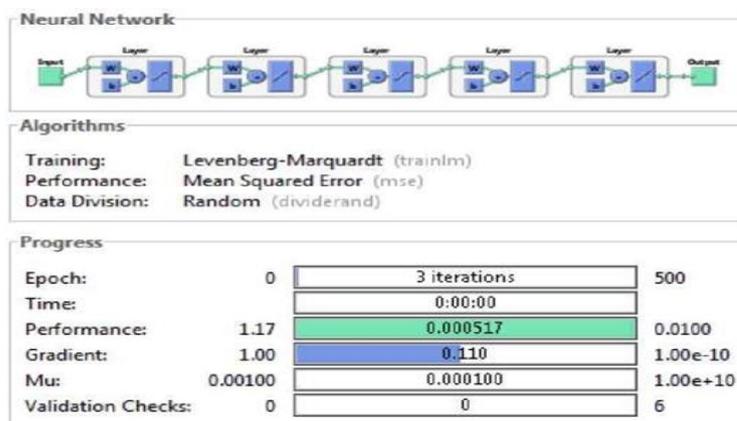


Figura 79. Resumen de la RNA para localización de fallas trifásicas

La figura 80 muestra el rendimiento de la red neuronal (en términos de entrenamiento, prueba y validación) con 6 neuronas en la capa de entrada, 1 capa oculta con 21 neuronas y 1 neurona en la capa de salida (6-6-21-16-1). Puede verse que el mejor rendimiento de MSE de esta red neuronal es 0,00060607 (indicado por la línea verde punteada), que está por debajo del objetivo de MSE de 0,01 (indicado por la línea punteada negra).

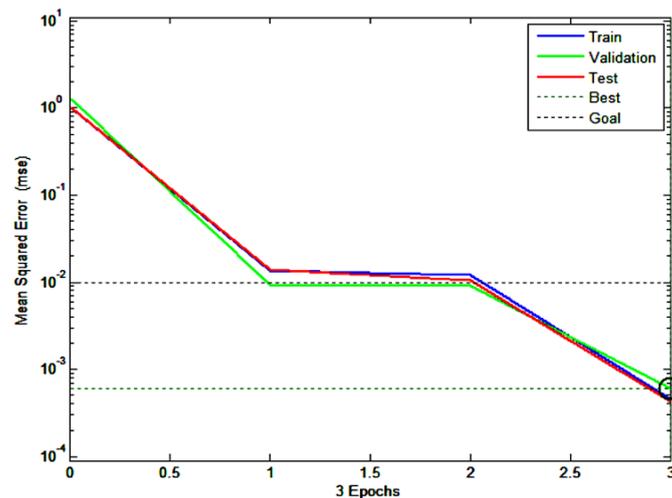


Figura 80. Error cuadrático medio, configuración (6-6-21-16-1)

4.3.4.2 Prueba de la red neuronal para localización de fallas trifásicas

Ahora que se ha entrenado la red neuronal, el siguiente paso es analizar el rendimiento de esta red, lo que se denomina prueba. Los métodos y medios por los cuales se ha probado esta red neuronal se analizan aquí en esta sección. Un factor importante que ayuda a probar la red es el gráfico de rendimiento de la fase de prueba, como se muestra en la figura 81. Cabe señalar que tanto el porcentaje de error promedio como el máximo para determinar con precisión la ubicación de la falla se encuentran en niveles aceptables y, por lo tanto, el rendimiento de la red es satisfactorio.

