

Método para la localización de fallas en sistemas de distribución de energía eléctrica basado en redes neuronales artificiales a partir del perfil de corriente y la medición de corriente de falla en cabecera de los alimentadores.

Eduardo Luis Rojas Medina

Trabajo de grado para optar al título de Ingeniero Electricista

Director

Jairo Blanco Solano

PhD en Ingeniería Eléctrica

Codirector

Daniel Camilo Galeano Suárez

Ingeniero Electricista

Universidad Industrial de Santander

Facultad de Ingenierías Físico Mecánicas

Escuela de Ingeniería Eléctrica, Electrónica y de Telecomunicaciones

Bucaramanga, Santander

2022

AGRADECIMIENTOS

A mis padres por ser los pilares de mi vida.

A mi novia por apoyarme en los momentos de dificultad.

A mis amigos por las experiencias vividas.

A Carlos, mi amigo, por darme una mano cuando la necesitaba.

A mi familia por siempre estar unida y presente.

A mi jefe Libardo, por siempre facilitarme el espacio para trabajar en este proyecto.

A mis directores por su guía y consejos.

A todos los profesores que me orientaron a lo largo de este camino.

Eduardo Luis Rojas Medina

CONTENIDO

RESUMEN	9
ABSTRACT	11
INTRODUCCIÓN.....	12
1. LOCALIZACIÓN DE FALLAS EN SISTEMAS DE DISTRIBUCIÓN DE ENERGÍA ELÉCTRICA	15
1.1. PLANTEAMIENTO DEL PROBLEMA	15
1.2. TIPOS DE FALLAS EN LOS SISTEMAS ELÉCTRICOS	18
1.3. REDES NEURONALES ARTIFICIALES	19
1.4. REVISIÓN LITERARIA	21
2. IMPLEMENTACIÓN DEL MÉTODO DE LOCALIZACIÓN DE FALLAS TIPO PARALELO	25
2.1. ALGORITMO PARA DETERMINAR EL TIPO DE FALLA:	25
2.2. ALGORITMO PARA DETERMINAR LA UBICACIÓN DE LA FALLA:	27
2.3. ALGORITMO PARA DETERMINAR EL RAMAL BAJO FALLA:.....	28
3. RESULTADOS	30
3.1. DETERMINACIÓN DEL TIPO DE FALLA:	31
3.2. DETERMINACIÓN DE LA UBICACIÓN DE LA FALLA:	32
3.3. DETERMINACIÓN DEL RAMAL BAJO FALLA	36
4. CONCLUSIONES	42
REFERENCIAS BIBLIOGRÁFICAS	43

APÉNDICES 46

LISTA DE FIGURAS

Figura 1 Problema de la múltiple estimación en sistemas de distribución.....	17
Figura 2 Fallas asimétricas. a) Fallas monofásicas a tierra. b) Fallas bifásicas. c) Fallas bifásicas a tierra.	18
Figura 3 Fallas simétricas. a) Fallas trifásicas. b) Fallas trifásicas a tierra.	19
Figura 4 Cantidad de artículos publicados cada año por tipo de medición.	23
Figura 5 Cantidad de artículos publicados cada año por tipo de inteligencia artificial.	24
Figura 6 División de cada rama del sistema.	27
Figura 7 Determinación del ramal bajo falla. Candidato 1, fase A.....	37
Figura 8 Determinación del ramal bajo falla. Candidato 2, fase A.....	38
Figura 9 Número de iteraciones contra error medio para la falla AN del sistema de 34 barras.	46
Figura 10 Número de iteraciones contra error medio para la falla BN del sistema de 34 barras.	46
Figura 11 Número de iteraciones contra error medio para la falla CN del sistema de 34 barras.	47
Figura 12 Número de iteraciones contra error medio para la falla AB del sistema de 34 barras.	48
Figura 13 Número de iteraciones contra error medio para la falla BC del sistema de 34 barras.	48
Figura 14 Número de iteraciones contra error medio para la falla CA del sistema de 34 barras.	49
Figura 15 Número de iteraciones contra error medio para la falla ABN del sistema de 34 barras.	49
Figura 16 Número de iteraciones contra error medio para la falla BCN del sistema de 34 barras.....	50
Figura 17 Número de iteraciones contra error medio para la falla CAN del sistema de 34 barras.	50
Figura 18 Número de iteraciones contra error medio para la falla ABC del sistema de 34 barras.....	51
Figura 19 Número de iteraciones contra error medio para la falla ABCN del sistema de 34 barras.	51
Figura 20 Número de iteraciones contra error medio para la falla AN del sistema de 123 barras.	52

Figura 21 Número de iteraciones contra error medio para la falla BN del sistema de 123 barras.	52
Figura 22 Número de iteraciones contra error medio para la falla CN del sistema de 123 barras.	53
Figura 23 Número de iteraciones contra error medio para la falla AB del sistema de 123 barras.	53
Figura 24 Número de iteraciones contra error medio para la falla BC del sistema de 123 barras.	54
Figura 25 Número de iteraciones contra error medio para la falla CA del sistema de 123 barras.	54
Figura 26 Número de iteraciones contra error medio para la falla ABN del sistema de 123 barras.	55
Figura 27 Número de iteraciones contra error medio para la falla BCN del sistema de 123 barras.	55
Figura 28 Número de iteraciones contra error medio para la falla CAN del sistema de 123 barras.	56
Figura 29 Número de iteraciones contra error medio para la falla ABC del sistema de 123 barras.	56
Figura 30 Número de iteraciones contra error medio para la falla ABCN del sistema de 123 barras.	57
Figura 31 Sistema de 34 barras a escala.	57
Figura 32 Sistema de 123 barras a escala.	57

LISTA DE TABLAS

Tabla 1 Cantidad de artículos publicados cada año por tipo de medición.	22
Tabla 2 Cantidad de artículos publicados cada año por tipo de inteligencia artificial.	23
Tabla 3 Número de eventos de falla para el sistema IEEE 34 barras.	30
Tabla 4 Número de eventos de falla para el sistema IEEE 123 barras.	31
Tabla 5 Porcentaje de acierto del algoritmo para determinar el tipo de falla para el sistema de 34 barras. 32	32
Tabla 6 Porcentaje de acierto del algoritmo para determinar el tipo de falla para el sistema de 123 barras.	32
Tabla 7 Métricas de desempeño del algoritmo para determinar la distancia de falla para el sistema de 34 barras.	34
Tabla 8 Cuartiles del error porcentual en distancia para el sistema de 34 barras.	34
Tabla 9 Métricas de desempeño del algoritmo para determinar la distancia de falla para el sistema de 123 barras.	35
Tabla 10 Cuartiles del error porcentual en distancia en metros para el sistema de 123 barras.	35
Tabla 11 Porcentaje de acierto del algoritmo para determinar el ramal bajo falla para el sistema de 34 barras.	39
Tabla 12 Cuartiles del error en distancia en metros cuando se acierta en el ramal para el sistema de 34 barras.	39
Tabla 13 Cuartiles del error en distancia en metros cuando no se acierta en el ramal para el sistema de 34 barras.	39
Tabla 14 Porcentaje de acierto del algoritmo para determinar el ramal bajo falla para el sistema de 123 barras.	40

Tabla 15 Cuartiles del error en distancia en metros cuando se acierta en el ramal para el sistema de 123 barras.	40
Tabla 16 Cuartiles del error en distancia en metros cuando no se acierta en el ramal para el sistema de 123 barras	40

RESUMEN

Título: Método para la localización de fallas en sistemas de distribución de energía eléctrica basado en redes neuronales artificiales a partir del perfil de corriente y la medición de corriente de falla en cabecera de los alimentadores.

Autor: Eduardo Luis Rojas Medina

Palabras clave: Localización de fallas, Sistemas de distribución, Redes neuronales artificiales, Perfiles de corriente.

Descripción:

En este trabajo de grado se presenta inicialmente una revisión literaria enfocada al problema de localización de fallas tipo paralelo en sistemas de distribución con miras en identificar métodos con desempeños significativos en la localización de falla en términos de distancia, a partir del uso de medidas de tensión y corriente en la cabecera principal del sistema de distribución. Se implementa un método de localización basado en redes neuronales artificiales para determinar la distancia desde la subestación hasta el punto de la falla. Con el fin de cubrir todo el espacio operativo de los sistemas IEEE-34 bus y IEEE-123 bus se simulan eventos de falla tipo paralelo a lo largo de cada ramal variando la resistencia de falla, para luego ingresar a una red neuronal que estima una posible distancia. Con el propósito de abordar el problema de la múltiple estimación del punto de falla, se utiliza el concepto de la corriente de falla neta en los ramales del sistema de distribución para estimar los cambios de esta corriente y seleccionar un grupo de candidatos como los ramales posibles bajo falla. Estos candidatos se clasifican mediante algoritmos de razonamiento para la selección final del ramal candidato bajo falla. El error porcentual en distancia para el

sistema IEEE-34 bus, en promedio para todos los tipos de falla es del 2% y acierta en el ramal bajo falla en el 94% de los eventos.

ABSTRACT

Title: Fault location method in electrical distribution systems based on artificial neural networks from current profile and fault current measuring on the beginning of the feeders.

Author: Eduardo Luis Rojas Medina

Key words: Fault location, Distribution system, Artificial neural networks, Current profile.

Description:

In this degree project, a literary review focused on the problem of locating shunt type faults in distribution systems is initially presented with the purpose of identifying methods with significant performance in locating faults in terms of distance, based on the use of voltage and current measurements at the main head of the distribution system. A fault location method based on artificial neural networks is implemented to determine the distance from the substation to the point of failure. To cover the entire operating space of the IEEE-34 bus and IEEE-123 bus systems, parallel fault events are simulated along each branch, varying the fault resistance, and then, entering a neural network that estimates a possible distance. To approach the problem of multiple fault point estimation, the concept of the net fault current in the branches of the distribution system is used to estimate the changes in this current and select a group of candidates as the possible branches under fault. These candidates are classified by reasoning algorithms for the final selection of the candidate branch under failure. The percentage error in distance for the IEEE-34 bus system, on average for all types of faults, is 2% and find the branch under fault in 94% of the events.

INTRODUCCIÓN

Cerca del 80% de las interrupciones en los sistemas de distribución son causadas por fallas (Md Shafiullah & Mohammad Ali Abido, 2017), las cuales impactan negativamente en los índices de confiabilidad de los sistemas de distribución. Es de importancia localizar y aislar estos eventos para la rápida restauración del servicio, favoreciendo las tareas de mantenimiento de equipos y en seguridad, así como en la reducción de pérdidas económicas (Souza et al., 2020). Adicionalmente, un elevado número de fallas de red conlleva a sanciones por el incumplimiento de los índices de confiabilidad como el SAIDI (system average interruption duration index), el cual mide la duración promedio de las interrupciones percibidas por un usuario conectado a un sistema de energía eléctrica (IEEE Guide for Electric Power Distribution Reliability Indices, 2012) y el SAIFI (system average interruption frequency index), que mide la cantidad de veces promedio que se presenta una interrupción para un usuario conectado a un sistema de energía eléctrica (IEEE Guide for Electric Power Distribution Reliability Indices, 2012). Varios métodos para la localización de fallas han sido propuestos en la literatura, pudiéndose clasificar en tres categorías: los basados en la impedancia, los de onda viajera y los basados en aprendizaje automático (Bahmanyar et al., 2017). En los métodos basados en la impedancia, la tensión y la corriente son registradas en la subestación, luego por medio de ecuaciones en función de la estructura del sistema, impedancias de las líneas, de la carga y de falla, se puede determinar la distancia a la falla (Lee et al., 2004). Debido a la configuración ramificada de los sistemas de distribución, estos métodos se enfrentan al problema de la múltiple estimación de los puntos posibles de falla. Las variaciones de carga y los cambios en la impedancia de falla también reducen el desempeño de este tipo de métodos (Zheng & Jia, 2011).

Los métodos de onda viajera requieren sistemas de monitoreo instalados en uno o los dos extremos de las líneas para registrar la reflexión de las ondas de tensión y corriente desde el punto de la falla hasta el lugar donde se instala el medidor (Kong et al., 2019). Esta estrategia se adapta muy bien para los sistemas de transmisión que no poseen tantos ramales (Sawai et al., 2020). Una primera desventaja es la alta sensibilidad de la propagación de la onda viajera ante conexiones eléctricas defectuosas en los elementos del sistema eléctrico y una segunda es el alto costo de los equipos de medición requeridos para el registro de la información requerida.

De los métodos basados en el aprendizaje automático, son usados comúnmente las redes neuronales artificiales (ANN), redes neuronales convolucionales (CNN), lógica difusa y las máquinas de soporte vectorial (SVM) (Haleem et al., 2018). Estos métodos dependen de la precisión en la recolección de datos de entrada y en la cantidad de datos para producir una salida confiable y en poco tiempo evitando el error humano. La etapa más importante es el entrenamiento en donde se simulan grandes paquetes de fallas o se toman muestras reales. Una vez que se completa el entrenamiento cubriendo toda la longitud de los sistemas con eventos de falla ya se puede predecir con alta exactitud la locación de las fallas.

Los localizadores de falla basados en ANN muestran mejores rendimientos que sus pares de aprendizaje automático, cuando se presentan variaciones en los parámetros del sistema y la resistencia de falla, además no requieren información de la configuración del sistema en dónde se va a implementar (Aslan & Yağan, 2017).

En este trabajo de grado se implementa y evalúa un método basado en redes neuronales propuesto en la literatura reciente, que permite ubicar la distancia de la falla a la subestación en un sistema de distribución de energía eléctrica. Se procesa la medición disponible en la cabecera de

los alimentadores, al momento de falla en un sistema de distribución, para luego determinar el tipo de falla mediante algoritmos de razonamiento y posteriormente se entrenará una red neuronal para que asocie la información de entrada con la distancia a la falla. En el entrenamiento se requiere que la red neuronal asimile gran cantidad de casos en distintos puntos de la red, que representen los diferentes tipos fallas en paralelo. Por último, se evalúa el desempeño del algoritmo en términos del error de la distancia a la falla.

1. LOCALIZACIÓN DE FALLAS EN SISTEMAS DE DISTRIBUCIÓN DE ENERGÍA ELÉCTRICA

1.1. PLANTEAMIENTO DEL PROBLEMA

Los sistemas eléctricos son susceptibles a alteraciones como fenómenos naturales y acciones del hombre. El proceso de distribución de energía eléctrica es especialmente vulnerable, porque se extiende sobre grandes áreas y por lo general cuenta con una baja implementación de sistemas de monitoreo y control.

Aunque la presencia de fallas de red sea inevitable, se requiere la oportuna restauración del servicio de energía eléctrica con miras en mitigar las afectaciones sobre el usuario final. Para ello se requiere de la determinación de los puntos bajo falla en la red eléctrica. De la variedad de métodos propuestos para tal fin, es frecuente el uso de los mismos registros de notificación por parte de los usuarios. Posteriormente se dispone de un equipo de búsqueda del punto de falla y la consecuente restauración del servicio, con el inconveniente principal que esta tarea puede tomar mucho tiempo.

Las estrategias para disminuir el tiempo de interrupción del servicio de energía son de interés para los operadores de red, con el fin de controlar los índices de calidad del servicio que se traducen en sanciones para las empresas (Bahmanyar et al., 2017).

La diversidad topológica y constructiva de los sistemas de distribución dificultan la ubicación de puntos de falla. Es así como se han desarrollado distintas estrategias, principalmente las basadas en cálculos de impedancia que se enfrentan al problema de múltiple estimación de los puntos de fallas. Los métodos basados en la impedancia la calculan desde el punto de medición (es decir, la cabeza del alimentador principal) y buscan en la red los puntos con la misma

impedancia que las posibles ubicaciones de fallas. En otras palabras, estos métodos dibujan un círculo centrado en el punto de medición con el radio de la impedancia vista y encuentran todas las intersecciones con secciones de línea de red como ubicaciones probables (Figura [1]). Por lo tanto, el problema radica en que, debido a la estructura ramificada en árbol de las redes de distribución, estos métodos de localización de falla dan como resultado múltiples posibles lugares de falla, que tienen la misma impedancia vista desde el punto de la medición (Myeon-Song et al., 2004). Por otro lado, están las estrategias basadas en la teoría de la reflexión de las ondas viajeras, con la desventaja que requieren la implementación de una infraestructura de medición avanzada. Por último, el uso de la inteligencia artificial en la localización de fallas se evidencia en un número importante de trabajos divulgados en la literatura científica, donde las redes neuronales y las máquinas de soporte vectorial se destacan por los desempeños que allí se reportan. Sus ventajas radican en la capacidad de capturar y establecer patrones en complejas relaciones de entrada/salida usando grandes conjuntos de datos. Sin embargo, considerando la ramificación en árbol y la medición la cabecera principal del alimentador, también surge el problema de la múltiple estimación, que es cuando existen múltiples posibles localizaciones de la falla para una misma distancia calculada. En la figura 1 se observa como la falla ocurre entre los nodos 8-9, pero la ramificación de la red hace que la distancia resultante de la estimación esté dentro de los nodos 7-8 y 3-5. Este inconveniente se soluciona usando un algoritmo para la estimación del ramal bajo falla que hace más precisa su localización exacta para una posterior acción del grupo de búsqueda o cuadrilla.

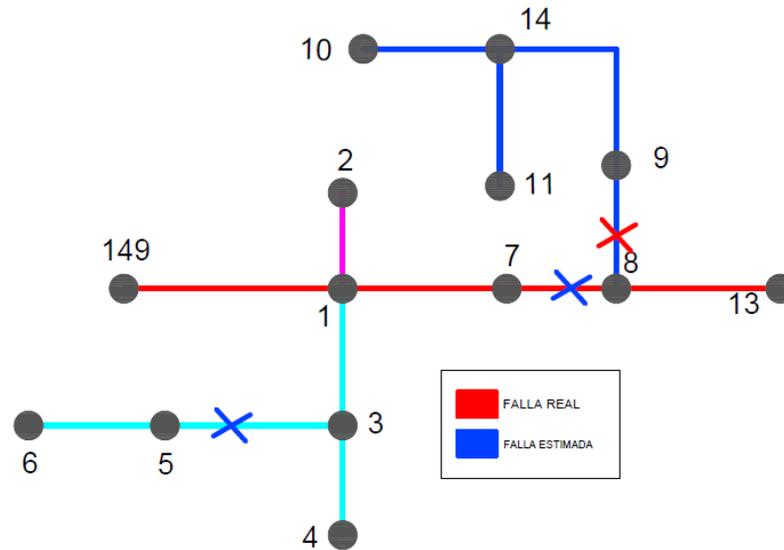


Figura 1 Problema de la múltiple estimación en sistemas de distribución.

Este trabajo de grado tiene como objetivo general: Implementar y evaluar el desempeño de un método basado en redes neuronales artificiales, propuesto en la literatura reciente, para estimar la distancia a la falla en un sistema de distribución de energía eléctrica, a partir de la medición de corriente de falla registrada en cabecera del alimentador y del perfil de corriente de falla en las líneas eléctricas.

Y como objetivos específicos:

- Construir la información de magnitudes eléctricas que se presentan ante diferentes tipos de fallas en un sistema de distribución de energía eléctrica, a partir de simulación.
- Implementar un método publicado en la literatura reciente basado en redes neuronales artificiales para localizar la distancia a la falla teniendo en cuenta la única medición en alimentador principal.
- Evaluar el desempeño del método implementado en términos del error de la localización de la distancia de la falla.

1.2. TIPOS DE FALLAS EN LOS SISTEMAS ELÉCTRICOS

Los sistemas eléctricos suelen experimentar fallas las cuales se pueden enmarcar en 2 grupos:

- Fallas en serie: son aquellas que surgen de la rotura del conductor de una fase y que no presentan contacto con tierra o con otras fases.
- Fallas en paralelo: son aquellas que surgen del contacto con tierra u otras fases.

En lo que respecta a líneas aéreas de los sistemas eléctricos, las fallas de mayor ocurrencia se corresponden con el segundo grupo, las cuales son comúnmente causadas por caídas de árboles, factores climáticos y factores de negligencia humana (Li Wang, 2016). Por este motivo, en este trabajo de grado serían consideradas las fallas en paralelo, dejando por fuera del alcance de este trabajo las fallas en serie o de alta impedancia.

Las fallas en paralelo se pueden clasificar según la cantidad de fases que intervienen. En este sentido decimos que existen fallas simétricas y asimétricas. Las asimétricas son las más frecuentes, donde el sistema opera de forma trifásica desbalanceada durante la falla. Las fallas asimétricas pueden ser de varios tipos. Como se muestra en la figura [2], dentro de las más comunes aparecen:

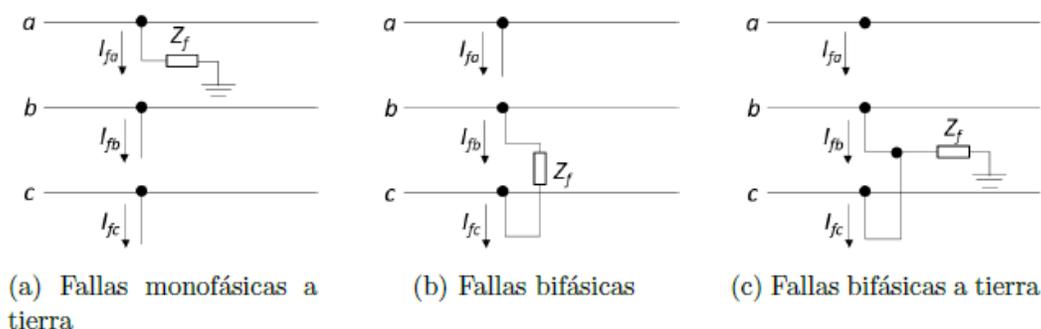


Figura 2 Fallas asimétricas. a) Fallas monofásicas a tierra. b) Fallas bifásicas. c) Fallas bifásicas a tierra.

En cambio, las fallas simétricas (Figura [3]) ocurren en las tres fases del sistema, por lo tanto, los desfases ya sean de corriente o tensión se mantienen en la falla.

De la literatura es posible determinar que cerca del 80% de las fallas son dentro de los sistemas de distribución (Bollen, 1993), y dentro de este conjunto las más frecuentes son las monofásicas a tierra, ocupando las mismas un 70% respecto del total (Li Wang, 2016).

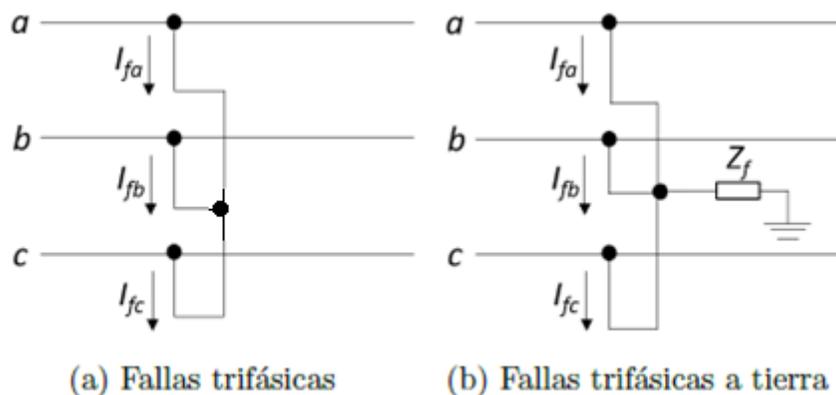


Figura 3 Fallas simétricas. a) Fallas trifásicas. b) Fallas trifásicas a tierra.

1.3. REDES NEURONALES ARTIFICIALES

Últimamente las redes neuronales artificiales han volcado las miradas de la comunidad investigativa como una tecnología para la resolución de problemas en muchas áreas de la ciencia ya que brinda las herramientas para modelarlos eficientemente. Son capaces de encontrar relaciones inductivas, la cual es una forma de razonamiento en que la verdad de las premisas apoya la conclusión, pero no la garantizan, por medio de algoritmos de aprendizaje basado en datos existentes. Pueden usarse para clasificar, optimizar, identificar, diagnosticar o predecir alimentándose de grandes grupos de datos históricos. Las ANN se inspiran en el comportamiento y función del cerebro humano, particularmente del sistema nervioso, que está compuesto por redes de neuronas biológicas que poseen bajas capacidades de procesamiento, sin embargo, toda su capacidad cognitiva se sustenta en la conectividad de éstas. En las redes neuronales biológicas, las células (neuronas) corresponden a los elementos de proceso anteriores. Las interconexiones se

realizan por medio de las ramas de salida (axones) que producen un número variable de conexiones (sinapsis) con otras neuronas (o quizás con otras partes como músculos y glándulas).

Por medio de un algoritmo de aprendizaje supervisado o no supervisado, las ANN ajustan su arquitectura y parámetros de manera de poder minimizar alguna función de error que indique el grado de ajuste a los datos y la capacidad de generalización de las ANN. El aprendizaje supervisado consiste en entrenar la red a partir de un conjunto de datos o patrones de entrenamiento compuestos por patrones de entrada y salida. El objetivo del algoritmo de aprendizaje es ajustar los pesos de la red de manera tal que la salida generada por la ANN sea lo más cercanamente posible a la verdadera salida dada una cierta entrada. Es decir, la red neuronal trata de encontrar un modelo al proceso desconocido que generó la salida y este aprendizaje se llama supervisado pues se conoce el patrón de salida el cual hace el papel de supervisor de la red. Por otra parte, en el aprendizaje no supervisado se presenta sólo un conjunto de patrones a la ANN, y el objetivo del algoritmo de aprendizaje es ajustar los pesos de la red de manera tal que la red encuentre alguna estructura o configuración presente en los datos.

Las ANN tienen se estructuran en función del número de niveles o capas, número de neuronas por nivel, patrones de conexión, y flujo de información. Son cuatro sus características, la primera es la arquitectura que consiste en la organización de las capas de entrada, ocultas y de salida y también del número de neuronas dispuesto para cada capa mencionada. La segunda, el mecanismo de aprendizaje que es el proceso por el cual una red neuronal modifica sus pesos en respuesta a una información de entrada. Se afirma que el proceso de aprendizaje ha terminado cuando el valor de los pesos permanece estable, ya que dichos valores varían en la mientras el algoritmo aprende. Los mecanismos de aprendizaje se dividen en aprendizaje en línea (ON LINE) y fuera de línea (OFF LINE). Cuando es OFF LINE se diferencia una fase de entrenamiento y una

fase de operación, existiendo un conjunto de datos para cada uno respectivamente. En cambio, cuando es ON LINE no se distinguen las fases de entrenamiento y de operación de tal forma que los pesos varían dinámicamente siempre que se presente una nueva información del sistema.

La tercera característica, es el tipo de asociación entre la entrada y la salida en las que existen dos formas primarias, la primera sería la denominada hetero-asociación, que se refiere al caso en que la red aprende parejas de datos de tal forma que cuando se le presenta una información de entrada A, deberá responder generando la correspondiente salida asociada B. La segunda se conoce como auto asociación, donde la red aprende ciertas informaciones de tal forma que cuando se le presenta una información de entrada realizará una autocorrelación, respondiendo con uno de los datos almacenados, el más parecido al de la entrada.

Por último, la cuarta característica, es la representación de la información de entrada y de salida. Se dividen en analógica, que son valores reales continuos, normalmente normalizados, y su valor absoluto será menor que la unidad. Cuando esto ocurre, las funciones de activación de las neuronas serán también continuas, de tipo lineal o sigmoideal. Y representación binaria, las cuales generan también unas respuestas a la salida de tipo binaria. En este caso, las funciones de activación de las neuronas serán del tipo escalón.

1.4. REVISIÓN LITERARIA

Para la selección del artículo a implementar se lleva a cabo 5 etapas:

Primero se realiza una búsqueda en la base de datos de revistas científicas y de la IEEE cuyo acceso es suministrado por la biblioteca de la Universidad Industrial de Santander, efectuando una búsqueda avanzada y empleando las palabras clave de “fault location”,

“distribution system” y “neural networks” de los cuales se encuentran 108 documentos de conferencias y 31 de revistas (Transactions) para tener un total en consideración de 139 documentos.

En una segunda fase, se filtran todos los documentos por las palabras clave, leyendo cada uno, ya que en la búsqueda anterior se encontraban artículos que no tenían que ver con dichas palabras.

La tercera etapa consta de la clasificación por tipo de medición frente a los años de publicación de cada documento (Figura [4]), separando los artículos en única medición (cabecera principal), generación distribuida (donde se toman registros en cabecera principal y en la barra donde se acopla la unidad de generación) y múltiple medición (se toman varios puntos de medición a lo largo del sistema) Tabla [1].

Años	Única medición	Generación distribuida	Múltiple medición
2021	0	1	4
2020	6	0	10
2019	7	1	10
2018	5	7	4
2017	1	3	1
2016	5	1	0
2015	1	2	3
2014	1	1	2
2013	2	2	2
2012	2	0	0
2011	4	6	1
2010	1	3	0
2009	1	4	1

Tabla 1 Cantidad de artículos publicados cada año por tipo de medición.

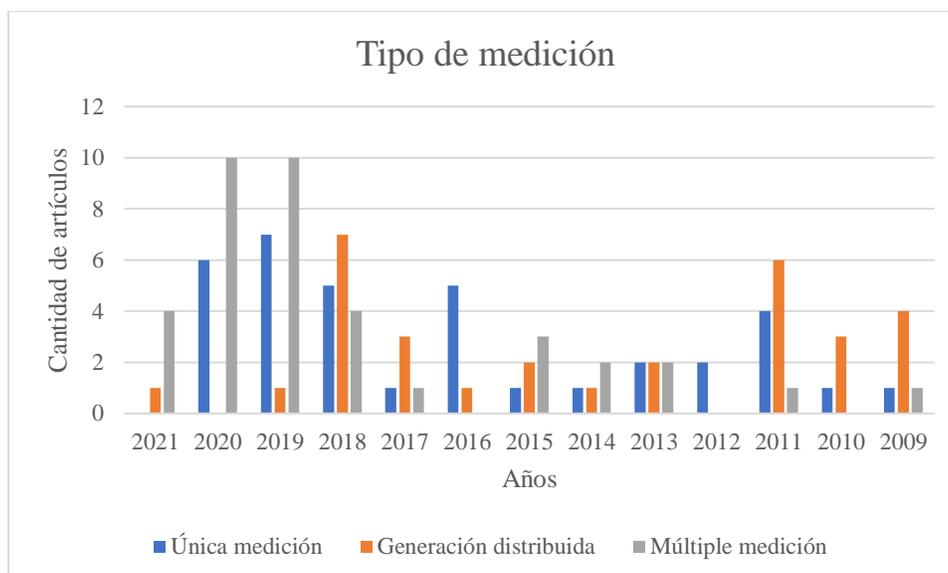


Figura 4 Cantidad de artículos publicados cada año por tipo de medición.

En la cuarta etapa, se realiza la segunda clasificación, donde se separa por tipo de aprendizaje automático frente a los años de publicación de cada documento (Figura [5]), donde predominan 3 de ellos: Redes Neuronales Artificiales (ANN), Redes Neuronales Convolucionales (CNN) y Máquinas de Soporte Vectorial (SVM). Se añaden a estos, otros tipos de aprendizaje automático que se van encontrando, como por ejemplo Kohonen Self Organized Maps (KSOM), Adaptive Neuro-Fuzzy Inference System (ANFIS), Sparse Auto-Encoders (SAE) y los híbridos Tabla [2].