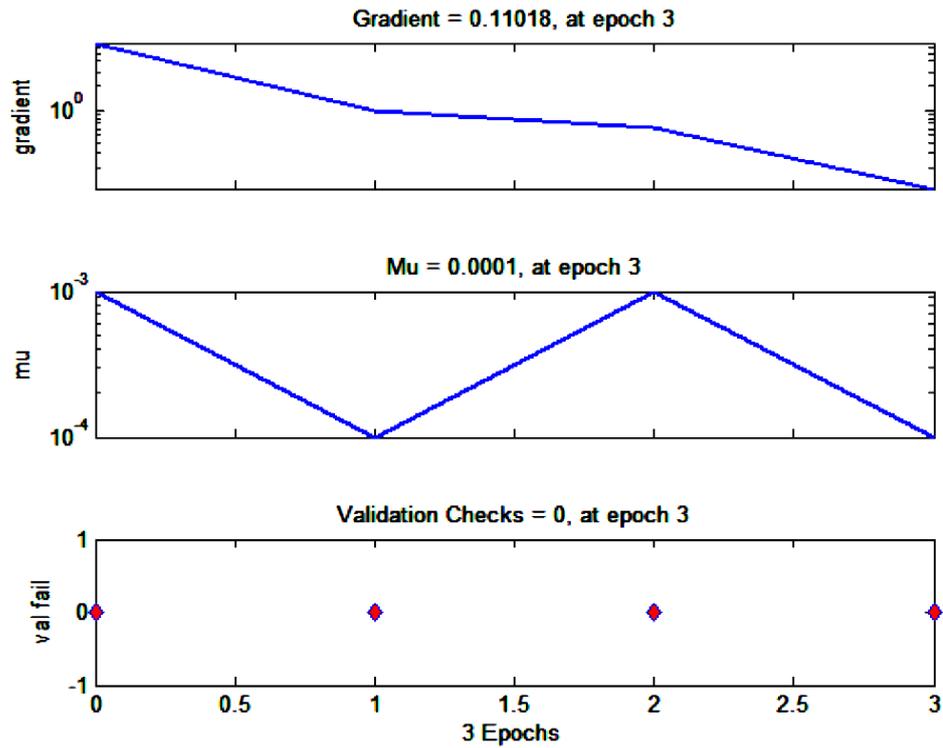


Figura 81. Gradiente y validación de la red, configuración (6-6-21-16-1)