Años	ANN	SVM	CNN	KSOM	ANFIS	SAE	Híbridos
2021	2	1	2	0	0	0	0
2020	13	0	7	1	1	0	0
2019	9	2	4	0	0	1	4
2018	13	1	3	0	0	0	2
2017	5	0	0	0	0	0	0
2016	6	0	0	0	0	0	0
2015	5	0	1	0	0	0	0
2014	4	0	0	0	0	0	0
2013	6	0	0	0	0	0	0
2012	2	0	0	0	0	0	0
2011	11	0	0	0	0	0	0
2010	3	0	0	0	0	0	0
2009	4	0	0	0	0	0	0

Tabla 2 Cantidad de artículos publicados cada año por tipo de inteligencia artificial.

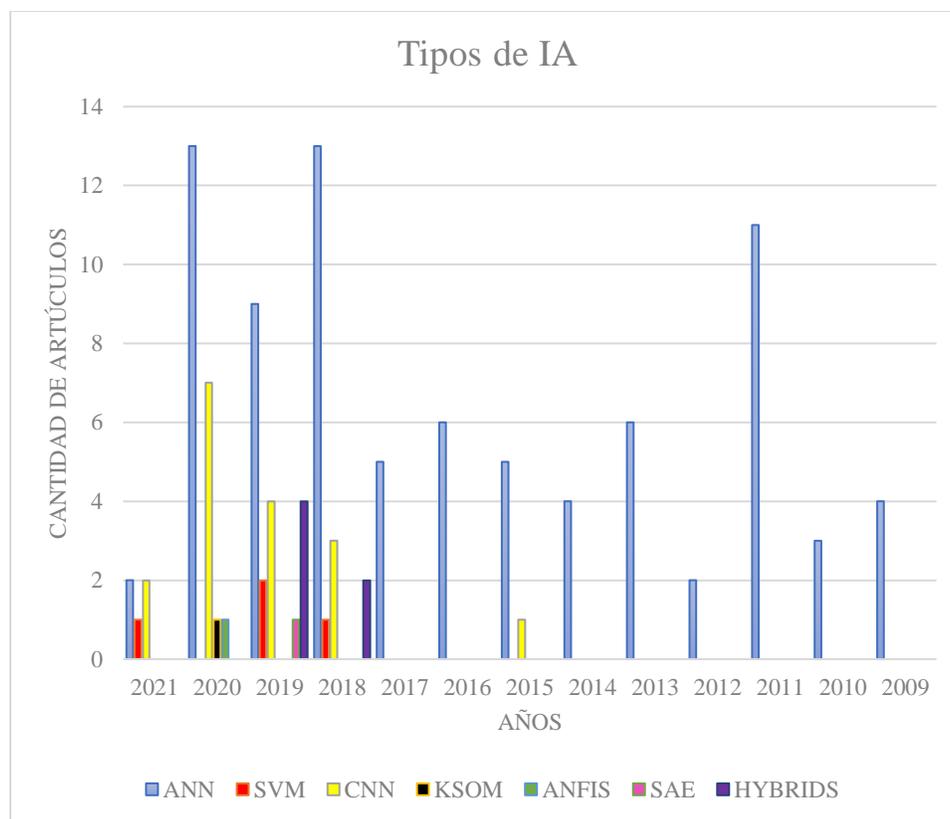


Figura 5 Cantidad de artículos publicados cada año por tipo de inteligencia artificial.

Por último, se procede a seleccionar el artículo. Acá se puede dividir en dos subetapas o filtrado de selección: La primera se desarrolla teniendo en cuenta el estudio realizado previamente. El estudio muestra una inclinación por los años 2020-2018 donde se concentran la mayoría de los documentos de investigación de interés para este problema en específico, por lo tanto, es un índice para empezar la selección. La segunda etapa es dependiendo de la claridad en la explicación de la metodología, si muestra un avance importante y si presenta una buena comparación de resultados con otros artículos.

2. IMPLEMENTACIÓN DE UN MÉTODO DE LOCALIZACIÓN DE FALLAS TIPO PARALELO

Se implementa el método presentado en el artículo “Fault location in radial distribution network based on fault current profile and the artificial neural network” publicado por “Scientific Bulletin of the Electrical Engineering Faculty (SCIENDO)” (Dashtdar & Dashtdar, 2020). En este artículo se propone un método basado en redes neuronales artificiales y variaciones lineales de la corriente de falla neta para determinar con precisión la ubicación de la falla. En este método, se generan candidatos para la ubicación de la falla para las redes que tienen una estructura de árbol. Estos candidatos se clasifican mediante algoritmos para determinar la ubicación de la falla más rápidamente. Este artículo evalúa sus resultados en el sistema IEEE 34-bus. La metodología de este estudio consta de tres algoritmos:

2.1. ALGORITMO PARA DETERMINAR EL TIPO DE FALLA

Se registra la corriente trifásica en la subestación (devanado secundario del transformador de potencia) en el momento de la falla. El algoritmo consta de 6 pasos:

- Paso 1: Para detectar una falla, las amplitudes de las corrientes trifásicas se comparan con la corriente nominal de la red (1). Se registra una falla si una de estas proporciones excede el valor nominal de corriente.

$$\frac{|I_k|}{|I_{nominal}|} > 1, k = a, b, c \quad (1)$$

- Paso 2: Calcular los componentes simétricos de la corriente mediante matriz de transformación de Fortescue. Esto se hace por medio de la ecuación (2).

$$\begin{bmatrix} I_0 \\ I_1 \\ I_2 \end{bmatrix} = \frac{1}{3} \begin{bmatrix} 1 & 1 & 1 \\ 1 & a & a^2 \\ 1 & a^2 & a \end{bmatrix} \begin{bmatrix} I_a \\ I_b \\ I_c \end{bmatrix}, \quad \begin{matrix} a=1 < 120^\circ \\ a^2=1 < -120^\circ \end{matrix} \quad (2)$$

- Paso 3: Para identificar el cortocircuito monofásico, se compara el valor de la tercera parte de la magnitud de corriente de cada fase con la magnitud de corriente de secuencia obtenida en el segundo paso, según la ecuación (3).

$$e_{mk} = \left| \frac{1}{3} |I_k| - |I_m| \right|, \begin{cases} k = a, b, c \\ m = 0, 1, 2 \end{cases} \quad (3)$$

Existe una falla monofásica si se cumple que:

$$e_{1k} \text{ and } e_{2k} < |I_1^0|, |I_2| < |I_k|, |I_0| > \varepsilon \quad (4)$$

Donde $|I_1^0|$ es la corriente de secuencia positiva en condición pre-falla y ε es un número pequeño debido a errores de desviación, que idealmente se puede establecer en cero.

- Paso 4: Para detectar la falla bifásica, se compara la corriente trifásica y los dos valores más grandes (en amplitud) se denominan ILL1 y ILL2 respectivamente. Se comparan con la suma de la magnitud de la corriente de la secuencia de fases, acorde a lo expresado en la ecuación (5).

$$E_x = |I_{LLx} - |I_0 + I_1 + I_2||, x = 1, 2 \quad (5)$$

Se registra una falla bifásica si se cumple que:

$$E_x < |I_1^0|, |I_0| < \varepsilon, |I_2| > \varepsilon \quad (6)$$

- Paso 5: Existe una falla bifásica a tierra si se cumple que:

$$||I_0| + |I_2|| < |I_1|, |I_0| > \varepsilon, |I_2| < |I_k| \text{ and } |I_j|, j \neq k = a, b, c \quad (7)$$

Para determinar las fases en cortocircuito, las dos fases con la mayor amplitud de corriente se designan como fases bajo falla.

- Paso 6: Para determinar el cortocircuito trifásico, si el valor de corriente de la secuencia cero y negativa es menor que ε , el tipo de falla será trifásica. Ecuación (8).

$$|I_0| \text{ and } |I_2| < \varepsilon \quad (8)$$

2.2. ALGORITMO PARA DETERMINAR LA UBICACIÓN DE LA FALLA

El proceso de identificación de la ubicación de fallas en el algoritmo propuesto se diseña en tres pasos:

Paso 1: Se construye una base de datos en función de la magnitud y el ángulo de la corriente y la magnitud de la impedancia de fase de cortocircuito. Posteriormente la información de la base de datos se utiliza como entrada para entrenar la ANN.

En función de los datos registrados en la base de datos y el tipo de falla, se determinan 11 ANN. El método de adquisición de datos se basa en que los circuitos ramales se dividen en 5 partes y para cada punto del 20% de la longitud de la línea se simula un cortocircuito. Se considera la resistencia a fallas de 0 a 50 ohms en 10 pasos con un paso de 5 ohms, Figura [6].



Figura 6 División de cada ramal del sistema.

Paso 2: Después de la detección del tipo de falla, se selecciona el ANN (dependiendo del tipo de falla). Se usan como descriptores la magnitud y los ángulos de corriente y la magnitud de impedancia de las fases cortocircuitadas previamente tratadas en el paso 1. Se configuran M neuronas en la capa de entrada, N en la capa oculta (M y N son números determinados a prueba y error en función de los mejores resultados) y 1 en la de salida. Se usan las funciones de activación de tipo tangente hiperbólico y lineal para la capa oculta y la de salida, respectivamente.

Paso 3: Al obtener la salida, el porcentaje de error para el algoritmo de localización de fallas se obtiene de la ecuación (9).

$$error(\%) = \frac{|dF - d_{act}|}{L} \times 100 \quad (9)$$

Donde dF es la distancia estimada por la ANN, d_{act} es la distancia real desde la subestación a la falla, L es la longitud del ramal donde ocurrió la falla, dP y dQ son las distancias desde la subestación hasta el punto inicial y final de ramal, respectivamente.

La ubicación de la falla obtenida por la ANN se compara con la distancia de las líneas de la red de distribución desde el inicio de la estación para identificar los ramales candidatos. Ecuación (10).

$$mL = \frac{dF - dP}{dQ - dP}, \quad 0 < mL < 1 \quad (10)$$

Donde dP es la distancia desde la subestación al primer nodo del tramo y dQ la distancia desde la subestación al nodo extremo del tramo.

2.3. ALGORITMO PARA DETERMINAR EL RAMAL BAJO FALLA

El algoritmo propuesto consta de tres partes para determinar el ramal bajo falla.

Primera parte. Creación de una base de datos para la determinación de la rama defectuosa: Se registra la corriente de fase cortocircuitada y la corriente antes de que ocurra la falla en la fase defectuosa. La diferencia entre estas corrientes indica la corriente de falla neta. Ecuación (11).

$$I_{Nkti} = I_{Fkti} - I_{Sk}, \quad t = 0, 5, 10, \dots, 50 \Omega \quad (11)$$

$$I_{Nkti} = I_{Nkti}^{(Re)} + iI_{Nkti}^{(Im)} \quad (12)$$

Segunda parte. Creación del perfil de cambios de corriente de falla neta: Según el método de ajuste de la curva de datos, se determina el perfil de corriente de falla neta para cada línea. Las

investigaciones muestran que una buena aproximación de los cambios de la parte imaginaria en función de la parte real de la corriente neta puede asumirse como lineal, que puede expresarse mediante la ecuación (13).

$$I_{Nkti}^{(Im)} = A^{PQ} \times I_{Nkti}^{(Re)} + B^{PQ} \quad (13)$$

Donde los coeficientes A y B se calculan de la ecuación (14).

$$\begin{bmatrix} A^{PQ} \\ B^{PQ} \end{bmatrix} = \begin{bmatrix} \sum_{i=1}^n 1 & \sum_{i=1}^n (I_{Nkti}^{(Re)}) \\ \sum_{i=1}^n (I_{Nkti}^{(Re)}) & \sum_{i=1}^n (I_{Nkti}^{(Re)})^2 \end{bmatrix} \times \begin{bmatrix} \sum_{i=1}^n (I_{Nkti}^{(Im)}) \\ \sum_{i=1}^n (I_{Nkti}^{(Re)} \times I_{Nkti}^{(Im)}) \end{bmatrix} \quad (14)$$

Tercera parte: Algoritmo de coincidencia de datos: El criterio para determinar la rama de cortocircuito más probable se considera en función del mínimo de las variaciones de datos medidos en relación con el perfil de corriente de falla neta de las líneas candidatas. Este cambio mínimo se puede obtener a partir de relaciones geométricas.

El valor de la distancia medida en relación con el perfil de corriente de falla neta se puede determinar a partir de las relaciones geométricas de la distancia puntual más corta de la línea. Esta distancia se puede obtener a partir de la ecuación (15).

$$d_k^{PQ} = \frac{|A^{PQ} \times I_{NSkt}^{(Re)} - I_{NSkt}^{(Im)} + B^{PQ}|}{\sqrt{(A^{PQ})^2 + 1}} \quad (15)$$

El criterio para determinar la rama defectuosa para los tipos de cortocircuito se obtiene de la ecuación (16).

$$e_{index} = \sum_{k \in \{a,b,c\}} |d_k^{PQ}|^2 \quad (16)$$

3. RESULTADOS

La implementación del método planteado se lleva a cabo en un computador con procesador Intel® Core™ CPU i3-1005G1 1.2GHz y memoria RAM de 8GB, usando principalmente 3 softwares con el fin de optimizar, simular, almacenar y procesar datos. Para la construcción de la información de magnitudes eléctricas, se obtendrán los datos de simulaciones de fallas aleatorias en los sistemas de distribución de prueba IEEE 34 y 123 nodos (Figuras [29] y [30]), mediante una interfaz Matlab-OpenDSS con la finalidad de entrenar redes neuronales en el software Python.

Con el fin de evaluar la metodología del artículo propuesto, se expone el primero de los casos del tipo de falla AN del sistema IEEE 34 barras en la subsección 4.3. A continuación, se exponen las evaluaciones de los tres algoritmos expuestos en el capítulo anterior.

Tipo de falla	Eventos de entrenamiento	Eventos de validación
AN	18468	15484
BN	16605	13896
CN	14256	10473
AB	14256	854
BC	14256	874
CA	14256	935
ABN	14256	3383
BCN	14256	3280
CAN	14256	3331
ABC	14256	874
ABCN	14256	874

Tabla 3 Número de eventos de falla para el sistema IEEE 34 barras.

Tipo de falla	Eventos de entrenamiento	Eventos de validación
AN	312	312
BN	256	256
CN	352	352
AB	256	256
BC	256	256
CA	256	256
ABN	256	256
BCN	256	256
CAN	256	256
ABC	256	256
ABCN	256	256

Tabla 4 Número de eventos de falla para el sistema IEEE 123 barras.

3.1. DETERMINACIÓN DEL TIPO DE FALLA

Para evaluar el desempeño del algoritmo para la determinación del tipo de falla, se usa la ecuación (17).

$$\% \text{ de acierto} = \frac{\# \text{ de eventos acertados}}{\# \text{ total de eventos}} \times 100 \quad (17)$$

Los resultados del algoritmo para determinar el tipo de falla para el sistema de 34 barras y el sistema de 123 barras se exponen en las tablas [5] y [6] respectivamente.

Se evidencia alta precisión en el desempeño del algoritmo para los dos sistemas de prueba y en la mayoría de los casos es del 100%.

Tipo de falla	% de acierto
AN	98,7817
BN	98,7957
CN	98,7866
AB	100
BC	97,6437
CA	100
ABN	100
BCN	100
CAN	100
ABC	100
ABCN	100

Tabla 5 Porcentaje de acierto del algoritmo para determinar el tipo de falla para el sistema de 34 barras.

Tipo de falla	% de acierto
AN	93,1841
BN	98,9146
CN	95,1484
AB	100
BC	99,9641
CA	100
ABN	100
BCN	100
CAN	100
ABC	98,04
ABCN	98,04

Tabla 6 Porcentaje de acierto del algoritmo para determinar el tipo de falla para el sistema de 123 barras.

3.2. DETERMINACIÓN DE LA UBICACIÓN DE LA FALLA:

En esta etapa se diseña una red neuronal por cada tipo de falla para determinar la ubicación a la misma. Cada red tiene una arquitectura diferente dependiendo de los datos. Donde se modifica la cantidad de neuronas en la capa de entrada, como también en la capa oculta. El problema por ser de regresión tiene sólo una neurona en la capa de salida.

Los desempeños de cada red se evalúan con las métricas para regresión: Variance Score y Regressor Score de la librería scikit-learn; Mean Squared Error (MSE) para la etapa de

entrenamiento y prueba, mientras que el error en distancia se mide por medio de la ecuación (9), siendo \hat{y} la predicción de la ANN, y la distancia real a la que está la falla y Var la desviación estándar al cuadrado. La métrica variance score es calculada en la ecuación (18).

$$variance\ score(y, \hat{y}) = 1 - \frac{Var\{y - \hat{y}\}}{Var\{y\}} \quad (18)$$

El error medio cuadrático (MSE) es una métrica de riesgo correspondiente al valor esperado del error o pérdida cuadrática (cuadrática). Es calculado con la ecuación (19).

$$MSE(y, \hat{y}) = \frac{1}{n_{samples}} \sum_{i=1}^{n_{samples}} (y_i - \hat{y}_i)^2 \quad (19)$$

La métrica Regressor_score_R2 representa la proporción de varianza (de y) que ha sido explicada por las variables independientes en el modelo. Proporciona una indicación de calidad de ajuste y , por lo tanto, una medida de qué tan bien es probable que el modelo prediga las muestras invisibles, a través de la proporción de varianza explicada. Es calculado como se muestra en la ecuación (19).

$$R^2(y, \hat{y}) = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad , \quad \bar{y} = \frac{1}{n} \sum_{i=1}^n y_i \quad \sum_{i=1}^n (y_i - \hat{y}_i)^2 = \sum_{i=1}^n \epsilon_i^2 \quad (20)$$

Para las métricas de Score los resultados varían entre 0 y 1, donde 1 es el mejor valor posible. En cambio, para las de MSE, entre más se acerque a 0 es mejor es su desempeño. Los resultados se ven enmarcados en las tablas [7] y [9]. El error de la predicción con respecto a los datos de prueba se puede interpretar mejor con el uso de percentiles, como se muestra en las tablas [8] y [10]. En el capítulo de anexos, en las figuras [9] hasta la [30] se muestra el número de iteraciones necesarias de cada ANN por tipo de falla para que el error medio cuadrático converja a un valor aceptable.

Tipo de falla	MSE entrenamiento	MSE prueba	Regressor score	Variance score	Arquitectura (entrada, c. oculta)
AN	0,00037	0,00071	0,9865	0,9935	(128, 64)
BN	0,00023	0,01156	0,7927	0,8043	(256, 128)
CN	0,00020	0,00984	0,8286	0,8291	(256, 128)
AB	0,00020	0,00643	0,8931	0,8994	(256, 128)
BC	0,00012	0,01012	0,8366	0,87031	(512, 256)
CA	0,00020	0,02749	0,5779	0,6066	(512, 256)
ABN	0,00031	0,00591	0,8967	0,9008	(1024, 512)
BCN	0,00024	0,01180	0,7957	0,8845	(512, 256)
CAN	0,00012	0,00395	0,9293	0,9539	(512, 256)
ABC	0,00093	0,04575	0,8437	0,7367	(1024, 512)
ABCN	0,00093	0,04575	0,8437	0,7367	(1024, 512)

Tabla 7 Métricas de desempeño del algoritmo para determinar la distancia de falla para el sistema de 34 barras.

Tipo de falla	Cuartil 1	Cuartil 2	Cuartil 3	Mínimo error porcentual	Máximo error porcentual
AN	1,3208	2,3102	3,1849	0,0101	17,1862
BN	3,0430	4,2227	5,2276	0,0298	19,6486
CN	0,6714	1,1495	1,6474	0,0022	15,3549
AB	1,7653	3,4393	3,9921	0,0018	18,9536
BC	4,7933	6,5766	7,6609	0,0133	21,6434
CA	3,5420	8,1211	9,9237	0,5447	20,0576
ABN	1,5932	2,1665	2,8163	0,0523	16,3926
BCN	4,4879	9,1188	11,0823	0,2506	22,3970
CAN	2,4231	3,7672	4,6917	0,0121	18,4592
ABC	3,4113	5,9722	19,6959	2,8580	30,8124
ABCN	3,4113	5,9722	19,6959	2,4827	30,8063

Tabla 8 Cuartiles del error porcentual en distancia para el sistema de 34 barras.

Tipo de falla	MSE entrenamiento	MSE prueba	Regressor score	Variance score	Arquitectura (entrada, c. oculta)
AN	0,0019	0,1783	-1,9383	0,8118	(64, 32)
BN	0,0041	0,0999	-0,1389	0,1009	(128, 64)
CN	0,0012	0,3322	-4,8370	0,4869	(1024, 512)
AB	0,0007	0,1115	-0,9976	0,8782	(512, 256)
BC	0,0006	0,1407	-1,5217	0,8408	(512, 256)
CA	0,0009	0,1134	-1,0329	0,8650	(512, 256)
ABN	0,0040	0,2210	-5,2428	0,2136	(512, 256, 128)
BCN	0,0024	0,4181	-6,4893	0,3391	(512, 256, 128)
CAN	0,0008	0,2483	-3,4488	0,6691	(512, 256)
ABC	0,0017	0,0448	0,5965	0,6336	(512, 256)
ABCN	0,0023	0,0217	0,6099	0,6453	(128, 64)

Tabla 9 Métricas de desempeño del algoritmo para determinar la distancia de falla para el sistema de 123 barras.

Tipo de falla	Cuartil 1	Cuartil 2	Cuartil 3	Mínimo error porcentual	Máximo error porcentual
AN	33,1529	41,0971	48,7862	15,411	62,336
BN	20,6852	27,9298	34,2865	3,2226	71,2593
CN	46,0410	58,3426	66,5044	3,4115	72,2206
AB	28,3214	33,7222	38,0898	1,9652	46,2359
BC	29,9198	37,6182	42,9184	8,1353	40,6403
CA	26,7584	33,0890	39,0630	0,7463	45,3805
ABN	29,8601	44,1554	56,3730	3,7345	99,3904
BCN	49,5229	61,8459	76,4012	6,1844	99,9563
CAN	38,6285	49,4490	57,8810	9,4215	65,7311
ABC	7,5032	12,8536	23,7204	0,3207	29,2338
ABCN	3,1011	7,2282	15,4904	0,0535	27,8382

Tabla 10 Cuartiles del error porcentual en distancia en metros para el sistema de 123 barras.

El error porcentual en distancia es calculado como el valor absoluto de la diferencia entre la distancia estimada y la distancia real de las fallas dividido entre la distancia máxima del sistema. Los cuartiles son medidas estadísticas de posición que tienen la propiedad de dividir la serie estadística en cuatro grupos de números iguales de términos. El primer cuartil representa que el 25% de las predicciones tiene un error porcentual en distancia menor al valor mostrado. El segundo cuartil o mediana evidencia que el 50% de las predicciones tienen un

error porcentual menor al mostrado. Por último, el tercer cuartil presenta que el 75% de las predicciones tienen un error porcentual menor al mostrado en las tablas [6] y [8].

La implementación en el sistema de 34 barras presentó mejores resultados que en el sistema de 123 barras donde el mínimo error en distancia fue del 0.9% y sus predicciones fueron bastante acertadas. Los resultados evidencian que para que converja a una estimación de distancia de falla en la que no se obtuvieran salidas negativas en el sistema de 123 barras tuvo que emplearse una capa oculta adicional, contrario a lo que dicta el artículo tomado como referencia, que indica que sólo debe emplearse una capa intermedia. Aunque converge a un resultado aceptable en errores, la calidad de sus predicciones no resulta satisfactoria.

Esto puede explicarse, ya que el sistema 123 barras al ser un sistema urbano con muchas ramificaciones a unas distancias muy cortas, presenta similitud al momento de registrar los datos de tensión y corriente medidos desde la subestación, lo que causa que la red neuronal tenga inconvenientes al entregar una estimación acertada.

3.3. DETERMINACIÓN DEL RAMAL BAJO FALLA

Se simula una falla AN a 53070 metros, y se toman como posibles candidatos los tramos 888-890, 832-858 y 858-864. Por medio de la ecuación (10) se evalúa si es válida la elección del candidato.

$$mL_1 = \frac{53070 - 52712}{55931 - 52712} = 0,11$$

$$mL_2 = \frac{53070 - 52709}{54206 - 52709} = 0,24$$

$$mL_3 = \frac{53070 - 54206}{54699 - 54206} = -2,30$$

Se descarta mL_3 y se toman como candidatos mL_1 y mL_2 teniendo en cuenta la condición expuesta en la ecuación (10).

Se procede a calcular la corriente neta para cada candidato, por medio de la ecuación (11) y se separa en parte real e imaginaria como muestra la ecuación (12).

La creación del perfil de corriente de falla neta se hace por cada fase (cada fase se analiza por separado), como se muestra en las figuras [7], [8].

Luego se procede a calcular la distancia geométrica puntual medida desde el perfil de corriente (recta azul de las figuras 7 y 8) hasta el punto de falla por cada candidato, como dicta la ecuación (15).

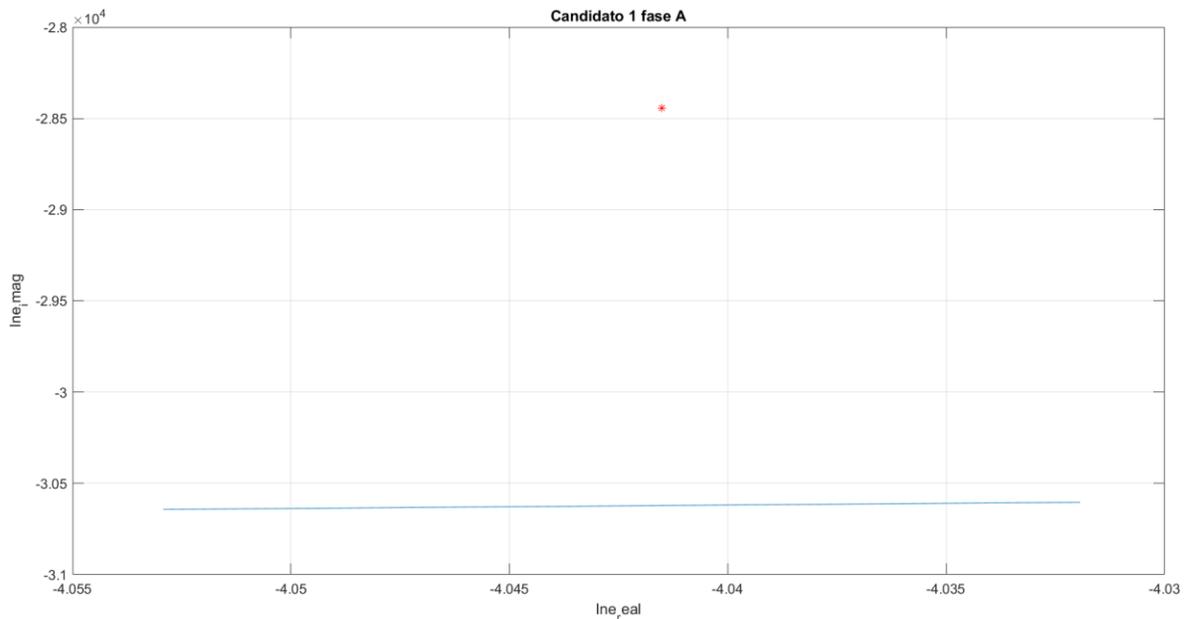


Figura 7 Determinación del ramal bajo falla. Candidato 1, fase A.

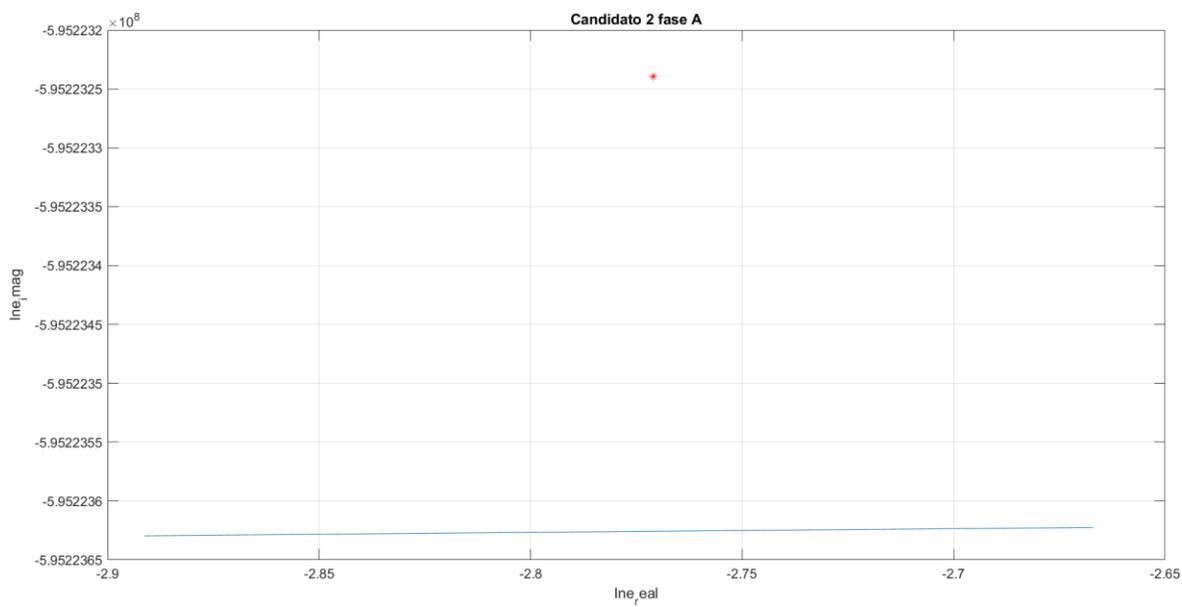


Figura 8 Determinación del ramal bajo falla. Candidato 2, fase A.

El criterio para la selección del ramal candidato lo sugiere la ecuación (16); el número “e” que tenga menor magnitud indica que está más cerca del punto de falla por lo tanto se determina el ramal como el verdadero.

Para evaluar el desempeño del algoritmo para la determinación del ramal bajo falla, se usa la ecuación (17).

Los resultados del porcentaje de acierto del algoritmo para determinar el ramal bajo falla para el sistema de 34 barras y el sistema de 123 barras se exponen en las tablas [11] y [14], respectivamente.

Tipo de falla	% de acierto
AN	94,1786
BN	91,1048
CN	94,4657
AB	95,8549
BC	95,4315
CA	94,7115
ABN	93,4194
BCN	93,0567
CAN	93,7585
ABC	92,0455
ABCN	95,4545

Tabla 11 Porcentaje de acierto del algoritmo para determinar el ramal bajo falla para el sistema de 34 barras.

Tipo de falla	Cuartil 1	Cuartil 2	Cuartil 3	Mínimo	Máximo
AN	529,6	954,4	1544,5	5,0607	9318
BN	1934,6	2470,9	2734,2	2,7111	7461,13
CN	111,5	422	1323,2	0,1345	5557,72
AB	1062,8	2201,6	2372,7	33	5391,4
BC	1123,2	1721,6	2315,1	140,44	4800
CA	2669,6	5363,2	6449,8	1,1155	8491,6
ABN	1220,6	2054,3	2500,4	5,2711	6235,3
BCN	3235,5	5769,1	7055,1	11,5157	10554,4
CAN	1596,4	2139,6	2979,5	22,4198	5799
ABC	642,6	988	1062,1	51,8303	4889,2
ABCN	642,6	788	962,1	51,8303	3985,6

Tabla 12 Cuartiles del error en distancia en metros cuando se acierta en el ramal para el sistema de 34 barras.