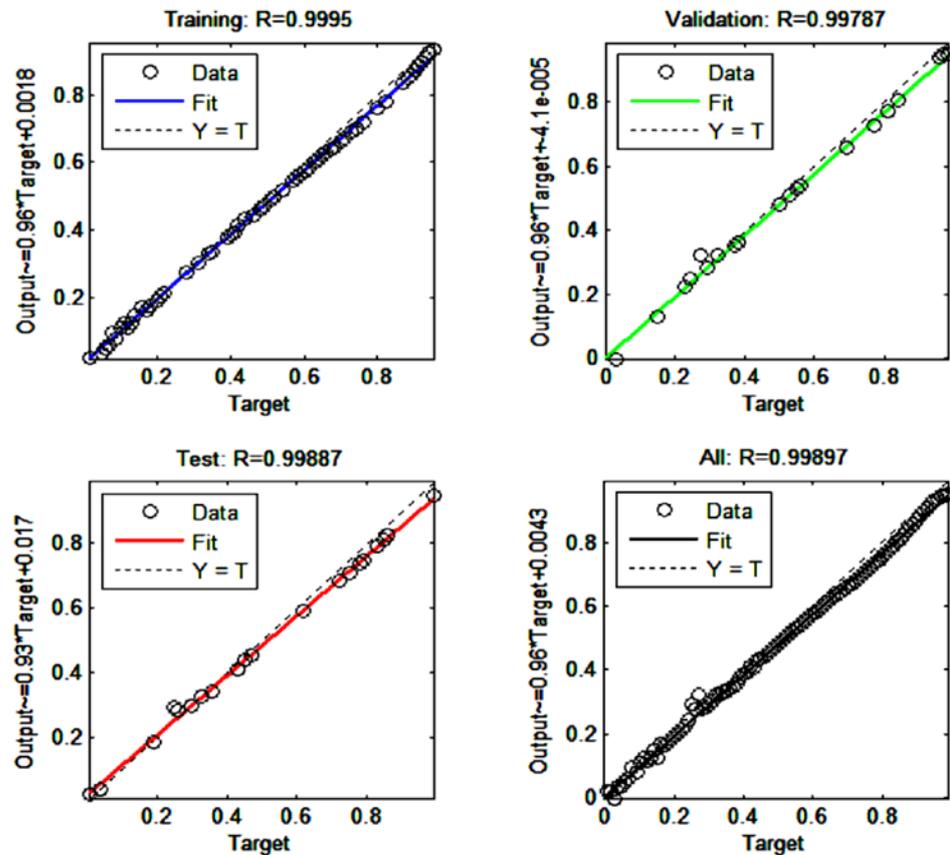


Figura 82. Regresión de las fases de aprendizaje RNA, configuración (6-6-21-16-1)

Otro medio importante para determinar la eficiencia de un sistema neuronal entrenado en red, es comprobar el gradiente y el gráfico de rendimiento de validación como se muestra en la Fig. 83. Se puede ver que hay una disminución constante y suave en el gradiente y también que el número máximo de errores de validación es 0 durante el proceso de entrenamiento. Esto indica un entrenamiento eficiente porque la fase de validación sigue de cerca a la fase de prueba si el número de errores de validación es bajo. Esto se indica además en las curvas de prueba y validación de la figura 82. Esto implica además que la red neuronal puede generalizar los nuevos datos que se le alimentan de manera más efectiva.

El tercer factor que se considera al evaluar el desempeño de la red es el coeficiente de correlación de cada una de las diversas fases de entrenamiento, validación y prueba. La figura 83 muestra los gráficos de regresión de las diversas fases, como entrenamiento, prueba y validación. Se puede ver que el mejor ajuste lineal coincide muy de cerca con el caso ideal con un coeficiente de correlación global de 0,99329.

La figura 83 muestra la estructura de la RNA elegida para fallas trifásicas con 6 neuronas en la capa de entrada, 1 capa oculta con 21 neuronas y 1 neurona en la capa de salida (6-6-21-16-1).

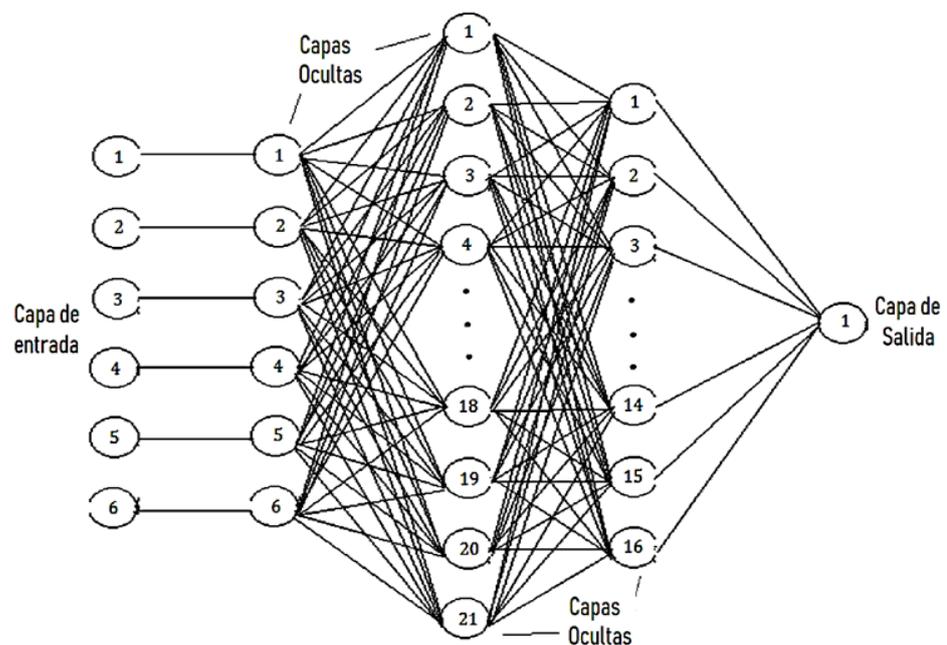


Figura 83. Estructura RNA para falla trifásica, configuración (6-6-21-16-1)