Tipo de falla	Cuartil 1	Cuartil 2	Cuartil 3	Mínimo	Máximo
AN	3200	3200	18130	3200	18130
BN	18130	18130	18130	3200,4	18130
CN	3200	3200	18130	3200,4	18130
AB	3200	3200	10665	3200,4	18130
BC	3200,4	3200,4	3200,4	3200,4	18130
CA	3200,4	3200,4	3200,4	3200,4	18130
ABN	3200	3200	14397	3200,4	18130
BCN	3200	3200	14397	1572,8	18130
CAN	3200,4	3200,4	3200,4	3200,4	18130
ABC	3200	3200	18130	3200,4	18130
ABCN	3200	18130	18130	3200,4	18130

Tabla 13 Cuartiles del error en distancia en metros cuando no se acierta en el ramal para el sistema de 34 barras.

Tipo de falla	% de acierto
AN	1,2821
BN	0,7813
CN	1,1364
AB	1,5625
BC	1,5625
CA	1,5625
ABN	1,9531
BCN	1,5625
CAN	1,5625
ABC	7,4219
ABCN	14,0625

Tabla 14 Porcentaje de acierto del algoritmo para determinar el ramal bajo falla para el sistema de 123 barras.

Tipo de falla	Cuartil 1	Cuartil 2	Cuartil 3
AN	433,6247	648,2576	910,0995
BN	32,6107	42,6029	52,5951
CN	278,8827	314,3141	466,1901
AB	47,3413	76,6827	118,6913
BC	211,0401	262,4711	296,2941
CA	209,7586	244,4411	254,5408
ABN	11,7974	46,6161	88,2666
BCN	254,3416	305,9751	369,2199
CAN	258,3760	324,8964	411,5748
ABC	12,3470	23,8808	50,7852
ABCN	11,9809	24,3164	41,9131

Tabla 15 Cuartiles del error en distancia en metros cuando se acierta en el ramal para el sistema de 123 barras.

Tipo de falla	Cuartil 1	Cuartil 2	Cuartil 3
AN	1400	2022,1	2342,9
BN	649,4	902,6	1089,6
CN	1531,5	2179,2	2542,2
AB	1034,4	1257,4	1410,7
BC	1131,5	1400	1580,6
CA	1034,4	1214,2	1409,8
ABN	1200	1634,4	2068,6
BCN	1434,4	2000	2409,8
CAN	1417,2	1834,4	2142,2
ABC	275,7300	449,6086	742,2814
ABCN	125,7705	306,6471	549,2929

Tabla 16 Cuartiles del error en distancia en metros cuando no se acierta en el ramal para el sistema de 123 barras

En las tablas [12], [13] y [15], [16] se muestran los cuartiles con las distancias de diferencia entre la distancia estimada por la red neuronal y la distancia real a la que ocurrió la falla en los casos en los que acierta al ramal bajo falla y en los que no es capaz de acertar.

En esta etapa es importante una buena predicción para garantizar excelentes resultados ya que una ligera variación en la distancia de salida en la red neuronal puede ser suficiente para que el algoritmo dicte un ramal vecino y el algoritmo que evalúa el acierto del ramal bajo falla, no lo tome como válido.

4. CONCLUSIONES

Se implementa y se evalúa el desempeño de un método de localización de falla con medición única en la subestación basado en redes neuronales. Su implementación presenta una solución eficaz y rápida con potencial aplicación práctica en el sistema de distribución colombiano extrayendo los parámetros del sistema SCADA de cualquier subestación. Este método es capaz de identificar el tipo de falla con alta precisión.

El desempeño del método de localización de falla para el sistema de 34 barras es satisfactorio incluso ante variaciones en la resistencia de falla, ya que la red neuronal fue entrenada con muestras de alta y baja resistencia de falla a lo largo de sus ramales. Este sistema, presenta resultados satisfactorios del orden de 94% de eficacia en la localización de fallas. La efectividad del método depende en gran parte de la etapa de validación para establecer predicciones con precisión ya que el algoritmo de selección del ramal afectado depende enteramente de esto.

El sistema de prueba 123 barras al ser un sistema con muchos ramales y con distancias cortas presenta similitud en el registro de tensión y corriente medidos desde el alimentador principal, es decir, los nodos vecinos pueden tener datos de falla muy parecidos lo que dificulta la capacidad de estimación acertada de la red neuronal.

Con el gran avance en la tecnología, cada vez se hace más económica la implementación de más medidores a lo largo del sistema eléctrico de distribución por lo que la investigación muestra una alta tendencia de los últimos 3 años hacia la localización de fallas usando múltiple medición.

REFERENCIAS BIBLIOGRÁFICAS

- A. M. I. Haleem, M. Sharma, K. S. Sajan and K. N. D. Babu, "A Comparative Review of Fault Location/Identification Methods in Distribution Networks," 2018 1st International Conference on Advanced Research in Engineering Sciences (ARES), 2018, pp. 1-6, doi: 10.1109/ARESX.2018.8723300.
- A. T. Jahromi, P. Wolfs and S. Islam, "A travelling wave detector based fault location device and data recorder for medium voltage distribution systems," 2016 Australasian Universities Power Engineering Conference (AUPEC), 2016, pp. 1-5, doi: 10.1109/AUPEC.2016.7749307.
- Aslan, Y. & Yağın, Yunus. (2017). Artificial neural-network-based fault location for power distribution lines using the frequency spectra of fault data. *Electrical Engineering*. 99. DOI: 10.1007/s00202-016-0428-8.
- Bahmanyar, Alireza & Jamali, Sadegh & Estebarsari, Abouzar & Bompard, Ettore. (2017). A comparison framework for distribution system outage and fault location methods. *Electric Power Systems Research*. 145. 19- 34. DOI:10.1016/j.epsr.2016.12.018.
- B. Kong, X. Liu, B. Pu, J. Feng, Z. Ying and S. Liu, "Modeling and Simulation of Fault Location with Traveling Wave for 35kV Distribution Networks," 2019 IEEE 3rd Conference on Energy Internet and Energy System Integration (EI2), 2019, pp. 2617-2620, Doi: 10.1109/EI247390.2019.9061740.

Dashtdar, Majid & Dashtdar, Masoud. (2020). Fault Location in Radial Distribution Network Based on Fault Current Profile and the Artificial Neural Network. *The Scientific Bulletin of Electrical Engineering Faculty*. 20. 14-21. DOI:10.2478/sbeef-2020-0103.

J. U. Núñez de Nunes and A. S. Bretas, "Extended impedance-based fault location formulation for active distribution systems," 2016 IEEE Power and Energy Society General Meeting (PESGM), 2016, pp. 1-5, doi: 10.1109/PESGM.2016.7741433.

K. Sun, Q. Chen, Z. Gao, D. Liu and G. Zhang, "Generalized impedance-based fault distance calculation method for power distribution systems," 2014 IEEE PES Asia-Pacific Power and Energy Engineering Conference (APPEEC), 2014, pp. 1-4, doi: 10.1109/APPEEC.2014.7066102.

Lee, Seung & Choi, Myeon & Kang, Sang-Hee & Jin, Bo-Gun & Lee, Duck-Su & Ahn, Bok-Shin & Yoon, Nam-Seon & Kim, Ho-Yong & Wee, Sang-Bong. (2004). An Intelligent and Efficient Fault Location and Diagnosis Scheme for Radial Distribution Systems. *Power Delivery, IEEE Transactions on*. 19. 524 - 532. 10.1109/TPWRD.2003.820431. "IEEE Guide for Electric Power Distribution Reliability Indices - Redline," in *IEEE Std 1366-2012 (Revision of IEEE Std 1366-2003) - Redline*, vol., no., pp.1-92, 31 May 2012.

Li Wang. The fault causes of overhead lines in distribution network. En *MATEC Web of Conferences*, tomo 61, pag. 02017. EDP Sciences, 2016.

Math HJ Bollen. Literature search for reliability data of components in electric distribution networks. Eindhoven University of Technology, Faculty of Electrical Engineering, 1993.

Md Shafiullah & Mohammad Ali Abido (2017). A Review on Distribution Grid Fault Location Techniques, *Electric Power Components and Systems*, 45:8, 807-824, DOI:10.1080/15325008.2017.1310772.

Myeon-Song Choi, Seung-Jae Lee, Duck-Su Lee and Bo-Gun Jin, "A new fault location algorithm using direct circuit analysis for distribution systems," in *IEEE Transactions on Power Delivery*, vol. 19, no. 1, pp. 35-41, Jan. 2004, doi: 10.1109/TPWRD.2003.820433.

Souza, Fabrício & Castoldi, Marcelo & Goedtel, Alessandro & Silva, Murilo. (2020). A cascade perceptron and Kohonen network approach to fault location in rural distribution feeders. *Applied Soft Computing*. 96. 106627. 10.1016/j.asoc.2020.106627.

S. Sawai, R. N. Gore and O. Naidu, "Novel Traveling Wave Phase Component-based Fault Location of transmission lines," 2020 IEEE International Conference on Power Electronics, Drives and Energy Systems (PEDES), 2020, pp. 1-5, doi: 10.1109/PEDES49360.2020.9379861.

T. Zheng & H. Jia, "Application of Multi-Agent and impedance-based algorithm for fault location in power distribution systems with DG," 2011 International Conference on Advanced Power System Automation and Protection, 2011, pp. 1044-1049, doi: 10.1109/APAP.2011.6180703.

APÉNDICES

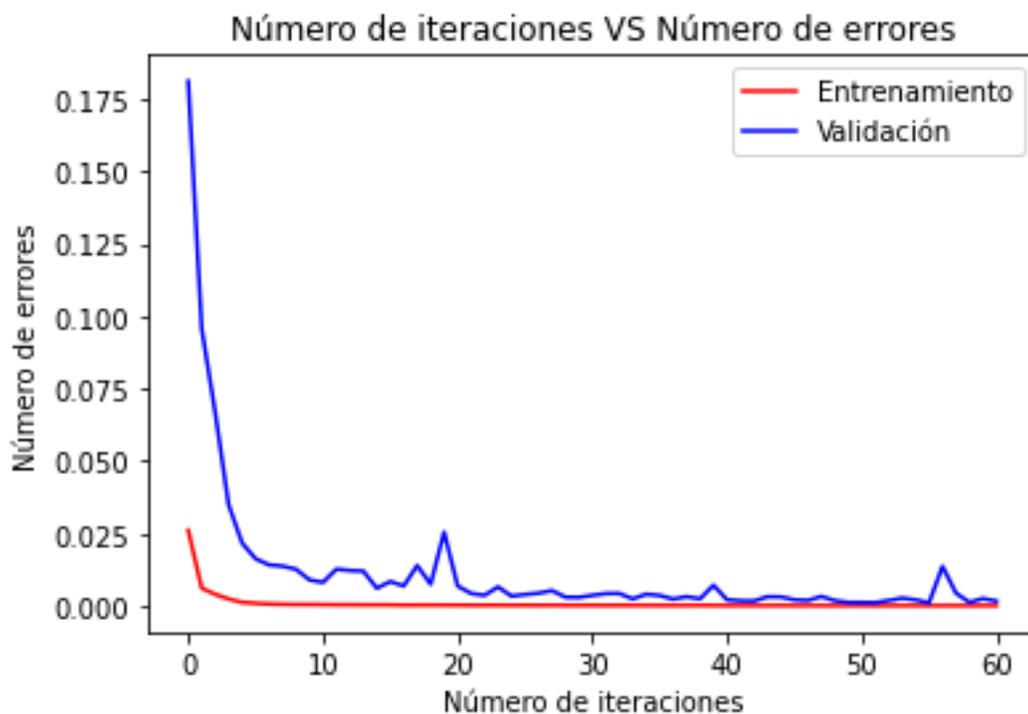


Figura 9 Número de iteraciones contra error medio para la falla AN del sistema de 34 barras.

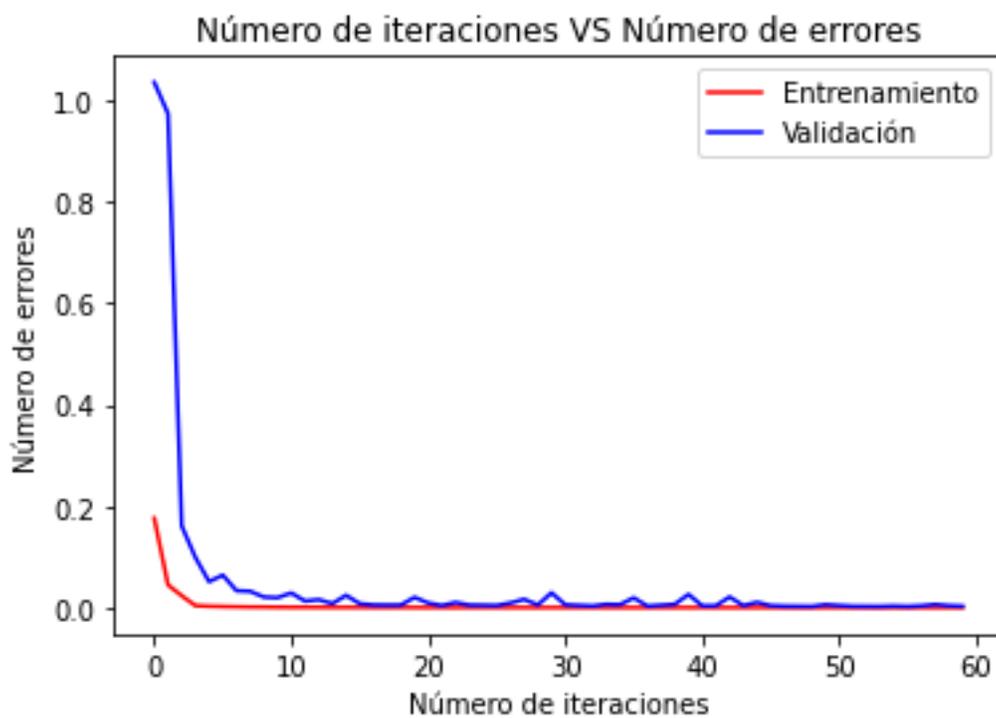


Figura 10 Número de iteraciones contra error medio para la falla BN del sistema de 34 barras.

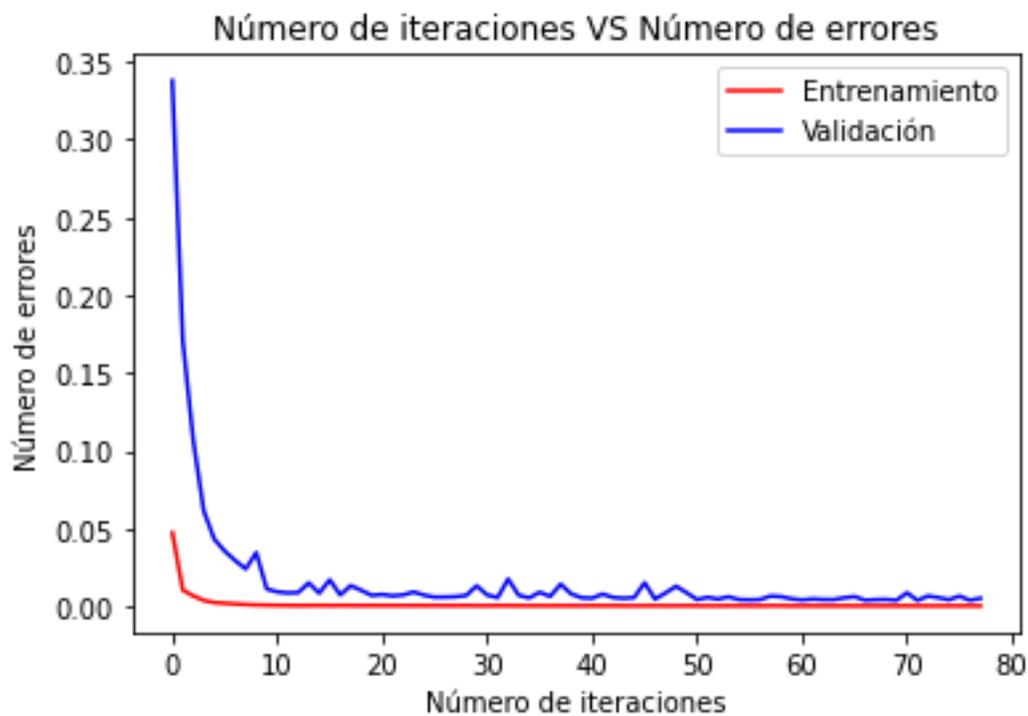


Figura 11 Número de iteraciones contra error medio para la falla CN del sistema de 34 barras.