La Tabla 6 ilustra los errores porcentuales en la ubicación de fallas en función de la distancia de falla y la resistencia de falla. Se han considerado dos casos diferentes (mostrados en columnas adyacentes), uno con una resistencia de falla de 20 ohmios y otro con una resistencia de falla de 60 ohmios. Cabe señalar que la resistencia de 20 ohmios se utilizó como parte del conjunto de datos de entrenamiento y, por lo tanto, el porcentaje de error promedio en la localización de fallas en este caso es solo 0,178 %. El segundo caso ilustra lo mismo con una resistencia de falla diferente de 60 ohmios que es relativamente muy alta y no forma parte del conjunto de entrenamiento. Por lo tanto, el rendimiento de la red neuronal en este caso ilustra su capacidad para generalizar y reaccionar ante nuevos datos. Cabe señalar que el error promedio en este caso es solo del 0,836 %, lo que sigue siendo aceptable.

Tabla 6

Porcentaje de errores en función de la distancia de falla y la resistencia de falla para la RNA elegida para la localización de fallas trifásicas

Serie No:	% de error frente a distancia de falla (resistencia de falla = 20 Q)			% de error frente a distancia de falla (resistencia de falla = 60 Q)		
	Falla Distancia (Km)	Medido Falla Ubicación	Porcentaje Error	Falla Distancia (Km)	Medido Falla Ubicación	Porcentaje Error
1	25	25.51	0.17	50	51.41	0.47
2	75	75.17	0.057	100	103.03	1.01
3	125	125.52	0.28	150	152.37	0.79
4	175	175.69	0.23	200	201.99	0,63
5	225	225.46	0.15	250	253.84	1.28



CONCLUSIONES

- Las redes neuronales son de hecho un esquema confiable y atractivo para un esquema ideal de localización de fallas en la línea de transmisión, especialmente en vista de la creciente complejidad de los sistemas modernos de transmisión de energía.
- Es muy esencial investigar y analizar las ventajas de una estructura de red neuronal particular y un algoritmo de aprendizaje antes de elegirlo para una aplicación porque debe haber una compensación entre las características de entrenamiento y los factores de rendimiento de cualquier red neuronal.
- Las redes neuronales de retro propagación son muy eficientes cuando se dispone de un conjunto de datos de entrenamiento lo suficientemente grande y, por lo tanto, las redes de retro propagación han sido elegido para los tres pasos en el proceso de localización de fallas, a saber, detección de fallas, clasificación y ubicación de fallas.



RECOMENDACIONES

- Como posible extensión de este trabajo, sería muy útil analizar todas las arquitecturas de redes neuronales posibles y proporcionar un análisis comparativo de cada una de las arquitecturas y sus características de rendimiento. Las posibles arquitecturas de redes neuronales que se pueden analizar además de las redes neuronales de propagación inversa son las redes neuronales de base radial (RBF) y las redes de máquinas de vectores de soporte (SVM).

BIBLIOGRAFÍA

- Alashter, M. A., Mrehel, O. G., y Shamekh, A. S. (2020). Design and evaluation a distance relay model based on artificial neural networks (ANN). *6th IEEE International Energy Conference, ENERGYCon 2020*, 685-690. Institute of Electrical and Electronics Engineers Inc. <https://doi.org/10.1109/ENERGYCon48941.2020.9236490>
- Alvarado, E. V. (2012). *Algoritmo neuro-difuso para la detección y clasificación de fallas en líneas de transmisión eléctrica del sistema ecuatoriano usando simulaciones y datos de registradores de fallas. (Tesis de maestría)* (Universidad de Cuenca). Universidad de Cuenca, Cuenca, Ecuador. Recuperado de <http://dspace.ucuenca.edu.ec/handle/123456789/2579?mode=full>
- Anderson, P. M. (1995). *Analysis of Faulted Power Systems*. London: Wiley-IEEE Press; Recuperado de https://www.amazon.com/Analysis-Faulted-Power-Systems-Anderson/dp/0780311450#detailBullets_feature_div
- Aurangzeb, M. (2001). Fault location using the high frequency travelling waves measured at a single location on a transmission line. *7th International Conference on Developments in Power Systems Protection (DPSP 2001)*, 2001, 403-406. IEE. <https://doi.org/10.1049/cp:20010185>
- Babayomi, O., Oluseyi, P., Ofodile, N. A., y Keku, G. (2017). Fault diagnosis in an extra-high voltage power line. *2017 IEEE PES PowerAfrica*, 311-316. IEEE. <https://doi.org/10.1109/PowerAfrica.2017.7991243>
- Bashier, E., y Tayeb, M. (2013). Faults Detection in Power Systems Using Artificial Neural Network. *American Journal of Engineering Research*.
- BlogSEAS. (2019). *El Relé: para qué es, para qué sirve y qué tipos existen*. Zaragoza: Seas Estudios Superiores Abiertos. Recuperado de <https://www.seas.es/blog/automatizacion/el-rele-para-que-es-para-que-sirve-y-que-tipos-existen/>
- Calderón, J. A., Moreno Cadavid, J., y Ovalle, D. A. (2008). Red neuronal para la clasificación de fallas en líneas de transmisión a partir de registros de osciloperturbografía. *DYNA (Colombia)*, 75(156), 99-107. Recuperado de <http://www.scielo.org.co/pdf/dyna/v75n156/a09v75n156.pdf>
- Calderón, O. M. (2004). Valoración económica del agua potable en la cuenca del río Endemedio Santa Cruz, Guanacaste, Costa Rica. *Recursos Naturales y Ambiente*,

(43).

- Chen, B. H., Wang, X. Z., Yang, S. H., y McGreavy, C. (1999). Application of wavelets and neural networks to diagnostic system development, 1, feature extraction. *Computers and Chemical Engineering*, 23(7), 899-906. [https://doi.org/10.1016/S0098-1354\(99\)00258-6](https://doi.org/10.1016/S0098-1354(99)00258-6)
- Cichocki, A., y Unbehauen, R. (1993). Neural networks for optimization and signal processing. *Choice Reviews Online*, 31(04), 31-2156-31-2156. <https://doi.org/10.5860/CHOICE.31-2156>
- Dalstein, T., y Kulicke, B. (1995). Neural network approach to fault classification for high speed protective relaying. *IEEE Transactions on Power Delivery*, 10(2), 1002-1011. <https://doi.org/10.1109/61.400828>
- Dalstein, T., y Kulicke, B. (1995). Neural Network Approach To Fault Classification For High Speed Protective Relaying. *IEEE Transactions on Power Delivery*, 10(2), 1002-1011. <https://doi.org/10.1109/61.400828>
- Das, R., y Novesel, D. (2015). Review Of Fault Location Techniques For Transmission And Subtransmission Lines. *researchgate.net*, (May 2000), 1-16. <https://doi.org/10.13140/2.1.2143.7767>
- Edmund O. Schweicher, I. (1993). A Review of Impedance-Based Fault Locating Experience. *Northwest Electric Light & Power Association Conference*, (October 1988).
- El-Sharkawi, M., y Neibur, D. (1996). *A tutorial course on artificial neural networks with applications to Power systems*. EEE Power Systems and Communications Infrastructures for the future. Recuperado de <https://pdfslide.net/documents/artificial-neural-networks-with-applications-to-power-systemsieee-doc.html?page=1>
- Eriksson, L., Saha, M. M., y Rockefeller, G. D. (1985). An accurate fault locator with compensation for apparent reactance in the fault resistance resulting from remote-end infeed. *IEEE Transactions on Power Apparatus and Systems*, PAS-104(2), 423-436. <https://doi.org/10.1109/TPAS.1985.319058>
- Grainger, J., y Stevenson, W. J. (1996). Analisis de Sistemas de Potencia. En *Cenace, Uanl*. London: Mc Graw Hill Interamericana Editores S.A. Recuperado de <https://catedras.facet.unt.edu.ar/sep/wp-content/uploads/sites/20/2020/03/Análisis-de-Sistemas-de-Potencia-Grainger-Stevenson.pdf>
- Haykin, S. (2005). *Neural Networks - A Comprehensive Foundation* (Second). India:

- Pearson Prentice Hall.
- Hernández, C. (2015). *Diagnóstico y detección de fallas empleando un método de sistemas inteligentes. (Tesis de maestría)*. Corporación Mexicana de Investigación en Materiales S.A. de C.V., Saltillo, México. Recuperado de [https://comimsa.repositorioinstitucional.mx/jspui/bitstream/1022/184/1/TESIS-MPICYT-HERNANDEZ.MORALES %282%29.pdf](https://comimsa.repositorioinstitucional.mx/jspui/bitstream/1022/184/1/TESIS-MPICYT-HERNANDEZ.MORALES%20%29.pdf)
- Howard, D., y Mark, B. (2004). Neural Network Toolbox Documentation. *Neural Network Tool*, 846.
- Huerta, E. (2014). *Localización de fallas en líneas de transmisión. (Tesis de maestría)*. Universidad Autónoma de Nuevo León, Nuevo León, México. Recuperado de <https://core.ac.uk/download/pdf/76596691.pdf>
- IEEE. (2014). IEEE Guide for Determining Fault Location on AC Transmission and Distribution Lines. En *Power and Energy Society* (Vol. 2014). Recuperado de <https://ieeexplore.ieee.org/document/7024095>
- Jamil, M., Sharma, S. K., y Singh, R. (2015). Fault detection and classification in electrical power transmission system using artificial neural network. *SpringerPlus*, 4(1), 334. <https://doi.org/10.1186/s40064-015-1080-x>
- Johns, A. T. (1993). Electrical Power System Protection. *Power Engineering Journal*, 7(6), 264. <https://doi.org/10.1049/pe:19930070>
- Kezunovic, M. (1997). A survey of neural net applications to protective relaying and fault analysis. *International Journal of Engineering Intelligent Systems for Electronics, Engineering and Communication*, 185-192.
- Kezunovic, M., Rikalo, I., y Sobajic, D. J. (1996). Real-time and off-line transmission line fault classification using neural networks. *International Journal of Engineering Intelligent Systems for Electrical Engineering and Communications*, 4(1), 57-63.
- Krishnanand, K. R., Dash, P. K., y Naeem, M. H. (2015). Detection, classification, and location of faults in power transmission lines. *International Journal of Electrical Power & Energy Systems*, 67, 76-86. <https://doi.org/10.1016/j.ijepes.2014.11.012>
- Kundur, P. (1994). *Power System Stability and Control*. London: Mc Graw Hill Interamericana Editores S.A.
- Leon, R., y Maldonado, J. L. (2018). *Clasificación de fallas en líneas de transmisión mediante la utilización de redes neuronales artificiales. (Tesis de grado)*. Universidad Politécnica Salesiana, Cuenca, Ecuador. Recuperado de <https://dspace.ups.edu.ec/bitstream/123456789/16161/1/UPS-CT007825.pdf>