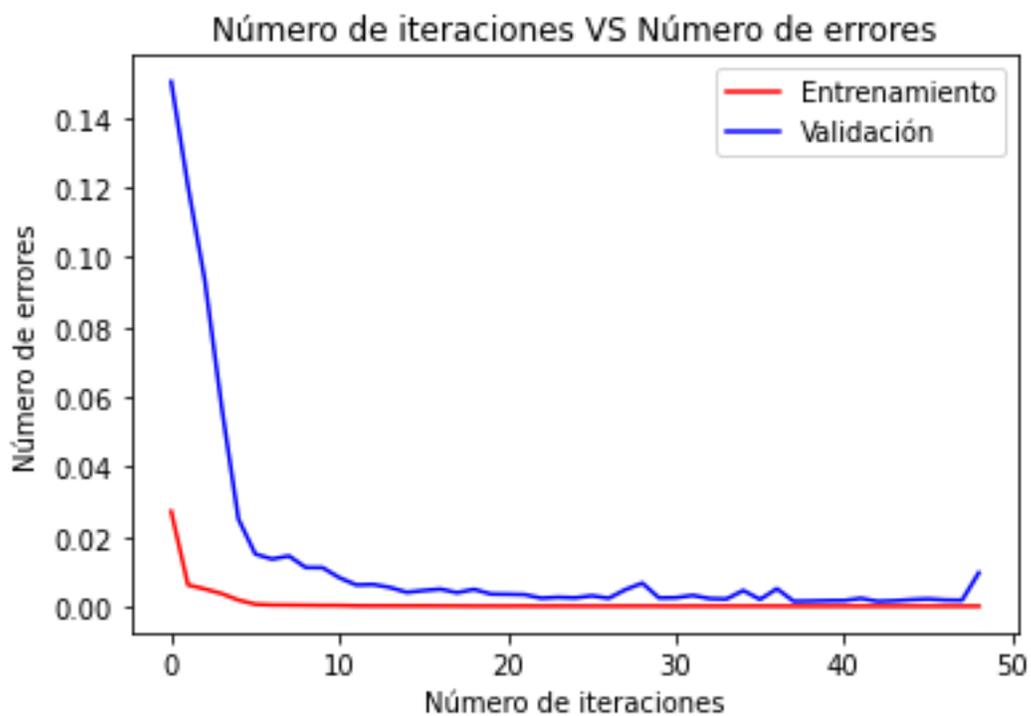


Figura 12 Número de iteraciones contra error medio para la falla AB del sistema de 34 barras.

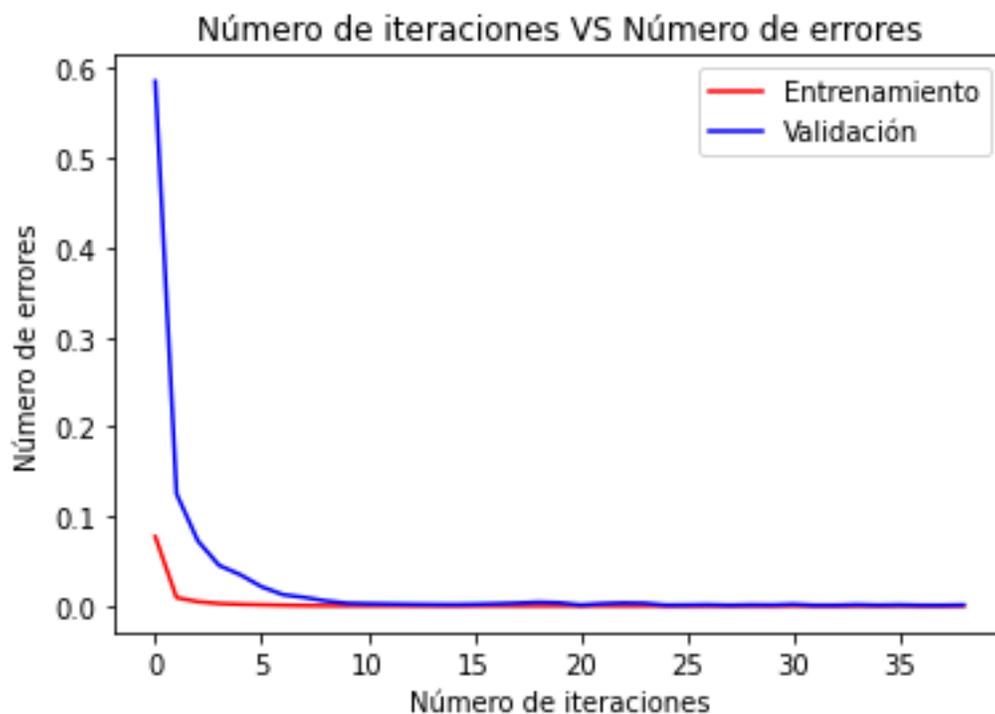


Figura 13 Número de iteraciones contra error medio para la falla BC del sistema de 34 barras.

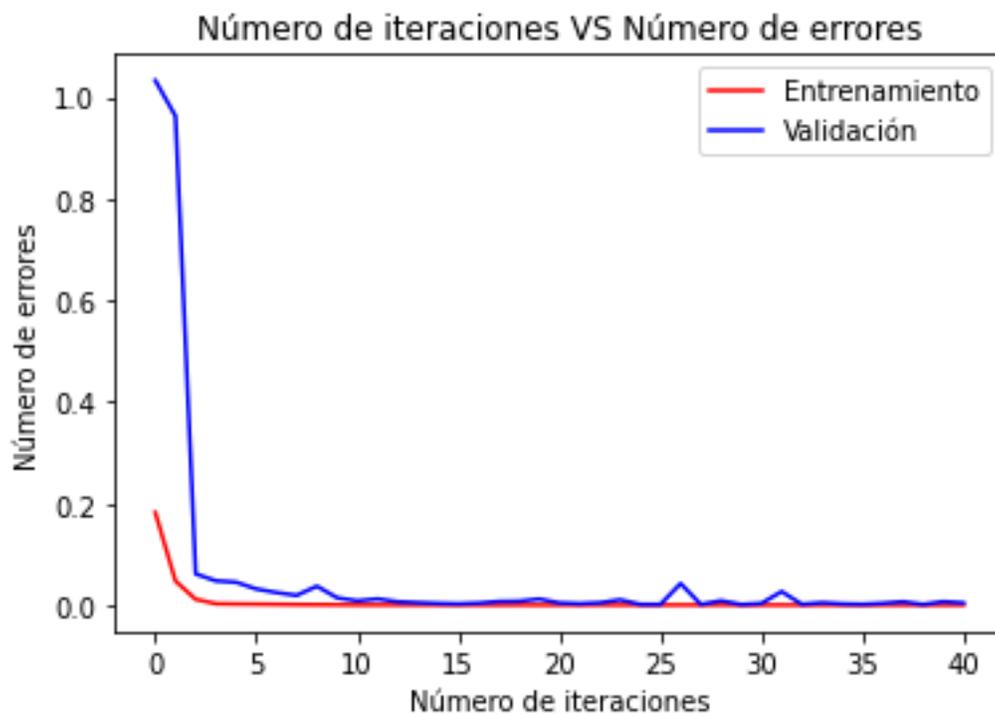


Figura 14 Número de iteraciones contra error medio para la falla CA del sistema de 34 barras.

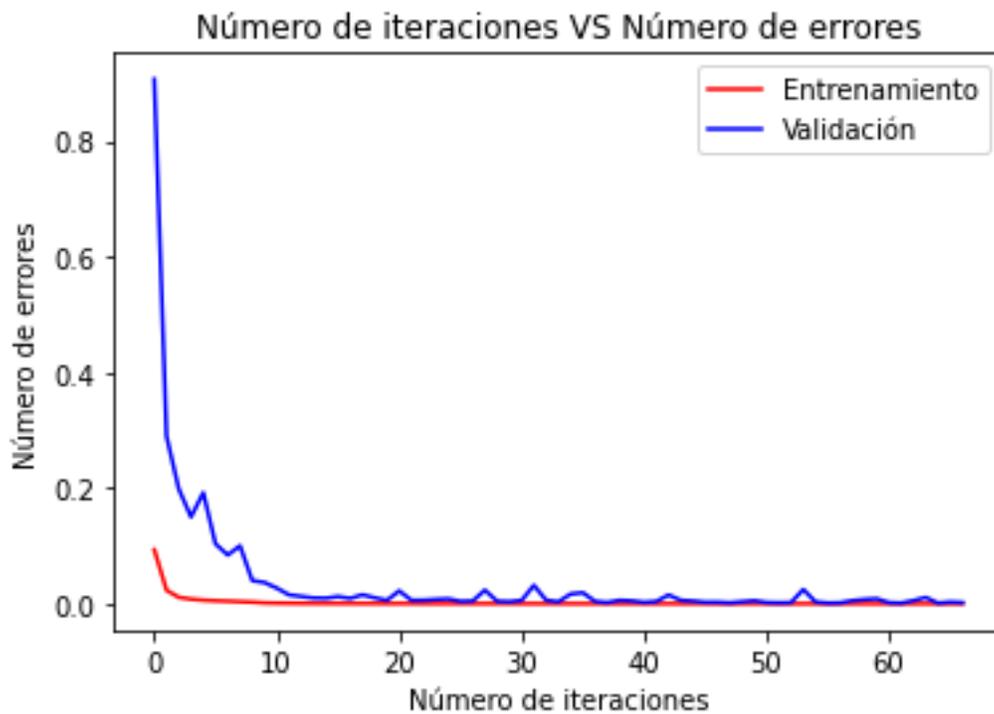


Figura 15 Número de iteraciones contra error medio para la falla ABN del sistema de 34 barras.

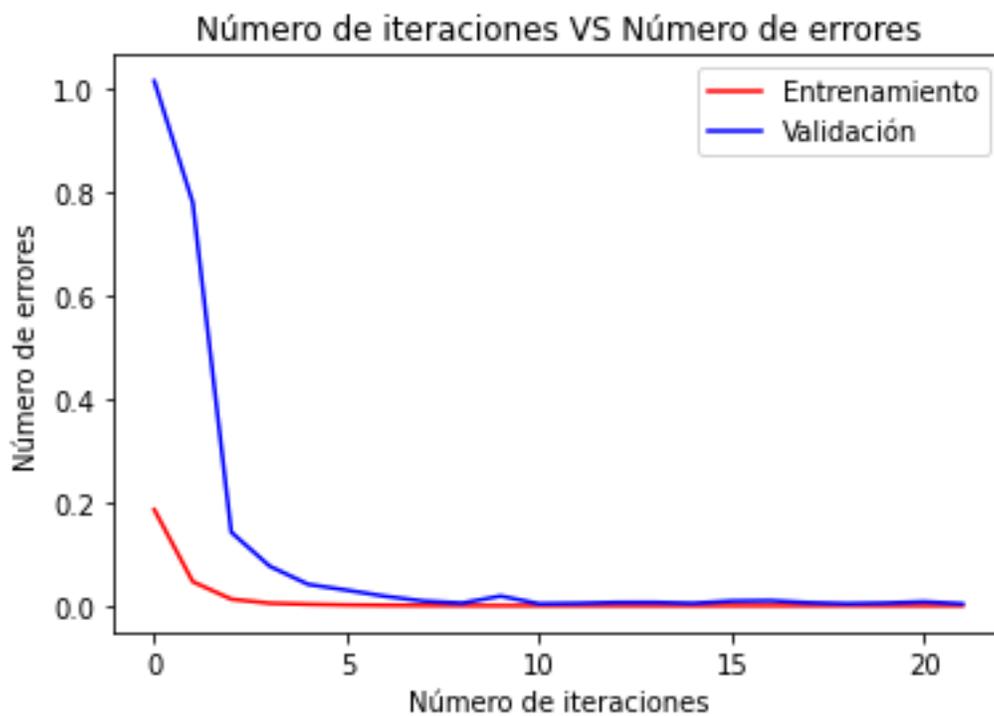


Figura 16 Número de iteraciones contra error medio para la falla BCN del sistema de 34 barras.

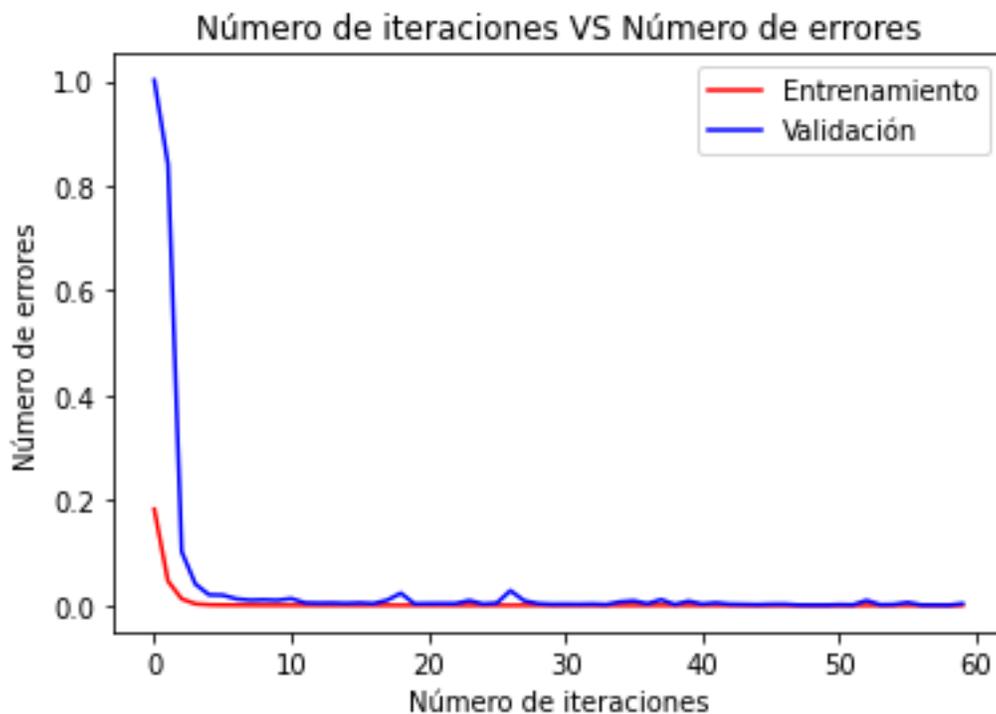


Figura 17 Número de iteraciones contra error medio para la falla CAN del sistema de 34 barras.