- León, T. S. (2017). Diseño E Implementación De Un Método De Localización De Fallas De Alta Impedancia En Líneas De Transmisión De Energía Eléctrica Aéreas Basado En Redes Neuronales. (Tesis de maestría). *Journal of Chemical Information and Modeling*, 53(9), 185. Recuperado de <https://biblioteca.utb.edu.co/notas/tesis/0068194.pdf>
- Liquinchana, D. S. (2022). *Clasificación de fallas eléctricas aplicando redes neuronales artificiales a la protección de distancia de líneas de transmisión basada en el algoritmo de Levenberg-Marquardt*. (Tesis de grado). Universidad Politécnica Salesiana, Quito, Ecuador. Recuperado de <https://dspace.ups.edu.ec/bitstream/123456789/23323/1/UPS - TTS961.pdf>
- López, L. H. (2012). *Predicción y Optimización de Emisiones y Consumo Mediante Redes Neuronales en Motores Diesel*. Barcelona: Reverté.
- Padilla, W. (2016). *Sistema para la localización automática de fallas en líneas de transmisión*. (Tesis de maestría). Universidad Nacional de Colombia, Medellín, Colombia. Recuperado de <https://repositorio.unal.edu.co/bitstream/handle/unal/59469/73201202.2016.pdf?sequence=1&isAllowed=y>
- Ramesh, S., y Mohod, S. (2021). A survey on various machine learning techniques for detection. *International Journal of Creative Research Thoughts (IJCRT)*, 9(6), 843-849. Recuperado de <https://ijcrt.org/papers/IJCRT2106565.pdf>
- Rincon, L. F., y Vargas, D. (2018). *Sistema de detección y diagnóstico de fallas de un proceso térmico mediante inteligencia artificial*. (Tesis de grado). Universidad Distrital Francisco José de Caldas, Bogotá, Colombia. Recuperado de <https://repository.udistrital.edu.co/bitstream/handle/11349/15883/VargasChavarroDavidAlejandro2019.pdf?sequence=1&isAllowed=y>
- Saha, M. M., Das, R., Verho, P., y Novosel, D. (2002). Review of Fault Location Techniques for Distribution Systems. *IEEE Power Systems and Communications Infrastructures for the future*, (September), 1-6.
- Shaik, A. G., y Pulipaka, R. R. V. (2015). A new wavelet based fault detection, classification and location in transmission lines. *International Journal of Electrical Power & Energy Systems*, 64, 35-40. <https://doi.org/10.1016/J.IJEPES.2014.06.065>
- Takagi, T., Yamakoshi, Y., Yamaura, M., Kondow, R., y Matsushima, T. (1982). Development of a new type fault locator using the one-terminal voltage and current data. *IEEE Transactions on Power Apparatus and Systems, PAS-101*(8), 2892-2898.



<https://doi.org/10.1109/TPAS.1982.317615>

- Tang, Y., Wang, H. F., Aggarwal, R. K., y Johns, A. T. (2000). Fault indicators in transmission and distribution systems. *DRPT2000. International Conference on Electric Utility Deregulation and Restructuring and Power Technologies. Proceedings (Cat. No.00EX382)*, 238-243. IEEE.
<https://doi.org/10.1109/DRPT.2000.855670>
- Torabi, N., Sundaram, V. M., y Toliyat, H. A. (2017). On-line fault diagnosis of multi-phase drives using self-recurrent wavelet neural networks with adaptive learning rates. *2017 IEEE Applied Power Electronics Conference and Exposition (APEC)*, 570-577. IEEE. <https://doi.org/10.1109/APEC.2017.7930751>
- Yadav, A., y Swetapadma, A. (2015). A novel transmission line relaying scheme for fault detection and classification using wavelet transform and linear discriminant analysis. *Ain Shams Engineering Journal*, 6(1), 199-209.
<https://doi.org/10.1016/j.asej.2014.10.005>
- Zimmerman, K., y Costello, D. (2006). Impedance-Based Fault Location Experience. *2006 IEEE Rural Electric Power Conference*, 1-16. IEEE.
<https://doi.org/10.1109/REPCON.2006.1649060>



ANEXOS

Anexo 1. Modelo estudiado en SimPowerSystems