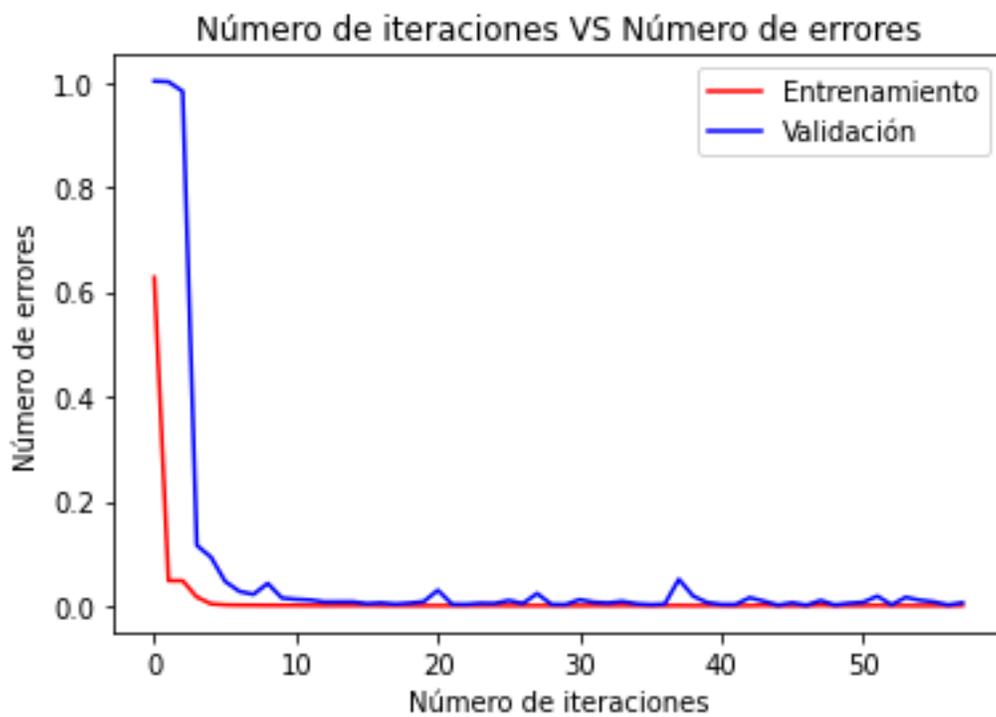


Figura 18 Número de iteraciones contra error medio para la falla ABC del sistema de 34 barras.

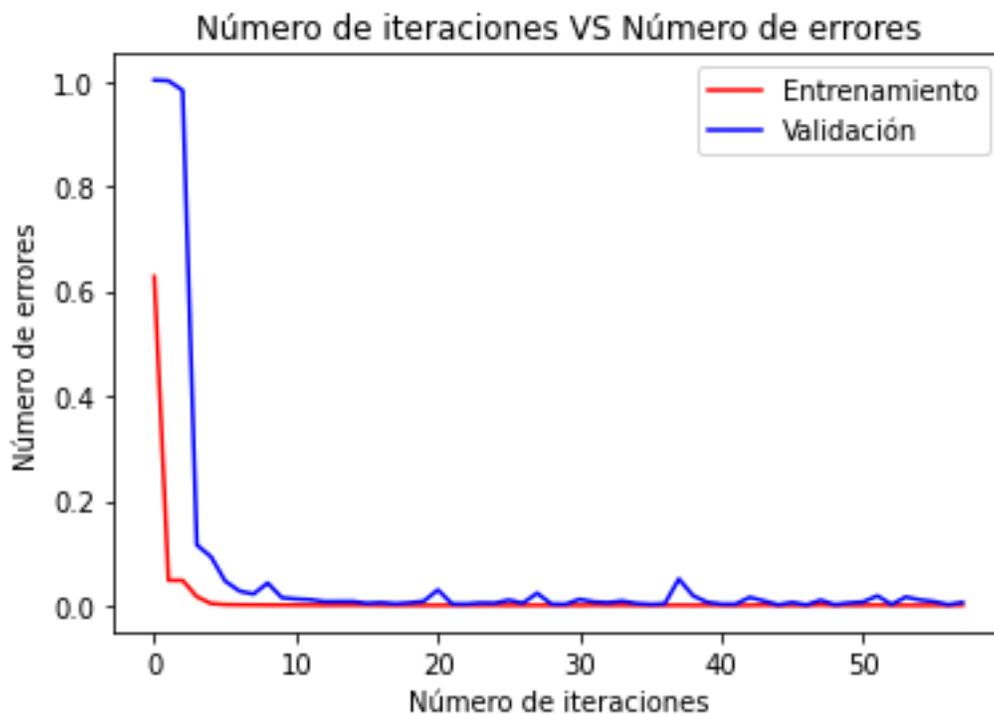


Figura 19 Número de iteraciones contra error medio para la falla ABCN del sistema de 34 barras.

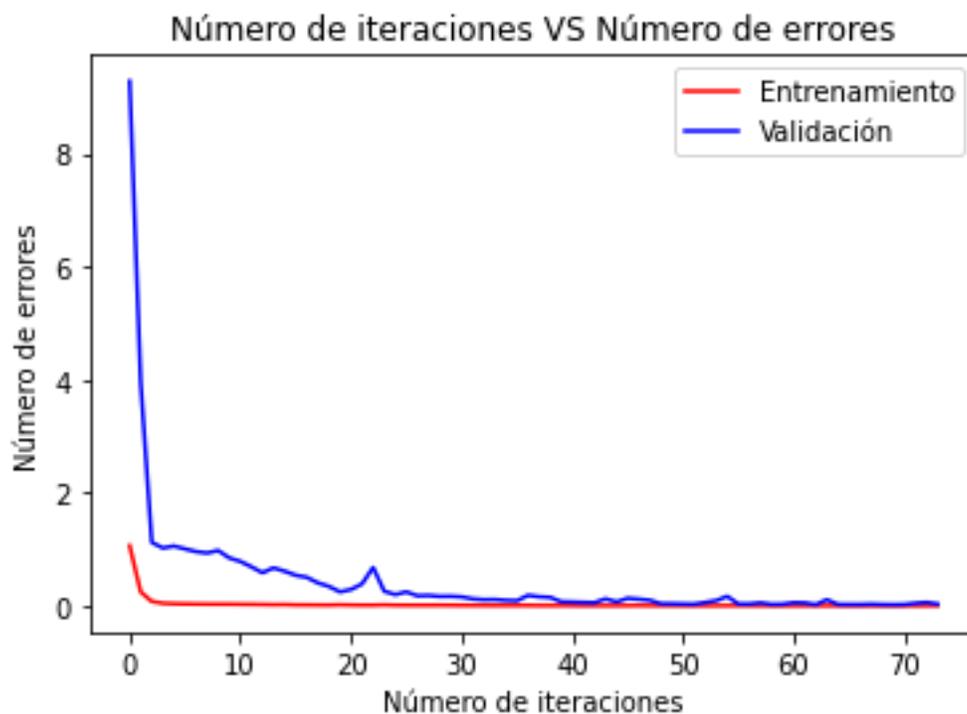


Figura 20 Número de iteraciones contra error medio para la falla AN del sistema de 123 barras.

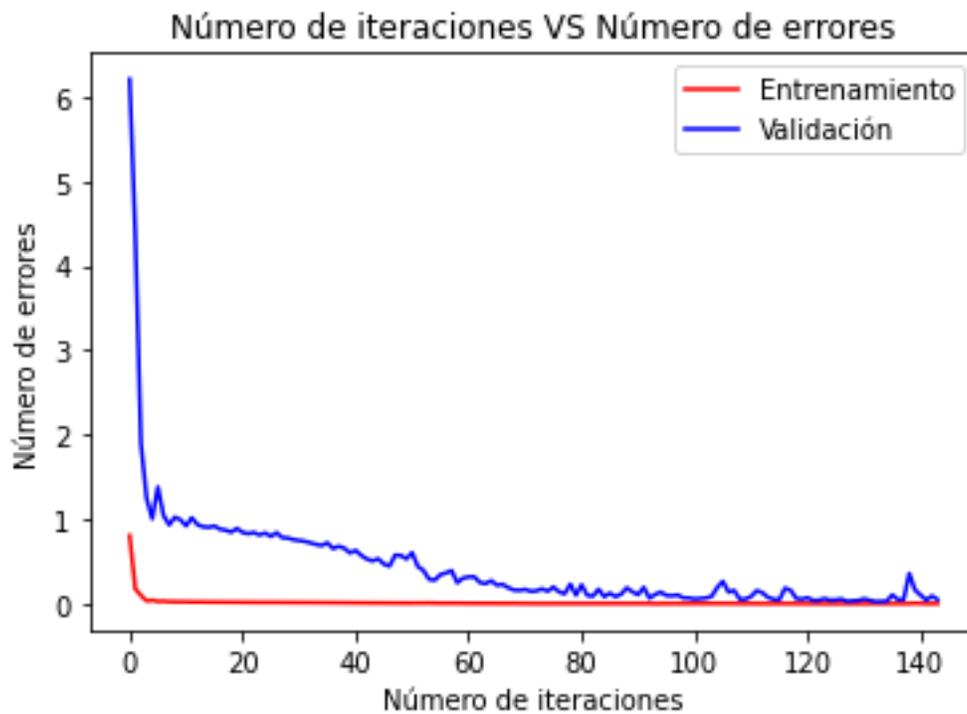


Figura 21 Número de iteraciones contra error medio para la falla BN del sistema de 123 barras.

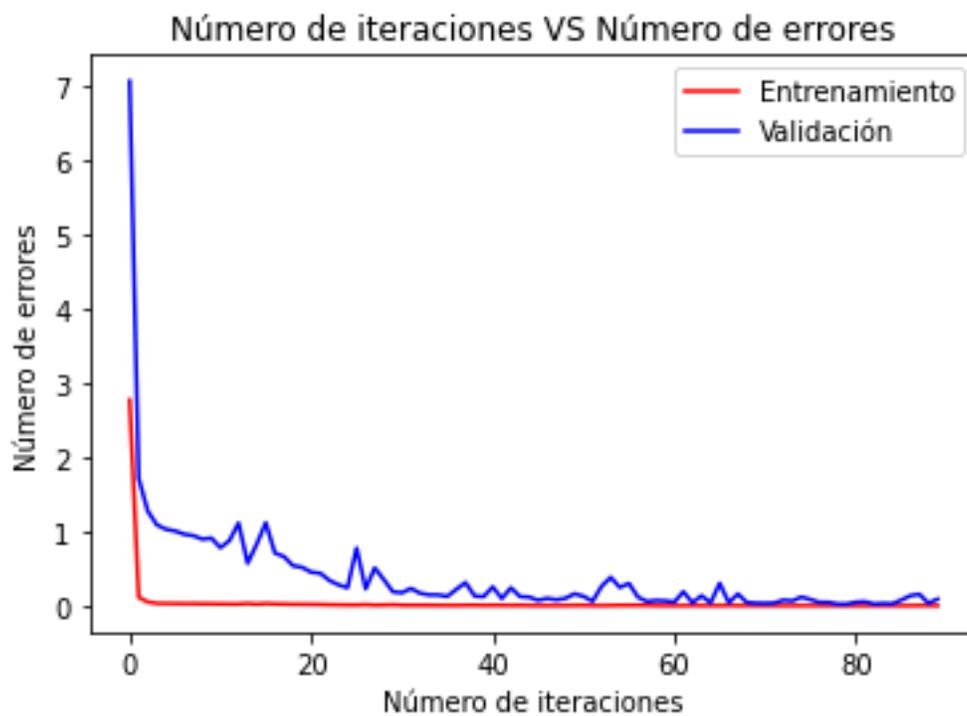


Figura 22 Número de iteraciones contra error medio para la falla CN del sistema de 123 barras.

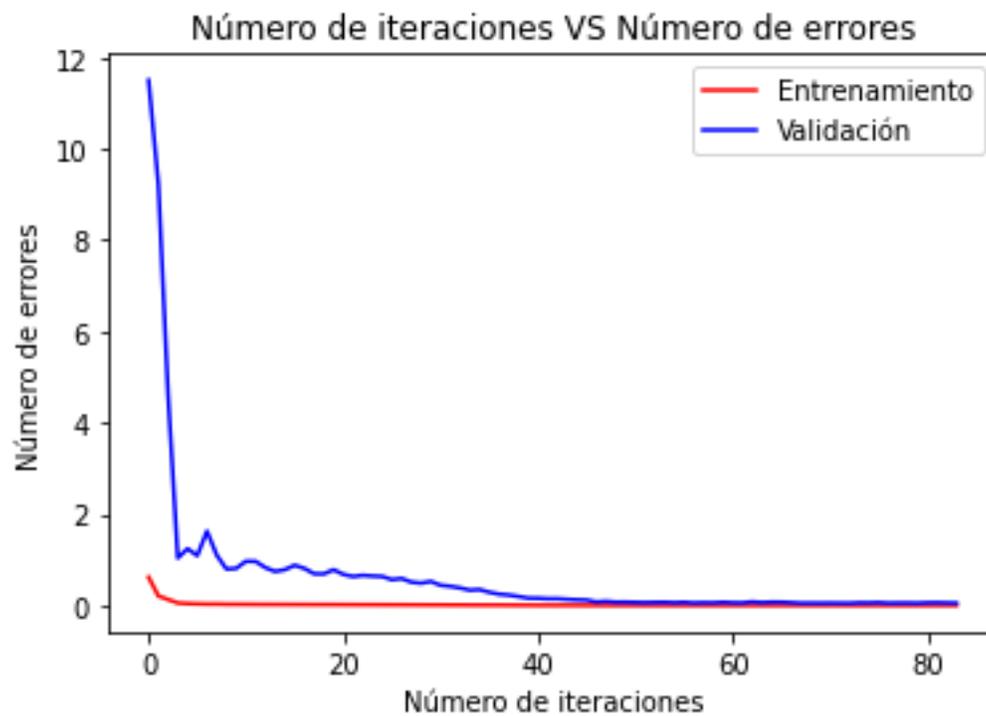


Figura 23 Número de iteraciones contra error medio para la falla AB del sistema de 123 barras.

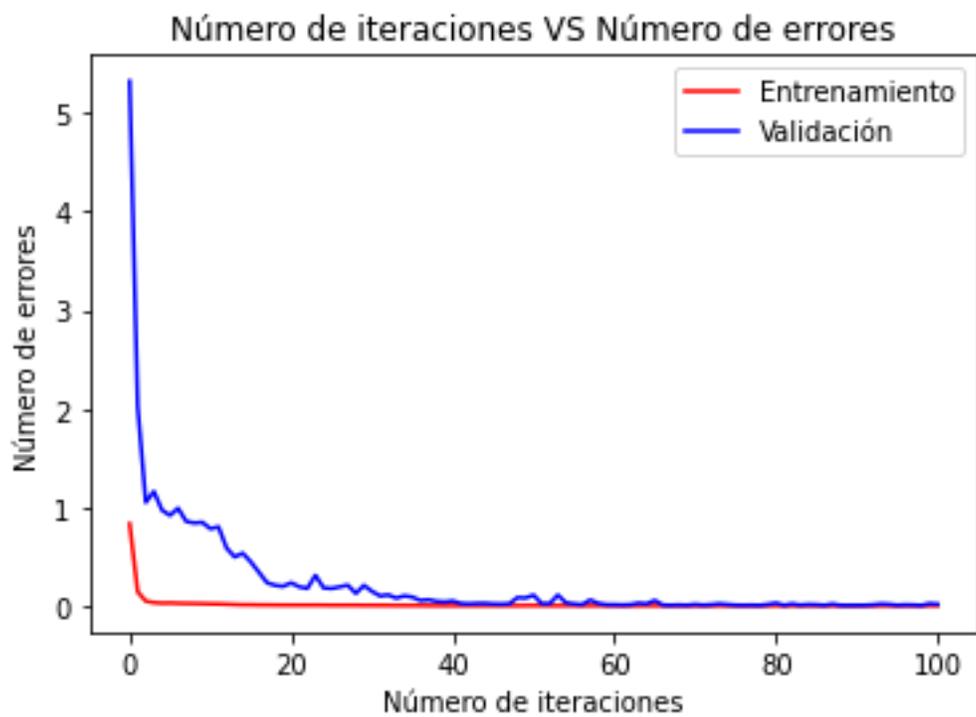


Figura 24 Número de iteraciones contra error medio para la falla BC del sistema de 123 barras.

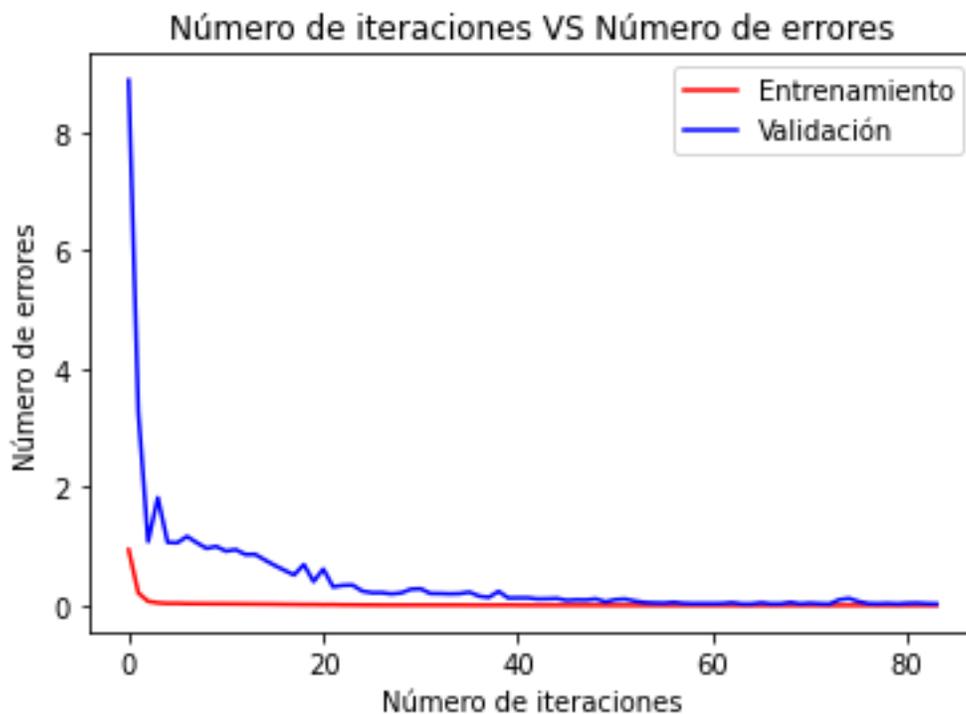


Figura 25 Número de iteraciones contra error medio para la falla CA del sistema de 123 barras.

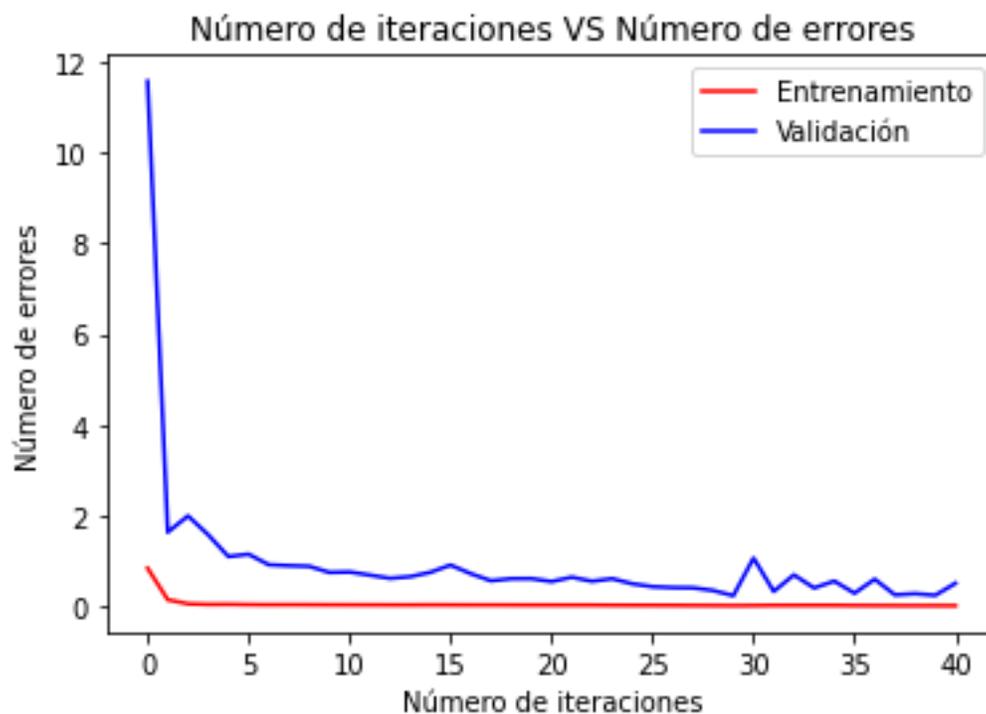


Figura 26 Número de iteraciones contra error medio para la falla ABN del sistema de 123 barras.

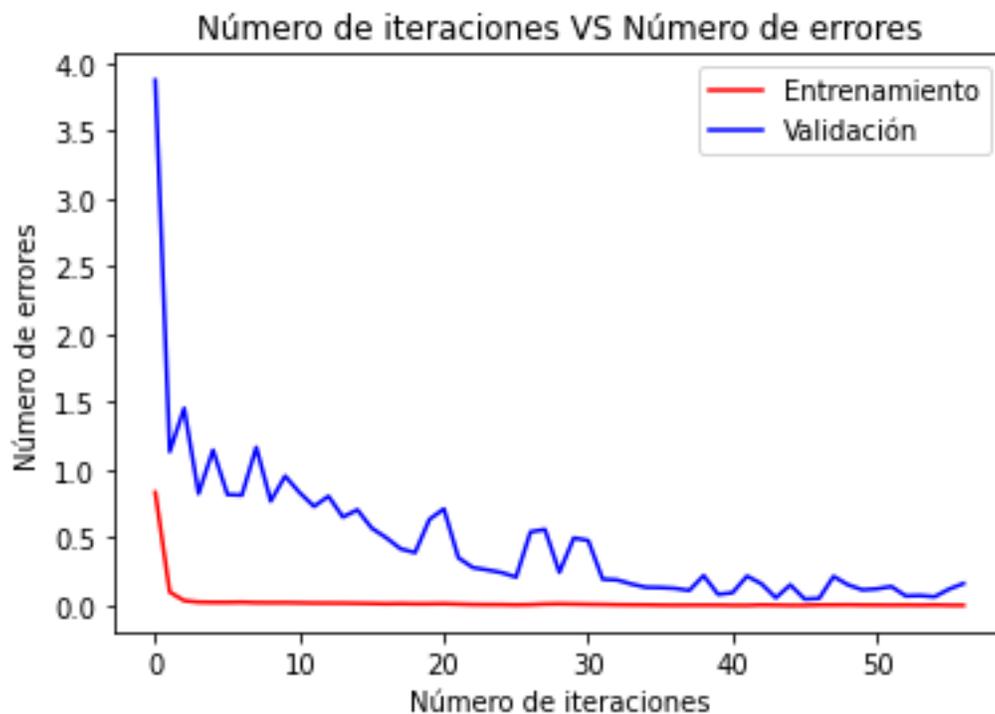


Figura 27 Número de iteraciones contra error medio para la falla BCN del sistema de 123 barras.

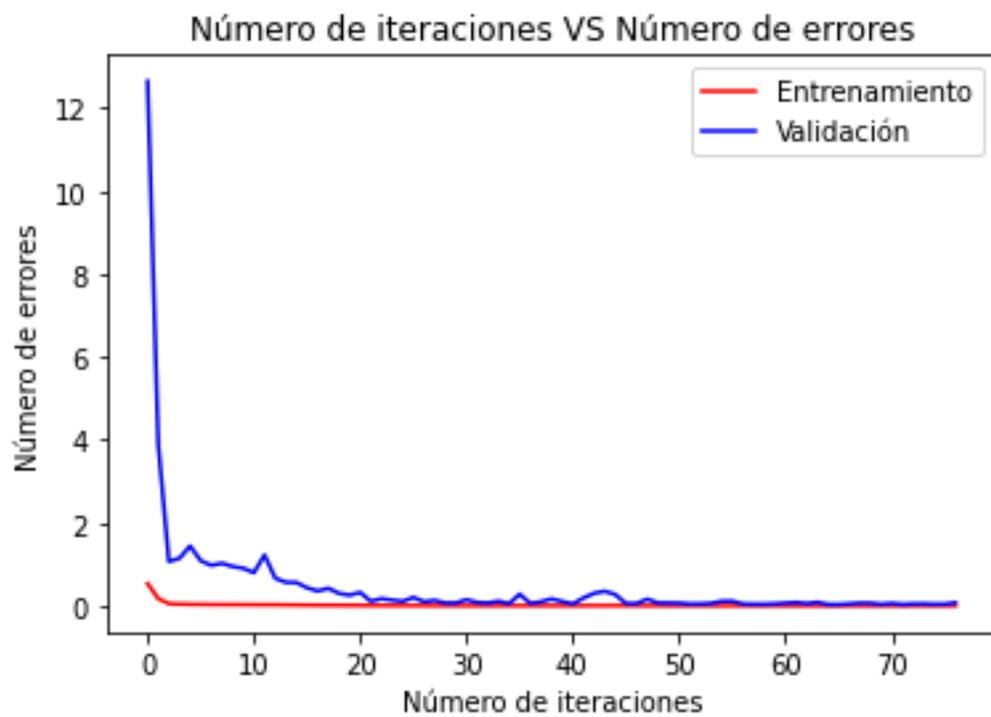


Figura 28 Número de iteraciones contra error medio para la falla CAN del sistema de 123 barras.



Figura 29 Número de iteraciones contra error medio para la falla ABC del sistema de 123 barras.

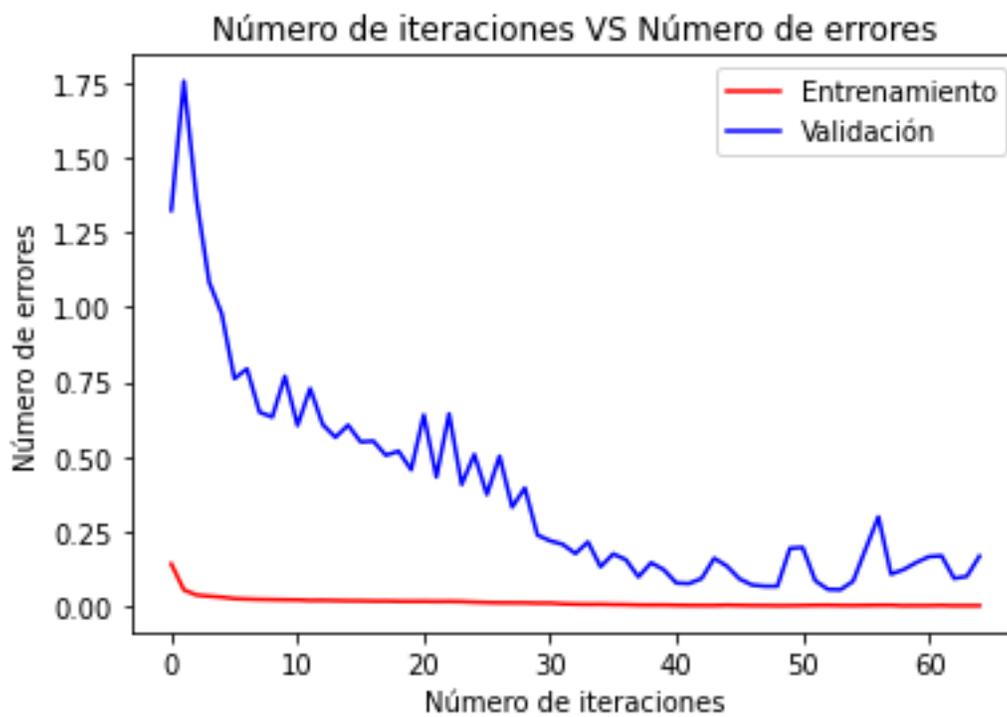


Figura 30 Número de iteraciones contra error medio para la falla ABCN del sistema de 123 barras.

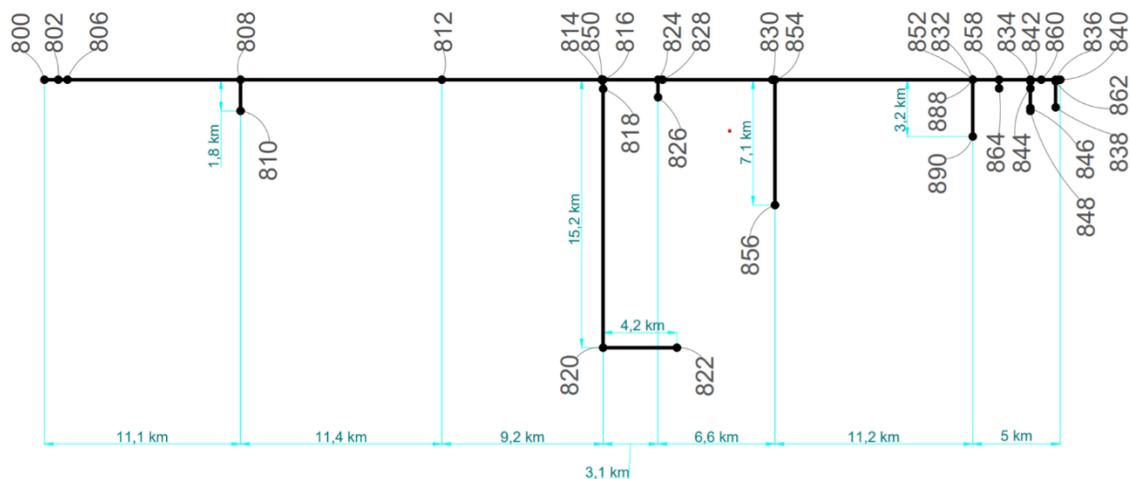


Figura 31 Sistema de 34 barras a escala.

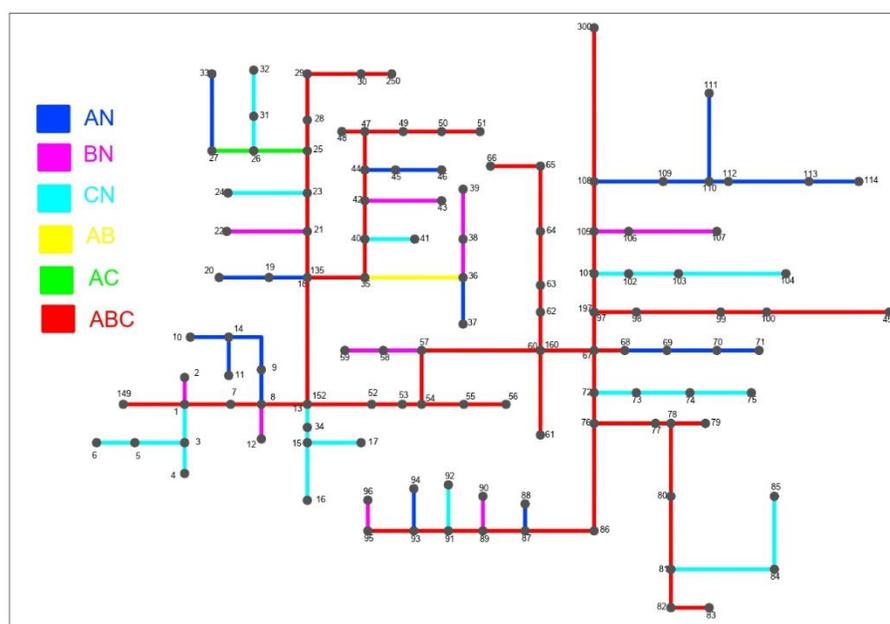


Figura 32 Sistema de 123 barras a escala.